

# 무선 센서 네트워크 성능 향상을 위한 기계학습 응용동향 및 분석

김승환\*, 권기협\*, 김재우\*, 김동성<sup>o</sup>

## Analysis and Application Trend of Machine Learning Technology to Improve the Performance of Wireless Sensor Networks

Seung-Hwan Kim\*, Ki-Hyeob Kwon\*, Jae-Woo Kim\*, Dong-Seong Kim<sup>o</sup>

### 요 약

본 논문에서는 무선 센서 네트워크에서 복잡도, 에너지 효율, 이기종 센서 노드 등으로 발생하는 문제점을 해결하기 위하여 적용되어진 기계학습 기술동향에 대해 조사하였다. 먼저 무선 센서 네트워크의 문제점에 대하여 나타내었으며 다음으로 기계학습 세부기술 그리고 무선 센서 네트워크의 세부 응용분야에 대해서 조사하였다. 기계학습 기술 종류로는 크게 지도학습, 비 지도학습, 강화학습 그리고 준 지도학습으로 분류되어진다. 지도학습에서는 결정트리, 인공신경망, 서포트 벡터 머신,  $k$ -최근접 이웃 등의 기법들이 있으며 비 지도학습에는 계층적 클러스터,  $k$ -평균, 특이값 분해, 주성분 분석 등이 있고 강화학습에는 Q-학습 기법이 대표적이며 마지막으로 준 지도학습은 셀프 학습기법과 상호 학습기법이 대표적이다. 무선 센서 네트워크에서 기계학습 세부기법이 적용된 분야는 위치추정, 데이터 수집, 고장노드 탐지, 라우팅 등이 있다. 기계학습 기술 적용을 통한 네트워크 성능지표는 주로 정확도 향상에 집중되어 있으며 다음으로 에너지 효율과 계산 복잡도 감소 등이 있다. 마지막으로 기계학습 기술 동향 조사는 무선 센서 네트워크의 구체적인 응용분야에서 문제점 해결방안으로 적절한 기계학습 기술 선택에 대한 자료로 참고 될 수 있다.

**Key Words** : Wireless Sensor Networks, Machine Learning, Accuracy, Energy Efficiency, Complexity

### ABSTRACT

In this paper, machine learning technology are surveyed to solve the problem from wireless sensor networks by network complexity, energy efficiency, heterogeneous sensor node, and so on. First, the problems from wireless sensor networks are represented, and the detailed technology of machine learning and the detailed applications of wireless sensor networks are surveyed, respectively. The machine learning is mainly categorized into supervised learning, unsupervised learning, reinforcement learning, and semi-supervised learning. In supervised learning there are several schemes that are decision tree, artificial neural network, support vector machine,  $k$ -nearest neighbor and so on, in unsupervised learning hierarchical clustering,  $k$ -means, singular value decomposition, principle component analysis, and so on are, in reinforcement learning Q-learning is representative,

\* 본 연구는 한국연구재단의 “대학중점연구소 지원사업(2018R1A6A1A03024003)” 및 “기초연구 지원사업(2019R111A1A01063895)”으로 수행된 연구결과임.

♦ First Author : Kumoh National Institute of Technology ICT Convergence Research Center, ksh001@kumoh.ac.kr, 정희원

° Corresponding Author : Kumoh National Institute of Technology IT Convergence Engineering, dskim@kumoh.ac.kr, 종신희원

\* Kumoh National Institute of Technology ICT Convergence Research Center, navkwon@kumoh.ac.kr; Jaewookim@kumoh.ac.kr, 정희원  
논문번호 : 201910-224-B-RN, Received October 4, 2019; Revised November 5, 2019; Accepted November 5, 2019

finally in semi-supervised learning self-training and co-training are representative. The detailed applications of wireless sensor networks are position estimation, data aggregation, fault node detection, routing and so on, which machine learning technology are applied to. The performance metrics that focus on enhancing accuracy, energy efficiency and reducing computation complexity are represented by applying machine learning technology. Finally, this survey can be referred to select properly the detailed technology of machine learning for the detailed applications of wireless sensor networks.

## I. 서 론

무선 센서 네트워크는 MEMS(Micro Electro Mechanical Systems) 기술이 크게 개발됨에 따라 현재까지 세계적으로 주목을 받고 있다<sup>11</sup>. 무선 센서 네트워크는 일반적으로 기반시설이 없이 센서 노드로만 네트워크를 형성하여 원격으로 환경 모니터링과 목표물 추적의 용도로 사용된다<sup>2,31</sup>. 무선 센서 네트워크에서 MEMS 기반 센서 노드는 센싱, 데이터 처리 그리고 통신 컴포넌트를 통해 주변 환경에서 발생하는 빛과 소리, 온도, 압력, 습도, 진동, 물체이동 등에 대한 센싱과 센싱정보를 가공한 다음 무선 채널을 통해 센서 간에 정보를 교환을 수행한다. 일반적으로 센서 노드를 구동하기 위해 배터리가 사용되며 보조적으로 태양광 패널이나 에너지 하베스팅 기술을 통해 전원을 공급받을 수 있다<sup>46</sup>.

무선 센서 네트워크는 여러 분야 어플리케이션에 활용되거나 활용이 가능한 잠재성을 가지고 있다. 무선 센서 네트워크를 적용하기 위한 어플리케이션은 앞서 언급한 것과 같이 크게 모니터링 그리고 추적 어플리케이션 두 가지로 분류되어 진다. 모니터링 어플리케이션의 경우 실내 또는 실외 환경을 포함한 공장 내 상황, 구조물 상태, 장비 구동상태, 화학물질 누출 등과 관련된 공공 및 산업분야와 기상, 재난 등과 관련된 환경분야, 환자의 상태 파악과 관련된 헬스케어 분야, 합정의 추진기관, 조타장비상태, 보안 등과 관련된 국방분야가 있다. 추적 어플리케이션의 경우 모니

터링 어플리케이션과 유사하게 공공 및 산업분야와 국방분야 등이 있다<sup>7-10</sup>. 위와 같은 다양한 어플리케이션에 따라 무선 센서 네트워크의 규모는 차이가 있으므로 각 어플리케이션에 적합한 알고리즘이 요구된다. 또 내외적인 요인에 따라 동적으로 네트워크의 변화가 발생할 때 일반적으로 설계된 절차대로 재구성이 되며 이는 라우팅, 통신 범위, QoS 등의 성능을 떨어뜨릴 수 있다<sup>11,12</sup>.

기계학습 기술은 설계된 알고리즘에 따라 데이터를 학습하고 목표 어플리케이션의 성능을 향상시키는 기술로 다차원으로 구성된 입력 데이터를 빠르고 정확한 분석이 가능하게 한다. 따라서 무선 센서 네트워크에서 여러 요인으로 네트워크의 변동이 생겼을 때 기존의 고정적인 방식이 아닌 기계학습 기술을 적용을 통해 여러 가지 환경변수를 고려하여 최적의 네트워크의 성능을 가지게 하는 기술로 부각이 되고 있다. 기계학습 기술은 지도학습과 비 지도학습, 준 지도학습, 강화학습으로 구분할 수 있으며 일반적으로 지도학습의 분류 기법이 주로 사용된다. 최근 무선 센서 네트워크에서 발생하는 문제점을 해결하기 위해 기계학습 기술을 적용한 연구가 진행되고 있으며 적용되는 응용분야는 최적의 경로를 파악하여 데이터를 전송하는 라우팅 분야, 중복 전송을 방지하여 에너지 소모 효율을 높이는 클러스터링 분야, 통신의 오버헤드를 낮추기 위한 데이터 수집 분야, 센서 노드가 센싱한 정보는 그 위치를 알아야 그 정보가 유효하기 때문에 센서 노드의 위치를 추정하는 분야, 비정상적으로 동작하는 센서 노드를 탐지하는 분야 등이 있다. 따라서 기계학습 기술은 방대하게 수집된 데이터에 접근하여 각각의 목적에 맞게 설계되어 유용한 데이터를 추출하여 활용이 가능하게 하는 기술이다.

본 논문의 구성은 다음과 같다. II장에서는 무선 센서 네트워크의 문제점 분석을 하였으며 III장에서는 최근 무선 센서 네트워크를 위해 사용되어진 기계학습 기술에 대해 설명하였고 IV장에서는 기계학습 기술이 적용된 주요응용 분야와 사용된 기계학습 알고리즘에 대한 측정지표에 대해 나타내었으며 마지막으

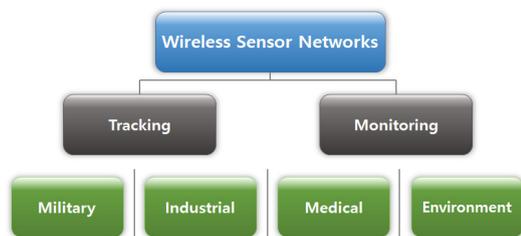


그림 1. 무선 센서 네트워크 응용분야 분류  
Fig. 1. Taxonomy of wireless sensor networks

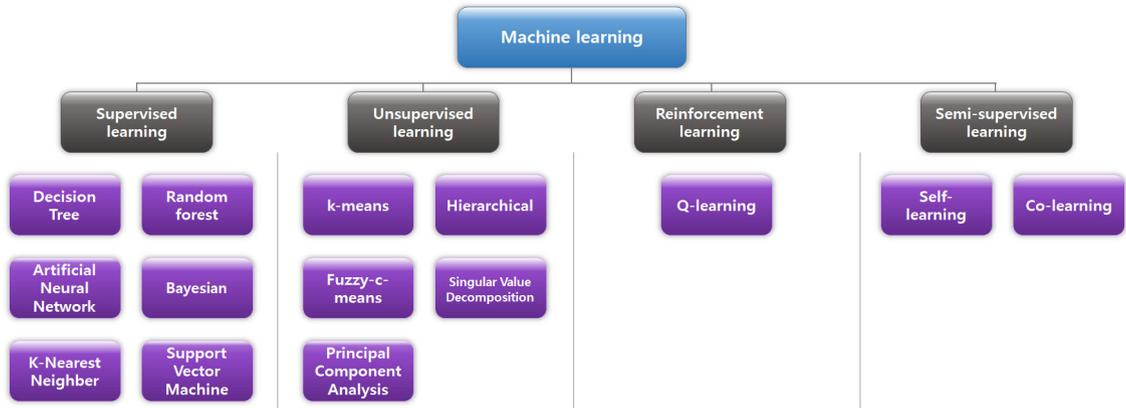


그림 2. 기계학습 기술 분류  
Fig. 2. Taxonomy of machine learning techniques

로 V장에서 연구되어진 성과를 요약하며 결론을 맺는다.

## II. 무선 센서 네트워크 문제점 분석

무선 센서 네트워크는 어플리케이션에 따라 노드가 고정된 형태와 움직이는 형태로 구분할 수 있으며 위치적으로는 일반적인 땅위, 동굴이나 지하, 그리고 수중속이 있을 수 있다. 또 각 어플리케이션에 따라 네트워크를 효율적으로 제어 및 관리하기 위해 설계 요구사항을 고려해야 한다. 배치되는 센서 노드는 일반적으로 목표 지역에 무작위로 배치되어지며 애드혹 네트워크 방식으로 동작하게 된다. 센서 노드는 데이터를 수집하는 센서 노드와 수집된 데이터를 모아 외부 기지국으로 전송하는 싱크노드로 구성되어진다. 무선 센서 네트워크에서 신뢰성 있는 통신을 유지하기 위해 제한된 에너지 자원을 가지고 있는 센서 노드의 수명을 늘리는 것이 중요하며 이는 제한된 데이터 처리능력과 메모리를 가진 센서 노드를 고려하여 센서 노드 간에 운용되는 효율적인 통신방식 채택을 통해 가능하게 한다. 통신방식은 노드 간에 단거리 전송 환경을 유지시키고 데이터 중복 전송을 방지하며 멀티홉 환경에서 최적의 라우팅 방식과 클러스터 간에 데이터 수집 방식 등을 고려하여 각 어플리케이션의 QoS와 전력 소모에 대한 핵심 요구조건을 만족시킬 수 있다. 위치적으로 동굴이나 지하인 경우 무선 신호에 대한 감쇠가 땅위에 위치했을 때보다 크고 유지보수가 더 어렵기 때문에 신뢰성 있는 통신시스템을 구현 위해 이에 대한 비용을 고려해야 한다. 수중의 경우에는 무선 통신 시 전자기파가 아닌 SONAR

(SOund Navigation And Ranging) 장치를 사용한 주파수대역(100Hz - 1MHz)을 활용하기 때문에 제한적 대역폭과 긴 전파지연 그리고 페이딩으로 인한 손실이 발생할 수 있다<sup>[13,14]</sup>. 또 수중 환경으로 인한 노드고장이 상대적으로 쉽게 발생할 수 있으므로 자체적으로 효율적으로 네트워크 재구성하는 기능에 대해 고려되어야 한다. 동적으로 움직이는 모바일 노드의 경우 모니터링, 추적 등의 용도로 대부분의 어플리케이션에 적용이 가능하며 특정 지역의 이벤트 발생 시 해당 위치에서 요구되는 통신범위와 연결성 확보가 가능하다. 하지만 노드의 고장과 이동성으로 인해 네트워크를 재구성하는 과정에서 일시적으로 또는 임의의 시간범위 안에서 각 노드 간에 통신이 단절이 발생할 수 있으며 이로 인해 지연이 발생하게 된다. 또 이를 방지하기 위한 알고리즘 수행으로 인해 통신 경로를 확보하기 위한 추가적인 오버헤드를 가지게 되는 단점을 가지게 된다. 따라서 위에 언급된 무선 센서 네트워크에서 발생하는 문제점을 기계학습 기법을 통해 네트워크 성능을 향상을 기대할 수 있다.

## III. 기계학습 기술

기계학습 기술은 데이터를 수집하고 상태를 파악 및 예측하는 모델로서 무선 센서 네트워크의 다양한 어플리케이션에 적용함을 통해 주요 성능지표에서 큰 성능향상을 가진다. 본장에서는 기계학습 기술의 세부적 기법에 대한 분류와 개념에 대한 간략한 설명을 하였다.

### 3.1 지도학습

지도학습은 미리 정의된 입력 값과 이에 대한 출력 값, 즉 목표 값이 있는 데이터셋을 기계학습 모델에 학습시킨 다음 기계학습 각 어플리케이션의 입력에 대해 회귀분석 및 데이터 분류의 기능을 수행하는 기계학습 기술 중 한 가지 방법이다<sup>15,16</sup>. 지도학습을 수행 후 기계학습 모델을 통하여 입력 값  $x$ 에 대하여 추정된 출력 값  $y$ 를 얻을 수 있으며 이는  $f: x \rightarrow y$ 로 표현할 수 있다. 이를 통해 지도학습에서 가장 큰 논점은 입력 값의 특징으로부터 판별된 출력 값에 대한 상호관계와 의존성을 명확히 구분하는 것이다.

#### 3.1.1 회귀분석

회귀분석은 변수 간의 함수관계에 대한 통계적 분석방법으로서 기계학습 기술에서 최소한의 오류로 결과를 예측하는 단순한 기법이다. 또 변수들 간의 상관관계를 예측을 위해 독립변수와 종속변수 사이의 관계를 수학적으로 모델링이 가능하며 단순 선형회귀분석 방법으로 식 (1)과 같이 나타낼 수 있다.

$$y = f(x) + e \quad (1)$$

여기서  $y$ 는 종속변수,  $x$ 는 독립변수,  $f(\cdot)$ 는  $x$ 와  $y$ 간의 관계를 나타내는 함수이며 그리고  $e$ 는 발생 가능한 오류를 의미한다. 식1의 회귀분석에서 독립변수를 2개 이상으로 나타낼 수 있으며 이는 다중회귀분석이라 한다. 회귀분석 기법을 사용하여 무선 센서 네트워크의 노드 위치 파악, 노드간의 연결성, 데이터 수집 등의 어플리케이션에서 관련 문제를 해결하기 위해 적용할 수 있다.

#### 3.1.2 결정트리

결정트리는 상태조건을 기반으로 한 분류 기법의 한 종류로서 계층적 구조로 되어있으며 최고 상위노드인 뿌리노드와 부모노드, 자식노드, 그리고 잎노드를 포함한다. 결정트리는 학습 데이터를 기반으로 입력 값을 분류 및 예측하며 선형적 입력 값에 대해서만 유효하게 동작한다. 따라서 결정트리 기법은 입력 값에 대한 광범위한 분석이 가능하게 하며 결정된 의사를 통해 결과가 명확하게 분류된다. 결정트리는 무선 센서 네트워크에서 데이터 손실률, 평균 고장률, 평균 복구율 등의 소수의 중요한 특징만으로 무선 센서 네트워크에 대한 신뢰성 판별이 가능함에 따라 연결성, 고장노드 탐지, 데이터 수집 등에서 문제해결 및 최적화를 위해 사용될 수 있다.

#### 3.1.3 랜덤 포레스트

랜덤 포레스트 방식은 하나의 결정트리를 확장하여 여러 개의 결정트리를 가지는 구조로 되어있으며 각각의 결정트리에서 나온 결과를 통합하여 최종 결과로 분류를 하는 앙상블 학습방식이다. 랜덤 포레스트는 아래와 같이 2가지 단계로 구분하여 동작한다. 첫 번째 단계는 오프라인으로 랜덤으로 데이터셋을 선택하여 각각의 결정트리 모델에 지도학습을 시키고, 두 번째 단계는 온라인으로 데이터를 수집하여 예측 및 판별을 수행한다. 여기서 데이터셋을 랜덤으로 선택하는 이유는 결정트리의 특징을 비상관화 함으로써 랜덤 포레스트의 일반화 성능을 향상시키고 또 대규모의 결정트리의 구성을 가능하게하기 때문이다. 랜덤 포레스트 기법을 사용하여 무선 센서 네트워크의 통신범위 진단과 침입 탐지 그리고 종단간의 지연을 줄이기 위한 라우팅 설계 등에 사용할 수 있다.

#### 3.1.4 인공신경망

인공신경망은 인체의 뉴런을 모방한 모델로 한 하나의 지도학습 기법이다. 따라서 대규모의 뉴런이 연결되어 정보를 처리하는 것과 같이 인공신경망 모델도 이와 같이 정확도를 높이기 위해 모델의 구조를 다수의 층으로 설계가 가능하다. 이는 입력층과 은닉층 그리고 출력층으로 구분되어진다. 여기서 입력층은 센서로부터 입력 값을 1차원 또는 다차원으로 입력 받을 수 있으며 은닉층은 설계된 코어 알고리즘에 따라 가중치를 부여하여 결과를 산출하며 여러 층으로 설계가 가능하다. 마지막으로 출력층은 은닉층으로부터 받은 값을 통해 최종 결과를 판정하게 된다. 심층 학습 또한 인공신경망에서 파생된 기법으로 인공신경망의 과적합 문제, 최적화 문제 등을 보완하였다. 결과적으로 인공신경망은 다른 분류기법보다 상대적으로 복잡하고 비선형성을 가진 데이터를 쉽게 분류가 가능한 장점을 가진다. 따라서 무선 센서 네트워크의 효율성을 높이기 위해 위치추정, 고장노드탐지, 라우팅, 데이터 수집 등에 적용이 가능하다.

#### 3.1.5 서포트 벡터 머신

서포트 벡터 머신은 입력 값을 두 가지 범주로 구분하기 위해 최적의 초평면을 찾아 구분하여 주는 이진분류 기법이다. 이때 초평면의 경계에 위치한 값을 서포트 벡터라 정의한다. 분류방법으로는 입력된 값의 상태에 따라 선형분류와 비선형분류 방법을 사용한다. 서포트 벡터 머신은 지도학습 기법과 동일하게 목표 값이 있는 데이터셋으로 학습을 시켜야 하지만 데이

터셋에 있는 수많은 특징들은 서포트 벡터 머신의 모델에 영향을 주지 않는다. 서포트 벡터 머신은 출력 결과에 대한 정확도가 높고 과적합 정도가 낮은 장점을 가지지만 학습에 대한 긴 시간이 필요하고 설계된 모델을 분석하기 어려운 단점을 가진다. 무선 센서 네트워크에 서포트 벡터 머신은 위치추정, 고장노드탐지, 라우팅 등에 적용될 수 있다.

### 3.1.6 베이지안 추정

베이지안은 추정 방식을 사용하여 조건적 독립사건을 학습하여 입력된 데이터셋의 관계를 찾는 기법이다. 하지만 다른 기계학습 기법들과 다르게 학습 시 상대적으로 작은 데이터셋을 필요로 한다. 베이지안 방식에서 핵심적인 부분은 결과가 나타나기 전의 사전확률을 결과가 발생하였다는 조건에서 가지는 사후확률로 갱신하기 위해 현재 수집된 데이터를 사용하는 것이다. 그리고 재귀적으로 반복하면서 사후확률 추정하게 되며 최적의 확률로 수렴하게 된다. 예를 들면 무선 센서 네트워크에서 네트워크 환경 변화에 대한 데이터를 수집하여 네트워크의 일관성을 추정하는 것으로 사용할 수 있다. 따라서 위치추정, 통신범위, 고장노드탐지, 데이터수집, 노드추적 등 광범위하게 적용가능하다.

### 3.1.7 $k$ -최근접 이웃

$k$ -최근접 이웃은 가장 인스턴스 기반 학습 기법으로  $k$ 값에 따라 지역적으로 분포되어 있는 목표 값이 있는 데이터와 입력되는 값의 거리를 고려하여 분류시킨다. 따라서 학습시킬 데이터셋을 통해 특징 공간에 분류를 시켜야하며  $k$ -최근접 이웃 알고리즘의 복잡도는 학습되는 데이터셋에 따라 결정된다.  $k$ -최근접 이웃에서 사용되는 거리판별 함수는 유클리드 거리, 해밍 거리, 캔버라 거리, 맨해튼 거리 등의 함수를 사용한다. 무선 센서 네트워크에서는 고장노드탐지, 데이터 수집 등에 적용할 수 있다.

## 3.2 비 지도학습

비 지도학습은 지도학습과 정반대로 시험 데이터셋을 통해 학습 없이 스스로 학습하는 방법으로 비 지도학습의 목표는 유사한 입력 값을 수집 후 패턴, 특성 등을 분석하여 각각의 클러스터로 분류하는 것이다<sup>[17,18]</sup>. 비 지도학습 방법으로 알려져 있는 대표적인 방식은  $k$ -평균, 계층적 클러스터링, 퍼지- $c$ -평균 등이 있으며  $k$ -평균과 계층적 클러스터링은 하드 클러스터링으로, 퍼지- $c$ -평균은 소프트 클러스터링으로 분

류된다. 비 지도학습은 비 지도학습만이 가지는 구조와 특성으로 인해 무선 센서 네트워크에서 폭넓게 사용될 수 있다.

### 3.2.1 계층적 클러스터

계층적 클러스터는 데이터의 유사성을 분석하여 하향식 또는 상향식으로 클러스터링 하는 기법이다. 하향식 클러스터링은 하나의 클러스터에서 데이터에 기반하여 여러 클러스터로 세분화시키는 방법이며 상향식은 여러 클러스터에서 하나의 클러스터로 통합되는 방식이다. 계층적 클러스터는  $k$ -평균 방법과 다르게 임의로 클러스터링 수를 설정할 필요 없지만 시간 복잡도는  $O(n^3)$ 으로  $k$ -평균보다 더 긴 시간 필요하며 요구되는 메모리 공간은  $O(n^2)$ 가 필요하다. 계층적 클러스터는 무선 센서 네트워크에서 데이터 수집, 동기화 문제 등에 적용이 가능하다.

### 3.2.2 $k$ -평균

$k$ -평균은 주어진 데이터셋으로부터  $k$ 개의 클러스터로 분류하는 하드 클러스터링 기법이다. 초기의 각 클러스터는 일반적으로 임의로 구분하고 각 클러스터에 소속된 데이터를 통해 각 클러스터의 평균값을 구할 수 있다. 그리고 각 클러스터의 평균값을 기반으로 데이터의 유클리드 거리를 비교하여 가장 가까운 클러스터로 데이터가 재조정되어지며 각 클러스터에 가장 가장자리에 위치한 데이터를 기반으로 클러스터의 범위를 나타낼 수 있다. 각각의 클러스터는 소속된 데이터를 기반으로 평균값을 다시 계산함을 통해 클러스터의 범위를 재구성하게 되며 클러스터의 평균값이 정해진 임계값 이하로 변동이 되지 않을 때 최적화를 완료한다.  $k$ -평균의 시간 복잡도는 평균의 수  $k$ 와 데이터의 수  $n$ , 반복횟수  $i$  그리고 차원의 수  $d$ 의 입력으로 하여  $O(k*n*i*d)$ 의 시간이 걸린다.  $k$ -평균의 특징에 따라 무선 센서 네트워크에서 싱크노드로 데이터 전송을 위한 최적의 클러스터 헤드 노드를 찾는 분야에 적용이 가능하다.

### 3.2.3 퍼지- $c$ -평균

퍼지- $c$ -평균은  $k$ -평균 기법의 단점을 개선하기 위해 제안된 소프트 클러스터링 기법으로 각 데이터는 하나이상의 클러스터에 소속되는 것이 가능한 차이점을 가진다. 퍼지- $c$ -평균은  $k$ -평균과 유사하게  $c$ 개의 클러스터 수에 따라 각 클러스터의 초기 평균값을 임의로 정하고 클러스터의 평균값을 기준으로 각 클러스터에 소속된 데이터에 가중치를 부여하며 각각

의 데이터 가중치는 1을 넘지 않는다. 계속해서 소속된 각 데이터의 거리를 기반으로 각 클러스터의 평균을 재조정하고 클러스터의 평균이 임계값과 비교하여 변화되는 값이 작을 때 최적화를 완료한다. 퍼지-c-평균 기법은 다른 클러스터링 기법보다 복잡도가 높은 단점을 가진다. 무선 센서 네트워크에서는 위치추정, 노드간의 연결성 등에 사용되어질 수 있다.

### 3.2.4 특이값 분해

특이값 분해는  $m \times n$  차원 행렬을 분해하여 차원을 증가시키거나 또는 줄이는 목적으로 사용되는 기법 중 하나이다. 특이값 분해는 식 (2)와 같이 정의된다.

$$A = U\Sigma V^T \quad (2)$$

여기서  $U$ 는  $m \times m$  크기의 직교행렬로  $A$ 의 왼쪽 특이벡터를 나타내며,  $V^T$ 는  $n \times n$  크기의 직교행렬로  $A$ 의 오른쪽 특이벡터를 나타내고, 마지막으로  $\Sigma$ 는  $A$ 의 특이값을 나타낸다. 특이값 분해는 무선 센서 네트워크에서 주어진 특징 공간의 데이터 차원을 줄이기 위하여 사용되어지며 라우팅 설계, 데이터수집 등에 사용되어 질 수 있다.

### 3.2.5 주성분 분석

주성분 분석은 특이값 분해와 유사하게 입력 데이터 차원을 줄이기 위한 기법으로 분산된 중요 정보를 추출하여 직교선형변환을 통해 새로운 좌표축으로 나타내는 방식이다. 주성분 분석을 통해 2차원 좌표평면에 나타내기 위한 방식은 모든 정보를 조합하여 데이터 집합의 중심을 얻고 데이터가 가장 많이 분포된 방향을 첫 번째 주성분 축으로 두며 다음으로 첫 번째 주성분과 직교된 방향으로 데이터가 많이 분포된 방향을 두 번째 주성분 축으로 놓는다. 따라서 많이 분포된 방향 외의 분포된 데이터 정보는 생략함을 통해 입력된 데이터의 특징공간의 차원을 줄일 수 있다. 주성분 분석은 무선 센서 네트워크에서 위치추정, 고장노드탐지, 데이터 수집 등에 사용이 가능하다.

### 3.3 강화학습

강화학습은 하나의 응용분야에서 정의된 에이전트에 의해 어떤 행동에 따라 주는 보상에 근거하여 시간별로 얻은 보상 중에서 최대의 보상을 얻기 위하여 관련된 행동을 선택하도록 유도하는 방법이다<sup>19)</sup>. 이러한 강화학습을 위하여 일반적으로 알려진 기법은 Q-

학습 기법이며 Q-학습 기법은 주어진 모델이 없� 경험을 통한 결과를 근거로 강화학습이 가능한 장점을 가진다<sup>20)</sup>. Q-학습에서 전체 보상 값은 식 (3)을 통해 나타낼 수 있다.

$$Q(s_{t+1}, a_{t+1}) = Q(s_t, a_t) + \gamma(r(s_t, a_t) - Q(s_t, a_t)) \quad (3)$$

여기서  $r(s_t, a_t)$ 는 행동을 하였을 때 즉시 주어지는 보상이며  $a_t$ 는 행동,  $s_t$ 는 상태 그리고  $\gamma$ 는 얼마나 빨리 학습을 하는지에 대한 비율을 의미한다. 강화학습은 무선 센서 네트워크에서 라우팅 최적화를 위해 사용되어 질 수 있다.

### 3.4 준 지도학습

준 지도학습은 목표 값을 사용하는 지도학습 방법과 목표 값을 사용하지 않는 비 지도학습 방법을 조합하여 사용하는 기법이다. 따라서 준 지도학습은 지도학습과 비 지도학습에서 가지고 있는 회귀, 분류, 클러스터링과 같은 형태로 사용이 가능하며 귀납적 예측을 통해 무선 센서 네트워크의 응용분야에 따라 적은 학습 데이터를 가지고 목표 값 예측 및 예측함수 설계가 가능한 장점을 가진다<sup>21,22)</sup>. 준 지도학습 방식은 크게 셀프 학습기법과 공동 학습기법 두 가지로 구분된다. 셀프 학습기법<sup>23)</sup>은 초기 데이터를 학습한 후 시험 데이터를 예측 시 정확도가 높게 예측된 데이터를 다시 학습을 위한 데이터로 반복적으로 활용하는 기법으로 주어진 시험 데이터에서 학습할 데이터를 추출하기 위해 정확하게 예측하는 방식이 핵심요소이다. 다음으로 상호 학습기법<sup>24)</sup>이 있으며 상호 학습기법은 독립된 2개의 알고리즘을 사용하여 셀프 학습기법과 유사하게 시험 데이터에서 학습할 데이터를 추출하는 기법이다. 여기서 임의의 조건을 예측할 때 상관성이 높지만 완전하게 일치하지 않는 데이터를 추출하여 학습함으로 조건을 예측함에 있어서 상호 보완성을 가지며 예측 정확도를 향상시켜준다. 준 지도학습은 실시간을 요구하는 응용분야에 적합하며 무선 센서 네트워크에서는 위치추정과 고장노드탐지에 대한 문제 등을 다루는데 사용되어질 수 있다.

## IV. 무선 센서 네트워크를 위한 기계학습 기술

본 장에서는 무선 센서 네트워크의 각 응용분야에 다양한 기계학습 기술들을 적용한 연구사례에 대하여 나타내었다. 또한 각 응용분야의 문제점 또는 최적화

를 위하여 적용된 기계학습 기술들에 대한 특징을 나타냄을 통해 다른 응용분야에도 활용가능성을 보였다.

#### 4.1 위치추정

무선 센서 네트워크에서 위치추정은 배치된 센서 노드들의 물리적 그리고 지리적 위치를 파악하는 것이다. 일반적으로 무선 센서 네트워크에서 배치된 센서 노드들은 무작위로 배치되기 때문에 위치에 대한 정보를 가지고 있지 않는다. 그러나 센서 노드의 위치를 파악하는 것은 무선 센서 네트워크의 통신 경로 최적화를 위해 매우 중요한 요소이다. 따라서 기존의 센서 노드의 위치추정 방법은 수동배치를 하거나 지리적 위치 시스템 사용을 통해 가능하며 자신의 좌표 정보를 알고 있는 앵커 노드를 사용하여 주위의 센서 노드의 위치를 추정하는 방식이 있다. 이는 근거리 기반 위치추정, 통신 범위 기반 위치추정, 각도 및 거리 기반 위치추정, 알려진 위치정보 기반 위치추정으로 분류된다. 센서 노드의 위치는 외부적 요인으로 인해 변경 될 수 있으며 이는 네트워크가 재구성되어야 함을 의미한다. 따라서 이와 같은 환경에서 기계학습 기술 적용을 통해 앵커 노드와 센서 노드와 쉽게 구분이 가능하게 하며 센서 노드들의 클러스터링을 통해 각 센서 노드의 위치를 빠르게 파악이 가능함으로 위치추정의 정확도를 향상시킬 수 있다. 더욱이 이동성을 가지는 센서 노드의 경우 기계학습 기술을 통해 기존의 기법보다 위치추정의 정확도를 더욱 높일 수 있다.

S. S. Banihashemian, et al.<sup>[25]</sup>은 Range-Free 알고리즘 기반의 인공지능망을 사용하여 에너지 효율적인 위치추정 기법을 제안하였다. 여기서 Range-Free 알고리즘은 센서 노드간의 연결성을 중심으로 앵커 노드의 위치정보를 활용하여 임의의 센서노드의 위치를

추정해 내는 기법이다. 네트워크 환경은 센서 노드가 등방성과 비등방성 형태로 분포된 경우를 고려하였고 또 인공지능망의 은닉계층을 최적화하기 위하여 입자 군 최적화 기법을 사용하였다. 여기서 3개의 앵커 노드 중 하나의 앵커 노드를 헤더로 선정하여 인공지능망을 통한 학습을 수행한다. 시뮬레이션과 구현을 통해 다른 유사한 방식<sup>[26,27]</sup>과 비교하여 저장 용량의 오버헤드를 줄이고 위치추정의 정확성이 향상되었음을 나타내었다. 하지만 인공지능망 학습을 위한 계산과정의 에너지 소모에 대한 언급은 없으며 다수의 앵커 노드가 배치되는 응용 분야에서는 비용 문제로 인해 적용의 어려움이 있다. S. K. Gharghan, et al.<sup>[28]</sup>은 실내·외 환경에서 움직이는 노드의 위치추정을 위하여 하이브리드 입자 군 최적화 알고리즘을 적용한 인공지능망 기법을 제안하였다. 제안된 기법은 로그 정규 음영 모델과 비교하여 위치추정의 정확도를 비교하였으며 수신된 신호 강도를 통해 위치를 추정하였다. 실내는 체육관 내부에서, 실외는 자전거 트랙에서 측정하였으며 각 신호세기에 대한 거리 값을 인공지능망에 학습시키고 입자 군 최적화 방식을 통해 인공지능망의 은닉계층을 최적화 하였다. 여기서 3개의 앵커 노드 중 하나를 선정하여 인공지능망 학습을 수행하였으며 인공지능망 알고리즘을 수행하기 위한 에너지 소모에 대한 고려는 하지 않았다. 위치추정의 정확도는 시뮬레이션을 통해 나타내었으며 기존의 로그 정규 음영 모델과 비교하여 약 98%이상의 정확도가 향상된 것을 나타내었다. 하지만 제안된 규모보다 넓은 범위에서 센서 노드에 대한 위치 추정 시 측정 오차율은 증가하여 예측 정확도가 낮아질 수 있다. J. H. Kang, et al.<sup>[29]</sup>은 배수 누수 탐지 시스템을 위한 합성 신경망과 서포트 벡터 머신 기술 조합을 통한 누수 지

표 1. 위치추정을 위한 기계학습 기술 요약  
Table 1. A summary of machine learning technique for localization estimation

Machine Learning Algorithm	Complexity	Application	Node Mobility	Disadvantage	Contribution
ANN[25]	High	Object Tracking Applications	Stationary Node	High cost	Enhanced accuracy, Reduced Storage Overhead
ANN[28]	High	Indoor and Outdoor Track Cycling	Mobile Node	Focused small scale	Enhanced Accuracy
ANN & SVM[29]	High	Water Leakage Monitoring System	Stationary Node	High computation complexity	Enhanced Accuracy, Reduced Time Synchronization Error
SVM[32]	Low	Location-Based Services (Indoor)	Stationary Node	High energy consumption	Enhanced Accuracy
Bayesian[34]	Moderate	Environmental Monitoring Applications	Stationary Node	Performance week	Enhanced Accuracy

점의 위치추정 기법을 제안하였다. 먼저 그래프 기반 위치탐색 알고리즘을 적용하여 분포된 센서 노드를 통해 가장 근접한 누수지점을 탐지하여 전신주에 있는 중계기를 통해 게이트웨이로 전송하며 게이트웨이는 수집된 데이터를 서버로 전송한다. 여기서 서버는 인공지능망과 서포트 벡터 머신 기술을 통해 학습 및 분류를 수행한다. 제안된 기법은 기존 센서 간의 전송되는 신호를 처리하기 위해 소요되는 연산 양을 줄임으로 전체적인 통신 시간도 단축되는 효과를 가지게 하였다. 또 제안된 기법의 시뮬레이션 결과를 통해 기존의 1차원 합성신경망<sup>[30,31]</sup> 보다 위치추정의 정확도를 향상 시켰으며 위치추정의 정확도는 99.3%의 성능을 가진다. J. H. Hong, et al.<sup>[32]</sup>은 다중 클래스 서포트 벡터 머신 기술을 사용하여 디바이스 프리 위치추정 기법을 제안하였다. 제안된 기법은 펄크프린터 방법을 사용하였으며 실내 공간에서 사람의 각 위치를 기반으로 대규모 페이딩, 소규모 페이딩 그리고 노이즈에 따라 변화되는 고유벡터 값을 어레이 안테나를 가진 센서를 통해 측정하여 시공간의 평균값을 서포트 벡터 머신에 학습시킨 후 판별하는 기법이다. 측정 환경은 LoS(Line of Sight)와 NLoS(None-LoS) 두 가지 환경을 고려하였으며 기존의 수신신호기 방식<sup>[33]</sup>과 비교하여 두 가지 환경에서 위치추정 정확도가 향상된 것을 나타내었다. 하지만 독립적으로 수집된 특징을 다중의 서포트 벡터 머신을 통해 수행함으로써 데이터 처리를 위한 큰 에너지 모소가 발생한다. T. L. T. Nguyen, et al.<sup>[34]</sup>는 베이지안 추론을 기반 한 순차 몬트 카를로 샘플러를 사용하여 다중 센서 노드의 위치를 파악하는 기법을 제안하였다. 무선 센서 네트워크에서 저가의 센서 노드를 균일하게 분포된 경우로 목표 센서 노드에서 위치신호를 주위 센서 노드로 전달하면 수신 받은 센서 노드가 퓨전 센터로 불완전한

채널을 통해 중계하는 시스템 구성을 가진다. 여기서 센서 노드는 퓨전 센터로 수신 받은 신호를 전송하기 전에 양자화를 위한 신호처리를 수행하여 센서 노드에서 추가적인 전력소모가 발생하지만 신호추정의 정확성에 초점을 두고 있다. 제안된 기법의 성능분석은 사후 크레머 라오 경계 이론을 통해 베이지 추론에 대한 이론적 성능 값을 기준 값으로 두고 기존의 중요 샘플링 방식<sup>[35]</sup>과 비교하여 제안된 기법의 성능이 크게 향상된 것을 나타내었다.

#### 4.2 데이터 수집

무선 센서 네트워크에서 센서 노드로부터 데이터 수집을 위해 먼저 센서 노드로부터 데이터 수집을 통해 센서 노드간의 데이터 전송이 이루어지고 최종적으로 싱크 노드로 데이터 전달을 통해 통신을 종료한다. 데이터 수집을 통해 발생하는 문제점 중 하나는 공간적으로 센서 노드가 싱크 노드 주위로 위치되었을 때 라우팅 경로로 빈번하게 사용됨으로 다른 센서 노드보다 상대적으로 큰 전력을 소모하게 되며 이는 무선 센서 네트워크의 전체적인 수명을 감소시킨다. 또 센서 노드가 밀집된 곳에 싱크 노드가 위치하였을 때 데이터 전송이 집중됨에 따라 센서 노드에서 데이터 오버플로우가 발생함으로 데이터 손실이 발생할 수 있다. 따라서 손실된 데이터를 재전송이 일어남을 통해 시간적 지연과 추가적인 전력소모가 발생하게 되고 이는 네트워크의 전체적인 성능을 떨어뜨리게 된다. 기계학습 기술은 기존의 제안된 방식보다 더 효율적인 방식을 제안함을 통해 네트워크 수명시간이 향상시켰다. 제안된 방식은 각 센서 노드의 균등한 전력 사용을 위하여 최적의 클러스터 노드를 선정하는 방식이 있으며, 센서 노드의 데이터의 차원 축소를 통해 센서 간의 통신지연에 대한 오버헤드를 낮추는 방식이 있고, 네트워크 경로 재구성을 최소화하여 경로

표 2. 데이터 수집을 위한 기계학습 기술 요약  
Table 2. A summary of machine learning technique for data aggregation

Machine Learning Algorithm	Complexity	Application	Node mobility	Disadvantage	Contribution
$k$ -NN[36]	Moderate	Environmental Monitoring Applications	Stationary Node	Performance contribution low	Reduced Computation Complexity
Bayesian[38]	Low	Environmental Data Collection Applications	Stationary Node	Low accuracy	Reduced Computation complexity
PCA[39]	Low	Monitoring Applications (Medical, Industry, etc.)	Stationary Node	Limited application	Enhanced Energy Efficiency
PCA[41]	Low	General Wireless Sensor Network Applications	Stationary Node	Increased energy consumption	Reduced Computation complexity
PCA[43]	Low	Environmental Monitoring Applications	Stationary Node	Low accuracy	Enhanced Energy Efficiency

탐색에 대한 비용을 줄이는 방법 등이 있다.

Y. Y. Li, et al.<sup>[36]</sup>은 무선 센서 네트워크에서 센서 노드 간의 데이터 수집 중 불안정한 채널 상태와 센서 노드 간의 동기화 문제, 비정상적인 센서 노드 등으로 인해 발생하는 데이터 손실 값을 대체하기 위해 시공간 상관관계를 이용한  $kd$ -트리 기반  $k$ -최근접 이웃 알고리즘 기법을 제안하였다. 먼저 공간적으로 분포된 센서 노드로부터 시간별로 최신의 데이터를 수집하고  $kd$ -트리 알고리즘에 적용하여 손실 값 대체 모델을 구축한다. 만약 특정 센서 노드로부터 수신된 데이터가 손실이 된다면 해당 데이터를 복구하기 위해  $kd$ -트리 알고리즘을 통해 탐색을 시작하며  $k$ 개의 클러스터링 설정을 통해 손실된 데이터와 가장 근접된 데이터를 데이터 손실 값에 대한 대체 값으로 사용한다. 여기서 가장 근접한 센서 노드의 값을 확인하기 위해 유클리드 거리 값을 적용하였고 이는 시공간 상관관계 매개변수로  $kd$ -트리 알고리즘에 적용하였다. 제안된 기법의 성능은 기댓값 최대화 알고리즘<sup>[37]</sup>과 비교하여 큰 정확도를 가지며 계산 복잡도도 상대적으로 낮음을 나타내었다. S. G. Hwang, et al.<sup>[38]</sup>은 베이지안 압축 센싱 방식을 통해 데이터 수집 시 분포된 센서 노드 중 동작하는 센서 노드와 대기 중인 센서 노드를 선택하여 전체적인 무선 센서 네트워크의 성능을 향상 시켰다. 제안된 기법은 압축된 신호를 측정하여 베이지안 추정을 통해 물리적 환경에서 변형된 원 신호를 추정하였으며 이때 공분산 행렬 오류 결정 요인을 최소화함으로써 추정 오류를 감소시켰다. 제안된 기법의 성능은 압축 센싱 방식을 사용하였기

때문에 기존의 신호 샘플링 방식보다 복잡성을 낮추었고 특정한 수의 센서 노드만 선택하여 데이터를 수집함으로써 전체적인 네트워크의 수명을 향상시켰다. A. Morell, et al.<sup>[39]</sup>은 무선 센서 네트워크에서 데이터 수집을 위해 주성분분석 방식을 제안하였다. 먼저 클러스터 헤더가 클러스터에 포함된 센서 노드의 센싱 값을 입력 받아서 예측 값과 추정 값의 오류가 요구되는 오류 값 이하를 만족하는 범위 내에서 데이터 압축을 시행한다. 두 번째는 분포된 값의 투영 기준을 갱신하고 제어와 관련된 신호정보와 함께 싱크 노드로 압축 데이터를 전송한다. 마지막으로 싱크 노드가 수신받은 신호를 재구성하여 평균, 표준편차, 공분산 그리고 투영 기준을 갱신한다. 제안된 방식의 성능은 데이터 압축 방법을 사용하여 센서 노드의 계산 복잡성을 낮춤으로 전력 사용을 줄이고 투영 기준을 갱신함을 통해 무선 통신의 오류율을 줄여 재전송 횟수를 낮춤으로 결과적으로 전력 효율의 성능이 기존의 기법<sup>[40]</sup>보다 향상되는 결과를 나타내었다. T. Yu, et al.<sup>[41]</sup>은 무선 센서 네트워크에서 환경적인 요소로 인해 발생하는 센서 노드의 데이터 이상치를 제거하고 데이터를 수집하기 위한 회귀적 주성분 분석방법을 제안하였다. 제안된 시스템 모델은 분포된 센서 노드들은 공간적으로 각 클러스터에 소속이 되고 각 클러스터의 헤더 노드들은 소속된 센서 노드들로부터 데이터를 수집하여 시스템 중앙센터로 데이터를 전송하는 클러스터 트리 네트워크 구조를 가진다. 여기서 수집되는 데이터는 서로 다른 종류의 센서 노드로부터 수집되는 각각의 데이터를 의미한다. 제안된 기법은 초기화 단계

표 3. 고장노드 탐지를 위한 기계학습 기술 요약  
Table 3. A summary of machine learning technique for fault node detection

Machine Learning Algorithm	Complexity	Dataset	Application	Node mobility	Contribution
SVM[46]	Moderate	Intel Berkeley Research Laboratory and Grand St. Bernard Dataset[54]	Safety Critical Application	Stationary node	Enhanced accuracy (Test Set Accuracy : 99.6%)
ANN[48]	High	Thermocouple Sensors	Nuclear Power Plants	Stationary Node	Enhanced accuracy (Test Set Accuracy : 93.88%)
ANN[49]	Moderate	Sinc Function and Nonlinear Autoregressive Time Series[55]	General Node Fault Situation	Stationary Node	Enhanced Generalized Accuracy (Test Set MSE : 0.018)
Random forest[51]	Moderate	Tennessee Eastman Simulation Dataset[52]	Industrial Processes	Mobile Node	Enhanced Fault Classification (Test Set Accuracy : 71.46%)
		Three-Phase Flow Dataset[56]			(Test Set Accuracy : 99.54%)
Bayesian[53]	Low	MIMIC II Waveform dataset [57]	Medical Body Sensor Network	Stationary Node	Enhanced Accuracy (True Positive Rate : 81.7%)

와 회귀 단계로 구분되어지고 초기화 단계에서는 서로 다른 종류의 센서 노드의 값의 동일한 축으로 통일하기 위해서 정규화를 하고, 정규화 된 값을 통해 공분산 행렬 값을 초기화 한다. 다음 회귀 단계에서는 차후에 수집되는 데이터에 대한 정규화 과정과 수집된 데이터의 평균 및 표준 편차를 사용하여 제곱 예측 오류에 대한 임계값과 비교하여 이상치를 판별하는 과정을 반복한다. 제안된 기법의 성능은 기존의 주성분분석 방식<sup>[42]</sup>보다 정확하게 이상치를 판별하는데 있어서 15% 추가로 향상된 것을 나타내었다. M. Wu, et al.<sup>[43]</sup>은 무선 센서 네트워크의 수명향상을 위해 데이터 예측, 압축 그리고 복구를 통한 에너지 효율적인 데이터 수집 방법을 제안하였다. 먼저 에너지 효율을 향상시키기 위해 센서 노드들을 클러스터링 하였고 클러스터 헤더의 역할을 각 노드에게 공정하게 부여하는 라운드 로빈 스케줄링을 사용함으로써 클러스터 헤더에 집중되는 부하를 분산하였다. 여기서 센서 노드는 클러스터 헤더로 센싱 값을 전송할 때 과거 센싱된 값과 비교하여 비정상적인 값을 예측 및 대체를 통해 에너지 효율을 향상 시켰으며 예측 방법은 최소 평균 제곱법을 기반으로 하였다. 또 헤더 노드에서부터 베이스 노드로 수집된 데이터를 전송하기 위해 주성분분석 방법을 통한 공간적으로 중복되는 데이터를 제거하여 데이터를 용량을 줄인 후 전송함으로써 통신 비용을 감소시켰다. 제안된 기법은 정확도 향상과 데이터 처리에 대한 효율성을 향상 시켰으며 이론적 분석을 기반으로 실제 구현의 가능성에 대해 나타내었다.

### 4.3 고장노드 탐지

무선 센서 네트워크에서 분포된 노드들은 내·외적인 요인으로 인해 하드웨어 부분인 센싱 파트, 전원 파트, 신호처리 파트에 문제가 발생할 수 있으며 소프트웨어 부분인 펌웨어 파트 그리고 통신 채널이 불안정할 때 신호가 손실 및 고장이 발생 될 수 있다. 이러한 문제를 효과적으로 대처하기 위해 단순한 모델이 아닌 기계학습 기술을 이용한 모델 설계가 필요하다. 항공우주와 같은 특정한 분야에서는 하나의 센서 노드 고장만으로 치명적인 결과를 초래할 수 있으며, 일반적으로는 네트워크 수명에 대한 성능 부분에 영향을 줄 수 있다. 기존의 방식의 경우 하드웨어를 이용하는 방법<sup>[44]</sup>과 수집된 데이터를 기반으로 하여 고장노드를 탐지하는 방법<sup>[45]</sup>을 사용한다. 하드웨어 방식은 센서 노드를 추가 배치하는 것과 같은 하드웨어 이중화를 통하여 고장 허용치를 향상 시켜왔다. 하지만

이는 하나의 센서 노드에 대한 추가 비용과 복잡도, 추가 전력소모 등의 단점이 발생한다. 두 번째로 수집된 데이터를 기반으로 하는 경우는 고장노드 탐지 알고리즘을 설계하여 고장노드를 탐지하는 방법으로 고장확률이 증가할수록 고장노드를 탐지하는 정확도가 크게 줄어들게 된다. 여기서 기존의 알고리즘을 통한 예측 방법보다 고장확률에 상관없이 기계학습 방법을 적용하였을 때 탐지 정확도 향상과 손실을 최소화하기 위하여 실시간 탐지성이 향상 될 수 있다.

고장노드 탐지를 위해 설계된 각 기계학습의 공통적인 단점은 각 응용 분야에서 요구되는 요구조건이 다르므로 다른 응용 분야에 적용 시 제안된 구조에서 정확도 성능이 낮아질 수 있다. S. Zidi, et al.<sup>[46]</sup>은 고장노드 탐지를 위해 서포트 벡터 머신의 통계적 학습 이론을 기반으로 결정 함수를 정의하였으며 예측 과정을 간소화하여 클러스터 헤더에서 쉽게 고장노드를 탐지할 수 있도록 기계학습을 이용한 기법을 제안하였다. 제안된 기법은 정상 및 비정상 데이터를 학습을 통해 라그랑지안 계수를 결정함으로써 서포트 벡터 머신의 최대 마진을 구하고 이를 통해 실시간으로 입력되는 관찰 데이터의 정상 및 비정상 탐지하는 결정 함수를 얻는다. 제안된 기법의 성능은 베이저안 방식을 적용한 기법<sup>[47]</sup>보다 고장확률이 증가할 때 탐지 정확성이 크게 향상 되었으며 관찰 데이터의 99% 이상을 확률로 비정상 데이터를 탐지하는 결과를 나타내었다. S. Mandal, et al.<sup>[48]</sup>은 원자력 발전소에서 사용하는 열전대 센서의 고장 여부를 판단하기 위해 인공신경망과 우도비율검정을 사용하였다. 제안된 기법은 심층 신뢰 네트워크를 사용하여 열전대 센서 노드로부터 입력되는 데이터로부터 고장 데이터를 분류한 다음 정상적인 데이터의 평균을 참고하여 최대 제곱근 오차를 찾아 고장 센서 노드를 식별하고 우도비율 검증 알고리즘을 사용하여 고장 패턴을 분류한다. 여기서 사용된 심층 신뢰 네트워크는 하나의 입력 뉴런층과 하나의 은닉 뉴런층으로 구성된 제한 불쓰만 머신을 스택 형식으로 다수를 가지는 구조로 되어있으며 확률적 결과 데이터를 나타낸다. 제안된 기법의 성능은 서포트 벡터 머신 방식과 비교하여 고장 노드 예측 오류율을 1.72% 낮춤을 통해 정확도 향상을 나타내었다. Y. Xiao, et al.<sup>[49]</sup>은 단일 네트워크에서 부분적으로 발생하는 고장노드를 대체를 통한 네트워크 신뢰성을 높이기 위해 인공신경망 방식을 통한 일반적으로 적용이 가능한 통합 고장노드 모델을 설계하였다. 모델 설계를 위하여 기존의 고장 노드에서 발생하는 stuck-at-zero 또는 stuck-at-one 출력 형태 고장

노드 탐지 모델을 조사하였으며 두 가지의 문제점을 고려하여 stuck-at-any 출력 형태를 가지는 조건에서 고장노드를 탐지 가능한 통합 모델을 설계하였다. 여기서 통합 모델은 방사형 기저 함수 신경망<sup>[50]</sup>를 기반으로 하였으며 이는 하나의 은닉층과 출력층을 가지는 네트워크 구조로 빠른 학습시간, 일반화 등의 장점을 가진다. 설계된 모델은 단일 네트워크 안에서 한 종류의 고장 노드 탐지뿐 아니라 여러 종류의 고장노드 탐지도 가능하며, 제안된 기법의 성능은 최소자승법 방식과 비교하여 정확도를 크게 향상시킨 것을 나타내었다. Z. Chai, et al.<sup>[51]</sup>은 산업공정 과정에서 발생할 수 있는 고장 노드를 탐지하기 위해 향상된 랜덤 포레스터 알고리즘을 통해 효과적으로 고장노드의 등급을 분류하여 고장 노드를 탐지하는 기법을 제안하였다. 여기서 사용된 느린 특징 분석은 급격히 변화되는 입력 값을 정규화한 후 특이 값 분해 방식을 적용하여 중복된 데이터를 제거하고 느리게 변화 되는 특징을 추출한 방법이다. 추가로, 일반적인 느린 특징 추출 방식은 비지도 방식을 사용하지만 제안된 기법에서는 지도 방식을 사용하여 고장의 정도를 더 정확하게 분류하기 위해 최적화 되도록 하였다. 또 제안된 기법은 고장의 등급을 분류하기 위해 고정된 센서 노드에서 추출된 정보만 사용하지 않고 동적인 센서 노드에서 추출된 정보를 동시에 랜덤 포레스트의 학습 데이터로 사용하여 고장 예측의 정확을 향상 시켰다. 제안된 기법의 성능분석을 위해 테네시 이스트만 및 다중 단계 흐름 과정 시험 데이터<sup>[52,56]</sup>를 사용하였으며 테네시 이스트만 과정의 경우 일반적인 랜덤 포레스트 기법보다 정확도가 약 6% 향상이 되었고 서포트 벡터 머신 방식보다 약 32% 향상되었으며 다중 단계

흐름 과정의 경우 일반 랜덤 포레스트 기법보다 약 4% 그리고 서포트 벡터 머신보다 약 31% 향상되었다. H. Zhang, et al.<sup>[53]</sup>은 환자의 상태 진단을 위해 사용되는 센서 데이터 값의 신뢰도를 높이기 위해 고장 노드를 탐지하여 오류가 있는 데이터가 활용되지 않도록 하는 누적된 학습을 기반으로 한 베이지안 모델을 제안하였다. 제안된 기법은 시간 및 공간적 상관도를 얻어 정상적인 센서 판독 값을 얻기 위해 베이지안 모델을 설계하였다. 제안된 기법은 공개적으로 배포된 데이터에서 고장 신호를 삽입하여 센서 노드로부터 오는 신호와 이전 신호 값을 사용하여 조건부 확률로 나타내어 미리 정의된 임계값과 비교하여 고장 신호를 판별하였다. 제안된 기법의 성능은 대규모 센서 노드로부터 수집된 중복된 데이터를 활용한 것보다 고장 탐지율을 향상시킨 것을 나타내었다.

#### 4.4 라우팅

무선 센서 네트워크에서 라우팅 최적화 문제는 네트워크의 제안된 대역폭과 제한적인 전력자원 문제, 저용량 메모리 그리고 낮은 신호처리 성능을 고려할 때 네트워크의 수명을 향상시키는데 중요한 부분 중의 하나이다. 일반적으로 싱크노드 주변에 위치한 센서노드들이 전체적으로 분포된 센서노드로부터 전송된 신호를 빈번하게 중계역할을 함으로써 전력소모가 더 빨리 이루어진다. 또 몇몇 센서노드의 고장과 배터리 방전 등으로 발생하는 라우팅 경로 문제를 고려해야 된다. 따라서 기계학습 기반의 라우팅 프로토콜 설계 목표는 위와 같은 문제 가운데서 라우팅 경로를 최적화하여 데이터 전송 지연 및 손실 등을 낮춤으로 센서노드의 전력사용을 줄이기 위한 목표를 가진다.

표 4. 기계학습 기반 라우팅 기법을 위한 기술 요약  
Table 4. A summary of machine learning technique for fault node detection

Machine Learning Algorithm	Complexity	Network Operation	Type of MAC	Disadvantage	Contribution
ANN[58]	Low	Hybrid Clustering (Centralized, Distributed)	TDMA	Thin description of ANN	Improved Energy Efficiency
ANN[61]	Low	Non Clustering	-	Focused on small scale network	Improved Route Discovery Improved Throughput
Reinforcement Learning[65]	Moderate	Distributed Clustering	TDMA	Conditionally low energy efficiency	Improved Network Lifetime
Reinforcement Learning[68]	Low	Non Clustering	CSMA-based	Focused on small scale network	Improved Throughput Improved End-to-End Delay
Reinforcement Learning[71]	High	Non Clustering	S-FAMA	Decreased life time	Improved End-to-End Delay

A. Mehmood, et al.<sup>[58]</sup>은 무선 센서 네트워크에서 산업 오염 모니터링을 위해 인공신경망을 기반으로 에너지 효율적인 라우팅 기법을 제안하였다. 제안된 기법에서 전체 네트워크는 3개의 층으로 구분되고 각 층마다 마스터 노드가 1개씩 존재하며 각 층에는 여러 그룹이 형성되어 있고 각 그룹마다 헤더 노드가 1개씩 선정이 되어 진다. 그룹에서 가장 중앙에 있는 노드가 헤더 노드로 선정되고 그룹에서 가장 경계에 있는 센서노드가 다른 그룹과 통신을 담당한다. 헤더 노드는 그룹 멤버 각각의 잔류에너지를 확인하며 그룹 경계에 있는 노드에게 정보를 전송하여 마스터 노드와 관련 정보를 공유하고 마스터 노드는 잔류에너지 임계값 정보를 기반으로 임계값 이하의 노드 ID와 임계값 이상의 노드 ID로 라우팅 테이블을 작성하여 각 헤더 노드로 전송한다. 기지국의 경우 잔류에너지, 그룹 관리 노드와 거리, 부하량 등에 대한 데이터를 헤더 노드를 통해 수신 받아 인공신경망을 사용하여 마스터 노드와 헤더 노드를 선정하고 최적의 에너지 잔량 임계값을 계산하여 헤더 노드와 마스터 노드로 전송한다. 제안된 기법의 에너지 효율은 일반적인 라우팅 기법 LEACH<sup>[59]</sup>와 HEED<sup>[60]</sup>보다 각각 42%, 30%이상 향상된 것을 나타내었다. Y. M. Lee<sup>[61]</sup>는 재난 환경 모니터링을 위해 심층 신경망을 활용하여 효과적인 라우팅 경로 기법을 제안하였다. 모니터링을 위한 네트워크 환경은 하이브리드 무선 애드혹 네트워크를 적용하였으며 기지국 사이는 유선 그 외 센서 노드는 MANET (Mobile Ad hoc Network)으로 구성되고 IP 통신을 기반으로 한다. 제안된 기법은 각 기지국을 통해 센서 노드의 위치 정보를 가지고 있는 백터 신호를 수집하여 심층 인공신경망을 수행하는 서버로 데이터를 전달한다. 여기서, 백터 신호는 신호의 방향 정보도 포함하고 있다. 심층 인공신경망을 서버는 기지국으로 전달받은 데이터를 기반으로 학습을 수행하며 노드의 방향성 및 노드 출현 패턴을 분석하여 가상 루트를 생성한 다음 기지국으로 다시 라우팅 경로 정보를 전달한다. 제안된 기법의 성능은 기존의 애드혹 라우팅 기법 OLSR<sup>[62]</sup>, AODV<sup>[63]</sup> 그리고 ZRP<sup>[64]</sup>보다 각각 약 53%, 23%, 26% 라우팅 경로 구축 시간을 줄이는 성능 향상을 보였다. S. Wang, et al.<sup>[65]</sup>은 강화학습을 기반으로 수중 센서 네트워크에서 효율적인 라우팅 기법을 제안하였다. 수중 네트워크 구조는 기지국 역할을 하는 배와 해저 바닥까지 여러 층으로 구분하였고 각 층에는 클러스터링 구조로 형성된다. 먼저 싱크노드는 클러스터 헤더와 기지국 사이의 중계 역할 및 클러스터 헤더로부터 수집한 데이

터를 특징 별로 분류하고 강화학습을 통해 효율적인 링크와 에너지 잔량을 분석한 다음 기지국으로 해당 데이터를 전송한다. 다음으로 기지국은 싱크노드에서 받은 데이터를 기반으로 최대 Q 값을 가진 채널과 노드의 최대 에너지 잔량을 비교하여 라우팅 테이블을 작성 후 각 클러스터 헤더로 전송한다. 제안된 기법의 성능은 기존의 Co-UWSN<sup>[66]</sup> 및 E-CBCCP<sup>[67]</sup> 보다 에너지 효율과 종단간의 지연 성능을 향상시킨 것을 나타내었다. 하지만 강화학습을 싱크 노드에서 수행함으로써 수중의 각 층에서 전송되는 채널상태가 실시간으로 갱신되지 않음으로 라우팅 경로에 대한 정확성이 떨어짐을 알 수 있으며, 또 싱크 노드에서 신호 처리에 대한 에너지 소모는 반영되지 않았다. V. D. Valerio, et al.<sup>[68]</sup>은 수중 센서 네트워크에서 강화학습 기반 멀티홉 적응형 라우팅 기법을 제안하였다. 수중 네트워크는 고정된 센서 노드에서 싱크노드로 데이터 전송하는 시나리오로 가정하였다. 제안된 기법은 각 2가지로 환경에 대해 구분하여 알고리즘을 정의 하였고 첫째는 센서 노드가 이웃 노드 정보를 가지고 있을 경우 최대 전송 홉수를 정하여 이웃 노드로 데이터를 전송한다. 여기서 센서 노드는 최적의 이웃 노드 선정을 위해 강화학습을 통해 저장하며, 입력 값으로는 시도 홉수와 성공 홉수를 고려한다. 데이터 전송 성공 여부는 이웃노드에서 라운드 타임 동안 동일한 패킷을 전송한 것을 감지할 때 성공한 것으로 간주한다. 둘째는 이웃 노드 정보를 가지고 있지 않은 경우, 센서 노드는 브로드캐스팅 함으로 무작위로 주위 노드로 알리며 이는 신뢰성을 높일 수 있지만 에너지 효율은 낮아지는 방법이다. 제안된 기법의 성능은 기존 라우팅 기법인 CARP<sup>[69]</sup>와 기계학습 기반 라우팅 기법인 QELAR<sup>[70]</sup> 등과 비교를 통해 에너지 효율과 종단간 지연에 대한 우수한 성능을 나타내었고 센서 노드 40개를 기준으로 최대 부하에서 PDR (Packet Delivery Ratio)의 경우 최소 30% 이상 성능향상을 나타내었다. Z. Jin, et al.<sup>[71]</sup>은 수중 센서 네트워크에서 트래픽 혼잡도를 낮추기 위해 강화학습 기반의 라우팅 기법을 제안하였다. 네트워크 구조는 센서노드와 싱크노드로 구성을 하였으며 각각의 센서 노드에서 최적의 라우팅을 위한 강화학습을 수행한다. 먼저 각 센서 노드는 단일 홉 내에 있는 물리적 노드 정보를 확보하고 혼잡도, 지연 그리고 에너지 잔량에 대한 3가지 입력에 따라 학습된 Q 값을 기준으로 단일 홉 내의 가상 라우팅 경로를 결정하고 S-FAMA<sup>[72]</sup> MAC 프로토콜을 기반으로 데이터를 전송한다. 제안된 기법의 성능은 기계학습 기반 라우팅 기법인 QELAR<sup>[70]</sup>

보다 분산된 노드가 증가할수록 중단간 지연 성능을 향상되었으며 에너지 소모와 데이터 처리량을 소폭 향상되었다. 하지만 제안된 기법의 알고리즘은 센서 노드에서 3가지 파라미터에 대한 연산 및 강화학습 수행해야 함으로 이에 대한 에너지 소모비용은 고려되지 않았다.

#### 4.5 MAC(Media Access Control)

무선 센서 네트워크의 환경에 따라 센서 노드의 네트워크 참여 및 단절 등으로 인해 네트워크의 변화가 발생할 수 있으므로 제한된 자원을 효율적으로 사용하여 센서 노드간의 충돌횟수와 지연을 줄이고 데이터 처리량과 에너지 효율의 성능을 향상시키기 위해 최적의 MAC 프로토콜 설계는 중요한 요소이다. MAC 프로토콜은 크게 경쟁 기반과 스케줄링 기반 그리고 경쟁과 스케줄링이 혼합된 하이브리드 기반으로 분류될 수 있다. MAC 프로토콜의 종류에 따라 여러 성능지표에 차이를 가짐으로 기계학습을 적용함을 통해 기존 MAC 프로토콜의 성능에 대한 보완 및 향상이 가능하다.

S. Kosunalp, et al.<sup>[73]</sup>은 무선 센서 네트워크에서 강화학습을 기반으로 한 실용적인 MAC 프로토콜을 제안하였다. 제안된 기법은 슈퍼프레임과 같이 하나의 프레임에 여러 개의 슬롯들이 있으며 각 노드는 경쟁 기반의 알로하 방식으로 각 슬롯에 접근한다. 또 각 노드에서 슬롯에 접근 시 충돌여부에 따라 보상 또는 벌을 주는 방식의 강화학습을 통해 각 슬롯에 우선순위를 부여하는 방식을 통해 강화학습 후에는 스케줄링 방식과 유사하게 동작하게 된다. 보상 또는 벌에 대한 값은 Q 변수로 나타내며 Q 값은  $t+1$ 에서 갱신되어진다. 여기서 최적의 슬롯을 탐색 및 선정하기 위해  $\epsilon$  파라미터를 추가하여 지역적으로 최적화된 슬롯

사용을 방지하였다. 제안된 기법의 성능은 Z-MAC<sup>[74]</sup>과 비교하여 네트워크 트래픽 부하가 50% 이상일 때 데이터 처리량에 대한 성능이 약 20% 향상된 것을 나타내었다. 여기서 센서 노드에서 강화학습을 위한 복잡도 증가와 신호처리를 위한 에너지 소모는 고려되지 않았으며 강화학습 알고리즘을 수행하기 위한 신호처리 하드웨어에 대한 추가 비용도 발생할 수 있다. C. Savaglio, et al.<sup>[75]</sup>은 무선 센서 네트워크에서 에너지 효율을 고려한 강화학습 기반 적응형 MAC 프로토콜을 제안하였다. 네트워크 구조는 무작위로 분산된 센서 노드와 하나의 싱크노드로 구성하였으며 CSMA/CA MAC 프로토콜을 기반으로 동작한다. 제안된 기법은 각 센서 노드가 동일한 슬롯에서 전송된 패킷 성공률, 정상적인 패킷 수신율, 엿듣기를 통해 이웃 노드의 패킷 수신율, 그리고 이웃 노드의 패킷 전송 성공률에 대한 패턴을 강화학습을 수행을 통해 시간슬롯에 Q 값을 부여하여 Q 값에 따라 각 센서 노드의 On-Off 시간을 적응적으로 조정하여 에너지 효율을 향상시키는 기법이다. 제안된 기법의 성능은 일반적인 CSMA/CA MAC 프로토콜과 비교하여 100개 센서 노드를 기준으로 PDR 성능은 유사하게 나왔지만 에너지 효율은 약 60% 향상된 것을 나타내었다. 여기서 에너지 효율은 신호처리 부분의 에너지 사용은 고려되지 않았다. E. Nisioti, et al.<sup>[76]</sup>은 무선 센서 네트워크에서 MAC 프로토콜 설계를 위한 강인한 조정 강화학습 기반 비정규 반복 슬롯 알로하 알고리즘을 제안하였다. 제안된 네트워크는 시간에 따라 채널 상태가 변하며 네트워크 토폴로지가 변동하는 구조를 가지고 네트워크는 클러스터 멤버 노드와 클러스터 헤드 그리고 싱크노드로 구성된다. 제안된 기법은 그룹별로 종속 및 분산된 POMDP (Partially Observable

표 5. 기계학습 기반 MAC 프로토콜 설계를 위한 기법 요약  
Table 5. A summary of fault node detection based on machine learning

Machine Learning Algorithm	Complexity	Network Variation	Type of MAC	Disadvantage	Contribution
Reinforcement Learning[73]	Moderate	Non Variation	Slotted ALOHA	Not to consider learning computation	Improved Throughput Conditionally Improved End to End Delay
Reinforcement Learning[75]	Moderate	Non Variation	CSMA/CA	Not to consider learning computation	Improved Energy Efficiency Improved Throughput
Reinforcement Learning[76]	High	Variation	Slotted ALOHA	Focused on small scale network	Improved Throughput Reduced Complexity for Tiny Networks
Fussy Logic[78]	High	Variation	CSMA/CA	High computation complexity	Improved Throughput Improved Delay

Markov Decision Process) 모델을 기반으로 하여 Q 학습을 통해 동작된다. 각 센서 노드는 IRSA (Irregular Repetition Slotted ALOHA)<sup>[77]</sup>에 따라 프레임의 슬롯 예약이 가능하며 예약을 하기 위한 센서 노드의 활동은 조정 그래프의 최대 합 알고리즘에 따라 이루어진다. 여기서 최대 합 알고리즘은 센서 네트워크의 복잡도를 줄이기 위해 다중 배낭 문제 기반 알고리즘이다. 각 센서 노드는 동작에 따라 데이터 전송의 성공 및 충돌이 발생 하였을 때 Q 표를 작성하고 Q 값을 갱신하여 다음 데이터 전송 시 참고로 사용한다. 제안된 기법의 성능은 최대 트래픽이 발생하였을 때 일반적인 IRSA 프로토콜보다 약 3배의 데이터 처리량 성능을 보였으며 복잡도 성능의 경우 트래픽이 점점 증가 할 때 일반적인 최대 합 알고리즘보다 다중 배낭 문제 기반 최대 합 알고리즘을 통한 시간이 크게 떨어진 것을 나타내었다. 하지만 센서 노드 개수가 16로 구성된 매우 소규모 네트워크의 경우이며, 따라서 네트워크 규모가 증가 할수록 충돌 횟수 증가로 인한 데이터 처리량 감소와 학습시간이 크게 증가하는 단점을 가진다. I. Bouazzi, et al.<sup>[78]</sup>은 무선 센서 네트워크에서 퍼지로지 기반 CSMA/CA MAC 프로토콜의 백오프 시간을 적응적으로 조절하여 에너지 효율 및 데이터 처리량의 성능을 향상시키는 알고리즘을 제안하였다. 네트워크 구조는 클러스터 트리 형태를 가지며 제안된 기법은 트래픽 부하로 인해 중계 노드에서 발생할 수 있는 오버플로우로 인한 패킷 손실과 네트워크 전체적 데이터 처리성을 떨어뜨리는 것을 방지하기 위해 큐 길이와 트래픽 부하량을 측정하여 퍼지 로직 기법을 통해 백오프 시간을 적응적으로 줄이거나 늘리는 알고리즘이다. 제안된 기법의 성능은 일반적인 CSMA/CA 프로토콜보다 트래픽 부하가 증가할 때 에너지 효율 및 데이터 처리량에 대한 성능이 향상된 것을 나타내었다. 여기서 제안된 기법은 비퍼지화 시 평균 중심 법보다 연산 시간이 오래 걸리는 무게 중심법을 적용하였으며, 또한 퍼지화, 비퍼지화 그리고 퍼지 추론을 수행하기 위한 에너지 소모는 고려되지 않았다.

## V. 결 론

본 논문은 무선 센서 네트워크를 위한 기계학습 기술에 대하여 조사를 하였다. 기계학습의 세부 기술은 지도학습, 비 지도학습, 강화학습 그리고 준 지도학습으로 크게 4가지로 분류되어지며 각각의 학습 방식에 따라 회귀, 분류, 클러스터링 등의 세부 기법으로 분

류된다. 무선 센서 네트워크의 세부 응용분야에는 데이터 수집, 위치 추정, 고장노드 탐지 등이 있으며 목적에 따라 기계학습의 세부기술을 적용하여 일반적으로 정확도를 향상시키는 연구가 진행되었고 지도학습 기법 중 인공신경망이 대표적으로 가장 많이 적용되었다. 또 무선 센서 네트워크의 세부 응용분야에 성능 향상을 위해 최근 연구 동향을 나타내었으며 정확도, 계산 복잡도, 에너지 효율 등 특정한 성능지표 향상을 위해 사용된 기법들을 소개함으로 추후 응용분야의 연구를 위한 참고자료로 활용이 가능하다. 향후연구 방향은 센서노드에 기계학습 기법을 적용하였을 때 복잡도 증가와 센서노드의 수명에 미치는 영향 등에 대한 분석을 통해 실제 적용 및 구현을 위한 연구가 필요하다.

## References

- [1] J. Lu, H. Okada, T. Itoh, T. Harada, and R. Maeda, "Toward the world smallest wireless sensor nodes with ultralow power consumption," *IEEE Sensors J.*, vol. 14, no. 6, pp. 2035-2041, Jun. 2014.
- [2] I. F. Akyildiz, W. Su, Y. Sankarasubramaniam, and E. Cayirci, "Wireless sensor networks: A survey," *Computer Netw.*, vol. 38, no. 4, pp. 393-422, Mar. 2002.
- [3] D. D. Tan and D. S. Kim, "Dynamic traffic-aware routing algorithm for multi-sink wireless sensor networks," *Wireless Netw.*, vol. 20, no. 6, pp. 1239-1250, Aug. 2013.
- [4] S. H. Kim, J. M. Lee, and D. S. Kim, "Cooperative communication schemes for multi-hop wireless sensor network of aircraft," *J. IEIE*, vol. 55, no. 10, pp. 1181-1191, Oct. 2018.
- [5] C. Wang, J. Li, Y. Yang, and F. Ye, "Combining solar energy harvesting with wireless charging for hybrid wireless sensor networks," *IEEE Trans. Mob. Comput.*, vol. 17, no. 3, pp. 560-576, Mar. 2018.
- [6] N. T. Tuan, D. S. Kim, and J. M. Lee, "On the performance of cooperative transmission schemes in industrial wireless sensor networks," *IEEE Trans. Ind. Informatics*, vol. 14, no. 9, pp. 4007-4018, Sep. 2018.
- [7] R. Deng, S. He, P. Cheng, and Y. Sun,

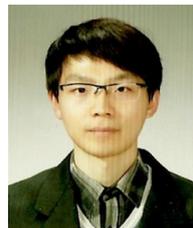
- “Towards balanced energy charging and transmission collision in wireless rechargeable sensor networks,” *J. Commun. and Netw.*, vol. 19, no. 4, pp. 341-350, Aug. 2017.
- [8] S. Sasirekha and S. Swamynathan, “Cluster-chain mobile agent routing algorithm for efficient data aggregation in wireless sensor network,” *J. Commun. and Netw.*, vol. 19, no. 4, pp. 392-401, Aug. 2017.
- [9] M. L. F. Miguel, M. C. Penna, E. Jamhour, and M. E. Pellenz, “A CoAP based control plane for software defined wireless sensor networks,” *J. Commun. and Netw.*, vol. 19, no. 6, pp. 555-562, Dec. 2017.
- [10] T. Ngo, A. Abdukhakimov, and D. S. Kim, “Long-range wireless tethering selfie camera system using wireless sensor networks,” *IEEE Access*, vol. 7, pp. 108742-108749, 2019.
- [11] B. Han, J. Leblet, and G. Simon, “Query range problem in wireless sensor networks,” *IEEE Commun. Lett.*, vol. 13, no. 1, pp. 55-57, Jan. 2009.
- [12] J. J. Cho, Y. Ding, Y. Chen, and J. Tang, “Robust calibration for localization in clustered wireless sensor networks,” *IEEE Trans. Automat. Sci. and Eng.*, vol. 7, no. 1, pp. 81-95, Jan. 2010.
- [13] M. Jouhari, K. Ibrahim, H. Tembine, and J. Ben-Othman, “Underwater wireless sensor networks: A survey on enabling technologies, localization protocols, and internet of underwater things,” *IEEE Access*, vol. 7, pp. 96879-96899, Jul. 2019.
- [14] K. Chen, M. Ma, E. Cheng, F. Yuan, and W. Su, “A survey on MAC protocols for underwater wireless sensor networks,” *IEEE Commun. Surv. & Tuts.*, vol. 16, no. 3, pp. 1433-1447, Mar. 2014.
- [15] P. Louridas and C. Ebert, “Machine learning,” *IEEE Software*, vol. 33, no. 5, pp. 110-115, Sep. 2016.
- [16] J. A. Morente-Molinera, J. Mezei, C. Carlsson, and E. Herrera-Viedma, “Improving supervised learning classification methods using multigranular linguistic modeling and fuzzy entropy,” *IEEE Trans. Fuzzy Syst.*, vol. 25, no. 5, pp. 1078-1089, Oct.
- [17] D. Lam, M. Wei, and D. Wunsch, “Clustering data of mixed categorical and numerical type with unsupervised feature learning,” *IEEE Access*, vol. 3, pp. 1605-1613, Sep. 2015.
- [18] A. Faktor and M. Irani, ““Clustering by composition”—Unsupervised discovery of image categories,” *IEEE Trans. Pattern Anal. and Mach. Intell.*, vol. 36, no. 6, pp. 1092-1106, Jun. 2014.
- [19] D. L. Poole and A. K. Mackworth, “*Artificial intelligence: Foundations of computational agents*,” Cambridge University Press, 2010.
- [20] C. J. C. H. Watkins and P. Dayan, “Q-learning,” *Machine Learning*, vol. 8, no. 3-4, pp. 279-292, May 1992.
- [21] P. K. Mallapragada, R. Jin, A. K. Jain, and Y. Liu, “SemiBoost: Boosting for semi-supervised learning,” *IEEE Trans. Pattern Anal. and Mach. Intell.*, vol. 31, no. 11, pp. 2000-2014, Nov. 2009.
- [22] A. Arshad, S. Riaz, and L. Jiao, “Semi-supervised deep fuzzy c-mean clustering for imbalanced multi-class classification,” *IEEE Access*, vol. 7, pp. 28100-28112, Feb. 2019.
- [23] C. Rosenberg, M. Hebert, and H. Schneiderman, “Semi-supervised self-training of object detection models,” *IEEE Wrkshsp. Appl. Comput. Vision*, pp. 29-36, Breckenridge, U.S.A, Jan. 2005.
- [24] A. Blum and T. Mitchell, “Combining labeled and unlabeled data with co-training,” *The Wrkshps. Computational Learning Theory*, pp. 92-100, Wisconsin, U.S.A, Jul. 1998.
- [25] S. S. Banihashemian, F. Adibnia, and M. A. Sarram, “A new range-free and storage-efficient localization algorithm using neural networks in wireless sensor networks,” *Wireless Pers. Commun.*, vol. 98, no. 1, pp. 1547-1568, Jan. 2018.
- [26] D. A. Tran and T. Nguyen, “Localization in wireless sensor networks based on support vector machines,” *IEEE Trans. Parallel and Distrib. Syst.*, vol. 19, no. 7, pp. 981-994, Jul.

- 2008.
- [27] A. Chatterjee, "A Fletcher-Reeves conjugate gradient neural-network-based localization algorithm for wireless sensor networks," *IEEE Trans. Veh. Technol.*, vol. 59, no. 2, pp. 823-830, Feb. 2010.
- [28] S. K. Gharghan, R. Nordin, M. Ismail, and J. A. Ali, "Accurate wireless sensor localization technique based on hybrid PSO-ANN algorithm for indoor and outdoor track cycling," *IEEE Sensors J.*, vol. 16, no. 2, pp. 529-541, Jan. 2016.
- [29] J. Kang, Y. Park, J. Lee, S. Wang, and D. Eom, "Novel leakage detection by ensemble CNN-SVM and graph-based localization in water distribution systems," *IEEE Trans. Ind. Electron.*, vol. 65, no. 5, pp. 4279-4289, May 2018.
- [30] T. Ince, S. Kiranyaz, L. Eren, M. Askar, and M. Gabbouj, "Real-time motor fault detection by 1-D convolutional neural networks," *IEEE Trans. Ind. Electron.*, vol. 63, no. 11, pp. 7067-7075, Nov. 2016.
- [31] O. Abdeljaber, O. Avci, S. Kiranyaz, M. Gabbouj, and D. J. Inman, "Realtime vibration-based structural damage detection using one-dimensional convolutional neural networks," *J. Sound and Vibration*, vol. 338, no. 3, pp. 154-170, Feb. 2017.
- [32] J. Hong and T. Ohtsuki, "Signal eigenvector-based device-free passive localization using array sensor," *IEEE Trans. Veh. Technol.*, vol. 64, no. 4, pp. 1354-1363, Apr. 2015.
- [33] M. Seifeldin, A. Saeed, A. E. Kosba, A. El-Keyi, and M. Youssef, "Nuzzer: A large-scale device-free passive localization system for wireless environments," *IEEE Trans. Mob. Comput.*, vol. 12, no. 7, pp. 1321-1334, Jul. 2013.
- [34] T. L. T. Nguyen, F. Septier, H. Rajaona, G. W. Peters, I. Nevat, and Y. Delignon, "A bayesian perspective on multiple source localization in wireless sensor networks," *IEEE Trans. Sign. Process.*, vol. 64, no. 7, pp. 1684-1699, Apr. 2016.
- [35] E. Masazade, R. Niu, P. K. Varshney, and M. Keskinoz, "Energy aware iterative source localization for wireless sensor networks," *IEEE Trans. Sign. Process.*, vol. 58, no. 9, pp. 4824-4835, Sep. 2010.
- [36] Y. Y. Li and L. E. Parker, "Nearest neighbor imputation using spatial-temporal correlations in wireless sensor networks," *Inf. Fusion*, vol. 15, pp. 64-79, Jan. 2014.
- [37] R. J. Little, D. B. Rubin, "Statistical Analysis with Missing Data," John Wiley & Sons, U.S.A., Aug. 1986.
- [38] S. Hwang, R. Ran, J. Yang, and D. K. Kim, "Multivariate bayesian compressive sensing in wireless sensor networks," *IEEE Sensors J.*, vol. 16, no. 7, pp. 2196-2206, Apr. 2016.
- [39] A. Morell, A. Correa, M. Barceló, and J. L. Vicario, "Data aggregation and principal component analysis in WSNs," *IEEE Trans. Wireless Commun.*, vol. 15, no. 6, pp. 3908-3919, Jun. 2016.
- [40] C. Anagnostopoulos and S. Hadjiefthymiades, "Advanced principal component-based compression schemes for wireless sensor networks," *ACM Trans. Sensor Netw.*, vol. 11, no. 1, pp. 1-34, Jul. 2014.
- [41] T. Yu, X. Wang, and A. Shami, "Recursive principal component analysis-based data outlier detection and sensor data aggregation in IoT systems," *IEEE Internet of Things J.*, vol. 4, no. 6, pp. 2207-2216, Dec. 2017.
- [42] S. C. Chan, H. C. Wu, and K. M. Tsui, "Robust recursive eigendecomposition and subspace-based algorithms with application to fault detection wireless sensor networks," *IEEE Trans. Instrumentation and Measurement*, vol. 61, no. 6, pp. 1703-1718, Jun. 2012.
- [43] M. Wu, L. Tan, and N. Xiong, "Data prediction, compression, and recovery in clustered wireless sensor networks for environmental monitoring applications," *Inf. Sci.*, vol. 329, pp. 800-818, 2016.
- [44] A. I. Moustapha and R. R. Selmic, "Wireless sensor network modeling using modified recurrent neural networks: Application to fault

- detection,” *IEEE Trans. Instrumentation and Measurement*, vol. 57, no. 5, pp. 981-988, May 2008.
- [45] S. Jia, L. Ma, and D. Qin, “Fault detection modelling and analysis in a wireless sensor network,” *J. Sensors*, vol. 2018, pp. 1-9, Oct. 2018.
- [46] S. Zidi, T. Moulahi, and B. Alaya, “Fault detection in wireless sensor networks through SVM classifier,” *IEEE Sensors J.*, vol. 18, no. 1, pp. 340-347, Jan. 2018.
- [47] C. Titouna, M. Aliouat, and M. Gueroui, “FDS: Fault detection scheme for wireless sensor networks,” *Wireless Pers. Commun.*, vol. 86, no. 2, pp. 549-562, Jan. 2016.
- [48] S. Mandal, B. Santhi, S. Sridhar, K. Vinolia, and P. Swaminathan, “Nuclear power plant thermocouple sensor-fault detection and classification using deep learning and generalized likelihood ratio test,” *IEEE Trans. Nuclear Sci.*, vol. 64, no. 6, pp. 1526-1534, Jun. 2017.
- [49] Y. Xiao, R. Feng, C. Leung, and J. Sum, “Objective function and learning algorithm for the general node fault situation,” *IEEE Trans. Neural Netw. and Learning Syst.*, vol. 27, no. 4, pp. 863-874, Apr. 2016.
- [50] H. Yu, P. D. Reiner, T. Xie, T. Bartczak, and B. M. Wilamowski, “An incremental design of radial basis function networks,” *IEEE Trans. Neural Netw. and Learning Syst.*, vol. 25, no. 10, pp. 1793-1803, Oct. 2014.
- [51] Z. Chai and C. Zhao, “Enhanced random forest with concurrent analysis of static and dynamic nodes for industrial fault classification,” *IEEE Trans. Ind. Informatics*, doi: 10.1109/TII.2019.2915559
- [52] X. Chen, “Tennessee eastman simulation dataset,” *IEEE Dataport*, 2019. [Online]. Available: <http://dx.doi.org/10.21227/4519-z502>. Accessed: Oct. 02, 2019.
- [53] H. Zhang, J. Liu, and N. Kato, “Threshold tuning-based wearable sensor fault detection for reliable medical monitoring using bayesian network model,” *IEEE Systems J.*, vol. 12, no. 2, pp. 1886-1896, Jun. 2018.
- [54] S. Suthaharan, M. Alzahrani, S. Rajasegarar, C. Leckie, and M. Palaniswami, “Labelled data collection for anomaly detection in wireless sensor networks,” *ICISSNIP*, pp. 269-274, Brisbane, Australia, Dec. 2010.
- [55] K. S. Narendra and K. Parthasarathy, “Neural networks and dynamical systems,” *Int. J. Approximate Reasoning*, vol. 6, no. 2, pp. 109-131, Feb. 1992.
- [56] Y. Cao, *A benchmark case for statistical process monitoring-Cranfield multiphase flow facility*, (2015). [Online]. Available: <http://uk.mathworks.com/matlabcentral/fileexchange/50938-a-benchmark-case-for-statistical-process-monitoring-cranfieldmultiphase-flow-facility>
- [57] *Physionet*, 2013. [Online]. Available: <http://www.physionet.org/cgi-bin/atm/ATM>.
- [58] A. Mehmood, Z. Lv, J. Lloret, and M. M. Umar, “ELDC: An artificial neural network based energy-efficient and robust routing scheme for pollution monitoring in WSNs,” *IEEE Trans. Emerging Topics in Computing*, doi: 10.1109/TETC.2017.2671847, Feb. 2017.
- [59] W. B. Heinzelman, A. P. Chandrakasan, and H. Balakrishnan, “An application-specific protocol architecture for wireless microsensor networks,” *IEEE Trans. Wireless Commun.*, vol. 1, no. 4, pp. 660-670, Oct. 2002.
- [60] O. Younis and S. Fahmy, “HEED: A hybrid, energy-efficient, distributed clustering approach for ad hoc sensor networks,” *IEEE Trans. Mob. Comput.*, vol. 3, no. 4, pp. 366-379, Dec. 2004.
- [61] Y. M. Lee, “Classification of node degree based on deep learning and routing method applied for virtual route assignment,” *Ad Hoc Netw.*, vol. 58, pp 70-85, Apr. 2017.
- [62] T. Clausen, C. Dearlove, P. Jacquet, and U. Herberg, “The optimized link state routing protocol version 2,” *Network Working Group RFC 7181*, Apr. 2014.
- [63] C. Perkins, E. Belding-Royer, and S. Das, “Ad hoc On-Demand Distance vector (AODV) routing,” *Network Working Group RFC 3561*, Jul. 2003.

- [64] J. H. Zygmunt, R. P. Marc, and P. Samar, "The zone routing protocol (ZRP) for ad hoc networks," *INTERNET DRAFT*, Jul. 2002.
- [65] S. Wang and Y. Shin, "Efficient routing protocol based on reinforcement learning for magnetic induction underwater sensor networks," *IEEE Access*, vol. 7, pp. 82027-82037, Jun. 2019.
- [66] S. Ahmed, N. Javaid, F. A. Khan, M. Y. Durrani, A. Ali, A. Shaukat, M. M. Sandhu, Z. A. Khan, and U. Qasim, "Co-UWSN: Cooperative energy-efcient protocol for underwater WSNs," *Int. J. Distrib. Sensor Netw.*, vol. 11, no. 4, pp. 116, Sep. 2015.
- [67] N. Javaid, T. Hafeez, Z.Wadud, N. Alrajeh, M. S. Alabed, and N. Guizani, "Establishing a cooperation-based and void node avoiding energy-efcient underwater WSN for a cloud," *IEEE Access*, vol. 5, pp. 11582-11593, Jul. 2017.
- [68] V. Di Valerio, F. L. Presti, C. Petrioli, L. Picari, D. Spaccini, and S. Basagni, "CARMA: Channel-aware reinforcement learning-based multi-path adaptive routing for underwater wireless sensor networks," *IEEE J. Sel. Areas in Commun.*, doi: 10.1109/JSAC.2019.2933968, pp. 1-14, Sep. 2019.
- [69] S. Basagni, C. Petrioli, R. Petrocchia, and D. Spaccini, "CARP: A Channel-aware routing protocol for underwater acoustic wireless networks," *Ad Hoc Netw.*, vol. 34, pp. 92-104, Nov. 2015.
- [70] T. Hu and Y. Fei, "QELAR: A machine-learning-based adaptive routing protocol for energy-efficient and lifetime-extended underwater sensor networks," *IEEE Trans. Mob. Comput.*, vol. 9, no. 6, pp. 796-809, Jun. 2010.
- [71] Z. Jin, Q. Zhao, and Y. Su, "RCAR: A reinforcement-learning-based routing protocol for congestion-avoided underwater acoustic sensor networks," *IEEE Sensors J.*, doi: 10.1109/JSEN.2019.2932126, pp. 1-11, Jul. 2019.
- [72] M. Molins and M. Stojanovic, "Slotted FAMA: a MAC protocol for underwater acoustic networks," *OCEANS 2006 - Asia Pacific*, pp. 1-7, Singapore, May 2006.
- [73] S. Kosunalp, Y. Chu, P. D. Mitchell, D. Grace, and T. Clarke, "Use of Q-learning approaches for practical medium access control in wireless sensor networks," *Eng. Appl. Artificial Intell.*, vol. 55, pp. 146-154, Oct. 2016.
- [74] I. Rhee, A. Warriar, M. Aia, J. Min, and M. L. Sichitiu, "Z-MAC: A hybrid MAC for wireless sensor networks," *IEEE/ACM Trans. Netw.*, vol. 16, no. 3, pp. 511-524, Jun. 2008.
- [75] C. Savaglio, P. Pace, G. Aloï, A. Liotta, and G. Fortino, "Lightweight reinforcement learning for energy efficient communications in wireless sensor networks," *IEEE Access*, vol. 7, pp. 29355-29364, Mar. 2019.
- [76] E. Nisioti and N. Thomos, "Robust coordinated reinforcement learning for MAC design in sensor networks," *IEEE J. Sel. Areas in Commun.*, vol. 37, no. 10, pp. 2211-2224, Oct. 2019.
- [77] G. Liva, "Graph-based analysis and optimization of contention resolution diversity slotted ALOHA," *IEEE Trans. Commun.*, vol. 59, no. 2, pp. 477-487, Feb. 2011.
- [78] I. Bouazzi, J. Bhar, and M. Atri, "Priority-based queuing and transmission rate management using a fuzzy logic controller in WSNs," *ICT Express*, vol. 3, no. 2, pp. 101-105, Jun. 2017,

김 승 환 (Seung-Hwan Kim)



2010년 8월 : 금오공과대학교 전  
자공학부 졸업  
2012년 8월 : 금오공과대학교 전  
자공학과 석사 졸업  
2018년 8월 : 금오공과대학교 전  
자공학과 박사 졸업  
2018년 8월~현재 : ICT융합특성  
화연구센터 전임연구원

<관심분야> 인지 무선 네트워크, 무선 센서 네트워크,  
인공신경망

[ORCID:0000-0002-4118-8703

**권 기 협 (Ki-Hyeob Kwon)**



2000년 2월 : 금오공대학교 전자공학부 학사 졸업  
2003년 2월 : 금오공대학교 전자공학부 석사 졸업  
2019년 8월 : 금오공과대학교 전자공학과 박사 졸업  
2014년 7월~현재 : ICT융합특성화연구센터 팀장

<관심분야> 머신러닝, 무선 센서 네트워크, 5G

**김 동 성 (Dong-Seong Kim)**



1992년 2월 : 한양대학교 전자공학과 졸업  
2003년 3월 : 서울대학교 전기 및 컴퓨터공학부 박사졸업  
2004년 : Cornell 대학교 ECE 박사 후 연구원  
2004년 3월~현재 : 금오공대 전자공학부 정교수

2019년~현재 : 금오공과대학교 산학협력단장  
2014년~현재 : ICT 융합특성화연구센터 센터장 (과기정통부 ITRC 및 연구재단 중점연구소)

2014년~현재 : IEEE/ACM Senior 회원

2015년~2018년 : 금오공대 융합기술원 원장

2016년 9월~현재 : 국방부 CIO 자문위원

<관심분야> 실시간 통신망 및 IoT 시스템, 네트워크 기반 분산제어시스템 시스템, 실시간 S/W

**김 재 우 (Jae-Woo Kim)**



2004년 2월 : 금오공과대학교 전자 공학과 학사 졸업  
2013년 8월 : 금오공과대학교 컴퓨터공학과 박사 졸업  
2014년~2018년 : (주)에이알텍 광통신 연구소 차장  
2018년~현재 : ICT융합특성화연구센터 연구교수

<관심분야> 광트랜시버, 이동통신, 임베디드 시스템