

# 디지털 농업을 위한 피드백 기반 스마트 관개 시스템

정민우\*, 강순주°

## Smart Irrigation System Based on Feedback for Digital Agriculture

Minwoo Jung\*, Soon Ju Kang°

요약

디지털 농업은 농업 현장에서 발생하는 현상을 디지털화하여 농업 활동의 편의성과 생산성을 향상시킬 수 있는 기술이다. 관개 시스템은 농업에서 가장 중요한 요소이다. 관개 시스템에 대한 자동화는 다양하게 진행되고 있다. 하지만, 대부분의 연구에서 초기 설정에 따라 확실적인 주기로 관개를 실행하기 때문에 관리자의 개입이 필요한 단점을 가진다. 본 연구는 기존 연구에서 발생했던 단점을 보완하기 위하여 실시간 토양 변화를 감지하여 머신러닝을 기반으로 토성을 분류할 수 있는 능동적인 스마트 관개 시스템을 제안한다. 능동적인 스마트 관개 시스템을 구축하기 위해서 토성 분석 기술과 소프트웨어 업데이트 기술이 필요하다. 토성 분류를 위해서 토양 변화에 대한 시계열 데이터를 기반으로 합성곱신경망, 순환신경망, 장단기 메모리와 같은 머신러닝 모델을 설계하였다. 또한, 토성 분류 결과를 원격지에 설치된 관개 제어기로 전송 및 수정할 수 있는 아키텍처를 제안한다. 머신러닝 모델을 평가하기 위해서 100회 반복하여 수행된 결과를 혼동행렬을 적용하여 신뢰성을 평가하였으며, 약 90%의 모델 신뢰성을 가지는 것을 확인하였다. 변경된 토성 분류 결과를 데이터베이스에서 관개 제어기로 전송하는 원격 시스템의 안정성을 검증하였다.

**Key Words** : Digital Agriculture, Irrigation System, Machine Learning, Soil Texture Classification, Smart Farm

### ABSTRACT

Digital agriculture is able to improve the convenience and productivity by digitalizing occurred event in agricultural process. The irrigation system is the most important element in agricultural process. There are various research on automation of irrigation system. Most of research have the disadvantage that administrator need to intervene to irrigate. In this work, we propose a smart irrigation system that can monitor agricultural environment and can decide irrigation period and irrigation time. Also, we design machine learning models base on time series data such as CNN, Simple RNN, LSTM to classified soil texture. Performance of the classification algorithm was evaluated using the confusion matrix, the classification performance was evaluated about 90%. In order to implement tiny machine learning on an embedded system in future work., we will consider Simple RNN that has the fewest parameters of them.

\* 본 연구는 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행되었습니다(No. NRF-2018R1D1A1B07041296).

° 본 연구는 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행되었습니다(No. NRF-2018R1A6A1A03025109).

• First Author : Center of Self-Organizing Software-Platform, Kyungpook National University, jungminwoo80@knu.ac.kr, 정희원

Corresponding Author : Department of Electronics, Kyungpook National University, sjkang@ee.knu.ac.kr, 종신희원

논문번호 : KICS2022-137-0-SE, Received June 28, 2022; Revised August 29, 2022; Accepted August 29, 2022

## 1. 서론

다양한 산업에서 디지털화가 활발하게 진행되면서, 농업 분야에서도 디지털 농업에 대한 연구가 다방면으로 연구되고 있다. 디지털 농업은 농업 현장에서 발생하는 경험적인 요인과 생산·유통·소비 등에서 발생하는 과정들을 디지털화하여 농업 활동의 편의성과 생산성을 향상시킬 수 있는 기술이다. 디지털 농업에 정보통신기술을 농업에 접목한 어그테크(Agtech)가 등장하면서 농업생명공학기술, 정밀농업, 대체식품, 식품 전자상거래 등 농업 분야에서 새로운 패러다임이 형성되고 있다.

정보통신기술이 농업 분야에 도입되면서, 시공간의 제약을 없앨 수 있는 스마트팜에 대한 관심이 급증하고 있다. 최근, 인공지능 기술이 스마트팜 분야에 도입되면서 혁신적인 스마트팜 솔루션들이 줄줄이 등장하여 비용 절감과 생산성 향상 효과를 가져오고 있다<sup>[1]</sup>. 그림 1은 IoT 기반 스마트팜 플랫폼을 보여주고 있다. 스마트팜 플랫폼은 원격지에 존재하는 농업시설에 배치된 다양한 센서를 통하여 농업 환경을 실시간 관측하며, 데이터 분석을 통해 원격지의 제어를 통하여 기반시설을 제어하는 기술이다. 현재, 스마트팜을 위한 대부분 솔루션은 온실 환경을 기반으로 연구되고 있다. 하지만, 현재의 농업은 대부분 노지에서 이루어지기 때문에, 사용자가 농업 환경의 제어를 하기 어렵다는 단점을 가진다. 또한, 온실 환경에서 스마트팜을 구축하기 위해서 노지 환경에서 최적의 조건을 분석하는 과정이 매우 중요하다. 스마트팜은 비용 절감과 생산성 향상이 목적이다. 스마트팜의 목적을 달성하기 위해서 최우선으로 고려해야 하는 농업

활동은 토양신정과 관개 계획 수립이다.

기존 관개시스템은 일반적으로 두 가지 농업 활동 과정을 가진다. 첫째, 환경 데이터를 분석하여 관개 계획을 수립하고, 수립된 계획에 따라 관리자가 개입하여 획일적인 관개 작업을 수행한다. 둘째, 자율 관개시스템은 초기에 설정된 관개 계획에 따라 획일적인 관개를 수행함으로써 비효율적인 작물 관리가 발생할 수 있기 때문에, 주기적인 관리자 개입이 필요하다는 단점을 가진다.

이러한 단점을 보완하기 위한 스마트 관개시스템은 환경 변화를 스스로 학습하여 능동적으로 제어한다. 스마트 관개시스템을 구축함으로써 시스템의 효율성과 신뢰성을 개선할 수 있다. 스마트 관개시스템의 핵심은 작물 생육에 필요한 수분과 영양분의 함량을 정밀하게 제어할 수 있는 능동형 관개시스템을 구축하는 것이다. 스마트 관개시스템은 작물 생육에 필요한 수분을 정확하게 투입하는 정밀농업으로 분류할 수 있다. 스마트 관개시스템이 효율적으로 구축되기 위해서 작물 상태와 토양의 성질과 주변 환경에 따라 적절한 관개 시점(Timing)과 관개 시간(Duration)이 결정해야 한다. 따라서, 스마트 관개시스템을 구축하기 위해서 정확히 토양 상태를 분석하는 것이 매우 중요하다. 토양 상태를 분석하는 과정에서 토성(Soil texture)은 농업 계획 수립단계에서 작물 재배의 적합도 및 관개 계획을 판단할 수 있는 중요한 요소이다. 토양은 흙의 알갱이 크기에 따라 모래, 미사, 점토로 나누어지며, 알갱이들의 혼합비율에 따라 12가지로 구분하여 붙여진 이름을 토성이라 정의한다. 이러한 토성 분류를 위해서 전문적인 지식이나 장기적인 실험이 필요하다는 단점을 가지고 있다. 이러한 단점을 보완하기 위해서 수분 센서를 이용하여 토양 수분 함량의 변화를 기반으로 토성을 분류할 수 있다.

본 논문에서는 스마트 관개 시스템을 구축하기 위해서 정확한 관개 주기와 관개 시간들을 능동적으로 결정하고, 머신러닝 기반 토성 분류 알고리즘을 구현하였다. 토성 분류 알고리즘은 기존 토성 분류와 달리 수분함량의 변화 데이터를 기반으로 간단하게 구현하였다.

본 논문의 구성은 다음과 같다. 2장에서 관개시스템과 관련된 연구에 대해서 살펴보고, 3장에서 제안하는 스마트 관개시스템에 대해서 설명한다. 4장에서 실험결과를 분석하고, 5장에서 결론 및 향후 연구에 대해서 기술한다.

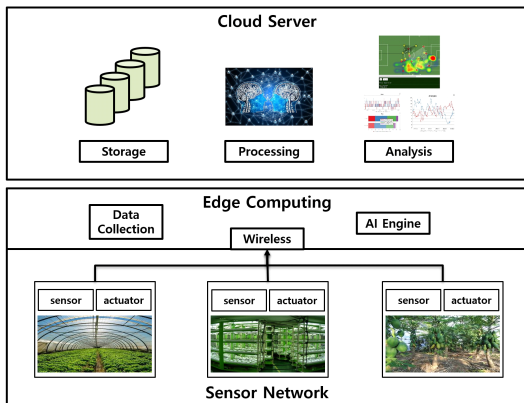


그림 1. IoT 기반 스마트팜 플랫폼 구성  
Fig. 1. Smart Farm Platform based on IoT

## II. 관련 연구

기존 연구들은 토양 상태를 고려하지 않고, 획일적인 관개 시스템을 구축하여 효율적인 작물관리가 어려운 단점을 가지고 있다. 경작지 내 구역마다 토양의 수분함량이 다르게 나타나기 때문에, 인접한 거리에서 수확량이 5배 이상 차이 나는 경우도 발생한다<sup>21</sup>. 이러한 문제를 극복하기 위해서 관리 구역을 지정하고, 구역별 특성에 따라 관개 주기(Period)와 시간을 다르게 설정하여 관개 효율성을 향상시키는 연구가 진행되었다<sup>3,41</sup>. 또한, 관리구역에 대한 토양, 식생 지수, 논리 클러스터링 방법론에 대한 연구도 함께 진행되었다<sup>5-7</sup>. 관리구역에 대한 연구는 잘 정립된 기술이지만, 대부분 농업 환경을 모니터링하는 기술을 다루고 있다. 스마트 관개 시스템을 구축하기 위해서 피드백 기반 능동적이고, 정밀한 제어시스템이 필요하다. 능동적 제어시스템은 적절한 양의 물을 전달하기 위해서 폐쇄회로 루프 제어 시스템을 활용하여 가변 관개 시스템을 활용한다<sup>8</sup>. 가변 관개 기술은 투입되는 수분 양을 동적으로 최적화 할 수 있으며, 관리 구역에 따라 관개 요구사항을 다르게 결정할 수 있다. 이 연구에서 위성을 활용하여 수분함량을 측정하기 때문에 농업환경에서 범용적으로 적용하기 어렵다. 또한, 토양의 상태를 고려하지 않고, 단순히 수분함량을 기반으로 관리되기 때문에, 환경 변수에 대한 대응이 어렵다는 단점을 가지고 있다.

최근, 사물인터넷 기반 정밀 농업에 대한 연구들이 활발히 진행되고 있다. 무선센서네트워크를 기반으로 토양 센서 정보(수분, 온도)를 수집하여 관개 계획을 수립하고, 갱신하는 임베디드 시스템을 연구하고 있다<sup>9, 10</sup>. 또한, 스마트폰을 활용하여 작물의 생육환경을 이미지화하여 실시간 모니터링하고, 와이파이 기반으로 워터펌프와 통신하여 관개 시스템을 제어하는 임베디드 플랫폼에 대한 연구도 진행되고 있다<sup>11</sup>. 머신러닝에 대한 관심이 고조되면서 농업 분야에서도 머신러닝 기술을 활용한 다양한 솔루션이 등장하고 있다. 기존에 센서로부터 수집된 토양 환경 데이터를 기반으로 회귀모델을 기반으로 머신러닝 알고리즘을 구현하는 연구가 진행되고 있다<sup>12</sup>. 열화상 센서를 이용하여 토양의 온습도를 측정하여 클라우드를 기반으로 실시간 스마트 관개 시스템을 제어할 수 있는 기술도 연구되고 있다<sup>13</sup>. 머신러닝을 이용하여 실시간으로 토양 습도 변화를 예측할 수 있는 알고리즘을 기반으로 관개 시스템을 제어하는 연구를 진행하고 있다<sup>14, 15</sup>. 토양의 샘플을 채취하여 이미지를 이용한 머신러

닝 기반 토성 분류 알고리즘을 제안하고 있다<sup>16</sup>. 앞에서 설명한 연구들은 대부분 제어 기술을 포함하지 않은 측정기술에 국한되어 있기 때문에, 능동적인 제어가 아닌 사람의 개입이 필요하다. 또한, 이미지를 이용한 머신러닝 기법을 사용하여 자원을 지나치게 많이 필요로 하는 단점을 가진다.

본 논문에서는 실시간으로 토양의 상태를 파악하여 적절한 시기에 적절한 양의 수분을 공급할 수 있는 폐쇄루프제어 알고리즘과 주기적인 토성 분석을 통하여 머신러닝 기반 토성 분류 알고리즘을 제안한다. 향후 관리 구역에 대한 연구를 진행하기 위해서 가변 관개와 토성 분류에 대한 연구는 반드시 필요하다. 노지 환경에서 토양은 구역마다 일조량과 수분함량이 다르기 때문에 토성도 다를 수 있다. 따라서, 구역마다 다른 관개 주기와 시간을 제공할 수 있는 관개 시스템이 필요하다. 본 연구의 가변 관개 시스템은 완전한 자동화와 토성에 따른 관개 일정을 능동적으로 수정할 수 있는 최적의 솔루션으로 제공된다. 또한, 많은 관개 시스템에 대한 연구를 다루고 있지만, 영양분 공급을 고려한 연구는 미흡한 실정이다.

## III. 스마트 관개시스템

### 3.1 시스템 아키텍처

제안하는 스마트 관개 시스템은 다양한 센서와 제어로 구성된 센서 계층, 센서 네트워크 관리와 데이터 수집을 위한 엣지 계층, 데이터 저장 및 분석을 위한 서버 계층으로 구성된다. 스마트 관개 시스템은 그림 2와 같이 센서 계층과 전체 시스템에서 이중 폐쇄루프제어 시스템으로 구성된다. 센서는 온도(T), 습도(H), 영양분(NPK), 전기전도성(EC), 산성도(pH)를 사용하였다. 센서 계층은 토양 센서 정보를 기반으로 수분과 영양분을 공급하는 폐쇄루프제어(Closed Loop Control) 시스템을 구축하였다. 토양의 수분함량을 기준으로 목표치 이하일 때, 솔레노이드 밸브를 활성화하여 관개 시간 동안 수분을 공급한다. 일정 지연시간이 지난 후 토양의 수분함량을 측정하여 목표치를 기준으로 관개 지속 여부를 결정한다. 영양분 공급 시스템도 수분공급과 동일한 폐쇄루프제어 시스템으로 동작한다. 영양분 변화를 관찰하기 위해서 전기전도성의 특성 변화를 실시간으로 관측하여 활용한다. 토양에 대한 데이터를 장기적으로 수집하여 토양의 수분함량 데이터를 기반으로 토성을 분류한다. 서버에서 분류된 토성에 대한 정보를 엣지 계층으로 전송하여 관개 계획을 수정한다. 앞에서 설명한 일련의 피드백 기반 제

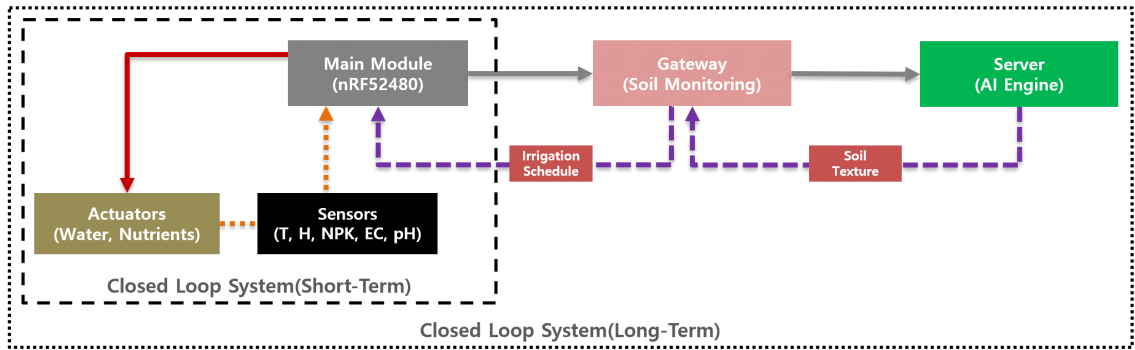


그림 2. 스마트 관개시스템 아키텍처  
Fig. 2. Smart Irrigation System Architecture

어시시스템을 통하여 스마트 관개 시스템을 구축할 수 있다. 서버로부터 제공되는 토성 정보의 피드백과 관개 스케줄 갱신에 대한 내용은 향후 연구에서 다룰 예정이다.

3.1.1 센서 계층

센서 계층은 토양 상태분석을 위한 다양한 토양 센서와 수분 및 영양분을 공급하기 위한 제어기로 구성되어 있다. 또한, 센서와 액추에이터 동작의 신뢰성을 확보하기 위한 관개 제어기(End Device)가 존재한다. 단일 관개 제어기는 RS-485 통신을 통해 4개의 토양 센서와 1개의 액추에이터를 연결할 수 있다. 토양 센서는 그림 3과 같이 온도, 산성도, 전기전도도, 영양분을 측정하는 센서로 구성되어 있다. 액추에이터는 수분공급을 제어하기 위해서 릴레이와 함께 솔레노이드 밸브를 장착하였다. 관개 제어기의 마이크로컨트롤러는 노르딕사의 nRF52840을 사용하였다. 탑재된 nRF52840은 블루투스 스택이 내장되어 있어서 별도의 블루투스 모듈 설치가 필요 없다. 멀티태스킹을 위해서 자체적으로 구현한 유비노스 운영체제를 탑재하

였다. 관개시스템은 수분과 영양분을 함께 공급하기 위해서 벤츄리를 사용하였다. 벤츄리는 수분이 공급되는 과정에서 좁은 통로를 통과하면서 진공이 발생하여 영양분을 함께 공급할 수 있는 장치이다. 관개 제어기의 기구부는 노지에 설치하였을 때, 방수가 가능한 수밀구조로 설계하였다. 향후 시스템의 최적화를 통하여 배터리 전원을 활용할 수 있도록 설계하였다.

3.1.2 엣지 계층

엣지 계층은 다수의 관개 제어기를 관리하고, 수집된 데이터를 변환하여 서버로 전송하는 기능을 한다. 엣지 계층은 BLE와 WiFi 모듈을 내장한 통신 기반 게이트웨이를 설치하였다. 게이트웨이는 주기적으로 BLE를 통하여 주변에 연결 가능한 관개 제어기를 검색한다. BLE 연결 프로토콜에 따라 게이트웨이와 관개 제어기가 연결되면, 토양 데이터 전송을 시작한다. 게이트웨이로 전송된 데이터는 파싱되고, 서버로 전송하기 위한 MQTT 메시지 구조체로 변환한다. 그림 4는 게이트웨이의 내부와 전체 모습을 보여주고 있다. 220V 상시전원을 사용할 수 있도록 플러그 타입으로




그림 3. 관개 제어기  
Fig. 3. Irrigation Controller



그림 4. 게이트웨이  
Fig. 4. Gateway

설계되었다. 향후 연구에서 임베디드기반 머신러닝을 구현하기 위해서 전원과 성능에 대한 리소스를 고려하여 설계하였다. 또한, 농업 환경에서 발생하는 이벤트를 음성으로 알려줄 수 있는 마이크와 도난에 대한 움직임을 감지할 수 있는 적외선 센서도 장착되어 있다.

### 3.1.3 서버 계층

서버 계층은 MQTT 브로커와 데이터베이스로 구성된다. MQTT 브로커는 원격지에 존재하는 게이트웨이로부터 전송되는 데이터를 메시지큐(Message Queue)에 저장하고, 수집된 데이터를 데이터베이스에 접근하여 저장한다. 데이터베이스는 MySQL을 기반으로 작성되었다. 토양 데이터를 기반으로 구축된 데이터베이스를 이용하여 토성 분류를 위한 머신러닝 알고리즘을 구현하였다. 머신러닝은 파이썬을 위한 딥러닝 프레임워크인 케라스를 사용하였다. 시공간 제약 없이 데이터를 확인할 수 있도록 아파치 HTTP 웹서버를 구축하고, 구축된 웹서버를 기반으로 PHPChart를 이용하여 GUI를 구현하였다. 그림 5는 웹서버를 기반으로 구현된 GUI를 보여주고 있다.




그림 5. 웹서버 기반 GUI  
Fig. 5. GUI based on Web Server

### 3.2 관개제어시스템

관개 제어기는 수분함량을 주기적으로 관찰하여 목표치 이하일 때, 정해진 관개 시간 동안 수분을 공급한다. 수분을 1회 공급한 후, 토양 수분 센서가 인식하기 위한 대기시간을 가진다. 대기시간 이후에 다시 수분함량을 관찰하여 목표치 이하일 경우 다시 수분을 공급한다. 관개 제어기와 토양 센서는 RS-485 통신으로 1:N 네트워크를 구축한다. 토양 센서는 개별 ID를 가지고 있으며, 정해진 주기마다 순차적으로 토양 센서 정보를 관개 제어기로 전송한다. 정해진 목표 수분함량을 제어하기 위해서, 관개 제어기는 센서와 액추에이터를 통한 폐쇄루프제어 시스템으로 구성한다. 정확한 제어를 하기 위해서 관개 제어기와 액추에이터

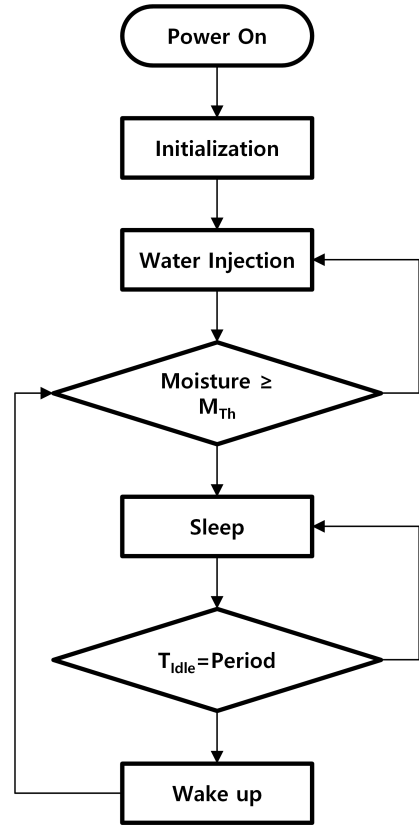


그림 6. 관개 제어기 흐름도  
Fig. 6. Irrigation Controller Flowchart

사이에 릴레이를 장착하여 제어하였다. 관개 제어기의 오동작을 분석하기 위해서 예외 처리 코드를 추가하였다.

그림 6은 관개 제어기의 흐름도를 보여주고 있다. 관개 제어기는 시스템 전원이 인가되면, 입출력 인터페이스, 센서, 솔레노이드 밸브를 초기화한다. 솔레노이드 밸브의 초기화가 진행되면, 정해진 시간 동안 수분을 공급한다. 초기화가 완료되면 토양센서는 정해진 주기마다 토양 정보를 센싱하고, 액추에이터를 위한 태스크는 유휴 모드로 진입하여 대기한다. 정해진 관개 주기에 관수 제어기에서 태스크가 활성화되어 목표 수분과 현재 수분 상태를 비교한다. 현재 수분 상태가 목표 수분 이하이면 정해진 관개 시간 동안 작동한다. 이러한 과정을 반복하여 실행한다.

### 3.3 토성분류알고리즘

토성에 따라 토양의 수분함량 변화가 다른 특징을 가진다. 토성 분류 알고리즘은 서버에 저장되는 장기적인 수분함량 데이터를 머신러닝 기반으로 시계열

분석한다. 토양 수분의 완전 증발되는 시간은 장시간 관측을 요구한다. 이러한 문제점을 보완하여 단시간 동안 축적된 토양 수분함량의 변화를 기반으로 미래 특정 시점에서 수분함량의 예측치를 추정하는 머신러닝 알고리즘을 구현하였다. 수분함량의 예측치를 기반으로 토성 분류 알고리즘을 구현하였다. 토성의 종류는 점토, 모래, 미사를 실험군으로 하였다.

### 3.3.1 전처리 알고리즘

초기 수분함량은 센서 장착 위치와 토양의 상태에 따라 다르게 나타나기 때문에 토양의 수분함량에 대한 절대값을 기준으로 분류하기 어렵다. 또한, 그림 7에서 살펴볼 수 있듯이 수분이 공급된 직후 수분함량이 급격히 변화하기 때문에 안정화 시간이 필요하다. 이러한 문제를 해결하기 위해서 데이터의 이상치 제거나 정규화와 같은 데이터 전처리 과정이 필요하다. 데이터 전처리는 머신러닝 모델의 성능을 좌우하는 중요한 과정이다.

데이터 정규화는 머신러닝에서 매우 중요한 부분이다. 일반적으로 특성 스케일링 또는 데이터 스케일링이라고 부른다. 데이터 정규화는 일반적으로 최대-최소 정규화, Z-점수 정규화, 표준 정규화를 사용한다. 최대-최소 정규화는 이상치(outlier)에 많은 영향을 받는다는 단점을 가지고 있다. 이러한 단점을 보완하기 위해서 Z-점수 정규화를 사용한다. Z-점수 정규화는 특정 값과 평균의 차이에 표준편차로 나누어준 값이다. 데이터가 평균과 일치하면 0으로 정규화 되고, 평균보다 작으면 음수, 평균보다 크면 양수를 나타낸다. 음수와 양수의 크기는 표준편차에 의해서 결정된다. 우선, 이상치 제거하기 위해서 토양 수분 함량의 변화를 정규화하였다. 정규화는 데이터와 평균을 기준으로

데이터의 분포 정도를 파악할 수 있다. 수식1을 기반으로 토양 수분 함량의 변화를 정규화하였다.

$$Z = \frac{X_i - \mu}{\sigma} \tag{1}$$

$X_i$ 는 토양 습도,  $\mu$ 는 토양 습도 평균,  $\sigma$ 는 표준편차를 나타낸다. 정규화 된 데이터는 이상치 제거를 위해서 사분위구간(Interquartile Range, IQR)으로 분류한다. 사분위 구간은 전체 데이터 값을 순서대로 정렬하여 구간을 분할하는 방식이다. 전체 데이터는 4개의 영역으로 분할하기 위해서 Q1(25%), Q3(75%) 지점을 추출하여 두 지점의 차이를 IQR으로 정의한다. 상한선(Upper boundary)과 하한선(Lower boundary)을 Q1, Q3를 기준으로 정하고, 영역 밖에 존재하는 데이터를 제거한다.

### 3.3.2 분류 알고리즘

전처리 과정을 통해서 출력된 데이터는 효율적인 예측을 위해서 훈련(70%), 검증(20%), 평가(10%) 데이터로 구분한다. 시계열 데이터는 시간 축을 유지하는 것이 중요하기 때문에 임의로 셔플되지 않는 순차적인 분할을 하였다. 전체 데이터를 학습에 사용하면 과대적합(Overfit)이 발생하기 때문에, 검증과 평가 데이터는 학습에 사용하지 않는다. 시계열 데이터를 위한 머신러닝 모델은 연속된 샘플창을 기반으로 슬라이딩 윈도우 기법을 이용하여 일련의 예측을 수행한다. 입력창은 입력 및 레이블 창의 너비, 시간 오프셋과 같은 특성을 가진다. 슬라이딩 윈도우 기법은 배열이나 리스트 요소의 특정 범위 값을 비교할 때 사용된다.

시계열 예측 구조는 일반적으로 단일 스텝 모델과 다중 스텝 모델로 구분된다. 단일 스텝 모델은 현재 조건을 기준으로 미래의 단일 타임 스텝을 예측한다. 다중 스텝 모델은 현재 조건을 기반으로 미래의 일정 범위의 타임 스텝을 예측한다. 다중 스텝의 일반적인 기법은 직접법(Direct multi-step), 재귀법(Recursive multi-step), 싱글샷(Multiple output) 등이 있다. 본 연구에서는 입력 데이터를 기반으로 미래의 수분함량 변화를 예측하기 위해서 다중 스텝 기법 중에서 재귀법을 이용하여 모델을 구현한다. 재귀법은 단일 타임 스텝을 확장하여 다중 스텝 모델로 예측하는 기법이다. 직전 타임 스텝의 예측값을 다음 타임 스텝 값을 예측하기 위한 입력값으로 사용한다.

시계열 예측을 위해서 일반적으로 사용되는 합성곱 신경망(Convolution Neural Network, CNN)과 순환

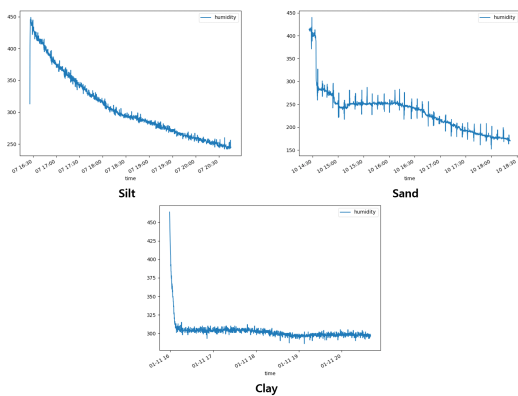


그림 7. 토성별 수분함량의 원시데이터  
Fig. 7. Moisture Content toward Soil Texture

신경망(Recurrent Neural Network, RNN)을 구현한다. 합성곱 신경망은 일반적으로 이미지 분류에서 활용되고 있다. 시계열 예측을 위해서 1차원 합성곱 신경망을 활용한다. 1차원 합성곱은 합성곱을 위한 커널과 적용하는 데이터가 1차원 시퀀스 모양을 가진다. 순환신경망은 시계열 데이터와 같이 시간 흐름에 따라 변화하는 데이터를 학습하기 위해서 많이 사용된다. 순환신경망의 특징은 과거의 출력 데이터를 재귀적으로 참조하는 것이다. 하지만, 입력과 출력 사이의 계층이 깊어지면 장기 의존성 문제가 발생하여 정확도가 떨어지는 단점을 가진다. 이러한 문제를 보완하기 위해서 장단기 메모리(Long Short Term Memory, LSTM) 알고리즘이 등장하였다. LSTM은 장기의존성 문제를 해결하기 위해서 메모리 셀을 두어 단기 상태와 장기 상태를 저장하여 참조한다. 메모리 셀은 장기의존성 문제 이외에도 학습 또한 빠르게 수렴할 수 있게 해준다. 성능 비교를 위해서 앞에서 설명한 3가지 모델을 설계하였다.

예측 모델에서 출력된 데이터를 기반으로 토성을 분류하였다. 분류를 위해서 구분할 수 있는 결정 경계(Decision Boundary)는 중요한 요소이다. 설계된 모델을 기반으로 100회 반복하여 학습된 결과를 수집하여 최대·최소 값을 기반으로 토성을 구분할 수 있는 결정 경계를 결정하였다. 수분함량에 대한 데이터는 선형 분리 가능한 패턴으로 형성되었다. 분류를 위해 다양한 시계열 데이터를 입력하고, 예측값에 따라 3가지 토성으로 구분되는 구조로 설계하였다.

#### IV. 실험 결과

##### 4.1 관개제어시스템

그림 8과 같이 관개 제어기는 실내와 실외로 구분하여 설치하였다. 실내는 파파야 나무가 심어진 화분에 설치하였으며, 실외는 팔공산 전원주택 정원에 설치하였다. 실외에 설치된 관개 제어기는 장시간 정상적으로 작동하는 것을 확인하였으며, 강우 상황에서 방수가 잘 되는 것을 확인하였다. 관개 제어기와 실내에 설치된 게이트웨이는 10m 이상 거리에서 정상적으로 블루투스 통신을 하였다. 실외에 설치한 관개 제어기는 토양 데이터의 수집과 시스템 안정성을 확인하였다. 그림 9에서 보듯이, 실외에서 온도 상승과 함께 수분함량이 선형적으로 감소하는 현상을 확인할 수 있다. 강수 상황에서 토양의 수분이 급격히 상승하면서 영양분이 활성화되어 NPK 센서의 데이터가 급격히 증가하는 것을 확인할 수 있다. 영양분을 센싱



그림 8. 관개 제어기 설치  
Fig. 8. Installation of Irrigation Controller in Outdoor

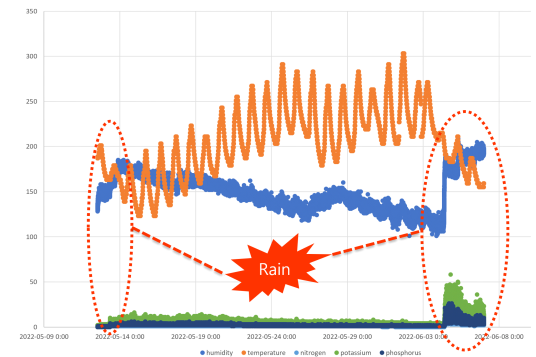


그림 9. 실외 토양 데이터  
Fig. 9. Outside Soil Data

하기 위해서 충분한 수분이 필요하다는 것을 확인할 수 있다. 실내환경에서 관개 주기는 8시간, 관개 시간은 10초로 설정하였다. 관개 주기를 짧게 설정하면, 수분이 배수되는 시간이 짧아서 뿌리가 썩는 현상이 발생하기 때문에 충분한 관개 주기가 필요하다. 관개 주기를 위한 태스크는 8시간 동안 슬립모드로 대기 후 wakeup되어 조건을 비교하여 동작한다. 목표 수분은 50%로 설정하였으며, 목표 수분 이하일 때 관개 시간 동안 물을 공급한다. 물을 공급하고 휴 속으로

흡수되어 센서가 인식할 수 있도록 대기시간을 30초로 설정하였다. 대기시간 후 수분을 모니터링하여 목표 수분 이하이면, 다시 관개 시간 동안 수분을 공급한다. 소프트웨어의 오작동이 발생하는 경우 리셋되도록 설계되었다. 관개 시스템에 대한 성능은 시스템이 정해진 주기로 수분함량의 목표치에서 정확하게 동작하여 변화된 데이터가 서버로 전송되는 것을 확인하였다.

그림 10은 관개 시스템을 통해서 서버에 저장된 데이터를 보여주고 있다. 목표 수분 이하에서 주기적으로 수분을 공급하는 것을 확인할 수 있었으며, 오동작도 간헐적으로 발생하였다. 오동작은 불안정한 통신 상태가 원인으로 파악되었다. 실내와 실외의 수분함량이 다르게 나타나는 것을 확인할 수 있었으며, 그림 12와 같이 실내 환경에서 수분공급 후 화분에서 유지하고 있는 수분함량 때문에 온도가 상승할 때, 토양의 습도가 함께 상승하는 것을 확인할 수 있다. NPK 센서의 데이터를 기반으로 영양분의 함량을 확인하였다. 영양분이 감소하는 구간에서 수분과 함께 영양분을 공




그림 10. 실내 토양 데이터  
Fig. 10. Inside Soil Data

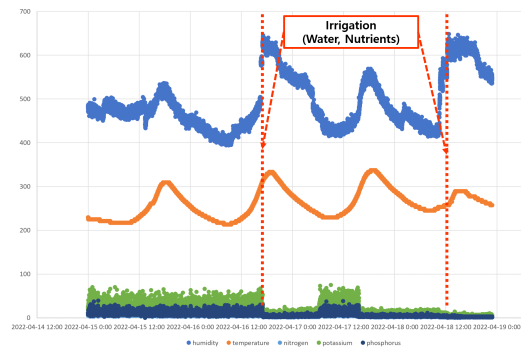


그림 11. 관개 시스템 성능검증  
Fig. 11. Performance Evaluation of Irrigation System




그림 12. 전처리를 통한 성능개선  
Fig. 12. Performance improvement with preprocessing

급하였다. 그림 11에서 보듯이 영양분을 공급하였을 때, 일정 시간 후 센서가 반응하는 것을 볼 수 있었다.

#### 4.2 토성분류알고리즘

이상치를 제거한 데이터를 모델에 적용하여 검증하였다. 검증모델은 시계열에서 일반적으로 가장 많이 사용하는 CNN, SimpleRNN, LSTM을 이용하였다. 그림 12는 이상치 제거 전후 예측값에 대한 평균오차율(Mean Absolute Error)을 관찰하였으며, 모든 모델에서 성능이 획기적으로 개선되는 것을 확인할 수 있다. Preprocessing은 전처리를 거친 데이터이며, Raw는 원시 데이터이다. V는 검증 데이터이며, T는 평가 데이터이다.

토성 분류를 위해서 3가지 토양을 용기에 준비하여 똑같은 조건에서 수분공급을 제어하여 데이터를 추출하였다. 분류모델 검증을 위해서 모델마다 혼동행렬을 기반으로 평가지표를 평가하였다. 혼동행렬의 평가지표는 정확도(Accuracy), 정밀도(Precision), 재현율(Recall), F1-Score가 대표적이다. 혼동행렬의 평가지표는 모두 장단점을 가지고 있다. 정확도는 전체 예측 결과에서 실제값과 예측값이 일치하는 비율을 나타내는 지표이다. 수식 2는 정확도를 구하기 위한 공식이다. 정확도는 부정의 확률이 너무 높은 상황에 대하여 제대로 분류하기 어려운 단점을 가지는데, 이러한 상황을 정확도 역설이라 한다.

$$A = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

정확도 역설을 보완해줄 수 있는 지표가 정밀도와 재현율이다. 재현율은 긍정 실제값을 긍정으로 예측한 비율을 나타낸다. 재현율은 부정 실제값에 대한 예측을 제공하지 않는다는 단점을 가진다. 수식 3은 재현율을 구하기 위한 공식이다.



표 1. 토성 분류 모델의 성능평가 결과  
Table 1. Result of performance evaluation for soil classification model

	CNN			SimpleRNN			LSTM		
	Clay	Silt	Sand	Clay	Silt	Sand	Clay	Silt	Sand
Accuracy	91%	95%	97%	87%	96%	96%	92%	99%	95%
Recall	90.4%	98%	91.3%	85.8%	98.4%	96.5%	91.8%	97.4%	90%
Precision	89.9%	83.3%	86.7%	85.3%	90.4%	88.5%	90.8%	99.5%	97.2%
F1	90.1%	89.2%	88.4%	85.6%	93.6%	93.2%	91.3%	98.4%	82.8%

$$R = \frac{TP}{TP+FN} \tag{3}$$

정밀도는 모델의 긍정(Positive) 예측값이 긍정 실제값과 일치하는 비율을 나타낸다. 정밀도는 부정 예측값의 신뢰성을 제공하지 않는다는 단점을 가진다. 수식 4는 정밀도를 구하기 위한 공식이다.

$$P = \frac{TP}{TP+FP} \tag{4}$$

재현율과 정밀도를 결합하여 F1-Score 분류 성능지표를 기반으로 평가를 수행한다. F1-Score는 정밀도와 재현율 사이에 트레이드오프(Trade-off)가 존재하기 때문에 한쪽으로 치우치지 않을 때, 높은 수치가 나타난다. 수식 5는 F1-Score를 구하기 위한 공식이다.

$$F_1 = 2 \times \frac{P \times R}{P+R} \tag{5}$$

분류모델 검증을 위해서 토성 3종류에 대한 2시간 측정된 데이터셋을 10개씩 준비하였다. 준비된 데이터를 100회 반복하여 혼동행렬의 평가지표에 따라 측정하였다. 예측을 위해 설계된 3가지 모델을 모두 검증하였다. 표 1은 토성 분류 모델의 성능평가 결과를 보여주고 있다. 모든 모델에서 대부분 정확도는 90% 이상 나타나고 있으며, 재현율과 정밀도의 상관관계를 나타내는 F1-Score도 85% 이상의 성능을 보여주고 있다.

### V. 결론

본 연구에서는 피드백 기반 스마트 관개 시스템을 제안하였다. 디지털 농업에 대한 연구가 활발히 진행되면서, 관개 시스템의 스마트화를 위한 연구들이 많

이 진행되고 있다. 특히, 사물인터넷 기반 스마트팜 시스템을 구축하여 작물 재배 능력을 향상시키기 위한 노력이 많이 이루어지고 있다. 스마트팜 연구는 대부분 온실 환경에 초점을 맞추고 있지만, 여전히 농업은 노지에서 이루어지는 경우가 많다. 또한, 온실에서 작물 생장에 대한 환경을 조성하기 위해서 노지에서 환경과 토양에 대한 데이터를 충분히 수집해야 한다. 본 연구는 노지 환경에서 토양의 데이터를 수집이 가능할 뿐 아니라, 머신러닝 기반으로 토성을 분류함으로써 작물과 토성의 적합도를 분석할 수 있는 시스템이다. 또한, 엣지 레벨에서 폐쇄루프제어 환경을 구축하여 정확한 시기에 수분 공급이 가능하며, 수분과 함께 영양분을 공급할 수 있는 구조로 설계되었다. 향후 연구에서 토성 분류 결과를 게이트웨이로 전송하여 관개스케줄을 자동으로 업데이트 할 수 있는 폐쇄루프를 구성할 것이다. 또한, 테스트베드를 확장하여 다수의 관개 제어기를 네트워크 형성하여 관리구역 연구를 위한 시스템을 구축할 것이다. 본 연구의 결과를 기반으로 농업환경에서 생성되는 아날로그 데이터의 디지털화와 시스템의 가상화를 통해서 최근에 각광 받고 있는 디지털 트윈 기술을 농업에 접목시킬 수 있을 것이다.

### References

[1] D. Seo, K. C. Kim, M. Lee, K. D. Kwon, and G. Kim, "Research on tomato flowers and fruits object detection model in greenhouse environment using deep learning," *J. KICS*, vol. 46, no. 11, pp. 2072-2077, 2021. (10.7840/kics.2021.46.11.2072)

[2] L. G. Santesteban, S. Guillaume, J. B. Royo, and B. Tisseyre, "Are precision agriculture tools and methods relevant at the whole-

- vineyard scale?," *Precision Agric.*, vol. 14, no. 1, pp. 2-17, 2013.  
(<https://doi.org/10.1007/s11119-012-9268-3>)
- [3] R. G. V. Bramley and R. P. Hamilton, "Understanding variability in winegrape production systems," *Australian J. Grape and Wine Res.*, vol. 10, no. 1, pp. 32-45, 2004.  
(<https://doi.org/10.1111/j.1755-0238.2004.tb00006.x>)
- [4] M. Pedroso, J. Taylor, B. Tisseyre, B. Charnomordic, and S. Guillaume, "A segmentation algorithm for the delineation of agricultural management zones," *Comput. and Electr. in Agric.*, vol. 70, no. 1, pp. 199-208, 2010.  
(<https://doi.org/10.1016/j.compag.2009.10.007>)
- [5] D. L. Corwin and S. M. Lesch, "Apparent soil electrical conductivity measurements in agriculture," *Comput. and Electr. in Agric.*, vol. 46, no. 1-3, pp. 11-43, 2005.  
(<https://doi.org/10.1016/j.compag.2004.10.005>)
- [6] A. Hall, D. W. Lamb, B. P. Holzapfel, and J. P. Louis, "Withinseason temporal variation in correlations between vineyard canopy and winegrape composition and yield," *Precision Agric.*, vol. 12, no. 1, pp. 103-117, 2011.  
(<https://doi.org/10.1007/s11119-010-9159-4>)
- [7] A. Tagarakis, V. Liakos, S. Fountas, S. Koundouras, and T. A. Gemtos, "Management zones delineation using fuzzy clustering techniques in grapevines," *Precision Agric.*, vol. 14, no. 1, pp. 18-39, 2013.  
(<https://doi.org/10.1007/s11119-012-9275-4>)
- [8] J. Klein, F. Hamann, N. Hinds, S. Guha, L. Sanchez, B. Sams, and N. Dokoozlian, "Closed loop controlled precision irrigation sensor network," *IEEE Internet of Things J.*, vol. 5, no. 6, pp. 4580-4588, 2018.  
(10.1109/JIOT.2018.2865527)
- [9] V. George, M. Tucker, C. Perry, C. Kvien, and C. Bednarz, "A real-time wireless smart sensor array for scheduling irrigation," *Comput. and Electr. in Agric.*, vol. 61, no. 1, pp. 44-50, 2008.  
(<https://doi.org/10.1016/j.compag.2007.05.009>)
- [10] G. Joaquín, J. F. Medina, A. Nieto-Garibay, and M. A. Porta-Gándara, "Automated irrigation system using a wireless sensor network and GPRS module," *IEEE Trans. Instrumentation and Meas.*, vol. 63, no. 1, pp. 166-176, 2013.  
(10.1109/TIM.2013.2276487)
- [11] J. G. Jagüey, J. F. Villa-Medina, A. López-Guzmán, and M. A. Porta-Gándara, "Smartphone irrigation sensor," *IEEE Sensors J.*, vol. 15, no. 9, pp. 5122-5127, 2015.  
(10.1109/JSEN.2015.2435516)
- [12] G. Anat, L. Fink, A. Meitin, S. Bohadana, O. Lutenberg, and G. Ravid, "Applying machine learning on sensor data for irrigation recommendations: Revealing the agronomist's tacit knowledge," *Precision Agric.*, vol. 19, no. 3, pp. 421-444, 2018.  
(<https://doi.org/10.1007/s11119-017-9527-4>)
- [13] R. Mehdi, P. Rad, and K. K. R. Choo, "Cloud of things in smart agriculture: Intelligent irrigation monitoring by thermal imaging," *IEEE Cloud Comput.*, vol. 4, no. 1, pp. 10-15, 2017.  
(10.1109/MCC.2017.5)
- [14] G. Amarendra, D. Sharma, A. K. Shukla, and C. R. Krishna, "An IoT based smart irrigation management system using machine learning and open source technologies," *Computers and Electr. in Agric.*, vol. 155, pp. 41-49, 2018.  
(<https://doi.org/10.1016/j.compag.2018.09.040>)
- [15] G. Amarendra, D. Sharma, A. K. Shukla, and C. R. Krishna, "Comparative study of regression models towards performance estimation in soil moisture prediction," in *Proc. Int. Conf. Advances in Comput. and Data Sci.*, pp. 309-316, 2018.  
(10.1007/978-981-13-1813-9\_31)
- [16] P. Srivastava, A. Shukla, and A. Bansal, "A comprehensive review on soil classification using deep learning and computer vision techniques," *Multimedia Tools Appl.*, vol. 80, pp. 14887-14914, 2021.  
(<https://doi.org/10.1007/s11042-021-10544-5>)

정 민 우 (Minwoo Jung)



2015년 2월: 경북대학교 전자  
공학과 박사

2015년 3월~2018년 5월: 경북  
IT융합산업기술원 선임연구  
원

2018년 6월~2021년 8월: 카네  
비컴 기술연구소 응용시스템  
팀 팀장

2021년 9월~현재: 경북대학교 자율군집소프트웨어  
연구센터 연구교수

<관심분야> 스마트팜, 사물인터넷, 디지털트윈, 실  
시간 시스템

[ORCID:000-0003-3013-6104]

강 순 주 (Soon Ju Kang)



1983년 2월: 경북대학교 전자  
공학과 학사

1985년 2월: 한국과학기술원  
(KAIST) 컴퓨터공학과 석사

1995년 2월: 한국과학기술원  
(KAIST) 컴퓨터공학과 박사

1895년~1996년: 한국원자력연  
구원(KAERI) 연구위원 겸 전산정보연구부장

1996년 3월~현재: 경북대학교 IT대학 교수

<관심분야> 실시간 임베디드 시스템, 홈 네트워크,  
스마트홈, 분산컴퓨팅

[ORCID:000-0002-8171-195X]