

농업기상 빅데이터를 활용한 스마트 식물병 관리

Smart Plant Disease Management Using Agrometeorological Big Data

*Corresponding author

Tel: +82-51-745-3980

Fax: +82-51-745-3949

E-mail: kh.kim@apcc21.org

ORCID

<https://orcid.org/0000-0003-3265-5899>

김광형^{1*} · 이준혁²

¹APEC 기후센터, ²(주)노트스퀘어

Kwang-Hyung Kim^{1*} and Junhyuk Lee²

¹APEC Climate Center, Busan 48058, Korea

²NoteSquare Inc., Seoul 03989, Korea

Climate change, increased extreme weather and climate events, and rapidly changing socio-economic environment threaten agriculture and thus food security of our society. Therefore, it is urgent to shift from conventional farming to smart agriculture using big data and artificial intelligence to secure sustainable growth. In order to efficiently manage plant diseases through smart agriculture, agricultural big data that can be utilized with various advanced technologies must be secured first. In this review, we will first learn about agrometeorological big data consisted of meteorological, environmental, and agricultural data that the plant pathology communities can contribute for smart plant disease management. We will then present each sequential components of the smart plant disease management, which are prediction, monitoring and diagnosis, control, prevention and risk management of plant diseases. This review will give us an appraisal of where we are at the moment, what has been prepared so far, what is lacking, and how to move forward for the preparation of smart plant disease management.

Keywords: Artificial intelligence, Big data, Climate change, Plant disease management, Smart agriculture

Received July 28, 2020

Revised August 19, 2020

Accepted August 24, 2020

스마트농업과 빅데이터

기후변화와 이상기후, 농산물 시장의 세계화, 그리고 급속도로 진행되는 고령화와 소수 농업화는 우리나라의 식량안보와 수출경쟁력을 위협하는 중요한 원인이 되고 있다(Jeon, 2011; Kim 등, 2010; Schmidhuber와 Tubiello, 2007). 하지만 더이상 기존 관행농업을 통해 국내 농업의 지속가능한 양적, 질적 성장을 확보하는 데 한계가 있기 때문에, 이를 해결하기 위한 농업의 4차 산업혁명, 즉 농업 4.0 (Agriculture 4.0)이 본격적으로 논의되고 있으며, 대표적으로는 농업 빅데이터를 활용한 스마

트농업이 활발하게 연구되고 있다(Rose와 Chilvers, 2018). 우리나라에서는 주로 시설원예를 중심으로 온습도, 광, 관개 등 재배 환경을 원격으로 자동제어하는 하드웨어 중심의 스마트팜 (smart farm)이 시도되고 있지만(Ahn과 Lee, 2015), 기후변화와 이상기후로 작물 재배환경이 수시로 변화되는 상황에서 생육에 미치는 부정적인 영향을 최소화하고 효율을 극대화하기 위해서는 빅데이터 기반의 의사결정지원을 포함한 소프트웨어적인 스마트농업(smart agriculture)으로 접근할 필요가 있다.

스마트농업은 농업 가치사슬 전반에 걸쳐 정보통신기술 (Information Communication Technology, ICT), 사물인터넷 (Internet of Things, IoT), 빅데이터(big data), 클라우드 컴퓨팅 (cloud computing), 인공지능(Artificial Intelligence, AI) 등의 신기술 접목을 통해 효율성과 효과성을 제고한다(Wolfert 등,

Research in Plant Disease

pISSN 1598-2262, eISSN 2233-9191

www.online-rpd.org

2017). 즉, 스마트농업은 첨단 신기술을 농작물 및 가축의 생육 환경에 접목하여 실시간 상태에 따라 요구되는 환경 제어(재배, 사육, 수확, 저장, 가공 등)를 통해 필요한 작업을 스스로 수행할 수 있는, 즉 자율제어가 가능한 농업을 이르는데, 최근엔 농업 가치사슬 내 농업 활동, 인적 자원 관리, 인력 배치, 자재 구매, 위험 관리, 저장, 물류, 유지 관리, 마케팅 및 생산성 예측을 단일 시스템으로 통합하여 관리하는 것으로 그 범위가 넓어지고 있다(Seo, 2016).

스마트농업에서는 IoT (사물에 센서를 부착해 데이터를 실시간으로 인터넷을 통해 주고받는 기술)를 통해 실시간으로 쏟아지는 데이터를 저장/관리/분석하기 위한 빅데이터 기술이 필수적이다. 빅데이터는 기존 데이터베이스와 관리도구로는 처리가 어려울 정도로 복잡하고 방대한 양의 데이터를 이르는데, 속도(velocity), 크기(volume), 다양성(variety)의 3V에 해당하는 모든 데이터를 빅데이터라고 하며(Coble 등, 2018), 크게 정형의 데이터(인덱싱 가능한 일반 데이터)와 비정형의 데이터(소리나 사진과 같이 쉽게 저장할 수 없는 데이터)로 나눌 수 있다. Stubbs (2016)에 의하면, 농업에서의 빅데이터는 데이터의 크기에 초점을 맞추기보다는 보다 효과적이고 효율적인 방식으로 정보를 처리하는 새로운 기술과 선진 분석기법의 조합으로 볼 수 있다. 즉, 작물과 가축의 재배와 사육, 가공, 판매 과정에서 생성되는 방대한 양과 다양한 종류의 데이터를 모두 포함할 수 있는데(Schönfeld 등, 2018; Wolfert 등, 2017), 예를 들어 기후, 환경, 토양 유형 및 작물의 영양상태, 지리정보, 비료량, 수확량 및 농작업 기록 등을 농업에서의 빅데이터로 볼 수 있다. 현재 빅데이터 기반 스마트농업은 농업의 새로운 패러다임으로 대두되고 있지만, 실제로 농업분야에서 수집되고 활용되는 제한된 양과 질의 데이터를 봤을 때 농업의 빅데이터 응용을 위해서는 데이터 관리 전반의 연구개발이 필요한 실정이다(Tantalaki 등, 2019).

빅데이터 분석을 통해 수많은 데이터의 상호 연관 관계를 발견하고 이를 활용할 수 있게 되면 농업에서의 다양한 의사결정을 지원할 수 있고 현재뿐만 아니라 미래의 농업을 위한 새로운 정보와 지식을 추출할 수 있게 된다. 실제 스마트농업에서 빅데이터 기술은 매우 중요한 역할을 수행하고 있다. 다양한 센서로부터의 모니터링 자료를 직접 활용하는 것에서부터 날씨 정보나 시장 가격과 같은 다른 빅데이터들과 유기적으로 결합하여 미래를 예측하는 알고리즘을 개발하는 등 다양한 기능을 수행한다. 이렇게 빅데이터로부터 유용한 정보를 수집/분석/활용하는 것이 빅데이터 분석법(big data analytics)이다. 빅데이터 분석법은 예측 분석, 데이터 마이닝, 통계, AI, 자연어 처리(인간 언어의 의미를 컴퓨터를 통해 이해하고 처리하기 위한 연구 분

야) 등 다양한 도구 유형의 모음이다. 그중 최근 몇 년간 전산 시스템, 특히 많은 자료를 빠른 속도로 처리할 수 있는 Graphical Processing Units (GPU) 프로세서의 성능(performance)이 향상되고, 이를 잘 활용하는 딥러닝(deep learning) 등의 머신러닝(machine learning) 알고리즘이 급속히 성장하였다(LeCun 등, 2015). 머신러닝은 기존 통계 모형에 비해 데이터 자체에 중점을 두고 특정 작업의 성능을 강조하는 방식인데, 식별과 감지, 분류, 정량화, 예측 분야에 활용이 되고 있다. 현재 딥러닝 기술은 이미지 인식(Cireşan 등, 2011; LeCun 등, 1998), 음성 인식(Hinton 등, 2012), 응용 분석(Ma 등, 2019) 등 복잡한 프로세스가 필요한 분야에서 활발한 연구가 되고 있는데, 지난 몇 년간 농업 분야에서는 식물병 진단이나 잡초 구분, 과실 성숙도 추정 등과 같이 이미지 인식 분야에서 주로 시도되고 있다(Carranza-Rojas 등, 2017; Ip 등 2018; Yang과 Guo, 2017).

스마트농업은 ICT, IoT, 클라우드 컴퓨팅, AI 등의 첨단기술에 농업 빅데이터가 접목된 결과이다. 농업분야에서는 이미 개발되어 있는 첨단기술들을 융합해 스마트농업에 활용할 수 있지만 농업 빅데이터 자체는 농업에서 각 분야의 전문성을 바탕으로 확보되고 활용 분야가 개척되어야 한다. 예를 들어, 식물병에 대한 전문성을 가진 식물병리학자를 중심으로 고품질의 필수적인 빅데이터가 수집/분석/활용이 되어야 영농 현장에 바로 적용가능한 스마트농업을 통한 식물병 관리가 가능하다. 따라서 본 리뷰에서는 스마트농업을 통한 식물병 관리, 즉 스마트식물병관리에 필수적인 농업기상(agricultural meteorology 또는 agrometeorology) 빅데이터에 대해 자세히 알아보려 한다. 다음으로 농업기상 빅데이터를 활용한 스마트식물병관리의 순차적 단계들, 즉 식물병의 예측, 모니터링 및 진단, 방제(control), 예방 및 위험관리에 대한 리뷰를 바탕으로 현재까지 스마트식물병관리를 위해 준비해온 것과 미흡했던 부분, 앞으로 나아가야 할 방향을 제시하고자 한다.

농업기상 빅데이터

농업기상 빅데이터(agrometeorological big data)는 농업 활동의 공간적 경계 내에 존재하는 기상환경(climate and environment) 빅데이터뿐만 아니라 이와 시공간적으로 연결된 재배, 작물, 주변 생물학적 생태계에 대한 농업(agriculture) 빅데이터를 모두 포함하는 개념이다. World Meteorological Organization (2010)이 총 6개로 나눈 농업기상 데이터 범주와 비교하면, (1) 기상과 (2) 토양 환경과 관련된 데이터를 기상환경 빅데이터에 포함시킬 수 있고, 그 외 (3) 환경에 대한 농업 생물체의 반응, (4) 재배 활동 및 관련 사회경제적 정보, (5) 농업재해의

Table 1. Agrometeorological big data required for the smart plant disease management

Collection methods	Climate and environment	Agriculture
Automated collection through sensors	Air temperature, dew point temperature, gas, humidity, leaf wetness, precipitation, wind speed/direction, light, solar radiation, vapor pressure, pan evapotranspiration Soil temperature, pH and moisture	Image sensor-based crop growth stage, leaf area, color, length, number of flowers or fruits, pest/disease signs or symptoms, planting space, etc. Farm equipment movement and application records Meta-data for location, time, duration, etc.
Automated collection through public or private database access	Weather observations from nearby weather stations, Weather/sub-seasonal/seasonal forecasts and typhoon/hail forecast from national met service or private companies	Real-time market information for supply, price, trade, etc. Disease monitoring and outbreaks, and management Remote sensing data from satellite, radar, drone, etc. Social media data Omics data for genome sequencing, transcriptome, etc.
Manual collection by information users	Regular analysis results for soil profile including nutrients, texture, or chemicals Weather and environment, data recorded by computer devices or on hardcopy books	Farming activities for planting, harvesting, weeding, pruning, irrigation, greenhouse controls, etc. Chemical applications for fertilizer, pesticides, herbicide, etc. Crop yields, pest/disease incidences, damages by abiotic stressors Crop variety, cropping pattern, etc. Images or farm account data recorded by app, computer devices or on hardcopy books
Manual collection by information providers	Historical data: climate observations and forecasts Soil profiles Climate change scenarios	Historical data (statistics) for farm environment and management, biotic/abiotic stresses, yield, cost/profit, market, land use change, etc.

영향, (6) 시공간적 분포 기록 데이터가 농업 빅데이터에 포함된다. 데이터 소스를 기준으로 기상, 통계 등과 같이 공공기관에서 제공하는 데이터뿐만 아니라 사용자에게 의해 농업 기계나 장치, 각종 센서를 통해 수집되는 데이터, 그리고 민간회사나 기관으로부터 제공받을 수 있는 데이터로 나눌 수 있다(Bronson과 Knezevic, 2016). 이 모든 데이터를 통합하여 의미 있는 정보로 가공하고 새로운 정보를 생성하는 것이 바로 빅데이터 분석 방법이다. 본 리뷰에서는 농업기상 빅데이터를 식물병과 연관된 기상, 토양, 식물, 병원균, 인간의 재배활동에 관한 데이터로 한정한다. 앞서 언급된 Stubbs (2016)의 정의에 따라, 방대한 크기의 데이터뿐만 아니라, 지속적이고 체계적인 수집과 관리를 통해 향후 빅데이터의 범주에 포함될 가능성이 있는 데이터, 그리고 이러한 빅데이터와 함께 의미 있는 정보를 생성할 수 있는 데이터도 함께 다루기로 한다. 또한 다양한 소스에서 수집되는 기상 및 환경정보 중 농업정보와 시공간적으로 연결이 가능하면서 농업적인 의미를 가진 경우에만 농업기상 빅데이터로 간주하여 다루었다(Table 1).

빅데이터는 기상기후와 토양환경에 대한 관측 및 예측정보를 포함한다. 기상환경 빅데이터는 수집하는 방법을 기반으로 4개 범주로 구분이 가능하다: 센서를 통한 자동수집(automated collection through sensors), 공공 또는 민간 데이터베이스 접속을 통한 자동수집(automated collection through public or private database access), 사용자에게 의한 수동수집(manual collection by information users), 그리고 서비스 제공자에게 의한 수동수집(manual collection by information providers). 우선 스마트농업 대상농지의 미세 기상환경(microclimate, 식물 캐노피 또는 온실 내 기온, 습도, 풍향, 풍속, 일사, 일조시수, 강수, 엽면수분, 토양수분, 토양 혹은 양액의 온도/양분/산도/전기전도도 등)은 대부분 자동 관측센서를 통해 수집되고, 대상농지를 포함한 주변지역의 매크로 기상환경(macroclimate, 경작지 주변의 기온, 습도, 풍향, 풍속, 일사, 일조시수, 강수, 토양정보 등)의 경우 직접 관측장비를 설치하여 자료를 수집하는 것도 가능하지만 우리나라의 경우 공공기관(기상청, 농진청 등)이나 민간회사의 웹기반 데이터베이스에 접근해 수집하는 것이 가능하다. 센서를 통한 자동 수집이 불가능한 데이터의 경우 정기적으로 사용자(농민)나 스마트농업 서비스 제

기상환경 빅데이터. 기상환경(Table 1의 Climate and en-

공사(공공기관 또는 민간회사)가 직접 기록하여 입력해야 한다. 이러한 종류의 기상환경 빅데이터는 정기적인 토양양분 분석, 실내외 가스성분 분석, 수동측정이 필요한 기상요소(서리, 우박 등) 관측 데이터와 지난 과거기간의 기후나 토양환경, 토지이용 등과 같이 디지털기록물로 저장되어 있는 데이터를 포함한다. 이러한 데이터들도 광범위한 지역에서 지속적으로 오랜기간 기록을 하게 되면 특정 시공간을 대표하는 값으로써 스마트식물병관리에 빅데이터로 활용이 가능하다.

식물병 관리에 중요한 일부 기상환경 데이터의 경우 특정 센서가 설치되지 않은 경우가 많기 때문에 가용한 데이터를 통해 추정하는 경우가 있다. 대표적인 예로 곰팡이와 세균 병의 병환에서 초기 감염기작에 중요한 요소인 엽습윤지속시간(leaf wetness duration, LWD)의 정확한 추정을 위해 다양한 모형이 개발되었는데 모형에 따라 다양한 기상 데이터가 입력값으로 활용된다(Rowlandson 등, 2015). Montone 등(2016)은 직접 LWD 센서로 관측된 값과 classification and regression tree (CART), dew point depression (DPD), number of hours with relative humidity equal or greater than 90% (NHRH $\geq 90\%$), 그리고 Penman-Monteith (P-M) 등 총 4개의 LWD 모형의 추정값을 비교평가하였는데 CART 모형이 가장 안정적인 결과를 나타냄을 보고하였다. NHRH는 가장 간단한 모형으로 상대습도만으로 LWD를 추정하는 반면, DPD는 기온과 이슬점온도로, CART는 상대습도, 기온, 이슬점온도, 풍속을 바탕으로 LWD를 추정한다. P-M은 잠열(latent heat flux)를 추정하는 물리 모형이기 때문에 순복사량과 지중열류량, 수증기압, 풍속, 기온 등 많은 기상요소를 입력값으로 사용하여 LWD를 추정한다. 저자들은 물리 모형인 P-M이 가장 성능이 좋지만 입력값의 정확도에 따라 LWD 추정값의 변동이 커서 실제 환경에서 활용도가 떨어진다고 하였다. 마찬가지로 기상환경 빅데이터의 활용은 센서의 정확성과 내구성에 크게 좌우되기 때문에 센서의 지속적인 유지보수 서비스가 확보되어야 하며, 민감도 테스트를 통해 어느 정도의 허용된 에러 범위 내에서 안정적인 결과를 낼 수 있는 빅데이터 분석법을 선택해야 할 필요가 있다.

농업 분야에서는 필지나 최소 행정구역 단위의 의사결정을 지원할 수 있기 위해 고해상도 격자(grid)로 된 기상환경 빅데이터를 필요로 한다. 현재 우리나라에 운영 중인 기상관측망은 지점에 대한 기상정보만을 제공하고 있기 때문에 내삽(interpolation)과 같은 가공과정을 거쳐 고해상도 격자 데이터를 생산한다. 대표적으로 Eum 등(2018)이 Improved GIS-based Regression Model (IGISRM) 기법으로 제작한 3 km 격자 해상도의 과거 1973-2018년간의 기온과 강수량 데이터(<http://adss.apcc21.org>)와 Kim 등(2012)이 Parameter-elevation Regres-

sion on Independent Slopes Model (PRISM) 기법으로 제작한 1 km 격자 해상도의 과거 11년(2000-2010)간 기온과 강수량 데이터(<http://www.climate.go.kr>)가 공공 웹사이트에서 다운로드 가능하다. 침입 식물병(invasive disease)과 같이 주요 농산물의 수출입국가에 대한 모니터링과 검역(quarantine)을 통한 식물병 관리를 위해서는 아시아 또는 글로벌 지역에 대한 기상환경 데이터를 필요로 한다. 그중 농업에서 활용가능한 대표적인 데이터로는 대부분의 아시아지역을 포함하는 APHRIDITE gridded dataset (<http://aphrodite.st.hirosaki-u.ac.jp/products.html>)이 기상관측정보를 기반으로 0.25° 격자(약 50 km)의 기온과 강수량 데이터를 제공하고 있으며, 기후 재분석모형(reanalysis model)으로 부터 생성된 기후데이터를 농업 분야에 활용할 수 있도록 편이보정(bias correction)한 AgMERR (<https://data.giss.nasa.gov/impacts/agmipcf/agmerra>)는 1980-2020년간의 전지구에 대한 0.25° 격자의 기온, 강수량, 일사량 데이터를 제공하고 있다(Ruane et al., 2015).

이러한 기상환경 빅데이터를 수집하고 활용하는 데 있어 주의할 점이 있다. 먼저 실시간 빅데이터 수집과 환경 제어를 위한 IoT 생태계 내에 보안 정책이나 기술적 솔루션이 부족하면 인터넷규약(IP) 주소 또는 링크 변경, 장치 캡처 공격과 같은 네트워크의 물리적 주소의 변조로 인한 데이터 손실이나 개인 정보 및 기타 민감한 지적 재산권에 대한 침해가 일어날 수 있고 때로는 사용자 특히 농장에 대한 정보 유출로 인해 경제적인 손실로 이어질 수 있다(Vashi 등, 2017). 또한 이렇게 농업 목적으로 대규모 IoT 센서 장치를 배포하면 ZigBee, Wi-Fi, Sigfox 및 LoRa와 같이 개방용 주파수를 사용하는 다른 IoT 장치와의 신호 간섭 문제가 발생할 수 있다(Polak과 Milos, 2020). 간섭 현상으로 인해 데이터 손실이나 주변 IoT 생태계의 안정성이 전반적으로 떨어질 수 있다. 영농 현장에 설치된 센서들은 외부에 노출되어 있거나 보안이 허술한 곳에 설치되어 있는 경우가 많기 때문에 특히나 주의를 기울여야 할 필요가 있다. 실외 환경에 설치된 IoT 센서는 동물이나 자연재해에 의한 물리적 손상이 일어나거나 열악한 환경 조건에 노출되어 통신 장애뿐만 아니라 시간이 지남에 따라 센서의 성능이 저하될 수 있다. 따라서 지속적인 스마트식물병관리의 운용을 위해서는 설치된 IoT 센서 및 의사결정 시스템의 물리적 또는 통신상의 안전을 보장하기 위한 장치가 함께 고려되어야 한다.

농업 빅데이터. 농업 빅데이터(Table 1의 Agriculture)는 이질성(heterogeneity)이 높다(Ishii, 2014; Li 등, 2014). 데이터의 이질성은 수집된 데이터의 대상(즉, 무엇에 대한 데이터인지) 및 데이터가 수집되는 방식에 기인한다. 따라서 영농 현장에서 수

집한 데이터는 일반적으로 세 가지 범주로 나눌 수 있다(Devlin, 2012; Hammer 등, 2017; United Nations Economic Commission for Europe, 2013): 프로세스 매개(Process-Mediated, PM) 데이터, 기계 생성(Machine-Generated, MG) 데이터, 그리고 인간 매개(Human-Sourced, HS) 데이터. PM 데이터와 HS 데이터는 주로 사용자나 서비스 제공자에 의한 수동수집(manual collection by information users and providers)을 통해 확보가 가능하지만 일부 데이터는 공공 또는 민간 데이터베이스 접속을 통한 자동수집으로 확보할 수 있다(Table 1). 반면, MG 데이터는 대부분 센서나 공공 또는 민간 데이터베이스 접속을 통한 자동수집(automated collection through sensors and public or private database access)이 가능한 데이터에 속한다.

PM 데이터는 자재 구매, 파종, 관개, 비료나 농약 살포, 수확, 저장, 판매 등과 같은 농업 전반의 활동들을 기록하고 모니터링하는 과정 중에 발생한다. PM 데이터는 일반적으로 구조화되어 있으며 해당 농업 활동을 시공간적으로 정의하는 메타데이터(meta-data)도 함께 포함한다. 기업농의 경우 이러한 경영 및 비용 관련 데이터들은 특정 관계형 정보통신 데이터베이스를 통해 관리가 되는 경우가 대부분이지만, 개인농의 경우 통일된 규격이 아닌 각자의 개인용 컴퓨터나 앱, 영농일지 등으로 관리하는 경우가 많아 해당 데이터를 활용하기 위해서는 추가적인 데이터의 가공이 필요하다. 좀더 공간적 규모가 큰 PM 데이터의 경우, 정부 차원에서 혹은 국제기구나 연구기관, 비정부기구(Non-governmental Organization) 주도로 수집이 되어 다양한 스마트농업 정책결정 및 지원사업에 활용이 된다. 각국 정부와 공공기관에서 매년 실시하는 농업조사(agricultural census)에는 작물의 생산량과 재배면적, 주요 농산물과 자재 가격 변동, 수출입 현황, 병해충을 포함한 농업재해 발생 현황 등의 빅데이터가 생산이 된다. 국제적으로는 세계식량기구(Food and Agriculture Organization, FAO)가 매년 생산하는 국가별 작물 생산량이나 시장가격 통계자료, 정기적으로 업데이트되는 토양이나 농업재해 자료 등이 있고(<http://www.fao.org/statistics>), 농업 분야 연구기관이나 비정부기구의 프로젝트를 통해 생산된 자료들과 함께 시민참여형과학(citizen science)과 같은 사용자 주도형 데이터 수집의 결과 역시 빅데이터로써 활용이 가능하다(Ryan 등, 2018). 최근 딥러닝 기술을 활용해 식물병 진단이 가능한 모바일 어플리케이션(mobile application)이 활용되고 있는데(e.g., Agrio, CropsAI, Plantix), 이 역시 사용자 주도형 데이터 수집을 통해 상상할 수 없을 정도로 많은 빅데이터가 축적이 되고 이를 통해 다시 이미지 진단 기술이 지속적으로 개선되는 양의 루프(positive loop) 현상이 일어나고 있다.

MG 데이터는 물리적인 농업 과정을 측정하고 기록하는 데

사용되는 사물 인터넷 센서와 스마트 기계 등을 통해 수집된다. MG 데이터는 간단한 센서 수집자료에서 복잡한 컴퓨터 로그에 이르기까지 다양하며 체계적으로 구조화되어 있다. 이렇게 구조화된 특성은 컴퓨터 처리에 적합하지만 기존 데이터처리 기술로는 처리가 불가능할 정도로 용량이 커지는 단점이 있다. 또한 센서가 급증하고 데이터 양이 증가함에 따라 저장 및 처리되는 데이터의 구성 요소가 점차 중요해지고 있는 추세이다. 식물병 관리에 사용되는 대표적인 MG 데이터는 열 화상(thermography), 엽록소 형광(chlorophyll fluorescence), 적외선(infrared), 또는 초분광(hyperspectral) 이미지 센서를 통해 수집된 식물의 전체 혹은 부분에 대한 시계열 데이터이다(Mahlein, 2016). 다양한 이미지 센서들을 통해 수집된 빅데이터는 기존 테이블로 표현되는 데이터뿐만 아니라 사운드 또는 이미지와 같은 형식의 데이터도 포함하는데(Sonka, 2015), 이러한 다양한 형식의 데이터를 사용하기 위한 최신 데이터분석법이 개발되고 있다(Noyes, 2014; Vogt, 2013).

좀더 넓은 범위의 매크로 데이터는 원격탐사(remote sensing)기법을 통해 수집한다. 적외선 카메라와 Global Positioning System (GPS) 기술을 갖춘 unmanned aerial vehicles를 이용해 재배 현장의 다양한 적외선 이미지를 촬영하여 작물의 건강과 관련된 변화를 감지하는 것이 가능하다. 예를 들어 이미지 반사, 반사에 따른 잎의 색, 수분 함량 및 내부 구조 변화에 따라 작물의 스트레스를 감지할 수 있다. 원격탐사는 물체 또는 영역과 물리적 접촉을 하지 않고도 식물 식별 및 스트레스 반응, 생육단계, 병해충, 수확, 강우 패턴, 가뭄이나 홍수같은 기상 재해, 공기 및 토양수분 등을 모니터링할 수 있다.

차세대 염기서열 분석기법(next generation sequencing, NGS)의 급속한 발전으로 식물병 관리의 대상인 식물과 병원균의 방대한 유전자 정보가 쌓임에 따라 식물병리학은 유전자 빅데이터 시대에 들어서게 되었다. 지난 몇 년간 최신 NGS 기술이 광범위하고 빠르게 적용되어 엄청난 양의 멀티오믹스(multi-omics) 빅데이터가 기하급수적으로 생산되었다. 그 결과 유전자 자체를 연구하는 생물정보학(bioinformatics)뿐만 아니라 빅데이터 생물학(big data biology)이나 네트워크 생물학(network biology)처럼 다양한 생물간의 관계를 하나의 시스템 관점에서 통합하려는 연구들이 활발하게 진행되고 있다(Yan 등, 2018). 최근에는 유전자 빅데이터와 스마트농업을 연결시키려는 노력이 시도되고 있다(Kumar, 2015; Rose와 Chilvers, 2018; Weersink 등, 2018). 예를 들어, 병원균과 기주식물의 유전체 빅데이터와 이를 둘러싼 다중규모의 기상환경 빅데이터를 시공간 메타데이터와 함께 접목하여 미세 환경뿐만 아니라 매크로 환경에서의 유의미한 연관성을 분석하여 식물병 관리에 활용한다. 즉, 집단유전학과 식물병생태학

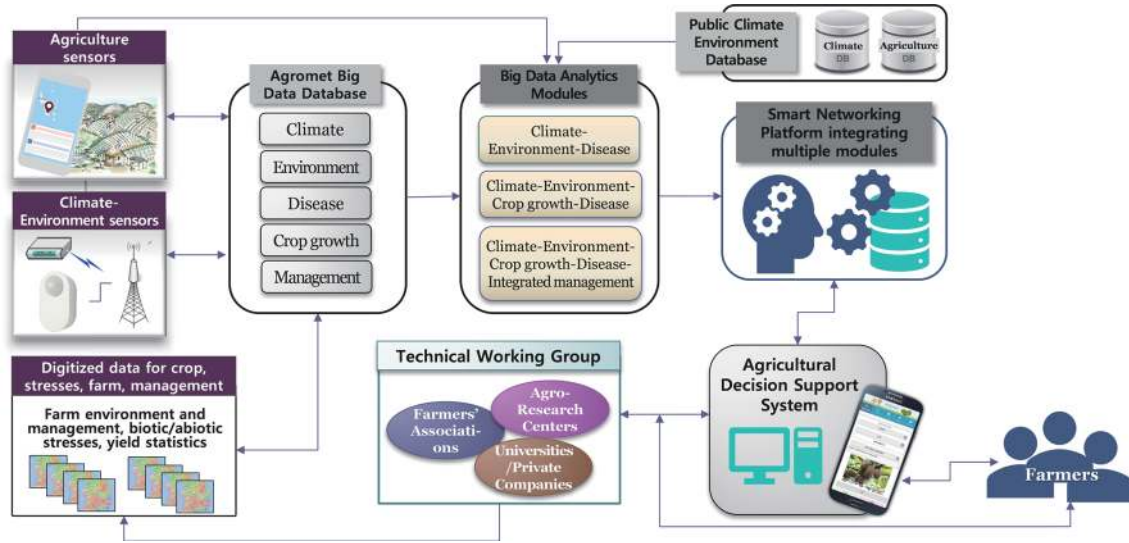


Fig. 1. Workflow of the smart plant disease management system. Agrometeorology big data from agro-data sensors, climate-environment sensors, historical digitized data from public and private sources, and real-time inputs from information users and providers are automatically or manually collected and stored in the Agromet Big Data Database. The BigData Analytics Modules then analyze and process the big data on the Smart Networking Platform, and the final information is re-processed and visualized to users (farmer, extension worker, and other agricultural stakeholders) through the Agricultural Decision Support System. The Technical Working Group participates in the whole process of the development and improvement of the smart plant disease management system by closely working with information users and providers.

를 접목한 연구를 바탕으로 식물병의 갑작스러운 시공간적 변이 (emerging 또는 re-emerging diseases)를 주도하는 환경-유전적 기작을 이해하고 예측하는 것이다(Giraud 등, 2010; Grünwald와 Goss, 2011; Milgroom과 Fry, 1997). 이러한 결과는 스마트농업에서 중장기적인 환경의 변화에 따라 식물병의 시공간적 변화를 예측하는 단서를 제공함으로써 중장기 식물병 관리 계획을 수립하는데 활용이 가능하다.

HS 데이터는 책과 예술 작품, 최근엔 소셜 네트워크 블로그나 메세지, 사진, 오디오 및 비디오의 형태로 기록되는 농업 활동과 관련된 인간 경험을 기록한 데이터이다. HS 데이터는 이제 개인 컴퓨터와 소셜 네트워크, 클라우드 등 거의 모든 곳에서 디지털데이터로 저장되지만 다른 데이터에 비해 덜 구조화되어 있다. 현재까지는 스마트농업과 빅데이터의 관점에서 마케팅 측면을 제외하고 HM 데이터에 대한 활용도는 낮은 편이다 (Verhoosel 등, 2016).

농업기상 빅데이터 활용 스마트식물병관리

스마트농업에서 스마트식물병관리는 다양한 농업기상 빅데이터의 수집/분석/활용을 통해 영농 기간 내 식물병관리를 위해 순차적으로 요구되는 다양한 의사결정을 효과적으로 지원하여 가장 효율적인 결과를 도출하게 한다(Fig. 1). 이러한 의사

결정이 이루어지기 위해서는 먼저 가용한 농업기상 빅데이터를 최대한 활용할 수 있도록 수집하고 저장하는 농업기상 빅데이터 데이터베이스(Agromet Big Data Database)가 구축이 되고, 다양한 최신 빅데이터 분석 기법을 접목해 개체들 간의 다중 (multiple) 상호작용을 해석하고 재현할 수 있는 알고리즘(Big Data Analytics Modules)이 개발되어야 한다. 이렇게 개발된 알고리즘들은 특정 의사결정을 위한 통합네트워킹플랫폼(Smart Networking Platform)을 통해 논리적으로 연결되어 최종 결과를 산출하게 되고, 최종적으로 산출된 정보를 이해하기 쉽게 가공하여 농업의사결정지원시스템(Agricultural Decision Support System, ADSS)을 통해 사용자가 최선의 의사결정을 할 수 있도록 지원한다.

하지만 ADSS는 사용자에게 지시하거나 명령하는 정보가 아니라 사용자가 최종 결정을 내리기 위해 필요한, 즉 의사결정 지원 정보를 제공한다. 스마트식물병관리의 빅데이터의 수집부터 계산, 정보의 표출 등 일련의 과정은 자동으로 이루어지지만 최종 결정은 사용자에게 의해 이루어지는 만큼 사용자와 정부, 전문가로 이루어진 기술위원회(Technical Working Group)에 의한 관리와 피드백이 필요하다. 기술위원회의 간섭을 통해 기존 스마트농업 데이터베이스와 호환될 수 있는 높은 확장성의 빅데이터를 수집하고, 가용한 빅데이터가 설명하지 못하는 불확실성을 전문가의 지식과 현장의 노하우를 바탕으로 최대한 줄

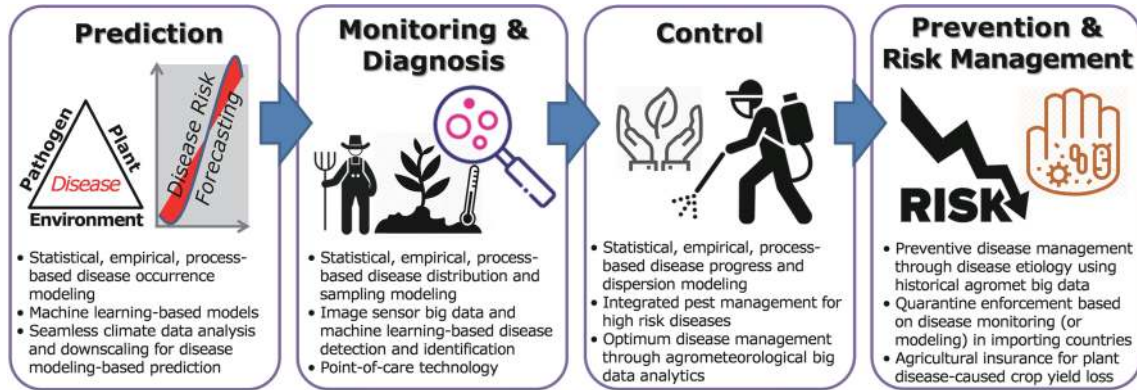


Fig. 2. Integrated plant disease management processes and related technologies required for each process. Integrated plant disease management starts from the prediction of plant diseases based on the plant disease triangle principle, moves to the monitoring and diagnosis of predicted diseases with high risk and the control of identified diseases using integrated pest management methods, and ends with the proactive prevention and risk management against potential emerging or re-emerging diseases in the near and distant future.

일 수 있으며, 보다 현실에 맞는 지역맞춤형 의사결정이 이루어 질 수 있게 한다.

스마트농업을 위해서는 종합적인 식물병 관리를 위한 일련의 과정인 예측, 모니터링 및 진단, 방제, 예방과 위험관리가 통합적으로 고려되어야 하지만, 현재 개발되거나 운영 중인 ADSS는 그 중 일부 과정에 대한 의사결정만을 지원하고 있다. 농업 4.0 이 최근에 소개된 개념이고 빅데이터 수집과 분석이 가능해진 시기가 얼마되지 않았음을 고려할 때 당연한 결과로 볼 수 있다. 따라서 본 리뷰에서는 스마트식물병관리의 각 단계별로 현재까지 개발된 기술과 연구 결과 등을 바탕으로 식물병리학에서 기여해야 하는 필수 빅데이터와 분석기법을 이해하고, 더 나아가 다학제적 융합연구의 필요성을 공유하고자 한다(Fig. 2).

예측. 스마트농업에서는 다양한 유형의 빅데이터를 기반으로 예측 알고리즘이나 모형을 개발하여 기상환경의 변화를 고려한 식물병 예측과 같은 데이터 기반 솔루션을 제공하는 것이 가능하다(Fig. 2의 Prediction). 전통적인 식물병 예측은 가장 간단한 경험적(empirical) 관계식부터 좀더 복잡한 병 발생 기작의 물리적 현상을 모델링한 과정기반(process-based or mechanical) 모형, 또는 충분한 데이터가 확보된 경우 적용 가능한 통계모형을 통해 이루어져 왔다. 최근에는 농업 빅데이터가 급속도로 늘어나면서 빅데이터의 장점을 활용할 수 있는 다양한 방법들이 시도되고 있다. Kim 등(2018a)은 Farm as a Service (FaaS)라는 IoT 기반 스마트팜 시스템을 통해 기존 General Infection Model (Magarey 등, 2005)을 활용한 딸기 잣빛곰팡이병 예측시스템을 개발하였다. 이 시스템은 기상환경 정보와 모수화된 모형을 통해 실시간 감염 위험도를 산출하고 이를 기반으로 농민들이 비닐하우스의 환경 조절을 통해 병해 위험도

를 낮추거나 즉각적인 방제 의사결정을 할 수 있도록 지원한다. Pavan 등(2009)에 의한 노지 딸기의 잣빛곰팡이병 방제 의사 결정시스템과 유사하지만 주변 기상관측장비의 데이터가 아닌 스마트팜 센서의 기상데이터를 사용했다. Tripathy 등(2014)은 한발 더 나아가 Wireless Sensor Network (WSN)에서 수집된 기상 빅데이터를 나이브 베이즈 분류기(Naïve Bayes classification) 데이터마이닝 기법으로 분석하여 땅콩 점무늬병을 예측하는 통계모형을 개발하였다.

최근에는 가용한 농업기상 데이터와 다양한 머신러닝 기법을 이용한 식물병 예측모형 개발도 활발하게 이루어지고 있다. Kaundal 등(2006)은 벼 도열병 예측에 있어서 Support Vector Machine (SVM) 모형이 다중회귀 통계모형보다 성능이 높다는 결과를 보고했고, Nettleton 등(2019)은 M5Rules와 Recurrent Neural Networks (RNN) 머신러닝 모형들이 기존 과정기반(process-based or mechanical) 모형보다 성능이 우수함을 보였다. 그외 벼 도열병(Kim 등, 2018b), 커피 녹병과 잎줄기무늬병(de Oliveira Aparecido 등, 2020), 포도 노균병(Chen 등, 2020), 감자 역병(Fenu와 Mallocci, 2019) 등에서 제한된 양의 식물병 발생데이터를 기반으로 머신러닝 모형의 가능성을 보고했다. 한편, Dietterich (2000)는 동일한 데이터를 기반으로 학습시킨 여러개의 머신러닝 모형을 결합하여 앙상블 모형을 만든 후 개별 모형보다 예측 정확도가 크게 향상되는 것을 보였다. 그럼에도 불구하고 본격적인 딥러닝 수준의 예측모형은 여전히 담보 상태인데, 이는 농업기상 빅데이터와 연결하여 분석할 수 있는 식물병 데이터의 양이 지극히 제한적이기 때문이다. 식물병 데이터의 사이즈를 키우기 위해 통제된 환경 안에서 실험적으로 기상·환경 데이터와 커플링된 식물병 조사자료를 증폭하거나 부트스트래핑(bootstrapping)과 같은 표본 재추출방법을

응용해 데이터 양을 늘리는 방법이 활용 가능하다(Pascual 등, 2006).

일단 식물병 예측모형이 준비되면 관측부터 단기 및 중장기 예측을 아우르는 기상기후 데이터를 기반으로 시공간을 특정 한 미래의 식물병 발생을 예측하는 것이 가능하다. 가용한 기상기후 예측정보는 시공간적인 상세화 과정을 거쳐 농지나 행정구역 수준의 기상 데이터로 변환될 수 있으며, 이를 활용해 이음새없는(seamless) 식물병 예측정보를 생산하게 되면 다양한 선행시간에 따른 식물병 관리 전략 및 기술을 세우는 것이 가능하다. 물론 기상기후 예측정보의 확률적 특성에 기인한 식물병 예측정보의 불확실성을 고려해야 하며, 이를 바탕으로 후회 없는(no-regret) 의사결정을 내릴 필요가 있다(McRoberts 등, 2011). 불확실성을 최소화하기 위해서는 ADSS와 같이 가용한 모든 농업기상 빅데이터를 기반으로 최종 정보의 불확실성을 정량화하고 체계적으로 제거해나가는 과정이 필요하다(Fig. 1).

모니터링과 진단. 식물병 예측정보를 바탕으로 발생 가능성이 높은 식물병이 특정이 되고 나면 데이터를 기반으로 한 해당 식물병의 모니터링 또는 감시(surveillance) 활동과 함께 현장에서 발견된 병징(symptom)이나 표징(sign)을 기반으로 정확한 식물병 진단이 되어야 한다(Fig. 2의 Monitoring & Diagnosis). 먼저 실시간으로 수집되는 농업기상 빅데이터와 확률 통계기법 또는 과정기반 모델링기법을 활용해 모니터링 우선 지점과 최적 샘플링 방법을 제안할 수 있다(Luo 등, 2012; Nelson 등, 1999; Scherm 등, 2006). 이를 통해 한정된 인적 물적 자원을 고위험 우선순위 시공간에 우선 투입하여 효율적인 모니터링 활동을 지원한다. 그럼에도 불구하고, 특정된 지점의 수많은 식물체를 샘플링 조사하여 병든 개체를 구분하는 것은 여전히 어려운 일이다. 식물병에 대한 전문적인 지식이나 필드 경험이 부족한 경우, 샘플링이 충분치 않은 경우, 조사자가 병 조사에 집중하지 않는 경우 존재하는 병징이나 표징을 놓치는 상황이 발생한다(Bell 등, 2014). 스마트농업에서는 원격 이미지센서를 통해 수집되는 이미지 빅데이터를 기반으로 이 문제를 해결하고자 하였다.

건강한 잎의 빛 반사율은 스트레스를 받는 잎의 빛 반사율과 다르기 때문에 원격 센서는 영농 현장에서 가시적인 증상이 나타나기 이전에 식물병을 직접 감지하는 것이 가능하다(Fahrentz 등, 2019). 열화상 및 엽록소 형광 센서는 각각 잎 표면 온도와 엽록소 활성의 변화를 측정한다. 이들 센서는 초기 스트레스 반응을 감지하는 데 강력한 수단이지만 식물병을 구분하지는 못한다(Bera 등, 2019). 초분광 센서는 이미지의 각 픽셀에 대해 수백 개의 좁은 인접 스펙트럼 대역을 생성하여 특정 식물병을 식

별할 수 있다. 실제 수많은 연구들이 이미지센서를 통해 수집된 빅데이터를 기반으로 다양한 머신러닝 기법을 사용해 식물병 진단을 시도하였다. Sannakki 등(2011)은 석류 잎 이미지에서 병든 부분을 분리(semantic image segmentation)하여 병징을 구분하고 퍼지 로직(fuzzy logic)을 이용해 병의 발생 정도(severity)를 진단하였다. Surendrababu 등(2014)은 차원분열도형(fractals)을 사용해 잎 이미지에서 식물병을 식별하였고, Anantrasirichai 등(2017)은 잎 병징을 식별하기 위한 전 처리 과정으로써 전체 식물 이미지로부터 잎만 캡처하는 방법을 고안하였다. 다른 연구 사례로는 토마토 노균병(Raza 등, 2015), 사탕무 잎집무늬마름병(Hillnhütter 등, 2011), 사과 검은별무늬병(Chéné 등, 2012), 보리 녹병(Wahabzada 등, 2015), 오렌지 황룡병(Huanglongbing) (Wetterich 등, 2013), 토마토 황화잎말림바이러스병(Mokhtar 등, 2015) 등을 포함한다. 머신러닝 기법과 이미지 빅데이터를 통한 추가적인 식물병 진단 연구의 사례는 Sperschneider (2019)와 Mahlein (2016)의 리뷰를 참조하면 된다.

식물병을 식별하는 데 주로 사용되는 초분광 센서의 이미지 데이터를 가공하고 분석하는 과정 중에 자료의 차원을 축소하기 위해 상당한 양의 전처리를 하게 된다. 이는 초분광 이미지와 같은 다변량 빅데이터의 과적합(overfitting)을 일으키는 차원의 저주(curse of dimensionality)를 피하기 위해 필수적인 과정이다(Paoletti 등, 2019; Sabarina와 Priya, 2015). 실제로 통제된 환경에서 특정 광 조건과 선택된 식물병을 대상으로 과적합된 상태로 개발된 진단 알고리즘은 노지 조건에서 식물병 탐지 성능이 급격히 저하되는 문제를 보였다(Mahlein, 2016). 이미지를 통한 식물병 진단은 다양한 생물적 및 비생물적 스트레스가 동시에 발생하고 광의 상태가 크게 가변적인 영농 현장에 적용되어야 하기 때문에 과적합을 줄임으로써 모델 검증 성능은 떨어지더라도 현장에서의 적용성(robustness)을 높이기 위한 노력이 수반되어야 한다(Barbedo, 2018). 이에 더해 복수의 병해충 및 생리적 피해가 동시에 발생한 경우에 적용가능한 진단 알고리즘이 개발되어야 영농 현장에서의 적용성을 높일 수 있다. 하지만 복합적인 요인에 의한 표현형(phenotype)은 주변 환경이나 발생 이력에 따라 변이가 크기 때문에 아직까지 미완성 분야 중 하나이다. 이런 경우에는 이미지 정보뿐만 아니라 다른 농업기상 데이터(기상, 토양, 병원체 등)를 통합적으로 활용해 상호보완적인 추정이 가능한 진단 알고리즘이 개발되어야 한다(Sperschneider, 2019).

그럼에도 불구하고 이미지 기반 식물병 진단은 머신 비전(machine-vision) 및 딥러닝을 통한 이미지 처리의 빠른 발전으로 인해 최근 상당한 진전을 보이고 있다. Mohanty 등(2016)은 14개 작물의 26개 식물병에 대한 54,306개의 데이터셋을

바탕으로 훈련시킨 컨볼루션 신경망(Convolutional Neural Network, CNN)을 통해 99.35%의 진단 정확도를 달성하였다. Too 등(2019)은 최근 CNN의 구조(architecture) 중 VGG-16, Inception-V4, Resnet 및 DenseNet의 식물병 진단 성능을 비교 평가하여 DenseNet이 99.75%의 정확도를 보인다는 연구결과를 발표하였다. 결과적으로 향후 빅데이터의 양과 질이 점차 증가하게 되면 딥러닝을 통한 이미지 진단이 영농현장에서의 빠른 진단을 가능하게 하는 현장진단(point-of-care) 기술과 함께 스마트식물병관리에서 상호보완적인 필수 기술로서 자리 잡을 것으로 예상된다.

방제. 스마트식물병관리에서 모니터링과 진단을 통해 정확한 병명과 발생 지점이 파악되면 해당 식물병에 대한 즉각적인 방제관리(control)가 이루어져야 한다(Fig. 2의 Control). 개별 농장의 경우 발견된 위험 수준에 따라 자연스럽게 방제 관리의 강도가 결정된다. 위험이 상대적으로 낮은 수준에서는 기상환경의 조절이나 비화학적/생물학적 수단을 통해 식물병의 위험도를 최소화하고, 고위험 수준에서는 즉각적인 관리를 위해 화학적 방제가 이루어질 수 있다. 좀더 광범위한 지역을 관리해야 할 경우, 특히 주변 전파에 의한 감염성이 상대적으로 높은 식물병에 대해서는 주변 기상환경 빅데이터와 식물병 시공간적 전파모델링을 통한 예상 전파범위(dispersal radius) 시뮬레이션을 통해 추가적인 전파를 차단하기 위한 적극적인 방제대책을 수립한다(Nelson 등, 1999; Ojiambo 등, 2017). 예를 들어, 전파 확률이 높은 식물병의 경우 예상 전파 범위 내 모든 기주식물을 제거(eradication)하되 그 외의 지역에서는 가능한 화학제품의 사용을 최소화하기 위한 종합관리(Integrated Pest Management, IPM)방법을 제시할 수 있다.

한편, 스마트식물병관리에서는 방제 의사결정에 대한 인간의 간섭이나 방제를 위한 노동력의 투입을 최소화할 수 있다. 기상, 영양소, 생육, 증산, 색, 광, 토양수분 등 각종 센서를 통해서 수집된 좋은 품질의 빅데이터는 끊임없이 변화하는 환경 조건에서 식물병을 최대한 억제하면서 생산성을 높일 수 있는 의사결정을 가능하게 하는 학습자료가 된다(Li 등, 2014; Schönfeld 등, 2018). 이렇게 개발된 방제 알고리즘은 IoT 시스템을 통해 어떤 상황에서도 가장 논리적이고 합리적인 결정을 자동으로 내리기 때문에 인간의 개입이 최소화될 수 있다. 결과적으로 스마트식물병관리는 예측이나 모니터링, 진단을 기반으로 농장의 소프트웨어적 기능을 제어하거나 사용자 환경을 최적화하고, 더 나아가서는 운영을 최적화하는 통합 알고리즘을 통해 방제 효율을 높이거나 생산성을 높인다(Rose와 Chilvers, 2018). 실제로 선진국의 농장에서는 각종 센서의 빅데이터를 바탕으로 화

학 농약과 비료를 농장의 특정 영역에 정확하게 적용하는 정밀 농업시스템을 운영중이다(Tantalaki 등, 2019). 이는 결국 농업 비용을 줄이면서 생산성을 향상시키는 결과를 가져온다. 하지만 아직까지 개발도상국에서는 스마트농업이 연구 단계에 머물러 있다. 개발도상국에서의 높은 시스템 확산 비용과 낮은 기술 및 인식은 여전히 IoT, 빅데이터 기반 스마트농업을 방해하는 요소이다. 또한 개발도상국은 우리나라의 농업시스템과 같이 대부분 소규모 농장이므로 대부분의 농민들은 스마트 농업을 적용할 필요가 없다고 생각한다. 기후변화와 이상기후의 피해에 가장 취약한 개발도상국의 최소한의 식량안보 확보를 위해서라도 이러한 저비용, 소규모 농장을 위한 적정기술, 스마트 식물병관리 솔루션을 개발하는 연구가 시급하다.

예방 및 위험관리. 마지막으로 기존 또는 새로운 식물병(emerging 또는 re-emerging diseases)이 농업 커뮤니티에 사회경제적인 피해를 일으키는 것을 사전에 차단하기 위한 일련의 예방조치(prevention)가 있어야 한다(Fig. 2의 Prevention & Risk Management). 스마트식물병관리에서는 가용한 빅데이터를 모두 활용하여 식물병 발생 원인 및 전파 경로의 선제적 차단, 기상 및 재배조건을 이용한 병 위험 예측, 모니터링 활동에 대한 가이드라인 제공 등 해당 식물병에 대해 수집된 모든 데이터를 기반으로 식물병의 IPM 관점에서 필요한 예방적 조치들이 함께 제시되어야 한다. 여기서 IPM이란 특정 취약지역(hotspot) 내 고위험 식물병의 잠재적 리스크를 줄이기 위해 최소한의 화학농약 사용과 함께 식물의 (비)기주 저항성이나 다양한 재배 관리 방법을 시스템적으로 조합하여 최선의 병 억제 관리 방안을 제시하는 것이다(Ehler, 2016). 특히 침입 식물병의 경우, 기후변화와 함께 국가간 농산물 교역 및 여행의 가파른 증가로 검역대상 병원균의 국내 침입을 원천적으로 막는 것이 불가능하다(Fisher 등, 2012). 따라서 우리나라뿐 아니라 주요 교역 및 방문 국가의 식물병 발생을 예의주시하고 현지 역학(epidemiological) 데이터를 기반으로 향후 국내에 미칠 잠재적인 피해를 최소화하기 위한 검역, 검출(detection), 방제에 관한 선제적 대응 전략 및 기술 개발이 필요하다. 이를 위해 주요 교역 및 방문 국가를 대상으로 검역 대상 식물병의 효과적 대응을 위한 과거 및 실시간 빅데이터 구축이 선행되어야 하며 주변 지역 내 가용한 빅데이터의 통합적인 활용이 필수적이다.

그럼에도 불구하고 실제 영농 현장에서는 최적의 의사결정에 필요한 일부 변수들이 여전히 가용하지 않거나, 빅데이터와 개발된 알고리즘 및 모형 모듈, 통합 의사결정플랫폼이 가진 역동성 혹은 불확실성이 여전히 존재하기 때문에 이에 대한 위험관리가 스마트식물병관리에 포함되어야 한다(Moschini와

Hennessy, 2001; Shtienberg, 2013). 현실적으로 실현가능한 위험관리 방안 중 농작물 보험을 들 수 있다. IoT와 빅데이터 기술은 농작물 보험의 효율성과 범용성을 증가시키는 계기가 되었고, 개발도상국과 같이 사회경제적인 인프라가 취약한 국가에서도 농작물 보험에 접근할 수 있게 하였다(Coble 등, 2018; Weersink 등, 2018). 원격 무인 관측망과 센서 네트워크를 통해 수집된 빅데이터를 기반으로 식물병을 포함한 농작물에 발생 가능한 각종 재해에 대한 직간접적 모니터링이 가능하게 되었다. 보험 정책과 함께 제공되는 농업재해 조기경보시스템은 생물적/비생물적(biotic/abiotic) 피해를 야기하는 비정상적인 기상 조건이 예측되면 피보험자에게 알람을 보내 작물이나 가축에 대한 예방적 조치를 취할 수 있게 한다. 또한 보험회사가 실제 재해 정도를 평가하기 위해 직접 방문하지 않고서도 피보험자의 농장 데이터에 원격으로 접근이 가능하기 때문에 극한 상황이 관찰되었을 때는 IoT 모바일결제 시스템을 통해 자동으로 보험금을 지급할 수 있다.

스마트농업을 통한 식물병 관리 사례

전 세계적으로 현재 스마트농업에 가장 근접한 모델들은 민간기업 주도로 이루어지고 있다. 이는 농업 의사결정의 다양성과 급격한 변화를 수용하는데 있어 민간기업의 빠르고 적극적인 전략 수립 및 체계적인 실행 방식이 정부나 공공기관의 그것보다 적합하기 때문이다. Climate Corporation의 Climate FieldView (<https://climate.com>)는 사용자의 농기계와 농경지 곳곳에 설치된 센서 데이터를 기상환경정보와 결합하여 스마트 맞춤형 정보, 즉 작물 성장, 병해충, 영향상태, 수확량 예측 등의 정보를 최적의 솔루션과 함께 사용자들에게 실시간으로 제공하고 있다. John Deere의 Lettuce Bot은 농기계에 부착해 작물과 잡초를 선별하여 잡초만을 제거하는 로봇인데 중요한 것은 농기계를 운영하는 매 순간 새로운 빅데이터를 수집하여 즉각 활용하고, 그 결과를 바탕으로 다시 AI 모델을 훈련하기 때문에 성능이 지속적으로 향상된다는 점이다(Yeo, 2019). IBM의 Deep Thunder는 기상환경 빅데이터를 기반으로 지역맞춤형 일기예보를 생성하여 병해충 관리와 같은 농작업의 최적화를 통해 생산성을 높인다(Bendre 등, 2015). Prospera는 AI를 기반으로 실시간 병해충 발생, 수확량 예측, 물과 영양분의 최적화 방안을 제시하는 서비스를 제공하고 있다. 우리나라에서는 여전히 공공부문의 주도로 스마트농업이 추진되고 있는데, 정보통신회사(KT, SK텔레콤)를 중심으로 IoT를 통한 스마트팜 원격제어가 시범적으로 시도되고 있는 정도이다. 그러나 스마트 식물병관리의 모습을 갖추고 있는 시스템은 농촌진흥청의 국

가농작물병해충관리시스템(National Crop Pest Management System, NCPMS)이나 일부 지방정부의 병해충예측시스템 정도인데 아직까지 빅데이터 활용이나 의사결정 지원 정도는 초기 수준에 머물고 있다. 최근 농촌진흥청에서 개발된 시군 및 주산지 단위 고해상도 서비스를 제공하고 있는 농업기상재해 조기경보시스템(<https://agmet.kr>)은 빅데이터 기반 작물별 기상재해에 대한 예측, 모니터링, 관리 방안 등을 통합적으로 전달하고 있다. 여전히 사용자와의 상호작용에 의한 적극적인 의사결정 지원은 이루어지고 있지 않지만, 추후 시스템 개선을 통해 수집된 빅데이터를 기반으로 다양한 스마트 알고리즘이 개발되어 쌍방향 의사결정과 연계된다면 식물병을 포함한 농업재해에 포괄적으로 활용이 가능할 것으로 보인다.

결 언

스마트농업의 실현을 위해서는 내외부의 다양한 빅데이터의 수집/분석/활용을 통한 자동제어 및 서로 다른 시스템 간의 상호보완적 네트워크를 통한 보다 전체론적이고(holistic), 신뢰할 만한(trustworthy), 그리고 후회없는 의사결정이 가능해야 한다. 앞서 본문에서 언급했던 것처럼 정보통신, IoT, 센서, 클라우드, AI는 식물병리학의 진전과는 별개로 급속도로 발전을 거듭할 것이다. 하지만 어떤 빅데이터를 어떻게 수집하고 활용할지, 그리고 식물-환경-병원균-인간의 복잡다단한 상호작용에 대한 이해를 기반으로 어떤 의사결정을 내릴지는 식물병리학에서 해결할 문제이다. 식물병리학 연구자들의 적극적인 개입이 없이는 스마트식물병관리가 실현되는 데 오랜 시간이 걸릴 것이고, 결과적으로 농업 4.0을 넘어 농업 5.0으로 가야하는 시기에 여전히 식물병 관리는 빅데이터와 상관없이 이전의 관행적인 방식에 의존하고 있을지도 모른다. 본 리뷰를 통해 식물병리학이 기여해야만 하는 농업기상 빅데이터와 다양한 빅데이터 분석 및 응용 방법을 이해하고 스마트식물병관리에 필요한 새로운 첨단기술을 제시하였다. 이를 통해 스마트농업을 위한 다학제적 융합연구가 본격적으로 시작되기를 바란다.

요 약

기후변화와 이상기후, 급변하는 사회경제적 환경 하에 식량 안보를 확보하고 지속가능한 성장을 위해서는 기존의 관행농업을 벗어나 빅데이터와 인공지능을 활용한 스마트농업으로의 전환이 시급하다. 스마트농업을 통해 식물병을 효율적으로 관리하기 위해서는 다양한 첨단기술과 융합할 수 있는 농업 빅데이터가 우선 확보되어야 한다. 본 리뷰에서는 스마트식물병관

리를 위해 식물병리학 분야에서 기여할 수 있는 기상환경 및 농업 빅데이터에 대해 알아보고 이를 활용한 식물병의 예측, 모니터링 및 진단, 방제, 예방 및 위험관리의 각 단계별로 현재 우리가 어느 위치에 있는지를 살펴보았다. 이를 바탕으로 현재까지 스마트식물병관리를 위해 준비해온 것과 미흡했던 부분, 앞으로 나아가야 할 방향을 제시하고자 한다.

Conflicts of Interest

Conflict of interest relevant to this article was not reported.

Acknowledgments

This work was supported by the APEC Climate Center.

References

- Ahn, J. and Lee, H. 2015. Smart farm using IoT that change the lives of rural people. *Plan. Policy* 5: 19-26.
- Anantrasirichai, N., Hannuna, S. and Canagarajah, N. 2017. Automatic leaf extraction from outdoor images. *arXiv* 1709.06437.
- Barbedo, J. G. A. 2018. Factors influencing the use of deep learning for plant disease recognition. *Biosyst. Eng.* 172: 84-91.
- Bell, H., Wakefield, M., Macarthur, R., Stein, J., Collins, D., Hart, A. et al. 2014. Plant health surveys for the EU territory: an analysis of data quality and methodologies and the resulting uncertainties for pest risk assessment (PERSEUS) CFP/EFSA/PLH/2010/01. *EFSA Support. Publ.* 11: 676E.
- Bendre, M. R., Thool, R. C. and Thool, V. R. 2015. Big data in precision agriculture: weather forecasting for future farming. In: 2015 1st International Conference on Next Generation Computing Technologies (NGCT), pp. 744-750. Institute of Electrical and Electronics Engineers, New York, NY, USA.
- Bera, T., Das, A., Sil, J. and Das, A. K. 2019. A survey on rice plant disease identification using image processing and data mining techniques. In: *Emerging Technologies in Data Mining and Information Security, Advances in Intelligent Systems and Computing*, Vol. 814, eds. by A. Abraham, P. Dutta, J. Mandal, A. Bhattacharya and S. Dutta, pp. 365-376. Springer, Singapore.
- Bronson, K. and Knezevic, I. 2016. Big data in food and agriculture. *Big Data Soc.* 3: 1-5.
- Carranza-Rojas, J., Goeau, H., Bonnet, P., Mata-Montero, E. and Joly, A. 2017. Going deeper in the automated identification of Herbarium specimens. *BMC Evol. Biol.* 17: 181.
- Chen, M., Brun, F., Raynal, M. and Makowski, D. 2020. Forecasting severe grape downy mildew attacks using machine learning. *PLoS ONE* 15: e0230254.
- Chéné, Y., Rousseau, D., Lucidarme, P., Bertheloot, J., Caffier, V., Morel, P. et al. 2012. On the use of depth camera for 3D phenotyping of entire plants. *Comput. Electron. Agric.* 82: 122-127.
- Cireşan, D. C., Meier, U., Masci, J., Gambardella, L. M. and Schmidhuber, J. 2011. Flexible, high performance convolutional neural networks for image classification. In: *Proceedings of the Twenty-Second International Joint Conference on Artificial Intelligence*, ed. by W. Toby, pp. 1237-1242. AAAI Press, Palo Alto, CA, USA.
- Coble, K. H., Mishra, A. K., Ferrell, S. and Griffin, T. 2018. Big data in agriculture: a challenge for the future. *Appl. Econ. Perspect. Policy* 40: 79-96.
- de Oliveira Aparecido, L. E., de Souza Rolim, G., De Moraes, J. R. D. S. C., Costa, C. T. S. and de Souza, P. S. 2020. Machine learning algorithms for forecasting the incidence of *Coffea arabica* pests and diseases. *Int. J. Biometeorol.* 64: 671-688.
- Devlin, B. 2012. The Big Data Zoo—Taming the Beasts: The Need for an Integrated Platform for Enterprise Information. 9sight Consulting, Cape Town, South Africa. 12 pp.
- Dietterich, T. G. 2000. Ensemble methods in machine learning. In: *Multiple Classifier Systems*, Vol. 1857 of Lecture Notes in Computer Science, eds. by J. Kittler and F. Roli, pp. 1-15. Springer, Berlin/Heidelberg, Germany.
- Ehler, L. E. 2006. Integrated pest management (IPM): definition, historical development and implementation, and the other IPM. *Pest Manag. Sci.* 62: 787-789.
- Eum, H.-I., Kim, J. P. and Cho, J. 2018. High-resolution climate data from an improved GIS-based regression technique for South Korea. *KSCE J. Civil Eng.* 22: 5215-5228.
- Fahrentrapp, J., Ria, F., Geilhausen, M. and Panassiti, B. 2019. Detection of gray mold leaf infections prior to visual symptom appearance using a five-band multispectral sensor. *Front. Plant Sci.* 10: 628.
- Fenu, G. and Mallocci, F. M. 2019. An application of machine learning technique in forecasting crop disease. In: *Proceedings of the 2019 3rd International Conference on Big Data Research*, pp. 76-82. Association for Computing Machinery, New York, NY, USA.
- Fisher, M. C., Henk, D. A., Briggs, C. J., Brownstein, J. S., Madoff, L. C., McCraw, S. L. et al. 2012. Emerging fungal threats to animal, plant and ecosystem health. *Nature* 484: 186-194.
- Giraud, T., Gladieux, P. and Gavrilets, S. 2010. Linking the emergence of fungal plant diseases with ecological speciation. *Trends Ecol. Evol.* 25: 387-395.
- Grünwald, N. J. and Goss, E. M. 2011. Evolution and population genetics of exotic and re-emerging pathogens: novel tools and approaches. *Annu. Rev. Phytopathol.* 49: 249-267.
- Hammer, C., Kostroch, D. C., Quiros, G. and STA Internal Group. 2017. *Big Data: Potential, Challenges and Statistical Implications*. International Monetary Fund, Washington DC, USA. 41 pp.
- Hillnhütter, C., Mahlein, A.-K., Sikora, R. A. and Oerke, E.-C. 2011. Remote sensing to detect plant stress induced by *Heterodera*

- schachtii* and *Rhizoctonia solani* in sugar beet fields. *Field Crops Res.* 122: 70-77.
- Hinton, G., Deng, L., Yu, D., Dahl, G. E., Mohamed, A.-R., Jaitly, N. et al. 2012. Deep neural networks for acoustic modeling in speech recognition: the shared views of four research groups. *IEEE Signal Process Mag.* 29: 82-97.
- Ip, R. H. L., Ang, L.-M., Seng, K. P., Broster, J. C. and Pratley, J. E. 2018. Big data and machine learning for crop protection. *Comput. Electron. Agric.* 151: 376-383.
- Ishii, K. 2014. Big data analysis in medicine, agriculture and environmental sciences. *Seibutsu-kogaku Kaishi* 92: 92-93.
- Jeon, S. 2011. Mechanisms of labor transition during agricultural transformation: the cases of South Korea and Indonesia. In: 2011 International Conference on Asia Agriculture and Animal IPCBEE, Vol. 13, pp. 21-26. IACSIT Press, Singapore.
- Kaundal, R., Kapoor, A. S. and Raghava, G. P. S. 2006. Machine learning techniques in disease forecasting: a case study on rice blast prediction. *BMC Bioinformatics* 7: 485.
- Kim, C.-G., Lee, S.-M., Jeong, H.-K., Jang, J.-K., Kim, Y.-H. and Lee, C.-K. 2010. Impacts of Climate Change on Korean Agriculture and Its Counterstrategies. Korea Rural Economic Institute, Naju, Korea. 306 pp.
- Kim, M.-K., Han, M.-S., Jang, D.-H., Baek, S.-G., Lee, W.-S. and Kim, Y.-J. 2012. A production method for historical climate data with 1-km-resolution grids. *Clim. Res.* 7: 55-68.
- Kim, S., Lee, M. and Shin, C. 2018a. IoT-based strawberry disease prediction system for smart farming. *Sensors* 18: 4051.
- Kim, Y., Roh, J.-H. and Kim, H. Y. 2018b. Early forecasting of rice blast disease using long short-term memory recurrent neural networks. *Sustainability* 10: 34.
- Kumar, A. 2015. Science of omics for agricultural productivity: future perspective: a national conference report. *Int. J. Comput. Bioinform. In Silico Model.* 4: 607-610.
- LeCun, Y., Bengio, Y. and Hinton, G. 2015. Deep learning. *Nature* 521: 436-444.
- LeCun, Y., Bottou, L., Bengio, Y. and Haffner, P. 1998. Gradient-based learning applied to document recognition. *Proc. IEEE* 86: 2278-2324.
- Li, X.-F., Chen, S.-H. and Guo, L.-F. 2014. Technological innovation of agricultural information service in the age of big data. *J. Agric. Sci. Technol.* 16: 10-15.
- Luo, W., Pietravalle, S., Parnell, S., Van den Bosch, F., Gottwald, T. R., Irey, M. S. et al. 2012. An improved regulatory sampling method for mapping and representing plant disease from a limited number of samples. *Epidemics* 4: 68-77.
- Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G. and Johnson, B. A. 2019. Deep learning in remote sensing applications: a meta-analysis and review. *ISPRS J. Photogramm. Remote Sens.* 152: 166-177.
- Magarey, R. D., Sutton, T. B. and Thayer, C. L. 2005. A simple generic infection model for foliar fungal plant pathogens. *Phytopathology* 95: 92-100.
- Mahlein, A.-K. 2016. Plant disease detection by imaging sensors: parallels and specific demands for precision agriculture and plant phenotyping. *Plant Dis.* 100: 241-251.
- McRoberts, N., Hall, C., Madden, L. V. and Hughes, G. 2011. Perceptions of disease risk: From social construction of subjective judgments to rational decision making. *Phytopathology* 101: 654-665.
- Milgroom, M. G. and Fry, W. E. 1997. Contributions of population genetics to plant disease epidemiology and management. *Adv. Bot. Res.* 24: 1-30.
- Mohanty, S. P., Hughes, D. P. and Salathé, M. 2016. Using deep learning for image-based plant disease detection. *Front. Plant Sci.* 7: 1419.
- Mokhtar, U., Ali, M. A. S., Hassanien, A. E. and Hefny, H. 2015. Identifying two of tomatoes leaf viruses using support vector machine. In: Information Systems Design and Intelligent Applications, eds. by J. K. Mandal, S. C. Satapathy, M. K. Sanyal, P. P. Sarker and A. Mukhopadhyay, pp. 771-782. Springer, New Delhi, India.
- Montone, V. O., Fraisse, C. W., Peres, N. A., Sentelhas, P. C., Gleason, M., Ellis, M. et al. 2016. Evaluation of leaf wetness duration models for operational use in strawberry disease-warning systems in four US states. *Int. J. Biometeorol.* 60: 1761-1774.
- Moschini, G. and Hennessy, D. A. 2001. Uncertainty, risk aversion, and risk management for agricultural producers. In: Handbook of Agricultural Economics, Vol. 1, eds. by B. L. Gardner and G. C. Rausser, pp. 87-153. Elsevier, Amsterdam, Netherlands.
- Nelson, M. R., Orum, T. V., Jaime-Garcia, R. and Nadeem, A. 1999. Applications of geographic information systems and geostatistics in plant disease epidemiology and management. *Plant Dis.* 83: 308-319.
- Nettleton, D. F., Katsantonis, D., Kalaitzidis, A., Sarafijanovic-Djukic, N., Puigdollers, P. and Confalonieri, R. 2019. Predicting rice blast disease: machine learning versus process-based models. *BMC Bioinformatics* 20: 514.
- Noyes, K. 2014. Big data poised to change the face of agriculture. Fortune data. URL <http://fortune.com/2014/05/30/cropping-up-on-every-farm-big-data-technology/> [30 May 2014].
- Ojiambo, P. S., Yuen, J., Van den Bosch, F. and Madden, L. V. 2017. Epidemiology: past, present, and future impacts on understanding disease dynamics and improving plant disease management: a summary of focus issue articles. *Phytopathology* 107: 1092-1094.
- Paoletti, M. E., Haut, J. M., Plaza, J. and Plaza, A. 2019. Deep learning classifiers for hyperspectral imaging: a review. *ISPRS J. Photogramm. Remote Sens.* 158: 279-317.
- Pascual, L., Romo, J. and Ruiz, E. 2006. Bootstrap prediction for returns and volatilities in GARCH models. *Comput. Stat. Data Anal.* 50: 2293-2312.
- Pavan, W., Fraisse, C. W. and Peres, N. A. 2009. A web-based decision support tool for timing fungicide applications in strawberry. *EDIS* 9: 1-5.
- Polak, L. and Milos, J. 2020. Performance analysis of LoRa in the 2.4

- GHz ISM band: coexistence issues with Wi-Fi. *Telecommun. Syst.* 74: 299-309.
- Raza, S.-e.-A., Prince, G., Clarkson, J. P. and Rajpoot, N. M. 2015. Automatic detection of diseased tomato plants using thermal and stereo visible light images. *PLoS ONE* 10: e0123262.
- Rose, D. C. and Chilvers, J. 2018. Agriculture 4.0: broadening responsible innovation in an era of smart farming. *Front. Sustain. Food Syst.* 2: 87.
- Rowlandson, T., Gleason, M., Sentelhas, P., Gillespie, T., Thomas, C. and Hornbuckle, B. 2015. Reconsidering leaf wetness duration determination for plant disease management. *Plant Dis.* 99: 310-319.
- Ruane, A. C., Goldberg, R. and Chryssanthacopoulos, J. 2015. Climate forcing datasets for agricultural modeling: merged products for gap-filling and historical climate series estimation. *Agric. For. Meteorol.* 200: 233-248.
- Ryan, S. F., Adamson, N. L., Aktipis, A., Andersen, L. K., Austin, R., Barnes, L. et al. 2018. The role of citizen science in addressing grand challenges in food and agriculture research. *Proc. Biol. Sci.* 285: 20181977.
- Sabarina, K. and Priya, N. 2015. Lowering data dimensionality in big data for the benefit of precision agriculture. *Procedia Comput. Sci.* 48: 548-554.
- Sannakki, S. S., Rajpurohit, V. S., Nargund, V. B., Kumar, R. A. and Yalpur, P. S. 2011. Leaf disease grading by machine vision and fuzzy logic. *Int. J. Comput. Technol. Appl.* 2: 1709-1716.
- Scherm, H., Ngugi, H. K. and Ojiambo, P. S. 2006. Trends in theoretical plant epidemiology. *Eur. J. Plant Pathol.* 115: 61-73.
- Schmidhuber, J. and Tubiello, F. N. 2007. Global food security under climate change. *Proc. Natl. Acad. Sci. U. S. A.* 104: 19703-19708.
- Schönfeld, M. V., Heil, R. and Bittner, L. 2018. Big data on a farm: smart farming. In: *Big Data in Context*, eds. by T. Hoeren and B. Kolany-Raiser, pp. 109-120. Springer, Cham, Switzerland.
- Seo, Y. J. 2016. Korea's smart agriculture status and major challenges. *World Agric.* 185: 51-71. (In Korean)
- Shtienberg, D. 2013. Will decision-support systems be widely used for the management of plant diseases? *Annu. Rev. Phytopathol.* 51: 1-16.
- Sonka, S. 2015. Big Data: from hype to agricultural tool. *Farm Policy J.* 12: 1-9.
- Sperschneider, J. 2019. Machine learning in plant-pathogen interactions: empowering biological predictions from field scale to genome scale. *New Phytol.* 228: 35-41.
- Stubbs, M. 2016. Big Data in U.S. Agriculture. Report R44331. Congressional Research Service, Washington, DC, USA. 14 pp.
- Surendrababu, V., Sumathi, C. P. and Umamathy, E. 2014. Detection of rice leaf diseases using chaos and fractal dimension in image processing. *Int. J. Comput. Sci. Eng.* 6: 69-74.
- Tantalaki, N., Souravlas, S. and Roumeliotis, M. 2019. Data-driven decision making in precision agriculture: the rise of Big Data in agricultural systems. *J. Agric. Food Inf.* 20: 344-380.
- Too, E. C., Yujian, L., Njuki, S. and Yingchun, L. 2019. A comparative study of fine-tuning deep learning models for plant disease identification. *Comput. Electron. Agric.* 161: 272-279.
- Tripathy, A. K., Adinarayana, J., Vijayalakshmi, K., Merchant, S. N., Desai, U. B., Ninomiya, S. et al. 2014. Knowledge discovery and leaf spot dynamics of groundnut crop through wireless sensor network and data mining techniques. *Comput. Electron. Agric.* 107: 104-114.
- United Nations Economic Commission for Europe. 2013. Classification of types of big data. URL <http://www1.unece.org/stat/platform/display/bigdata/Classification+of+Types+of+Big+Data> [2 August 2016].
- Vashi, S., Ram, J., Modi, J., Verma, S. and Prakash, C. 2017. Internet of Things (IoT): a vision, architectural elements, and security issues. In: 2017 International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud) (I-SMAC), pp. 492-496. Institute of Electrical and Electronics Engineers, New York, USA.
- Verhoosel, J., van Bekkum, M. and Verwaart, T. 2016. HortiCube: a platform for transparent, trusted data sharing in the food supply chain. In: *Proceedings in System Dynamics and Innovation in Food Networks 2016*, eds. by G. Schiefer and U. Rickert, pp. 384-388. Universitat Bonn-ILB Press, Bonn, Germany.
- Vogt, W. 2013. Looking at big data one plant at a time. *Farm Industry News*. URL <http://farministrynews.com/blog/looking-big-data-one-plant-time> [7 May 2015].
- Wahabzada, M., Mahlein, A.-K., Bauckhage, C., Steiner, U., Oerke, E.-C. and Kersting, K. 2015. Metro maps of plant disease dynamics: automated mining of differences using hyperspectral images. *PLoS ONE* 10: e0116902.
- Weersink, A., Fraser, E., Pannell, D., Duncan, E. and Rotz, S. 2018. Opportunities and challenges for big data in agricultural and environmental analysis. *Annu. Rev. Resour. Econ.* 10: 19-37.
- Wetterich, C. B., Kumar, R., Sankaran, S., Junior, J. B., Ehsani, R. and Marcassa, L. G. 2013. A comparative study on application of computer vision and fluorescence imaging spectroscopy for detection of citrus huanglongbing disease in USA and Brazil. In: *Frontiers in Optics 2013/Laser Science*, pp. JW3A-26. Optical Society of America, Washington, DC, USA.
- Wolfert, S., Ge, L., Verdouw, C. and Bogaardt, M.-J. 2017. Big data in smart farming: a review. *Agric. Syst.* 153: 69-80.
- World Meteorological Organization. 2010. Guide to Agricultural Meteorological Practices. World Meteorological Organization No. 134. World Meteorological Organization, Geneva, Switzerland. 799 pp.
- Yan, J., Risacher, S. L., Shen, L. and Saykin, A. J. 2018. Network approaches to systems biology analysis of complex disease: integrative methods for multi-omics data. *Brief. Bioinform.* 19: 1370-1381.
- Yang, X. and Guo, T. 2017. Machine learning in plant disease research. *Eur. J. BioMed. Res.* 3: 6-9.
- Yeo, H. 2019. Overseas agricultural big data utilization status. *World Agric.* 266: 37-52. (In Korean)