

(19) 대한민국특허청(KR)  
(12) 공개특허공보(A)(11) 공개번호 10-2025-0095984  
(43) 공개일자 2025년06월27일

(51) 국제특허분류(Int. Cl.)

G06Q 50/02 (2024.01) A01G 7/00 (2019.01)  
G01S 13/88 (2006.01) G06N 3/0464 (2023.01)  
G06N 3/08 (2023.01) G06Q 50/10 (2012.01)  
H02S 10/40 (2014.01) H02S 20/30 (2014.01)

(52) CPC특허분류

G06Q 50/02 (2024.01)  
A01G 7/00 (2019.02)

(21) 출원번호 10-2023-0186746

(22) 출원일자 2023년12월20일

심사청구일자 2023년12월20일

(71) 출원인

충남대학교산학협력단

대전광역시 유성구 대학로 99 (궁동, 충남대학교)

대한민국(농촌진흥청장)

전라북도 전주시 덕진구 농생명로 300 (중동)

(72) 발명자

조병관

대전광역시 유성구 학하로 33 학하리슈빌 학의뜰  
아파트 103-701

박은성

대전광역시 유성구 대학로 99 충남대학교, 농업생  
명과학대학 2호관 2105호

(뒷면에 계속)

(74) 대리인

이충한


전체 청구항 수 : 총 6 항

(54) 발명의 명칭 비파괴 생육정보 및 품질 측정 센서 및 알고리즘

## (57) 요약

본 발명은 비파괴 생육정보 및 품질 측정 센서 및 알고리즘에 관한 것으로 본 발명의 일 양태에 따르면, 노지에 설치되고 노지 주변의 식물의 생육정보를 취득하는 노지 거치형 발작물 모니터링 장치가 제공된다. 상기 모니터링 장치는, 본체 프레임; 본체 프레임의 하부에 배치되는 배전함; 배전함의 상측으로 본체 프레임으로부터 연장되는 지주부; 상기 지주부와 평행하게 배전함으로부터 돌출하여 상측으로 연장되는 지지대에 거치되는 태양전지; 및 상기 지주부의 상측에 고정된 라이다센서를 포함한다.

대표도 - 도5



(52) CPC특허분류

*G01S 13/88* (2013.01)  
*G06N 3/0464* (2023.01)  
*G06N 3/08* (2023.01)  
*G06Q 50/10* (2015.01)  
*H02S 10/40* (2015.01)  
*H02S 20/30* (2015.01)

(72) 발명자

**이흥석**

경상남도 밀양시 미리벌중앙로6길 41, 302호

**이성태**

경상남도 진주시 신평공원길47번길 10-3

**박진기**

경상남도 밀양시 점필재로 20 국립식량과학원

**정희정**

경상남도 밀양시 점필재로 20 국립식량과학원

**정미혜**

대구광역시 수성구 신매로 71 천마타운 225동 203호

**박기도**

경기도 수원시 권선구 수인로 126 국립식량과학원

이 발명을 지원한 국가연구개발사업

|             |                          |
|-------------|--------------------------|
| 과제고유번호      | 1395077405               |
| 과제번호        | RD009808                 |
| 부처명         | 농촌진흥청                    |
| 과제관리(전문)기관명 | 농촌진흥청                    |
| 연구사업명       | 농업정책지원기술개발사업             |
| 연구과제명       | 발작물 생육정보 및 품질 자동측정 센서 개발 |
| 기 여 율       | 1/1                      |
| 과제수행기관명     | 국립식량과학원                  |
| 연구기간        | 2021.01.01 ~ 2023.12.31  |

---

## 명세서

### 청구범위

#### 청구항 1

노지에 설치되고 노지 주변의 식물의 생육정보를 취득하는 노지 거치형 발작물 모니터링 장치에 있어서,  
본체 프레임;  
본체 프레임의 하부에 배치되는 배전함;  
배전함의 상측으로 본체 프레임으로부터 연장되는 지주부;  
상기 지주부와 평행하게 배전함으로부터 돌출하여 상측으로 연장되는 지지대에 거치되는 태양전지; 및  
상기 지주부의 상측에 고정된 라이다센서를 포함하는 것을 특징으로 하는  
노지 거치형 발작물 모니터링 장치.

#### 청구항 2

제1항에 있어서,  
상기 태양전지는 상기 지지대에 틸팅 및 수평방향으로 회전가능하게 설치된 것을 특징으로 하는 노지 거치형 발작물 모니터링 장치.

#### 청구항 3

제1항에 있어서,  
상기 태양전지를 지지하는 지지대는 상기 본체 프레임의 상부에서 전면, 후면, 좌측면, 우측면 방향으로 이동가능하게 형성된 것을 특징으로 하는 노지 거치형 발작물 모니터링 장치.

#### 청구항 4

제1항에 있어서,  
상기 라이다 센서는 주변의 작물로부터 포인트 클라우드 데이터를 취득하고, 취득된 포인트 클라우드 데이터를 생육정보를 분석하는 분석 장치로 전달하도록 구성된 것을 특징으로 하는 노지 거치형 발작물 모니터링 장치.

#### 청구항 5

청구항 5에 기재된 노지 거치형 발작물 모니터링 장치의 라이다 센서로부터 취득된 작물에 대한 포인트 클라우드 데이터를 수신하고 수신된 포인트 클라우드 데이터를 이용하여 작물의 생육정보를 분석하는 생육정보 분석 시스템에 있어서,  
상기 생육정보 분석 시스템은  
상기 포인트 클라우드 데이터를 수신하는 데이터 수신부;  
수신된 포인트 클라우드 데이터에 대해 다운샘플링 및 정규화를 수행하는 전처리부;  
상기 전처리된 포인트 클라우드 데이터를 딥러닝 기반으로 줄기-잎-이삭을 포함하는 식물 기관으로 분할하는 단계;

상기 불할된 결과를 기반으로 표현형 특성을 추출하는 단계 - 여기서 표현형 특성은 식물 높이, 식물 관 직경, 식물 치밀도, 줄기 직경, 이삭 길이 및 이삭 너비를 포함함 -;를 포함하는 것을 특징으로 하는 생육정보 분석 시스템.

## 청구항 6

제5항에 있어서,

상기 딥러닝 기반으로 줄기-잎-이삭을 포함하는 식물 기관으로 분할하는 단계는 다음의 4가지 딥러닝 모델;

- 1) 포인트넷;
- 2) PointNet++;
- 3) 포인트CNN ;
- 4) 동적 그래프 CNN(DGCNN)

중 어느 하나에 의해 수행되는 것을 특징으로 하는 생육정보 분석 시스템.

## 발명의 설명

### 기술 분야

[0001] 본 발명은 비파괴 생육정보 및 품질 측정 센서 및 알고리즘에 관한 것으로 보다 구체적으로 3D 라이다를 활용한 노지 거치형 발작물 모니터링 시스템 및 생육정보 측정 알고리즘에 관한 것으로 보다 구체적으로는 노지 재배상태의 수수 및 콩에 대한 생육정보 측정을 위한 3D 라이다를 활용한 노지 거치형 발작물 모니터링 시스템 및 생육정보 측정 알고리즘에 관한 것이다.

### 배경 기술

[0003] 최근 건강기능성 농산물로 각광을 받고 있는 잡곡에 대한 소비가 지속적으로 증가하고 있는 상황이다(1인당 연간 소비량(콩 제외), 2008년 0.5kg → 2018년 1.5kg). 2019년 국내 콩 생산량은 전년 대비 17.8%, 재배면적은 15.6%가 증가하였고, 수수가 포함된 기타 잡곡은 2020년 국내 생산량이 전년 대비 126% 증가하였고, 재배면적도 27% 증가하였다.

[0005] 잡곡은 생육기간이 쌀에 비해 비교적 짧아 다모작 작부체계를 시행할 수 있는 지역에서는 간작, 윤작이 가능해 토지 이용률을 높일 수 있는 작물이다. 산간 건조지대에서는 농지황폐화와 토양 유실에 대한 농경지 보전 효과가 크며, 건조한 기후와 추위에 대한 내성이 강해 기후 변화 대응 미래 작물로서도 가능성을 인정받고 있다.

[0007] 그러나 잡곡 등 노지 발작물의 경우, 낮은 기계화율, 취약한 생산기술, 소규모 및 다품종 위주의 생산으로 체계적인 관리체계가 미흡한 실정이며, 노동력에 소요되는 비용에 비해 소득이 낮아 재배를 기피하고 있는 경우가 많으며, 쌀 위주로 진행되어 온 양곡정책으로 잡곡에 대한 연구투자가 미흡한 실정이다.

[0009] 최근 농업현장은 4차 산업혁명의 핵심 기술이 접목되어 농작업의 무인화·지능화가 시도되고, 전통적인 농업의 투입요소인 노동력, 지식, 경험 등이 데이터 기반의 시스템으로 대체되는 스마트 농업(Smart Agriculture)으로 급격히 방향 전환을 하고 있다.

[0011] 스마트 농업기술은 주로 시설원예작물을 중심으로 보급되어왔으나 최근 노지 발작물에 스마트팜 기술의 적용이 확대되고 있다. 전체 농경지 면적의 85.6%를 차지하는 노지 작물에 대한 생육정보 측정은 대부분 수작업에 의존하고 있어 노동력과 시간이 많이 소요되며, 노지환경의 열악한 작업환경 특성상 객관적이며 지속적인 데이터 수

집이 어려운 상황이다.

[0013] 노지 발작물의 우수형질 선별을 위한 생육정보 측정을 위해 노지 재배모니터링에 대표적으로 사용되는 드론영상 촬영기술이 활용될 수 있으나 개별 작물의 세부적인 형태 정보를 모니터링 해야 하는 잡곡인 수수 및 콩 작물의 경우는 상부에서 저해상도로 촬영하는 드론영상기술의 활용이 적합하지 않다.

[0015] 또한 노지 재배상태의 수수 및 콩에 대한 생육정보 측정을 위해서는 캐노피 내부에서 엽색, 엽폭, 초장, 줄기직경, 이삭크기 등의 세부 정보를 고해상도로 측정할 수 있는 영상장치와 이를 분석할 수 있는 영상분석 기술이 수반되어야 하며 또한 수확 후 종자상태에서 기능성 성분에 따른 우수형질 신속선별을 위해서는 수수 및 콩 종자에 대한 비파괴적인 성분측정 방법의 개발이 필요한 실정이다.

[0017] 또한 현재 농업 분야에서 노지 작물 생육정보 측정을 위한 방법으로는 직접 측정, 무인기(UAV)를 활용한 영상 데이터 수집, 트랙터 등에 부착한 카메라로 인한 데이터 측정 등의 방법이 있지만 직접 측정의 경우 인력, 시간 및 비용 발생이 크며, RGB 영상을 기반으로 한 영상분석의 경우 생육정보 측정에 활용하기에는 색상 정보 및 재배 면적 등의 간략한 정보만 확인 가능해서 작물의 자세한 생육정보(초고, 엽폭, 줄기직경, 이삭의 크기 등)를 측정하기 위해서는 고해상도로 정확하게 분석하기에는 한계가 있다.

[0019] 또한 무인기 또는 트랙터 등에 부착하여 데이터를 측정하기 위해서는 반드시 사람이 해당 장비를 현장에서 운용해야 하며, 현재까지 무인기의 운용 가능 시간이 40분 정도로 지속적인 모니터링 및 데이터 측정을 하기에는 부족한 실정이다.

## 선행기술문헌

### 특허문헌

[0021] (특허문헌 0001) 대한민국 등록특허 10-2264200(공고일 2021년06월11일)

## 발명의 내용

### 해결하려는 과제

[0022] 본 발명은 전술한 문제점에 기반하여 안출된 발명으로 3D 라이다(LiDAR) 센서를 활용, 노지에 거치 가능한 시스템을 제작함으로써 농업인 및 농업 연구 인력이 노지에 직접 방문하지 않고 재배하는 작물의 실제와 유사한 3D 데이터를 확보하여 시각화함으로써 노지 작물의 생육정보 획득과 재해 등에 의한 피해 여부를 실내에서 확인할 수 있고, 피노믹스 연구에 필요한 정확하고 객관적인 영상 데이터를 확보하며, 또한 획득된 3D 영상 데이터를 활용하여 노지작물의 생육정보를 자동 측정할 수 있는 3D 라이다를 활용한 노지 거치형 발작물 모니터링 시스템 및 생육정보 측정 알고리즘을 제공하는 것을 목적으로 한다.

### 과제의 해결 수단

[0024] 전술한 과제를 해결하기 위해 본 발명의 일 양태에 따르면, 노지에 설치되고 노지 주변의 식물의 생육정보를 취득하는 노지 거치형 발작물 모니터링 장치가 제공된다. 상기 모니터링 장치는, 본체 프레임; 본체 프레임의 하부에 배치되는 배전함; 배전함의 상측으로 본체 프레임으로부터 연장되는 지주부; 상기 지주부와 평행하게 배전함으로부터 돌출하여 상측으로 연장되는 지지대에 거치되는 태양전지; 및 상기 지주부의 상측에 고정된 라이다센서를 포함한다.

- [0026] 또한 전술한 어느 하나의 양태에서, 태양전지는 상기 지지대에 틸팅 및 수평방향으로 회전가능하게 설치된다.
- [0028] 또한 전술한 어느 하나의 양태에서, 태양전지를 지지하는 지지대는 상기 본체 프레임의 상부에서 전면, 후면, 좌측면, 우측면 방향으로 이동가능하게 형성된다.
- [0030] 또한 전술한 어느 하나의 양태에서, 라이다 센서는 주변의 작물로부터 포인트 클라우드 데이터를 취득하고, 취득된 포인트 클라우드 데이터를 생육정보를 분석하는 분석 장치로 전달하도록 구성된다.
- [0032] 또한 본 발명의 다른 양태에 따르면, 전술한 노지 거치형 발작물 모니터링 장치의 라이다 센서로부터 취득된 작물에 대한 포인트 클라우드 데이터를 수신하고 수신된 포인트 클라우드 데이터를 이용하여 작물의 생육정보를 분석하는 생육정보 분석 시스템이 제공되고, 생육정보 분석 시스템은
- [0033] 상기 포인트 클라우드 데이터를 수신하는 데이터 수신부;
- [0034] 수신된 포인트 클라우드 데이터에 대해 다운샘플링 및 정규화를 수행하는 전처리부;
- [0035] 상기 전처리된 포인트 클라우드 데이터를 딥러닝 기반으로 줄기-잎-이삭을 포함하는 식물 기관으로 분할하는 단계;
- [0036] 상기 분할된 결과를 기반으로 표현형 특성을 추출하는 단계 - 여기서 표현형 특성은 식물 높이, 식물 관 직경, 식물 치밀도, 줄기 직경, 이삭 길이 및 이삭 너비를 포함함 -;를 포함한다.
- [0038] 전술한 양태에서, 딥러닝 기반으로 줄기-잎-이삭을 포함하는 식물 기관으로 분할하는 단계는 다음의 4가지 딥러닝 모델;
- [0039] 1) 포인트넷;
- [0040] 2) PointNet++;
- [0041] 3) 포인트CNN ;
- [0042] 4) 동적 그래프 CNN(DGCNN) 중 어느 하나에 의해 수행될 수 있다.

### 발명의 효과

- [0044] 본 발명의 실시예에 따르면, 3D 라이다(LiDAR) 센서를 활용, 노지에 거치 가능한 시스템을 제작하고, 농업인 및 농업 연구 인력이 노지에 직접 방문하지 않고 재배하는 작물의 실제와 유사한 3D 데이터를 확보하여 시각화함으로써 노지 작물의 생육정보 획득과 재해 등에 의한 피해 여부를 실내에서 확인할 수 있고, 피노믹스 연구에 필요한 정확하고 객관적인 영상 데이터를 확보하며, 또한 획득된 3D 영상 데이터를 활용하여 노지작물의 생육정보를 자동 측정할 수 있는 3D 라이다를 활용한 노지 거치형 발작물 모니터링 시스템 및 생육정보 측정 알고리즘을 제공하는 것이 가능하다.

### 도면의 간단한 설명

- [0046] 도 1은 본 발명의 실시예에 따른 노지 거치형 발작물 모니터링 시스템의 일례를 나타내는 도면;
- 도 2는 도 1의 노지 거치형 발작물 모니터링 시스템에서 태양전지를 지지하는 지지대의 지지구조를 나타내는 도면;
- 도 3은 도 2는 도 1의 노지 거치형 발작물 모니터링 시스템에서 배전함의 내부 구성을 나타내는 도면;

도 4는 노지 거치형 발작물 모니터링 시스템에 이용되는 라이다센서의 사양을 나타내는 도면;

도 5은 식물 표현형 형질 추출을 위해 본 발명에서 제안된 접근법의 주요 단계를 나타낸 도면;

도 6은 본 발명에서의 전체적인 방법론을 설명하기 위한 도면;

도 7은 본 발명의 실시예에서 3차원 포인트 클라우드 분할을 위한 PointNet 모델 아키텍처를 나타내는 도면;

도 8은 본 발명의 실시예에서 3D 포인트 클라우드 분할을 위한 계층적 기능 학습 PointNet++ 아키텍처를 예시하는 도면;

도 9는 본 발명의 실시예에서 3D 포인트 클라우드 분할을 위한 포인트 CNN 아키텍처를 예시하는 도면;

도 10은 본 발명의 실시예에서 3D 포인트 클라우드 분할을 위한 DGCNN 아키텍처를 예시하는 도면;

도 11은 본 발명의 실시예에서 표현형 특성 줄기를 나타내는 도면으로, (a) 수수의 본래 줄기 (b) 최소 제곱 접근법을 사용하여 직선 세그먼트를 줄기 포인트 클라우드에 맞춤 (c) 수수의 본래 이삭 (d) 타원 피팅에 슬라이딩된 이삭 포인트 클라우드의 직교 투영한 도면;

도 12는 수수 식물의 라이다 3D 포인트 클라우드 데이터를 나타내는 도면으로, (a) 원시 데이터 (b) 잡음 제거 데이터 (c) 입력 데이터를 나타낸 도면;

도 13은 주석이 달린 수수 식물로 훈련된 심층 신경망을 사용하여 분할된 수수 식물을 나타내는 도면으로, (a) Ground truth (b) 포인트넷 (c) PointNet++ (d) 포인트CNN (e) DGCNN을 나타낸 도면;

도 14는 4개의 심층 신경망을 사용하여 얻은 수수 식물의 기관(줄기-잎-이삭) 분할 결과를 시각화한 도면으로, (a) 포인트넷 (b) PointNet++ (c) 포인트CNN (d) DGCNN을 이용한 도면;

도 15는 PointNet++ 심층신경망 분할 모델과 수동 측정값을 이용하여 추출된 수수 표현형 특성의 비교하는 그래프로, (a) 식물 높이, (b) 식물 크라운 직경, (c) 식물 치밀도, (d) 줄기 직경, (e) 이삭 길이 및 (f) 이삭 너비를 나타낸 도면이다.

### 발명을 실시하기 위한 구체적인 내용

- [0047] 본 발명의 이점 및 특징, 그리고 그것들을 달성하는 방법은 첨부되는 도면과 함께 상세하게 후술되는 실시예를 참조하면 명확해질 것이다. 그러나, 본 발명은 이하에서 개시되는 실시예에 한정되는 것이 아니라 서로 다른 다양한 형태로 구현될 것이다.
- [0049] 본 명세서에서 본 실시예는 본 발명의 개시가 완전하도록 하며, 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자에게 발명의 범주를 완전하게 알려주기 위해 제공되는 것이다. 그리고 본 발명은 청구항의 범주에 의해 정의될 뿐이다. 따라서, 몇몇 실시예들에서, 잘 알려진 구성 요소, 잘 알려진 동작 및 잘 알려진 기술들은 본 발명이 모호하게 해석되는 것을 피하기 위하여 구체적으로 설명되지 않는다.
- [0051] 명세서 전체에 걸쳐 동일 참조 부호는 동일 구성 요소를 지칭한다. 그리고, 본 명세서에서 사용된(언급된) 용어들은 실시예들을 설명하기 위한 것이며 본 발명을 제한하고자 하는 것은 아니다. 본 명세서에서, 단수형은 문구에서 특별히 언급하지 않는 한 복수형도 포함한다. 또한, '포함(또는, 구비)한다'로 언급된 구성 요소 및 동작은 하나 이상의 다른 구성요소 및 동작의 존재 또는 추가를 배제하지 않는다.
- [0053] 다른 정의가 없다면, 본 명세서에서 사용되는 모든 용어(기술 및 과학적 용어를 포함)는 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자에게 공통적으로 이해될 수 있는 의미로 사용될 수 있을 것이다. 또 일반적으로 사용되는 사전에 정의되어 있는 용어들은 정의되어 있지 않은 한 이상적으로 또는 과도하게 해석되지 않는다.
- [0055] 이하 첨부된 도면을 참조하여 본 발명의 바람직한 실시예에 대해 설명한다. 도 1은 본 발명에 따른 노지 거치형 발작물 모니터링 장치(1)의 일례를 나타내는 도면이다. 도 1에 도시된 바와 같이 발작물 모니터링 장치(1)는

본체 프레임의 하부에 배치되는 배전함(30); 배전함의 상측으로 본체 프레임으로부터 연장되는 지주부(12); 상기 지주부와 평행하게 배전함(30)의 상측으로 연장되는 태양전지(20); 상기 지주부(12)의 상측에 고정된 라이다 센서(10)를 포함한다.

[0057] 상기 태양전지(20)는 도 1에 도시된 바와 같이 상하 좌우 방향으로 회전가능하게 설치되며 그로 인해 태양의 위치에 따라 최적으로 태양관을 수광할 수 있게 구성된다.

[0059] 또한 도 2에 도시된 바와 같이 태양전지(20)를 지지하는 태양전지 지지부(21) 역시 배전함(30)의 상부에서 배전함 상부에 형성된 가이드부를 따라 배전함 상부에서 4방향으로 이동가능하도록 구성되어 있다. 이는 태양전지의 각도 조절시 후면부에 위치한 지주부(12)의 그림자에 의해 태양전지의 수광효율이 떨어지는 것을 방지할 수 있으며, 태양전지가 거치된 판이 회전할 때 라이다 센서가 거치된 지주부(12)와의 간섭을 방지할 수 있게 된다.

[0061] 또한 상기 배전함(30)에는 PC, 배터리, wifi-AP, 컨트롤러, 인버터와 같은 구성요소가 설치되어 있고, 이로 인해 모니터링 장치(1)를 동작시키고 라이다센서로부터 데이터를 수집하고 수집된 데이터를 원격지의 서버 등으로 전송하는 것이 가능하도록 구성되어 있다.

[0063] 이와 같은 노지 거치형 발작물 모니터링 장치(1)는 생육정보 취득이 필요한 노지 등에 설치되고 라이다 센서(10)는 설치된 장소의 작물의 3D 포인트 클라우드 정보를 수집한다. 3D LiDAR 포인트 클라우드는 Leica BLK360 이미징 스캐너(Leica Geosystems, Heerbrugg, Switzerland)를 사용하여 획득될 수 있으며 사용된 LiDAR 시스템의 기술 사양은 도 4에 도시된 바와 같다.

[0065] A. 실험의 설계 및 데이터 획득

[0066] 라이다 센서를 이용한 작물의 생육 정보 측정을 위해, 실험은 수수 식물에 대해 수행되었다. 이들 식물은 충남 대학교 생장실(온실)에서 재배되었다. 잘 심어진 수수 총 140개를 선별하여 화분에 이식되었다. 모든 연구 샘플의 3D LiDAR 포인트 클라우드는 전술한 바와 같은 Leica BLK360 이미징 스캐너(Leica Geosystems, Heerbrugg, Switzerland)를 사용하여 획득되었다.

[0068] 수수 식물의 3차원 포인트 클라우드와 수동으로 측정된 표현형 특성은 실내 조건에서 획득되었습니다. 포인트 클라우드 데이터와 RGB 이미지를 촬영한 후 식물 표현형 특성을 표준 기술을 사용하여 수동으로 측정하여 접근 방식의 성능을 평가했다. 당일 실측 데이터도 수집됐다.

[0070] 식물의 높이는 줄자를 사용하여 토양에서 나오는 줄기부터 식물의 꼭대기 위치까지 측정되었다. 식물 크라운 직경은 줄자를 사용하여 측정되었다. 이삭의 길이는 줄자를 사용하여 줄기의 꼭대기부터 이삭의 꼭대기까지 측정하였다. 줄기 직경과 이삭 폭은 줄기 부분에서 캘리퍼를 사용하여 측정되었다. 식물 기관 분할 및 식물 표현형 특성을 결정하기 위해 3D LiDAR 포인트 클라우드 데이터 처리 단계가 개발되었다. 도 5는 본 발명에서 제안된 접근 방식의 전반적인 작업 흐름을 나타낸다.

[0072] B. 포인트 클라우드 데이터 전처리

[0073] 다운샘플링된 포인트 클라우드는 연구 식물의 표현형 특성을 유지하고 식물 표현형 특성을 효율적으로 얻기에 충분하다는 것이 관찰되었다. 입력 포인트 클라우드 데이터는 다운샘플링 후 정규화되었다. 기능 스케일링 또는 정규화는 컴퓨터 비전 기반 알고리즘에서 필수적인 전처리 단계이다. 이는 정보 손실을 초래하지 않고 공통 경계 내의 모든 기능을 포함하기 때문이다.

- [0075] 포인트 클라우드에 주석을 추가하는 것은 데이터에 레이블을 지정하고 효율적인 모델 교육을 가능하게 하므로 식물 기관 분할에 딥 러닝을 적용하는 데 매우 중요하다. 대규모 플랜트 포인트 클라우드에 포인트별로 주석을 다는 것은 시간 집약적인 프로세스이며 현재 사용자 친화적인 주석 도구 키트가 부족하다. 다양한 수수 식물 기관을 분할하기 위한 레이블이 지정된 데이터셋을 준비하기 위해 입력 포인트 클라우드에 대해 포인트별 주석을 수행했다.
- [0077] 도 6은 본 발명에서 제안된 접근법을 나타내고 있다. 각 수수 식물의 잎, 줄기, 이삭 도 6(주석이 있는 점군)에 설명된 대로 클라우드비교 소프트웨어의 세그먼트 모듈을 사용하여 각각 0,1, 2 수동으로 레이블을 지정했다. 제안된 접근 방식은 다음 네 가지 섹션으로 구성된다.
- [0078] 1) 포인트 클라우드 데이터 전처리 및 주석;
- [0079] 2) 딥러닝 기반 식물 기관(줄기-잎-이삭) 분할;
- [0080] 3) 표현형 특성 추출; 및
- [0081] 4) 정확성 평가
- [0083] C. 3D 포인트 클라우드 기반 딥러닝 아키텍처
- [0084] 본 발명에서는 수수 식물의 기관(줄기-잎-이삭) 분할 문제에 3D 포인트 클라우드를 기반으로 한 주목할만한 네 가지 딥러닝 모델을 적용했다. 그 모델은 다음과 같다.
- [0085] 1) 포인트넷;
- [0086] 2) PointNet++;
- [0087] 3) 포인트CNN ;
- [0088] 4) 동적 그래프 CNN(DGCNN).
- [0090] 피쳐 및 레이어 수와 로컬 영역의 반경과 같은 기타 하이퍼 매개변수를 포함한 4개 네트워크의 설계 매개변수는 초기에 실내 위치 장면이 포함된 3D 포인트 클라우드 데이터셋에 대한 기본 설정으로 설정되었다. 이러한 매개변수를 조정하는 표준 절차는 검증 세트에서 다양한 설정을 실험하여 가장 좋은 성능을 내는 설정을 찾는 것이다. 본 발명에서 각 레이어의 특징 추출 및 하이퍼 매개변수를 포함하여 4개 모델 모두의 기본 아키텍처 설정이 식물 기관 분할 중에 변경되지 않은 상태로 유지되었다. 식물 데이터에서 잘 작동하려면 3D 포인트 기반 아키텍처를 생성하는 동안 식물의 자기유사성 및 다중 규모 특성을 고려해야 한다.
- [0092] 아키텍처는 계층적 순서로 네트워크의 다양한 수용 필드를 지원해야 하며, 그 크기는 다양한 플랜트 구조의 규모에 맞게 조정될 수 있도록 간단해야 한다. 3D 포인트 클라우드의 로컬 기하학적 구조를 인코딩하는 과제에 대한 이러한 딥 러닝 아키텍처의 두드러진 접근 방식은 다음 섹션에서 설명된다. 최상의 결과를 산출한 아키텍처의 매개변수가 제시된다.
- [0094] 1) PointNet:
- [0095] PointNet은 원본 포인트 클라우드를 입력데이터로 바로 사용하는 알고리즘으로, 각 3D점의 x, y, z 좌표가 매개변수를 공유하는 MLP(multi layer perceptron)에 의해 개별적으로 고차원 feature로 변환된다. 완벽히 연결된 (fully connected) MLP와 관련된 모든 포인트의 feature는 단일 최대 풀링 (single maximum pooling)을 통해 요약된다. Single global feature 벡터로 인한 결과를 통해 입력 포인트 클라우드를 설명할 수 있다. 포인트를 기반으로 하는 개별 기능은 이 feature 벡터에서 연결되고 후속 레이어에서 처리된다. 공유 가중치가 있는 MLP 레이어는 연결된 기능에 사용되어 각 포인트에 대한 클래스 점수를 결정합니다.

- [0097] 도 7은 3차원 포인트 클라우드 데이터 분할을 위한 PointNet 아키텍처를 나타낸다. 3D 포인트 클라우드 데이터의 segmentation에 사용된 PointNet의 구조를 나타낸다. PointNet 구조는 여러 MLP 레이어를 통해 점별로 독립적으로 feature를 학습하고 max-pooling layer를 사용하여 global feature를 추출한다. PointNet의 각 포인트는 feature를 독립적으로 학습하므로, 최종 예측은 주로 local 기하학적 구조의 구성보다는 포인트의 위치에 의해 영향을 받는다. 따라서, 각 포인트 사이의 local 기하학적 구조에 대한 정보를 받을 수는 없다.
- [0099] 2) PointNet++ :
- [0100] PointNet++는 각 포인트의 상세한 기하학적 구조를 확인할 수 있는 딥러닝 모델이다. 이 모델은 글로벌(global) 수준이 아닌 서로 다른 1로컬 스케일(local scale)에서 포인트를 기반으로 피쳐(feature)를 요약하도록 설계된 알고리즘이다. 입력 포인트 클라우드는 PointNet 구조가 사용되는 겹치는 로컬(local) 영역으로 나뉘어 로컬 이웃(local neighborhood)의 기하학적 구조를 캡처하는 피쳐벡터가 생성된다. 특징 추출 및 그룹화는 계층적 구조에 따라 진행된다. PointNet++의 구조는 set abstraction (SA) layer, feature propagation (FP) layer 두 종류의 계층으로 이루어지며, 샘플링과 그룹화가 SA 계층의 두 단계이다.
- [0101] 샘플링 단계에서 F개의 대표점을 선택하기 위해 가장 먼 점 샘플링 알고리즘이 사용되었다. 정의된 반경 R을 가진 지역 이웃은 그룹화 단계에서 각 대표 지점 주위에 생성되었다. 결과적으로 로컬 그룹이 겹쳐진다. M개의 포인트를 무작위로 선택하여 이 동네에 그룹을 형성했다. PointNet 아키텍처는 그룹의 모든 포인트에 걸쳐 요약된 특징을 추출하기 위해 각 그룹에 개별적으로 사용되었다.
- [0102] 입력 포인트 클라우드의 원본 포인트에 대한 그룹 기반의 특징 벡터가 FP 레이어를 통해 전파되었다. 한 지점의 가장 가까운 이웃의 특징으로부터 보간을 사용하여 해당 지점에 특징을 전파했다. SA 단계에서 보간된 특징과 기존 특징을 통합하여 각 포인트의 특징을 수정하기 위해 PointNet 아키텍처를 적용했다. 도 8는 3차원 포인트 클라우드 데이터 분할을 위한 PointNet++ 아키텍처를 나타낸다. 집합 추상화 계층은  $N \times (d + C)$  행렬을 입력으로 사용한다. 여기서 N은 샘플 포인트 수를 나타내고, d는 포인트 좌표의 차원, C는 포인트 특징의 차원, K는 중심점 인근에 있는 포인트 수를 나타낸다.
- [0104] PointCNN:
- [0105] PointCNN:는 포인트 클라우드 데이터의 공간적 로컬 상관 관계를 활용하는 CNN의 일반화이다. X-Conv로 정의된 컨볼루션 연산자가 PointCNN 아키텍처에 제시되었다. 이 연산자는 표준 컨볼루션이 처리하기 전에 이웃의 입력 포인트 특성에 가중치를 부여하고 순열한다. X-Conv 프로세스에서  $K \times K$  크기의 변환 행렬은 MLP를 사용하여 K개의 최근접 이웃 포인트에 대해 예측되었다.
- [0107] 그런 다음 변환된 특징을 위해 표준 컨볼루션 레이어가 사용되었다. 대표점은 컨볼루션을 위한 넓게 열린 필드를 정의하기 위해 가장 먼 점 샘플링 알고리즘을 사용하여 생성되었다. 그리고 X-conv 오퍼레이터에서 등장한 특징들은 이러한 대표점들로부터 축적되었다. 포인트가 요인에 의해 확장되고 X-conv 연산자가 계층적으로 적용되면 결과 포인트 특징이 더 적은 포인트로 누적되어 더 넓은 공간 영역을 나타낸다. 분할을 위한 포인트 특징을 처리하기 위해 인코더-디코더 구조가 사용되었다. 도 9는 3차원 포인트 클라우드 데이터 분할을 위한 PointCNN 모델의 아키텍처를 보여준다. 컨볼루션에 사용된 최근접 이웃 수는 K로 표시되었고, 샘플링된 포인트 수는 N으로 표시되었으며, 포인트 팽창률은 D로 표시되었다.
- [0109] 4) Dynamic Graph CNN (DGCNN):
- [0110] 이 아키텍처는 PointNet++에서 수행하는 개별 그룹화 프로세스 대신 3D 포인트의 로컬 이웃 정보를 네트워크 내에 직접 통합하도록 설계되었다. 그래프 구조는 한 지점의 지역적 이웃을 나타내는 데 사용되었다.
- [0112] EdgeConv 기술을 사용하여 점과 K-최근접 이웃 사이의 공간적 상관관계를 인코딩하기 위해 모서리 특징을 추출했다. 점 위치 대신 모서리 표현에 사용된 MLP를 사용하여 모서리 특징을 추출했다. 기존 그리드에서 사용되는

CNN 구조와 달리 고정 그래프는 적용되지 않았다. 각 레이어에서 포인트 피처의 K개 이웃이 변경되었다. 따라서 그래프가 업데이트되었다. 가장 가까운 이웃 점 사이의 기하학적 근접성은 아키텍처의 첫 번째 레이어에서만 고려되었다.

다음 레이어에서 에지 표현은 특징 공간에서 서로 가까운 가장 가까운 이웃 사이에서 구성되었다. 그러나 이는 특징 공간의 근접성에 대한 정보를 전파하는 데 유리했다. DGCNN에는 다중 규모 계층 구조의 로컬 공간 그룹화가 존재하지 않는다. 로컬 기하학의 구조는 극도로 국부적인 수준, 즉 포인트의 가장 가까운 이웃 내에서만 캡처되었다.

도 10은 3차원 포인트 클라우드 데이터 분할을 위한 DGCNN 모델의 아키텍처를 나타낸다.

#### D. 세그멘테이션의 성능 평가

각 딥러닝 모델의 세그멘테이션(segmentation) 결과에 대한 정량적 평가는 실측데이터를 사용하여 수행하였다. 수수 식물체별로 식물의 줄기-잎 segmentation 결과를 조사하였다. 잎은 positive 클래스로, 줄기는 negative 클래스로 하였다. 잎의 point가 올바르게 segmentation 된 경우 true positive(TP<sub>c</sub>), 줄기가 잎으로 잘못 segmentation 되었을 경우 false positive(FP<sub>c</sub>), 잎이 잘못 segmentation 되어 줄기로 표기될 경우 false negative(FN<sub>c</sub>)로 나타낸다. 위의 지표를 통해 Recall (R<sub>c</sub>), precision (P<sub>r</sub>), Intersection over Union (IoU), F1-score (F)를 구하였고 각각의 식은 다음과 같이 구했다.

$$R_c = \frac{TP_c}{TP_c + FN_c} \quad (1)$$

$$P_r = \frac{TP_c}{TP_c + FP_c} \quad (2)$$

$$IoU = \frac{TP_c}{TP_c + FN_c + FP_c} \quad (3)$$

$$F = \frac{2P_r R_c}{P_r + R_c} \quad (4)$$

$$\text{전체 정확도}_{(Acc)} = \frac{\text{올바르게 segmentation 된 포인트 수}}{\text{샘플 개체의 총 포인트 수}} \quad (5)$$

#### E. 표현형 특성 측정(Phenotypic Trait Measurement)

분할된 식물 기관(줄기-잎-이삭) 지점을 사용하여 개별 수수 식물 수준에서 표현형 특성을 측정했다. 분할된 포인트 클라우드에서 식물 높이, 크라운 직경, 식물 소형화, 줄기 직경, 이삭 길이 및 이삭 폭 등 6가지 표현형 특성을 측정했다.

포인트 클라우드 데이터에서 식별할 수 있는 형태학적 특성에는 1) 전체적인 표현형 특성과 2) 구성 요소 표현형 특성이라는 두 가지 유형이 있다. 전체적인 표현형 특성은 식물 높이, 크라운 직경 및 식물 소형화와 같은 전체 식물 구조를 평가한다. 구성 요소 표현형 특성은 줄기 직경, 이삭 길이, 이삭 너비와 같은 개별 식물 기관을 검사한다. 수수 식물의 높이는 포인트클라우드의 좌표값인 최대값과 최소값(식물 줄기가 토양에서 나옴) z의 차이를 사용하여 계산되었다. 유사하게, 수수이삭의 분할된 포인트 클라우드의 최대 및 최소 z 좌표값의 차이를 이용하여 이삭 길이를 계산하였다. 식물 높이(H)와 이삭 길이는 다음 방정식을 사용하여 추정할 수 있습니다.

$$H = z_{\max} - z_{\min}. \quad (6)$$

포인트 클라우드의 x좌표값의 최대값과 최소값의 차이를 이용하여 수수의 수관직경을 추정하였다. 크라운 직경(Cd)은 다음과 같이 계산할 수 있습니다.

$$C_d = x_{\max} - x_{\min}. \quad (7)$$

수수 식물의 식물 치밀도는 식물 수관 직경을 식물 높이로 나누어 결정되었다. 식물 치밀도(Cp)는 다음과 같이 계산할 수 있다.

$$C_p = \frac{C_d}{H}. \quad (8)$$

줄기 직경은 다음 단계를 사용하여 계산되었다.

- 1) 도 11의 (a) 및 (b)와 같이 최소자승법을 이용하여 줄기 포인트 클라우드에 직선분할을 맞추었다. 선분의 길이는 줄기 높이와 동일했다.
- 2) 줄기 포인트부터 선분까지의 모든 투영거리를 계산하였다.
- 3) 이 거리의 중앙값을 결정했다.
- 4) 마지막으로 중앙값의 두 배를 사용하여 줄기 직경을 계산했다.

세그먼트된 수수 이삭(panicle) 포인트 클라우드에서는 반밀집 이삭의 형태로 인해(도 11의 (c) 참조) 이삭의 폭을 측정하기 위해 각 조각의 두께가 1 cm인 4개의 이삭 조각을 사용하였다.

이삭 폭은 이삭의 대략 타원형 단면을 기준으로 추정되었다. 따라서 각 이삭 조각의 포인트 클라우드는 도 11의 (d)와 같이 YZ 평면에 직각으로 투영되었다.

그런 다음 OpenCV 라이브러리의 내장 기능을 사용하여 투영된 포인트 클라우드에 타원 피팅 작업을 적용했다. 이 함수는 먼저 윤곽선을 찾은 다음 대수적 분리를 제약 조건으로 줄여 타원을 근사화한다. 적합 타원의 장축은 타원형 단면의 장축을 따른 이삭 폭을 나타낸다(도 11의 (d)참조). 따라서 이삭 너비는 모든 이삭 조각 타원의 주요 축을 평균하여 결정될 수 있다.

#### F. 표현형 형질 추출 평가(Phenotypic Trait Extraction Evaluation)

딥러닝 분할 모델에서 파생된 측정과 추출된 모든 표현형 특성에 대한 수동 측정 간에 선형 회귀 분석이 수행되었다. 추출된 표현형 형질의 정량적 정확성을 알아보기 위해 RMSE(root-mean-square error), MAPE(mean absolute percentage error), 결정계수(R<sup>2</sup>) 통계치를 계산하였다.

RMSE는 예측된 식물 표현형 특성과 수동으로 측정된 식물 표현형 특성 간의 변화를 추정한다. MAPE는 모델의 정확도를 측정하고 R<sup>2</sup>는 예측된 식물 표현형 특성과 수동으로 측정된 식물 표현형 특성 간의 선형 관계를 평가한다. 이러한 통계 매개변수는 다음과 같이 계산되었다.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_i - \hat{x}_i)^2}{n}} \quad (9)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{x_i - \hat{x}_i}{x_i} \right| \quad (10)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (x_i - \hat{x}_i)^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (11)$$

여기서  $n$ 은 비교할 식물의 총 수,  $x_i$ 는 수동으로 측정한 값,  $\hat{x}_i$ 는  $i$ 번째 식물에 대한 딥러닝 분할 모델에서 예측한 표현형 특성의 값,  $\bar{x}$ 는 수동으로 측정한 결과의 평균을 나타낸다.

도 12는 수수 식물의 라이다 3D 포인트 클라우드 데이터를 나타내는 도면으로 (a)는 원 데이터 (b)는 디노이즈된 데이터 (c)는 입력데이터를 나타낸다.

도 9의 (a)에 도시된 원본 입력 포인트 클라우드 데이터는 open 3d의 통계적 이상치 제거 도구를 사용하여 노이즈를 제거했다. 수수 식물의 노이즈 제거된 포인트 클라우드는 도 9의 (b)에 도시되고 있으며, 입력 데이터는 도 9의 (c)에 도시되었다.

\* 줄기-잎-이삭 분할

4가지 딥러닝 모델(PointNet, PointNet++, PointCNN 및 DGCNN)이 수수 식물을 기관(줄기-잎-이삭)으로 분할하기 위해 테스트되었다. 각 레이어의 특징 추출을 포함한 기본 아키텍처 설정은 실험 중에 변경되지 않았다. PointNet, PointNet++, PointCNN 및 DGCNN은 각각 100, 201, 100 및 20 에포크(epochs)로 훈련되었다. 학습률은 PointNet, PointNet++, DGCNN의 경우 0.001이고 PointCNN의 경우 0.000001입니다. 데이터의 배치 크기는 PointNet, PointCNN 및 DGCNN의 경우 8이고 PointNet++의 경우 32이다.

4개의 딥러닝 모델은 모두 데이터 확대를 통해 500개의 수수 식물에서 생성된 800개의 훈련 샘플로 구성된 수동으로 레이블이 지정된 데이터 세트를 사용하여 훈련되었다. 48개의 개별 수수 식물로 구성된 테스트 세트를 사용하여 분할 결과를 평가했습니다. PointNet 모델의 훈련 시간은 약 2시간이었고 테스트 세트의 예측 시간은 약 25분이었습니다. 마찬가지로 PointNet++는 훈련에 약 3시간, 테스트 세트를 예측하는 데 약 30분이 필요했다. 반면 PointCNN은 훈련에 약 3시간 15분이 걸렸고, 테스트 세트의 예측 시간은 약 30분이었다. 마지막으로 DGCNN은 테스트 세트를 예측하는 데 약 3시간 35분, 약 45분의 훈련 시간이 소요되었다.

PointNet과 PointNet++는 개별 포인트 클라우드를 독립적으로 처리하도록 설계되었기 때문에 상대적으로 추론 시간이 빠르다. 마찬가지로 PointCNN은 포인트 클라우드로부터 공간적으로 지역적인 상관 관계를 만든다. 따라서 DGCNN보다 추론 시간이 상대적으로 빠르다. 대조적으로, DGCNN은 포인트 클라우드의 지역적 이웃을 고려하고 공간적 관계를 포착하기 위해 그래프 구조를 구축한다. 따라서 DGCNN은 다른 모델보다 더 복잡한 계산을 포함하므로 추론 시간이 약간 더 오래 걸린다. 세분화 결과는 Intel (R) Xeon (R) Gold 6230 CPU @ 2.10 GHz × 80, 256 GB RAM 및 GPU당 NVIDIA RTX TITAN 24 GB 4개를 갖춘 워크스테이션에서 수행되었다.

정량적 지표로 얻은 48개 수수 시험장을 대상으로 4가지 딥러닝 모델을 모두 활용한 세분화 성능평가 결과를 표 2에 나타내었다.

[표 2] 테스트 세트의 줄기-잎-이삭 분할을 위한 4가지 서로 다른 3D 포인트 기반 딥러닝 네트워크의 정확도 평가

| Segmentation evaluation |      | PointNet | PointNet++ | PointCNN | DGCNN |
|-------------------------|------|----------|------------|----------|-------|
| $R_e$                   | Min  | 92.8     | 94.4       | 93.5     | 92.4  |
|                         | Max  | 94.6     | 95.3       | 94.8     | 94.2  |
|                         | Mean | 93.7     | 94.9       | 94.2     | 93.3  |
| $P_r$                   | Min  | 82.1     | 93.5       | 90.2     | 87.3  |
|                         | Max  | 85.8     | 94.8       | 92.4     | 89.4  |
|                         | Mean | 84.0     | 94.2       | 91.3     | 88.4  |
| $F$                     | Min  | 87.2     | 94.3       | 91.6     | 89.6  |
|                         | Max  | 89.4     | 95.2       | 93.3     | 91.7  |
|                         | Mean | 88.3     | 94.8       | 92.5     | 90.7  |
| $IoU$                   | Min  | 78.8     | 89.8       | 86.6     | 81.8  |
|                         | Max  | 81.5     | 91.6       | 87.3     | 85.3  |
|                         | Mean | 80.2     | 90.7       | 86.9     | 83.6  |
| $Acc$                   | Min  | 81.3     | 90.4       | 87.4     | 84.5  |
|                         | Max  | 83.2     | 92.5       | 88.3     | 86.7  |
|                         | Mean | 82.3     | 91.5       | 87.9     | 85.6  |

[0168]

[0170] 수수 작물 테스트 데이터의 PointNet 분할 결과, 평균 재현율, 정밀도, F1-score, IoU 및 줄기-잎-이삭 분할에 대한 정확도는 각각 93.7%, 84.0%, 88.3%, 80.2%, 82.3% 였다.

[0172] 마찬가지로, 테스트 세트의 PointNet++ 분할 결과, 평균 재현율, 정밀도, F1-점수, IoU 및 줄기-잎-이삭 분할의 정확도는 각각 94.9%, 94.2%, 94.8%, 90.7%, 91.5% 였다.

[0174] 마찬가지로 테스트 세트의 PointCNN 분할 결과, 평균 재현율, 정밀도, F1-점수, IoU 및 줄기-잎-이삭 분할의 정확도는 각각 94.2%, 91.3%, 92.5%, 86.9% 및 87.9% 였다.

[0176] 그리고 테스트 세트의 DGCNN 분할 결과, 평균 재현율, 정밀도, F1-점수, IoU 및 줄기-잎-이삭 분할의 정확도는 각각 93.3%, 88.4%, 90.7%, 83.6%, 85.6% 였다.

[0178] 800개의 수수 식물로 훈련된 4가지 딥 러닝 모델 모두에 대한 테스트 식물의 분할 결과가 도 13에 도시되어 있다. 예측된 출력 줄기-잎-이삭 분할 결과는 주석이 달린 실제 테스트 플랜트와 상관관계가 있다.

[0180] PointNet++와 PointCNN의 정밀한 분할 결과는 약간의 차이를 보인 반면, PointNet과 DGCNN은 줄기에서 잎이 자라는 식물의 윗부분 근처에서 상당한 변화를 보였다.

[0182] 도 14은 딥러닝 분할 네트워크에서 얻은 수수 식물의 기관(줄기-잎-이삭) 분할 결과를 시각화한 도면이다.

[0183] 수수 식물 기관(줄기-잎-이삭) 분할은 LiDAR 3D 포인트 클라우드 데이터에서 구성 요소 식물 표현형 특성을 추출하는 데 필수적이다. 대부분의 기존 접근 방식에서는 사용자가 임계값과 맞춤형 특징을 정의하고, 이러한 임계값을 기반으로 장기를 분할하기 위한 경험적 규칙이 구성된다. 본 발명에서 활용된 4가지 딥러닝 모델은 다양한 모양과 크기의 수수 식물 수를 포함하는 LiDAR 3D 포인트 클라우드 데이터에서 식물 기관을 직접 분할할 수 있다. 사용자 정의 임계값과 경험적 규칙을 사용하는 대신 이 모델은 포인트 기반 네트워크로 식물 기관을 분할한다. 줄기-잎-이삭 분할에 사용되는 모델은 시간이 많이 소요되는 임계값 보정을 요구하지 않고 허용 가능한 결과를 자동으로 추정했기 때문에 기존 방법보다 선호될 수 있다. 줄기 직경이나 이삭 길이 및 너비의 차이, 잎의 광범위한 곡률을 포함한 클래스 내 기하학적 불일치를 비롯한 클래스 내 크기 차이를 설명하려면 여러 척도

에서 특징을 추출하는 접근 방식이 필수적이다. 복잡한 플랜트 구조는 서로 가까운 여러 요소를 수반하는 국지적 요소 가변성에 큰 영향을 미친다. 따라서 훈련 데이터 세트는 줄기, 잎 접촉, 이삭 등 다양한 국지적 기하학적 현상을 고려할 수 있어야 한다.

[0185] 3D LiDAR 포인트 클라우드 분할을 위해 사용된 4가지 딥 러닝 모델 모두의 이론적 기여는 다음과 같다.

[0186] 1) PointNet은 정렬되지 않은 포인트 클라우드를 처리하고, 전역 기능을 독립적으로 학습하고, 공유 가중치 MLP를 활용하고, 분할 네트워크를 통합하는 기능으로 구성된다.

[0188] 2) PointNet++는 계층적 포인트 클라우드 처리, 로컬 및 글로벌 기능 학습을 위한 SA 및 FP 모듈 도입, 적응형 기능 학습 메커니즘에 있다. 이러한 기여를 통해 PointNet++는 복잡한 기하학적 구조를 정확하게 캡처할 수 있다.

[0190] 3) PointCNN은 순서 독립적 컨벌루션 연산자, 적응형 이웃 학습, 기능 재가중화, 포인트별 학습 및 예측으로 구성된다. 이러한 기여를 통해 PointCNN은 정렬되지 않은 포인트 클라우드를 효과적으로 처리하고, 로컬 기하학적 정보를 캡처하고, 유용한 기능을 강조하고, 정확한 분할을 생성할 수 있다.

[0192] 4) DGCNN은 EdgeConv 작업을 통합하여 로컬 이웃 동적 그래프를 구성하고 점별 학습을 통해 로컬 기하학적 구조를 캡처한다. 이러한 이론적 기여는 딥 러닝 기반 분할 분야를 발전시켰으며 3D LiDAR 포인트 클라우드 데이터에서 수수 식물 기관의 정확하고 효율적인 분할을 가능하게 한다.

[0194] 본 발명에서는 식물 높이, 잎 수 및 반밀도 이삭 형태(semi-compact panicles morphology)가 서로 다른 수수 식물 기관 분할을 위해 4가지 주목할만한 딥 러닝 모델(예: PointNet, PointNet++, PointCNN 및 DGCNN)을 수행했다. 이 네 가지 모델 중에서 PointNet++가 가장 좋은 부분 분할 결과를 제공했다. 그러나 PointNet++ 분할 결과는 일반적으로 줄기-잎 교차점과 위쪽 잎 클러스터에서 포인트 클라우드로 표시된 지상 실제값과 약간 상이하다. 포인트 수준에서 PointNet 모델은 평균 정확도 82.3%로 최대 83.2%, 최소 81.3%의 줄기-잎-이삭 분할 정확도를 생성했다. 마찬가지로 PointNet++ 모델은 최대 92.5%, 최소 90.4%의 분할 정확도를 추정했으며 평균 정확도는 91.5%였다. PointCNN 모델은 최대 88.3%, 최소 87.4%의 분할 정확도를 계산했으며 평균 정확도는 87.9%였다. 마찬가지로 DGCNN은 최대 86.7%, 최소 84.5%의 분할 정확도를 측정했으며 평균 정확도는 85.6%였다.

[0196] 세 가지 딥 러닝 모델(PointNet++, PointCNN, DGCNN)의 수수 식물-기관 분할 성능은 85% 이상의 분할 평균 정확도를 제공했기 때문에 유망했다. 본 발명에서 PointNet++ 모델은 PointCNN 및 DGCNN에 비해 더 정확한 분할 결과를 제공했다. 따라서 PointNet++ 모델의 분할 결과는 표현형 특성 측정에 선택되었지만 포인트 클라우드 데이터의 복잡성과 훈련 샘플 수를 기반으로 분할 및 표현형 특성 추출을 위해 PointCNN 및 DGCNN 모델을 사용할 수도 있다.

[0198] 최적의 결과를 얻으려면 신중한 하이퍼파라미터 조정이 필요할 수 있다. 식물-기관 분할에 가장 적합한 3D 딥러닝 모델을 결정하려면 포인트 밀도, 객체의 복잡성 등 포인트 클라우드 데이터의 구체적인 특성이 필수적이다. 전반적으로, 식물 기관 분할 결과는 PointNet++ 모델이 다양한 식물 높이, 성장 주기, 잎 수 및 이삭을 가진 다양한 수수 식물에 대해 강력하다는 것을 제시한다. 하지만 PointNet++ 분할 모델에는 여전히 몇 가지 단점이 있으며, 특히 상위 리프 클러스터를 분할하는 경우 더욱 그러하다. 왜냐하면 사람의 손으로 관찰하더라도 수수줄기의 꼭대기 지점을 결정하는 것이 어렵기 때문이다. 따라서, 상단 잎 군집의 모델 분할 오류와 줄기 높이 추정은 어느 정도 허용되어야 한다.

[0200] \* 표현형 형질 추출(Phenotypic Trait Extraction)

[0201] PointNet++ 분할 결과를 기반으로 추출된 표현형 특성의 정확도 평가를 수동으로 측정한 특성 값과 비교했다. 도 15는 48개 수수 시험 식물 샘플에 대한 6가지 표현형 특성(예: 식물 높이, 식물 관 직경, 식물 치밀도, 줄기 직경, 이삭 길이 및 이삭 너비)에 대한 추출된 검증 결과를 나타낸다. 수수 식물 수준에서 식물 높이, 식물 관 직경 및 식물 치밀도의 추정 R2는 각각 0.97, 0.96 및 0.94 였다. 식물 높이, 식물 관 직경 및 식물 치밀도의 추정 RMSE는 1.07, 1.58 및 0.03cm 였다. 식물 높이, 식물 관 직경, 식물 치밀도의 추정 MAPE는 2.92, 3.76, 1.88 이었다. 수수 줄기 수준에서 줄기 직경의 추정 R2, RMSE 및 MAPE는 각각 0.90, 0.67mm 및 7.34였다. 수수 이삭 수준에서 추정된 이삭 길이와 이삭 폭의 R2는 각각 0.95와 0.88 이었다. 이삭 길이와 이삭 너비의 추정 RMSE는 0.37cm와 0.63cm 였다. 그리고 이삭 길이와 이삭 너비의 추정 MAPE는 1.11과 5.76이었다. 추출된 표현형 특성 결과, 줄기 직경과 이삭 너비에 대한 수동 측정 간의 상관관계는 중간이었고, 식물 높이, 식물 수관 직경, 식물 치밀도 및 이삭 길이 상관관계는 높았다.

[0203] 추출된 모든 표현형 특성은 식물 수준의 포인트 클라우드 분할 결과에 따라 달라진다. 추출된 표현형 형질에 대한 선형회귀분석 결과, 줄기 직경(R2 = 0.90)과 이삭 폭(R2 = 0.88)의 상관관계는 다른 4개 매개변수에 비해 약간 낮은 것으로 나타났다. 줄기의 경우, 아래에서 위로 줄기 직경 크기의 차이와 줄기-잎 접합부에서의 분할 결과로 인해 약간 낮은 상관 결과가 얻어지는 것으로 나타났다. 유사하게, 이삭의 경우, 달성된 약간 낮은 상관관계 결과는 아래에서 위로 이삭 너비와 반밀집형 이삭 형태의 차이로 인한 것일 수 있다. 시스템 기반 식물 높이, 식물 관 직경, 식물 치밀도, 줄기 직경, 수수 이삭 길이 및 수수의 이삭 폭은 추정된 R2가 0.97, 0.96, 0.94, 0.90, 0.95 및 0.88이므로 수동 측정과 각각 밀접한 상관관계가 있었다. 시스템에서 파생된 표현형 특성과 수동 측정 간의 높은 상관관계는 표현형 특성을 추출하기 위한 접근 방식의 정확성과 유용성을 검증한다.

[0205] 이 발명에서 수수 식물을 줄기, 잎 및 이삭으로 분할하기 위한 4가지 3D 포인트 클라우드 기반 딥 러닝 모델(예: PointNet, PointNet++, PointCNN 및 DGCNN)을 제시하였다. 이후, 분할된 포인트 클라우드를 이용하여 6개 수수 식물의 표현형 형질을 추출하였다. 주석이 달린 3D 포인트 클라우드 데이터 세트는 딥 러닝 네트워크 훈련에 사용되었다. 분할 결과는 PointNet 모델의 성능이 평균임을 나타냅니다. 평균 정확도 91.5%로 PointNet++ 모델이 최고의 분할 결과를 생성했다. PointNet++ 분할 모델의 이러한 완성은 다중 규모에서 특징 추출에 필요한 계층적 로컬 영역의 크기를 추정하는 단순성 때문일 수 있다. PointCNN 및 DGCNN 모델은 좋은 분할 결과를 생성했다. 그러나 포인트의 K-이웃으로 특징을 추출하기 위해 로컬 영역을 정의하는 것은 식물의 기하학적 모델을 모델링하는 데 있어 현실적이지 않다. 각 스케일에 대한 이상적인 K는 포인트의 밀도와 3D 포인트 클라우드의 식물 부분 구조 크기에 따라 달라지기 때문이다. 48개의 수수 식물 테스트 샘플에 대한 PointNet++ 모델의 분할 결과를 사용하여 6가지 표현형 특성(예: 식물 높이, 식물 크라운 직경, 식물 소형화, 줄기 직경, 이삭 길이 및 이삭 너비)이 정확하게 측정되었다. 더욱이, 모든 표현형 특성에 대한 R2 값은 0.88에서 0.97 사이였다. 수수 식물 표현형 형질 추출 결과는 본 발명에서 조사한 형질을 측정하는 데 3차원 포인트 클라우드 기반 PointNet++ 딥러닝 분할 모델이 매우 적합하다는 것을 나타내었다.

[0207] 본 개시의 다양한 실시 예들은 기기(machine)(예: 컴퓨터)로 읽을 수 있는 저장 매체(machine-readable storage media)에 저장된 명령어를 포함하는 소프트웨어로 구현될 수 있다.

[0209] 기기는, 저장 매체로부터 저장된 명령어를 호출하고, 호출된 명령어에 따라 동작이 가능한 장치로서, 개시된 실시 예들에 따른 전자 장치(예: 전자 장치(A))를 포함할 수 있다. 상기 명령이 프로세서에 의해 실행될 경우, 프로세서가 직접, 또는 상기 프로세서의 제어하에 다른 구성요소들을 이용하여 상기 명령에 해당하는 기능을 수행할 수 있다.

[0211] 명령은 컴파일러 또는 인터프리터에 의해 생성 또는 실행되는 코드를 포함할 수 있다. 기기로 읽을 수 있는 저장매체는, 비일시적(non-transitory) 저장매체의 형태로 제공될 수 있다. 여기서, '비일시적'은 저장매체가 신호(signal)를 포함하지 않으며 실재(tangible)하다는 것을 의미할 뿐 데이터가 저장매체에 반영구적 또는 임시

적으로 저장됨을 구분하지 않는다.

[0213] 일 시예에 따르면, 본 발명에 개시된 다양한 실시 예들에 따른 방법은 컴퓨터 프로그램 제품(computer programproduct)에 포함되어 제공될 수 있다. 컴퓨터 프로그램 제품은 상품으로서 판매자 및 구매자 간에 거래될 수 있다. 컴퓨터 프로그램 제품은 기기로 읽을 수 있는 저장 매체(예: compact disc read only memory (CD-ROM))의 형태로, 또는 어플리케이션 스토어(예: 플레이 스토어™)를 통해 온라인으로 배포될 수 있다. 온라인 배포의 경우에, 컴퓨터 프로그램 제품의 적어도 일부는 제조사의 서버, 어플리케이션 스토어의 서버, 또는 중계 서버의 메모리와 같은 저장 매체에 적어도 일시 저장되거나, 임시적으로 생성될 수 있다.

[0215] 다양한 실시 예들에 따른 구성 요소(예: 모듈 또는 프로그램) 각각은 단수 또는 복수의 개체로 구성될 수 있으며, 전술한 해당 서브 구성 요소들 중 일부 서브 구성 요소가 생략되거나, 또는 다른 서브 구성 요소가 다양한 실시예에 더 포함될 수 있다. 대체적으로 또는 추가적으로, 일부 구성 요소들(예: 모듈 또는 프로그램)은 하나의 개체로 통합되어, 통합되기 이전의 각각의 해당 구성 요소에 의해 수행되는 기능을 동일 또는 유사하게 수행할 수 있다. 다양한 실시예들에 따른, 모듈, 프로그램 또는 다른 구성 요소에 의해 수행되는 동작들은 순차적, 병렬적, 반복적 또는 휴리스틱하게 실행되거나, 적어도 일부 동작이 다른 순서로 실행되거나, 생략되거나, 또는 다른 동작이 추가될 수 있다.

[0217] 이상의 설명은 본 발명의 기술 사상을 예시적으로 설명한 것에 불과한 것으로, 본 발명이 속하는 기술분야에서 통상의 지식을 갖는 자라면 본 발명의 본질적인 특성에서 벗어나지 않는 범위에서 다양한 수정 및 변형이 가능할 것이다. 따라서, 본 발명에 개시된 실시예는 본 발명의 기술 사상을 한정하기 위한 것이 아닌 설명을 위한 것이고, 이런 실시예에 의하여 본 발명의 기술 사상의 범위가 한정되는 것은 아니다.


[0219] 따라서 본 발명의 보호 범위는 전술한 실시예에 의해 제한되기 보다는 아래의 청구범위에 의하여 해석되어야 하며, 그와 동등한 범위 내에 있는 모든 기술 사상은 본 발명의 권리범위에 포함되는 것으로 해석되어야 할 것이다.

## 부호의 설명


[0221] 1: 노지 거치형 발작물 모니터링 장치  
10: 라이더 센서  
20: 태양전지  
30: 배전함  
40: 본체 프레임  
12: 지주부  
21: 태양전지 지지부

도면

도면1



도면2




도면3




도면4

| Leica BLK360                                                                      |                             | Specifications                                                          |
|-----------------------------------------------------------------------------------|-----------------------------|-------------------------------------------------------------------------|
|  | Scanning unit               |                                                                         |
|                                                                                   | Wavelength                  | 830 nm                                                                  |
|                                                                                   | Operational range           | minimum 0.6m - up to 60 m                                               |
|                                                                                   | Dimensions                  | Height: 165 mm / Diameter: 100 mm                                       |
|                                                                                   | Field of View               | Horizontal 360°   Vertical 300°                                         |
|                                                                                   | Acquisition speed           | up to 360.000 points/sec                                                |
|                                                                                   | Ranging accuracy            | 4 mm @ 10 m / 7 mm @ 20 m                                               |
|                                                                                   | 3D point accuracy           | 6 mm @ 10 m / 8 mm @ 20 m                                               |
|                                                                                   | Distance measurement method | Pulse transit time with waveform digitizing                             |
|                                                                                   | Camera unit (Imaging)       |                                                                         |
|  | RGB camera system           | 15 megapixels, 3-camera system,<br>FOV: Horizontal 360°   Vertical 300° |
|                                                                                   | Thermal camera              | Thermal panoramic image,<br>FOV: Horizontal 360°   Vertical 70°         |


도면5




도면6




도면7




도면8




도면9




도면10




도면11




도면12



도면13



도면14



도면15

