(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2022-0060079
(43) 공개일자 2022년05월11일

(51) 국제특허분류(Int. Cl.)
G01N 21/88 (2006.01) *B64C 39/02* (2006.01)
G01N 21/359 (2014.01) *G01N 33/00* (2006.01)
(52) CPC특허분류
G01N 21/8851 (2013.01)
B64C 39/024 (2013.01)
(21) 출원번호 10-2020-0145312
(22) 출원일자 2020년11월03일
심사청구일자 2020년11월03일

(71) 출원인
세종대학교산학협력단
서울특별시 광진구 능동로 209 (군자동, 세종대학교)
(72) 발명자
문현준
서울특별시 서대문구 북아현로1가길 20, 101동 1506호(북아현동, e편한세상신촌 1단지)
박한용
경기도 평택시 용죽6길 64, 509동 7호(용이동, 평택비전지웰테라스)
(뒷면에 계속)
(74) 대리인
송인호, 최관락

전체 청구항 수 : 총 10 항

(54) 발명의 명칭 **무의 시들음 병 검출 방법 및 장치**

(57) 요 약

본 발명은무의 시들음 병 검출 방법 및 장치를 개시한다. 본 발명에 따르면, 프로세서 및 상기 프로세서에 연결되는 메모리를 포함하되, 상기 메모리는, 하나 이상의 드론을 통해 촬영된 무 밭에 대한 가시광 영상 및 근적외 영상을 데이터 셋으로 저장하고, 상기 가시광 영상 및 근적외 영상의 적어도 일부로부터 획득된 무, 토양 및 비닐 각각에 대한 관심 영역 데이터 셋 및 근적외 영상을 복수의 컨볼루션 레이어 및 복수의 최대 풀링 레이어를 포함하는 컨볼루션 신경망에 입력하여 상기 컨볼루션 신경망의 학습을 진행하고, 학습이 완료된 상기 컨볼루션 신경망에 무 밭에 대한 제1 가시광 영상 및 제1 근외적 영상을 입력으로 하여 무의 시들음 병을 검출하도록, 상기 프로세서에 의해 실행되는 프로그램 명령어들을 저장하는 무의 시들음 병 검출 장치가 제공된다.

대 표 도 - 도1

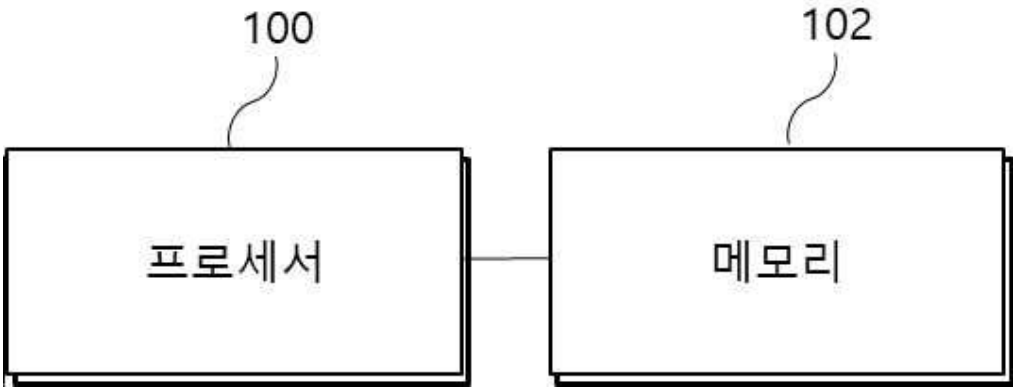

(52) CPC특허분류
G01N 21/359 (2013.01)
G01N 33/0098 (2013.01)
G06N 3/08 (2013.01)
G06T 3/4015 (2013.01)
G06T 7/0002 (2013.01)
G01N 2021/8887 (2013.01)
G06T 2207/10032 (2013.01)
G06T 2207/10048 (2013.01)
G06T 2207/20081 (2013.01)

(72) 발명자
당링민
서울특별시 광진구 능동로 209, 세종대학교 대양AI센터 810호(군자동)
남준영
인천광역시 부평구 부평문화로 138, 이안애비뉴 1차 801호(부평동)
민경복
서울특별시 서대문구 북아현로 29, 301동 801호(북아현동, 이편한세상신촌)

이 발명을 지원한 국가연구개발사업

과제고유번호	1345321135
과제번호	2020R1A6A1A03038540
부처명	교육부
과제관리(전문)기관명	한국연구재단
연구사업명	이공학학술연구기반구축(R&D)
연구과제명	자율지능무인비행체연구소
기 여 율	1/1
과제수행기관명	세종대학교 산학협력단
연구기간	2020.06.01 ~ 2021.02.28

명 세 서

청구범위

청구항 1

무의 시들음 병 검출 장치로서,

프로세서; 및

상기 프로세서에 연결되는 메모리를 포함하되,

상기 메모리는,

하나 이상의 드론을 통해 촬영된 무 밭에 대한 가시광 영상 및 근적외 영상을 데이터 셋으로 저장하고,

상기 가시광 영상 및 근적외 영상의 적어도 일부로부터 획득된 무, 토양 및 비닐 각각에 대한 관심 영역 데이터 셋 및 근적외 영상을 복수의 컨볼루션 레이어 및 복수의 최대 풀링 레이어를 포함하는 컨볼루션 신경망에 입력하여 상기 컨볼루션 신경망의 학습을 진행하고,

학습이 완료된 상기 컨볼루션 신경망에 무 밭에 대한 제1 가시광 영상 및 제1 근외적 영상을 입력으로 하여 무의 시들음 병을 검출하도록,

상기 프로세서에 의해 실행되는 프로그램 명령어들을 저장하는 무의 시들음 병 검출 장치.

청구항 2

제1항에 있어서,

상기 근적외 영상은 600 내지 1000nm 파장 범위를 갖는 무의 시들음 병 검출 장치.

청구항 3

제1항에 있어서,

상기 컨볼루션 뉴럴 네트워크는 제1 내지 제5 컨볼루션 레이어를 포함하고,

제1 컨볼루션 레이어, 제2 컨볼루션 레이어 및 제3 컨볼루션 레이어는 다른 커널 크기를 가지며, 제3, 제4 및 제5 컨볼루션 레이어는 동일한 커널 크기를 갖는 무의 시들음 병 검출 장치.

청구항 4

제2항에 있어서,

상기 복수의 최대 풀링 레이어 중 제1 최대 풀링 레이어는 상기 제2 컨볼루션 레이어 다음에 위치하고, 제2 최대 풀링 레이어는 상기 제3 컨볼루션 레이어의 다음에 위치하며, 제3 최대 풀링 레이어는 상기 제4 컨볼루션 레이어의 다음에 위치하는 무의 시들음 병 검출 장치.

청구항 5

제3항에 있어서,

상기 컨볼루션 신경망 모델은 3개의 드랍아웃 정규화를 수행하며, 제1 및 제2 드랍아웃 정규화는 동일한 제1 값을 갖고, 제3 드랍아웃 정규화는 상기 제1 값보다 큰 값을 갖는 무의 시들음 병 검출 장치.

청구항 6

제1항에 있어서,

상기 프로그램 명령어들은,

RGB 값을 갖는 상기 제1 가시광 영상을 HSV로 변환하고,

미리 설정된 임계값을 통해 상기 HSV로 변환된 영상을 이진 영상으로 변환하여 무의 시들음 병의 심각도를 판단하는 무의 시들음 병 검출 장치.

청구항 7

제6항에 있어서,

상기 프로그램 명령어들은,

상기 제1 근적외 영상을 이용하여 식생지수 NDVI(Normalized Difference Vegetation Index)를 계산하여 상기 무의 시들음 병을 검출하는 무의 시들음 병 검출 장치.

청구항 8

프로세서 및 메모리를 포함하는 장치에서 무의 시들음 병을 검출하는 방법으로서,

하나 이상의 드론을 통해 촬영된 무 밭에 대한 가시광 영상 및 근적외 영상을 데이터 셋으로 저장하는 단계;

상기 가시광 영상 및 근적외 영상의 적어도 일부로부터 획득된 무, 토양 및 비닐 각각에 대한 관심 영역 데이터 셋 및 근적외 영상을 복수의 컨볼루션 레이어 및 복수의 최대 풀링 레이어를 포함하는 컨볼루션 신경망에 입력하여 상기 컨볼루션 신경망의 학습을 진행하는 단계; 및

학습이 완료된 상기 컨볼루션 신경망에 무 밭에 대한 제1 가시광 영상 및 제1 근외적 영상을 입력으로 하여 무의 시들음 병을 검출하는 단계를 포함하는 무의 시들음 병 검출 방법.

청구항 9

제8항에 있어서,

상기 컨볼루션 뉴럴 네트워크는 제1 내지 제5 컨볼루션 레이어를 포함하고,

제1 컨볼루션 레이어, 제2 컨볼루션 레이어 및 제3 컨볼루션 레이어는 다른 커널 크기를 가지며, 제3, 제4 및 제5 컨볼루션 레이어는 동일한 커널 크기를 갖는 무의 시들음 병 검출 방법.

청구항 10

제8항에 따른 방법을 수행하는 컴퓨터 판독 가능한 프로그램.

발명의 설명

기 술 분 야

[0001] 본 발명은 무의 시들음 병 검출 방법 및 장치에 관한 것이다.

배 경 기 술

[0002] 무는 야채 생산의 10%를 차지하고 있지만 무를 감염시키는 곰팡이에 의한 Fusarium Wilt 질병(시들음 병)으로 인해 생산 비율이 현저히 감소하고 있다. 이런 문제를 해결하기 위해 오랫동안 수동으로 식물의 손상을 판단하는데 이는 많은 비용과 인적 자원이 소요되는 문제가 있다.

[0003] Fusarium Wilt 질병에 걸린 무를 자동 검출하기 위해 기존에는 많은 센서와 고해상도 카메라를 갖는 저고도 원격 감지(Low-altitude remote sensing:LARS) 장치를 사용하였다. 하지만 이러한 장치를 작은 영역을 위해 배치해야 하기 때문에 많은 비용이 든다는 문제가 있다.

[0004] 또한 무 밭이 넓어 획득한 데이터로부터 좁은 영역을 판별하기는 쉽지 않다. 자동화 시스템을 위해 획득 이미지를 분석하기 위해 딥러닝(Deep Learning) 모델인 Inception-V3, VGG-16 등 많은 모델을 사용하여 훈련한다. 하지만 질병 무를 판단하기 위해서는 이미지의 labeling, mosaic 등 처리하여 이미지의 크기를 정밀하게 나누기 때문에 이미지의 크기가 작아진다.

[0005] 다른 딥러닝 모델들의 구조에 맞춰 이미지 크기를 늘리게 되면 화질의 문제가 발생하게 되고 화질 개선을 위해

다른 알고리즘을 적용해 시간과 비용이 든다는 문제가 발생된다.

선행기술문헌

비특허문헌

[0006] (비특허문헌 0001) Ha, J.G., et al., Deep convolutional neural network for classifying Fusarium wilt of radish from unmanned aerial vehicles. Journal of Applied Remote Sensing, 2017. 11(4): p. 042621

발명의 내용

해결하려는 과제

[0007] 상기한 종래기술의 문제점을 해결하기 위해, 본 발명은 적은 시간과 비용으로 무의 질병을 정확하게 검출할 수 있는 무의 시들음 병 검출 방법 및 장치를 제안하고자 한다.

과제의 해결 수단

[0008] 상기한 바와 같은 목적을 달성하기 위하여, 본 발명의 일 실시예에 따르면, 무의 시들음 병 검출 장치로서, 프로세서; 및 상기 프로세서에 연결되는 메모리를 포함하되, 상기 메모리는, 하나 이상의 드론을 통해 촬영된 무 밭에 대한 가시광 영상 및 근적외 영상을 데이터 셋으로 저장하고, 상기 가시광 영상 및 근적외 영상의 적어도 일부로부터 획득된 무, 토양 및 비닐 각각에 대한 관심 영역 데이터 셋 및 근적외 영상을 복수의 컨볼루션 레이어 및 복수의 최대 풀링 레이어를 포함하는 컨볼루션 신경망에 입력하여 상기 컨볼루션 신경망의 학습을 진행하고, 학습이 완료된 상기 컨볼루션 신경망에 무 밭에 대한 제1 가시광 영상 및 제1 근외적 영상을 입력으로 하여 무의 시들음 병을 검출하도록, 상기 프로세서에 의해 실행되는 프로그램 명령어들을 저장하는 무의 시들음 병 검출 장치가 제공된다.

[0009] 상기 근적외 영상은 600 내지 1000nm 파장 범위를 가질 수 있다.

[0010] 상기 컨볼루션 뉴럴 네트워크는 제1 내지 제5 컨볼루션 레이어를 포함하고,

[0011] 제1 컨볼루션 레이어, 제2 컨볼루션 레이어 및 제3 컨볼루션 레이어는 다른 커널 크기를 가지며, 제3, 제4 및 제5 컨볼루션 레이어는 동일한 커널 크기를 가질 수 있다.

[0012] 상기 복수의 최대 풀링 레이어 중 제1 최대 풀링 레이어는 상기 제2 컨볼루션 레이어 다음에 위치하고, 제2 최대 풀링 레이어는 상기 제3 컨볼루션 레이어의 다음에 위치하며, 제3 최대 풀링 레이어는 상기 제4 컨볼루션 레이어의 다음에 위치할 수 있다.

[0013] 상기 컨볼루션 신경망 모델은 3개의 드랍아웃 정규화를 수행하며, 제1 및 제2 드랍아웃 정규화는 동일한 제1 값을 갖고, 제3 드랍아웃 정규화는 상기 제1 값보다 큰 값을 가질 수 있다.

[0014] RGB 값을 갖는 상기 제1 가시광 영상을 HSV로 변환하고, 미리 설정된 임계값을 통해 상기 HSV로 변환된 영상을 이진 영상으로 변환하여 무의 시들음 병의 심각도를 판단할 수 있다.

[0015] 상기 프로그램 명령어들은, 상기 제1 근적외 영상을 이용하여 식생지수 NDVI(Normalized Difference Vegetation Index)를 계산할 수 있다.

[0016] 본 발명의 다른 측면에 따르면, 프로세서 및 메모리를 포함하는 장치에서 무의 시들음 병을 검출하는 방법으로서, 하나 이상의 드론을 통해 촬영된 무 밭에 대한 가시광 영상 및 근적외 영상을 데이터 셋으로 저장하는 단계; 상기 가시광 영상 및 근적외 영상의 적어도 일부로부터 획득된 무, 토양 및 비닐 각각에 대한 관심 영역 데이터 셋 및 근적외 영상을 복수의 컨볼루션 레이어 및 복수의 최대 풀링 레이어를 포함하는 컨볼루션 신경망에 입력하여 상기 컨볼루션 신경망의 학습을 진행하는 단계; 및 학습이 완료된 상기 컨볼루션 신경망에 무 밭에 대한 제1 가시광 영상 및 제1 근외적 영상을 입력으로 하여 무의 시들음 병을 검출하는 단계를 포함하는 무의 시들음 병 검출 방법이 제공된다.

[0017] 본 발명의 또 다른 측면에 따르면, 상기한 방법을 수행하는 컴퓨터 판독 가능한 프로그램이 제공된다.

발명의 효과

[0018] 본 발명에 따르면, 가시광 영상과 근적외 영상을 동시에 이용하여 무의 시들음 병을 빠르고 정확하게 검출할 수 있는 장점이 있다.

도면의 간단한 설명

[0019] 도 1은 본 발명의 바람직한 일 실시예에 따른 무의 시들음 병 검출 장치를 도시한 도면이다.

도 2는 서로 다른 고도에서 촬영된 가시광 영상과 근적외 영상을 나타낸 것이다.

도 3은 서로 다른 지역에서 동일한 조건으로 촬영하여 획득한 가시광 영상 및 근적외 영상을 나타낸 것이다.

도 4는 가시광 영상에서 무, 토양 및 비닐에 해당하는 관심 영역을 설정한 것을 예시적으로 나타낸 도면이다.

도 5는 본 실시예에 따른 관심 영역 데이터 셋의 훈련 데이터 셋과 테스트 데이터 셋을 나타낸 것이다.

도 6은 본 발명의 일 실시예에 따른 컨볼루션 신경망을 도시한 도면이다.

도 7은 본 실시예에 따른 무의 시들음 병 검출을 위한 컨볼루션 신경망의 세부 사항을 나타낸 것이다.

도 8은 본 실시예에 따른 무의 시들음 병 검출을 위한 알고리즘을 도시한 도면이다.

도 9는 본 실시예에 따른 임계값 비교 결과를 나타낸 도면이다.

도 10은 본 발명과 종래 모델의 무 시들음 병 검출 정확도를 나타낸 것이다.

발명을 실시하기 위한 구체적인 내용

[0020] 본 발명은 다양한 변경을 가할 수 있고 여러 가지 실시예를 가질 수 있는 바, 특정 실시예들을 도면에 예시하고 상세하게 설명하고자 한다.

[0021] 그러나, 이는 본 발명을 특정한 실시 형태에 대해 한정하려는 것이 아니며, 본 발명의 사상 및 기술 범위에 포함되는 모든 변경, 균등물 내지 대체물을 포함하는 것으로 이해되어야 한다.

[0023] 본 발명은 무 밭에서 무에 해당하는 영역을 정확하게 추출하여 무 질병(Fusarium wilt)을 빠른 시간에 정확하게 검출하기 위해 데이터 셋을 구축하고, 무 질병 검출을 위해 가시광 영상과 근적외 영상을 이용하는 딥러닝 모델을 제안한다.

[0024] 도 1은 본 발명의 바람직한 일 실시예에 따른 무의 시들음 병 검출 장치를 도시한 도면이다.

[0025] 도 1에 도시된 바와 같이, 본 실시예에 따른 장치는 프로세서(100) 및 메모리(102)를 포함할 수 있다.

[0026] 여기서, 프로세서(100)는 컴퓨터 프로그램을 실행할 수 있는 CPU(central processing unit)나 그밖에 가상 머신 등을 포함할 수 있다.

[0027] 메모리(102)는 고정식 하드 드라이브나 착탈식 저장 장치와 같은 불휘발성 저장 장치를 포함할 수 있다. 착탈식 저장 장치는 컴팩트 플래시 유닛, USB 메모리 스틱 등을 포함할 수 있다. 메모리(102)는 각종 랜덤 액세스 메모리와 같은 휘발성 메모리도 포함할 수 있다.

[0028] 이와 같은 메모리(102)에는 프로세서(100)에 의해 실행 가능한 프로그램 명령어들이 저장된다.

[0029] 본 실시예에 따른 프로그램 명령어들은, 하나 이상의 드론을 통해 촬영된 무 밭에 대한 가시광 영상 및 근적외 영상을 데이터 셋으로 저장하고, 상기 가시광 영상 및 근적외 영상의 적어도 일부로부터 획득된 무, 토양 및 비닐 각각에 대한 관심 영역 데이터 셋 및 근적외 영상을 복수의 컨볼루션 레이어 및 복수의 최대 풀링 레이어를 포함하는 컨볼루션 신경망에 입력하여 상기 컨볼루션 신경망의 학습을 진행하고, 학습이 완료된 상기 컨볼루션 신경망에 무 밭에 대한 제1 가시광 영상 및 제1 근외적 영상을 입력으로 하여 무의 시들음 병을 검출한다.

[0030] 무 시들음 병은 무 잎에 노랗게 변했는지 여부를 통해 주로 검출되나, 이는 토양과 유사한 색이므로 가시광 영상만으로는 무 시들음 병을 검출하기 어려운 문제점이 있다. 이에 본 발명의 바람직한 일 실시예에 따르면, 가시광 영상과 함께 근적외 영상을 동시에 이용한다.

[0031] 여기서, 가시광 영상은 RGB 영상이고, 근적외 영상은 600 내지 1000nm 파장 범위에서 획득된 영상이다.

[0032] 본 실시예에 따른 가시광 영상 및 근적외 영상은 하나 이상의 드론이 넓은 지역의 무 밭을 촬영하여 얻어질 수 있고, 동일한 조건에서 촬영된 서로 다른 지역에 대한 영상일 수 있다.

[0033] 보다 상세하게, 가시광 영상의 획득을 위한 드론에는 RGB CMOS 카메라 센서가 장착될 수 있고, 근적외 영상의 획득을 위한 드론에는 NRG(Near Infrared, Red, Green) 필터를 갖는 카메라가 장착될 수 있다.

[0034] 여기서, NRG 필터는 520-575nm (녹색), 600-670nm (빨간색) 및 600-1030nm (NIR)의 다중 스펙트럼 이미지 획득을 위한 필터이다.

[0035] 본 실시예에 따른 데이터 셋 구축을 위해 드론이 서로 다른 고도에서 촬영을 수행한다.

[0036] 도 2는 서로 다른 고도에서 촬영된 가시광 영상과 근적외 영상을 나타낸 것이고, 도 3은 서로 다른 지역에서 동일한 조건으로 촬영하여 획득한 가시광 영상 및 근적외 영상을 나타낸 것이다.

[0037] 도 3에서, S01 내지 S04는 서로 다른 지역을 의미한다.

[0038] 본 실시예에 따르면, 상기한 과정을 통해 얻은 가시광 영상과 근적외 영상을 이용하여 컨볼루션 신경망의 학습을 진행한다.

[0039] 컨볼루션 신경망 학습을 위해서는 무 질병이 잘 관찰될 수 있는 고도(예를 들어, 3m)에서 얻은 가시광 영상 및 근적외 영상을 이용하며, 또한, 무, 토양 및 비닐을 분류하기 위해 관심 영역을 설정한다.

[0040] 도 4는 가시광 영상에서 무, 토양 및 비닐에 해당하는 관심 영역을 설정한 것을 예시적으로 나타낸 도면이다.

[0041] 가시광 영상으로부터 얻어진 관심 영역 데이터 셋의 일부는 컨볼루션 신경망 모델의 훈련을 위해 사용되고, 나머지는 테스트를 위해 사용된다.

[0042] 근적외 영상에 대해서도 동일하게 관심 영역 데이터 셋을 생성하는 과정이 수행될 수 있으며, 이하에서는 가시광 영상으로부터 획득된 관심 영역 데이터 셋을 중심으로 설명한다.

[0043] 도 5는 본 실시예에 따른 관심 영역 데이터 셋의 훈련 데이터 셋과 테스트 데이터 셋을 나타낸 것이다.

[0044] 도 5를 참조하면, 무(Radish), 토양(Soil) 및 비닐(Plastic mulch) 각각의 관심 영역 데이터 셋이 85:15의 비율로 훈련 데이터 셋과 테스트 데이터 셋으로 분할된다.

[0045] 본 실시예에 따르면, 무, 토양 및 비닐 각각에 대한 관심 영역 데이터 셋 및 근적외 영상을 복수의 컨볼루션 레이어 및 복수의 최대 풀링 레이어를 포함하는 컨볼루션 신경망에 입력하여 컨볼루션 신경망의 학습을 진행한다.

[0046] 관심 영역 데이터 셋은 작은 크기(예를 들어, 100×100 픽셀 미만)를 가지며, 컨볼루션 신경망에 입력되는 영상은 64×64 픽셀 크기를 가질 수 있다.

[0047] 관심 영역 데이터 셋을 생성하기에 앞서, 드론을 통해 촬영된 영상에 스티칭 알고리즘을 적용하여 파노라마 영상을 생성하고, 지각적으로 의미있는 픽셀을 그룹화하는 슈퍼 픽셀 세그멘테이션이 수행될 수 있다.

[0048] 이는 당업자에게 공지된 사항이므로 이에 대한 상세한 설명은 생략한다.

[0049] 도 6은 본 발명의 일 실시예에 따른 컨볼루션 신경망을 도시한 도면이고, 도 7은 본 실시예에 따른 무의 시들음병 검출을 위한 컨볼루션 신경망의 세부 사항을 나타낸 것이다.

[0050] 도 6 내지 도 7을 참조하면, 본 실시예에 따른 컨볼루션 신경망은 제1 내지 제5 컨볼루션 레이어를 포함한다.

[0051] 복수의 컨볼루션 레이어들은 입력 영상으로부터 특징 맵을 생성한다.

[0052] 제1 내지 제3 컨볼루션 레이어의 커널 크기는 각각 7×7, 5×5 및 3×3이며, 제3 내지 제5 컨볼루션 레이어는 동일한 커널 크기를 갖는다.

[0053] 복수의 최대 풀링 레이어는 특징 맵의 공간 크기를 줄이고 과적합 문제를 줄이는 역할을 한다.

[0054] 복수의 최대 풀링 레이어 중 제1 최대 풀링 레이어(M1)는 제2 컨볼루션 레이어(C2) 다음에 위치하고, 제2 최대 풀링 레이어(M2)는 제3 컨볼루션 레이어(C3)의 다음에 위치하며, 제3 최대 풀링 레이어(M3)는 제4 컨볼루션 레이어(C4)의 다음에 위치한다.

[0055] 본 실시예에 따른 컨볼루션 신경망 모델은 3개의 드랍아웃 정규화를 수행하며, 제1 및 제2 드랍아웃 정규화는

동일한 제1 값(0.2)을 갖고, 제3 드랍아웃 정규화는 제1 값보다 큰 값(0.5)을 갖는다.

[0056] 본 실시예에 따른 컨볼루션 신경망은 밀도(dense) 레이어를 포함하며, 밀도 레이어는 무, 비닐, 토양을 출력한다.

[0057] 본 실시예에 따르면, 다양한 실험을 통해 무의 시들음 병을 검출하기 위한 컨볼루션 신경망 모델의 최적 파라미터를 상기한 바와 같이 결정한 것이다.

[0058] 컨볼루션 신경망이 출력한 정보 중 무에 해당하는 이미지를 이용하여 무의 시들음 병을 검출한다.

[0059] 무의 시들음 병 검출을 위해 가시광 영상은 HSV(hue, saturation, lightness) 영상으로 변환된다.

[0060] 변환된 HSV 영상에서 검은색 픽셀수가 카운팅 및 임계값 결정 과정이 수행된다.

[0061] 검은색 픽셀은 상기한 슈퍼 픽셀 세그멘테이션 분할 결과에 따라 나타나며, 도 8에 도시된 알고리즘에 나타난 바와 같이 정상 비율 값 계산 과정에서 생략된다.

[0062] 도 8의 알고리즘을 참조하면, HSV 영상에 대해 미리 설정된 임계값을 적용하여 이진 영상으로 변환한다.

[0063] 도 9에 도시된 바와 같이, 0에 해당하는 검은색 픽셀은 임계값 비교에 따라 시들음 병이 나타난 부분을 나타내며, 255에 해당하는 흰색 픽셀은 건강한 무를 나타낸다.

[0064] 검은색 픽셀의 수에 따라 무의 시들음 병의 심각도가 다르게 결정될 수 있다.

[0065] 예를 들어, 흰색 픽셀의 비율이 60 내지 90 퍼센트이면 약한 심각도, 60 퍼센트 미만이면 높은 심각도로 결정될 수 있다.

[0066] 본 실시예에 따르면, 근적외 영상을 이용하는 경우, 근적외 영상의 데이터 셋으로부터 계산된 식생지수 NDVI(Normalized Difference Vegetation Index)를 이용하여 무의 시들음 병을 검출할 수 있다.

[0067] 근적외 영상을 이용하는 경우, 적색 채널 (600-700 nm)과 NIR 채널 (700-900 nm)은 NDVI를 계산하는 주요 변수이다.

[0068] 본 발명의 바람직한 일 실시예에 따르면, 무 밭에 대한 가시광 영상과 근적외 영상은 학습 과정에서 교차 검증을 위해 사용될 수 있다.

[0069] 도 10은 본 발명과 종래 모델의 무 시들음 병 검출 정확도를 나타낸 것이다.

[0070] 도 10을 참조하면, 첫 번째 모델은 세 가지 다른 수준의 질병 무(건강한 식물, 가벼운 질병 및 심각한 질병)를 구분하는 Inception-V3 모델이고, 두 번째 모델은 건강한 식물과 질병 식물을 분류하기 위해 제안 된 맞춤형 VGG-16 모델이다. 본 실시예에 따른 모델과 Inception-V3모델, VGG-16 모델 간의 성능을 비교하면, 본 실시예에 따른 모델은 96.4 %의 가장 높은 분류 정확도를 보이고 약간 낮은 성능으로 VGG-16 모델과 Inception-V3 모델은 각각 93.1 % 및 95.7 %의 정확도를 보인다.

[0071] 상기한 본 발명의 실시예는 예시의 목적을 위해 개시된 것이고, 본 발명에 대한 통상의 지식을 가지는 당업자라면 본 발명의 사상과 범위 안에서 다양한 수정, 변경, 부가가 가능할 것이며, 이러한 수정, 변경 및 부가는 하기의 특허청구범위에 속하는 것으로 보아야 할 것이다.

도면

도면1

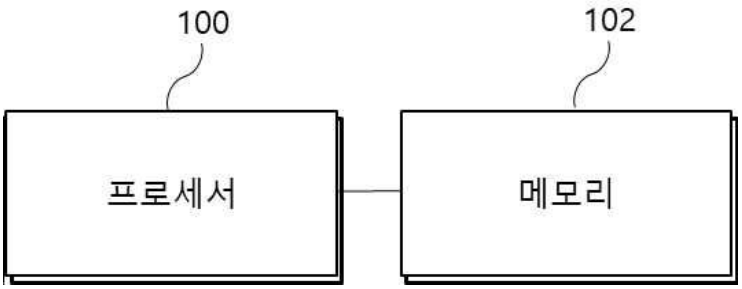

도면2

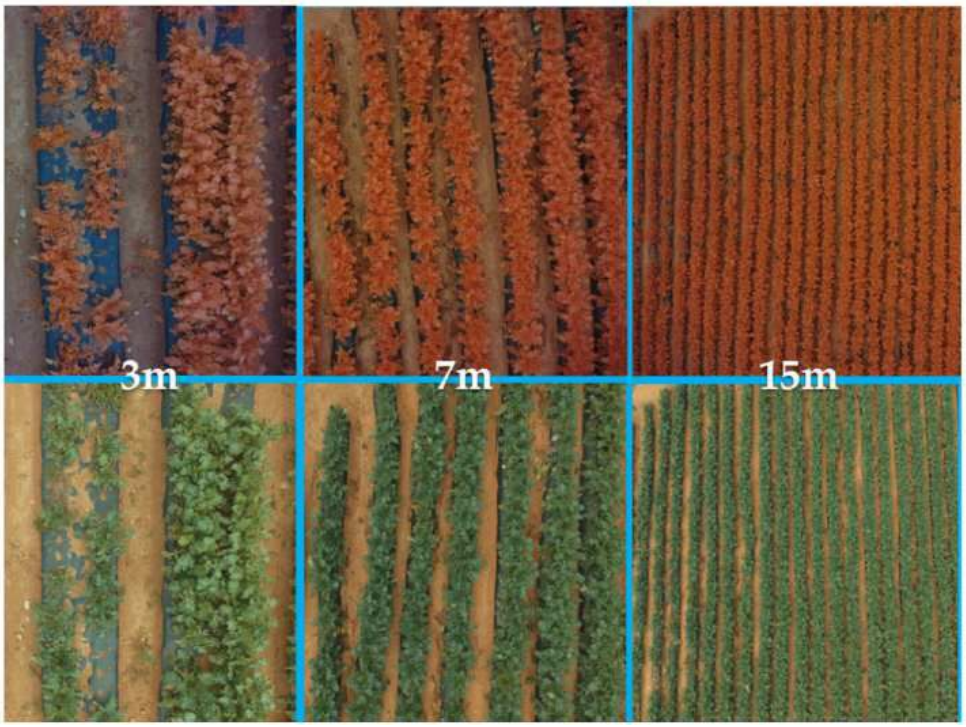

도면3

Site	Latitude, longtitude	Date	# fields	Altitude	# RGB images	# NIR images
S01	37° 0' 54.03" N , 127° 7' 48.36" E	04/11/17	1	7m, 15m	53	73
		04/28/17	2		126	171
		05/24/17	2		258	264
S02	37° 43' 24.23" N , 128° 24' 46.39" E	08/01/17	2	3m, 7m, 15m	1043	740
		08/18/17	2		781	279
		09/07/17	3		2640	1742
S03	33° 30' 5.44" N , 126° 51' 25.39" E	01/12/18	2	3m, 7m, 15m	1268	860
		01/28/18	2		1546	1137
S04	37° 7' 43.06" N , 127° 38' 0.03" E	07/04/18	4	10m, 15m	2780	2570
		07/19/18	3		2435	2762
		08/03/18	4		1754	1523
Total number of images					14,684	12,121

도면4

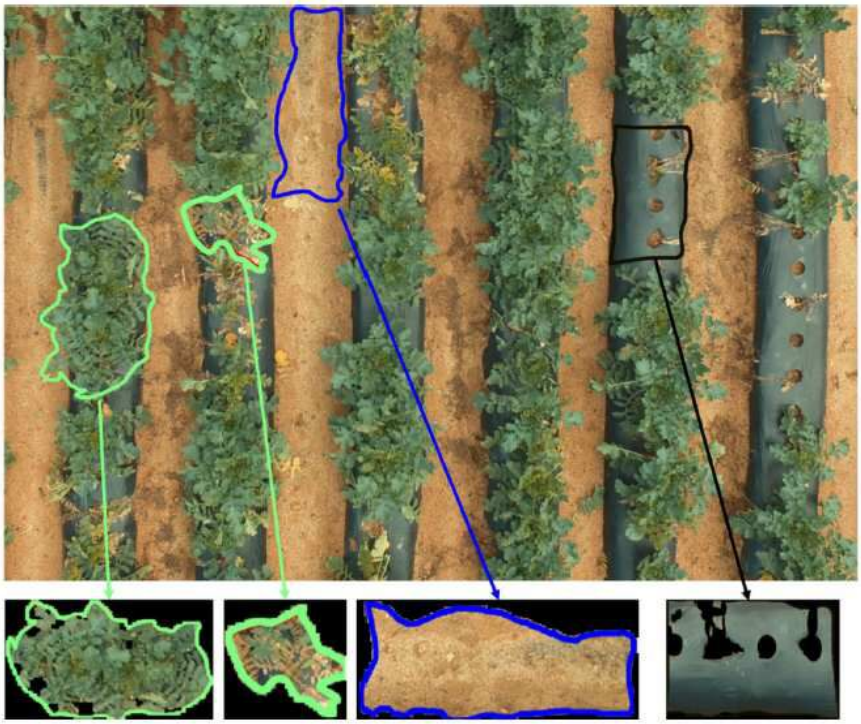

도면5

Class \ Subset	Training set	Testing set
Radish	510	90
Soil	493	87
Plastic mulch	442	78
Total	1445	255

도면6

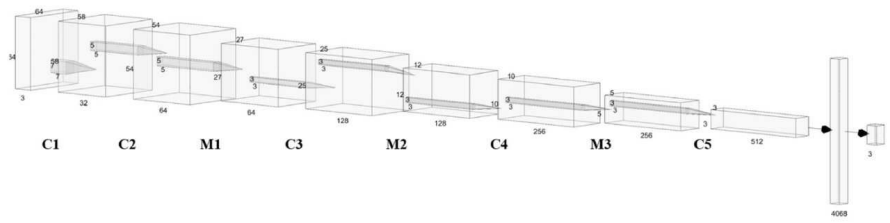

도면7

RadRGB		
Name	**Structure**	**(Widths, Heights, Channels)**
Input		64 × 64
Convolution_1	7 × 7	(58, 58, 32)
Convolution_2	5 × 5	(54, 54, 64)
Maxpool_1	2 × 2	(27, 27, 64)
Dropout_1	Probability: 0.2	
Convolution_3	3 × 3	(25, 25, 128)
Maxpool_2	2 × 2	(12, 12, 128)
Dropout_2	Probability: 0.2	
Convolution_4	3 × 3	(10, 10, 256)
Maxpool_3	2 × 2	(5, 5, 256)
Dropout_3	Probability: 0.2	
Convolution_5	3 × 3	(3, 3, 512)
BatchNorm		(3, 3, 512)
Dropout_4	Probability: 0.5	
Flatten		(4068)
Dense		(3)

도면8

Algorithm 1: Wilt Severity Analysis

Initialize count_seg_black, count_white equals to 0 and total_pixel equals to total number of pixels in img;
for *pixel* in *img* **do**
  if *pixel* **equals to** 0 **then**
    count_seg_black = count_seg_black +1
  end if
end for
  adaptiveThreshold(img, blockSize, C)
  for *pixel* in *bin_img* **do**
  if *pixel* **equals to** 255 **then**
    count_white = count_white + 1
  end if
end for

$$healthy_rate = \frac{count_white}{total_pixel - count_seg_black} \times 100$$

도면9

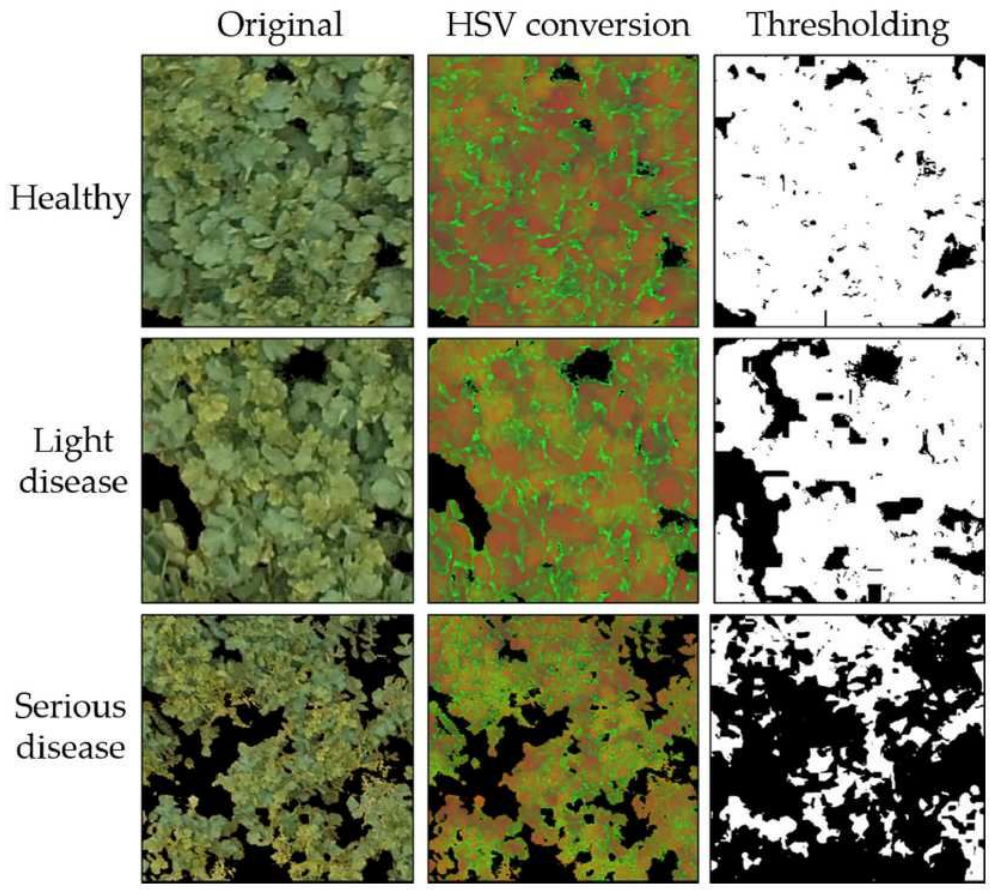

도면10

Model	Accuracy (%)
RadRGB	96.4
Inception-V3 [3]	95.7
VGG-16 [2]	93.1