



공학석사 학위논문

자율주행 트랙터를 위한 영상 센서 퓨전 기반 장애물 인식 및 충돌 방지 기술 개발

2023 년 2 월

서울대학교 대학원

바이오시스템공학과

황 예 빈

자율주행 트랙터를 위한 영상 센서 퓨전 기반 장애물 인식 및 충돌 방지 기술 개발

지도 교수 김 학 진

이 논문을 공학석사 학위논문으로 제출함 2023 년 2 월

> 서울대학교 대학원 바이오시스템공학과 황 예 빈

황예빈의 공학석사 학위논문을 인준함 2023 년 2 월

위육	원장	이 중 용	(인)
부위	원장	김 학 진	(인)
위	원	정 수	(인)

초 록

자율주행 농기계가 실용화되기 위해서는 농업 환경에서 신뢰할 수 있는 장애물 인식 시스템과 충돌을 방지하는 시스템이 필수적이지만, 카메라나 라이다. 레이더 등 단일 센서로는 다양한 환경에 대응하는 장애물의 인식에는 한계가 있다. 본 연구에서는 자율주행 트랙터에 필요한 장애물 자동 인식과 신속 대응이 가능하도록 영상 센서 융합기술을 이용하여 실시간으로 장애물을 인식하고 실제 상황에서의 충돌 대응이 가능한 시스템을 개발하고자 하였다. 장애물 인식 대상은 안전의 최우선이 되는 인명 보호를 위해 사람으로 하여 트랙터의 진행 방향에 대하여 설계된 위험과 경고 영역 범위내에서 작동하도록 하였다. 개발한 센서 융합 시스템은 객체 분류에 강점을 가지는 Intel社의 D435i RGB 카메라와. 거리 측정에 강인한 Velodvne社의 VLP16 라이다 센서로 구성하였다. 각 센서의 데이터는 카메라-라이다 캘리브레이션과 보정을 통하여 두 센서의 공간정보를 일치시켰으며, 인식 알고리즘은 RGB 영상에서 YOLO에 기반하여 사람을 인식하고, 영상에 투영된 라이다 데이터를 이용해 트랙터로부터의 상대 거리를 측정하였다. 충돌 방지 시스템은 인식 시스템에서 구한 장애물의 상대거리를 기준으로 장애물이 위험 영억에 있다고 판단되면 제어기가 트랙터를 정지시켜, 장애물이 사라지면 트랙터는 다시 주행하도록 개발되었다. 개발된 장애물 인식과 충돌 방지 시스템은 야외 평평한 농지에서 정적인 상황과 동적인 상황에서 유효성을 검증하였다. 충돌 위험 구간에서의 인식률은 99% 이상, 거리 측정의 RMSE는 24cm, 충돌 방지 및 대응 성공률은 98% 이상으로 나타났다.

주요어 : 머신 비전, 딥러닝, 센서 융합, 인식 시스템, 자율주행 농기계

i

학 번:2021-24813

제	1 장 서	론	1
	제 1 절	연구의 배경	1
	제 2 절	연구의 목적	3
	제 3 절	문헌 조사	4
제	2 장 재회	료 및 방법	8
	제 1 절	인식 시스템 구성 및 센서 융합	8
	제 2 절	인식 알고리즘 구성	19
	제 3 절	자율주행 플랫폼	27
	제 4 절	현장 평가	30
제	3 장 결 제 1 절 제 2 절 게 2 적	과 및 고찰 정적 상황에서의 장애물 감지 동적 상황에서의 장애물 감지 서계 요리 기바 아그리즈 편기	33 33 38
제 제	3 장 결 제 1 절 제 2 절 제 3 절 4 장 결	과 및 고찰 정적 상황에서의 장애물 감지 동적 상황에서의 장애물 감지 설계 요건 기반 알고리즘 평가 론	 33 38 48 51
제 제 참	3 장 결 제 1 절 제 2 절 제 3 절 4 장 결 고문헌	과 및 고찰 정적 상황에서의 장애물 감지 동적 상황에서의 장애물 감지 설계 요건 기반 알고리즘 평가 론	 33 38 48 51 52

표 목차

TABLE 1–1 SUMMERY OF OBSTACLE DETECTION	
SENSORS AND METHOD IN PREVIOUS	
STUDIES	7
TABLE 2-1 RGB CAMERA SPECIFICATION	.13
TABLE 2-2 LIDAR SPECIFICATION	.13
TABLE 2-3 EMBEDDED PC SPECIFICATION	.15
TABLE 2-4 CARRIER BOARD SPECIFICATION	.15
TABLE 2–5 PERCEPTION SYSTEM HARDWARE	
CONFIGURATION AND COST	.16
TABLE 2-6 COMPONENTS OF SNU AUTONOMOUS	
TRACTOR	.27
TABLE 2-7 TRACTOR MODEL SPECIFICATION	.28
TABLE 3-1 LAG TIME AND RUNNING DISTANCE OF	ì
EMERGENCY STOP	.39
TABLE 3-2 TEST 1 RESULTS BY HUMAN POSTURE	41
TABLE 3-3 TEST 1 RESULTS BY RELATIVE	
POSITION OBSTACLE	.41
TABLE 3-4 TEST 2 RESULTS BY HUMAN POSTURE	42
TABLE 3-5 TEST 2 RESULTS BY RELATIVE	
POSITION OBSTACLE	.42

그림 목차

FIGURE 2-1 ISO TEST OBJECT	.10
FIGURE 2–2 JAPANESE AUTONOMOUS TRACTOR	
TEST METHOD	.10
FIGURE 2-3 INTEL REALSENSE D435I CAMERA	12
FIGURE 2-4 VELODYNE VLP-16 LIDAR	12
FIGURE 2-5 NVIDIA JETSON XAVIER NX PC	.14
FIGURE 2-6 SEEED STUDIO A205 CARRIER BOARD	14
FIGURE 2-7 ROS NODE DIAGRAM	16
FIGURE 2-8 INTERFACE BETWEEN COMPONENTS	.17
FIGURE 2-9 THE INSTALLATION OF COMPONENTS	17
FIGURE 2-10 EMERGENCT STOP BLOCK DIAGRAM	ЭF
TRACTOR CONTROLLER	.18
FIGURE 2–11 TCP BLOCK DIAGRAM OF TRACTOR	
CONTROLLER	.18
FIGURE 2–12 CHECKERBOARD CAPTURE FOR	
CAMERA CALIBRATION	.19
FIGURE 2–13 CHECKERBOARD FOR CAPTURE	.21
FIGURE 2–14 CHECKERBOARD CAPTURED BY LIDAI	R
	.21
FIGURE 2–15 CHECKERBOARD CAPTURED BY RGB	
CAMERA	.22
FIGURE 2–16 LIDAR DATA PROJECTED ON RGB	
IMAGE	.22
FIGURE 2–17 OPTIMIZATION RESULT OF EXTERNA	L
PARAMETERS	.23
FIGURE 2–18 CAMERA–LIDAR CALIBRATION RESUL	LT
ON THE AGRICULTURAL FIELD	.23
FIGURE 2–19 OBJECT DETECTION BY YOLOV3–TIN	Y
	.25
FIGURE 2–20 THE ALGORITHM FLOW CHART	.25
FIGURE 2–21 SNU AUTONOMOUS TRACTOR	.27
FIGURE 2–22 DIAGRAM OF SNU AUTONOMOUS	0.0
TRACTOR COMPONENTS	. 28
FIGURE 2–23 COORDINATE TRANSFORMATION	0.1
BETWEEN LIDAR AND GPS	.31
FIGURE 2–24 TILLAGE PATH FORR SNU	0.0
AUTONOMOUS TRACTOR	.32
FIGURE 3–1 DETECTION ALGORITHM FIELD TEST-	-

STATIC CASE	33
FIGURE 3–2 DISTANCE MEASUREMENT	
PERFORMANCE COMPARISON	34
FIGURE 3–3 DETECTION SUCCESS RATE BY	
DISTANCE	34
FIGURE 3–4 DISTANCE ERROR COMPARISON WITH	
STEREOVISION	36
FIGURE 3-5 OBJECT POSITION ESTIMATION	36
FIGURE 3-6 OBJECT DETECTION AT FAR DISTANCE	£
	37
FIGURE 3-7 OBJECT DETECTION AT FAR DISTANCE	£
	37
FIGURE 3-8 WARNING ZONE AND HAZARD ZONE	39
FIGURE 3-9 VELOCITY CHANGE OF EMERGENCY	
STOP OPERATION	39
FIGURE 3–10 SITTING PERSON DETECTION	43
FIGURE 3–11 SAFEGUARD FUNCTION AT TURNING	
PATH	43
FIGURE 3–12 OFF–PATH PERSON DETECTION	43
FIGURE 3–13 DETECTION FAILURE BY COUNTER	
LIGHT	44
FIGURE 3–14 FALLEN PERSON DETECTION	46
FIGURE 3–15 SAFEGUARDING FALLEN PERSON	
AGAINST COLLISION	46
FIGURE 3–16 A PERSON ENTERING WARNING ZONE	47
FIGURE 3–17 A PERSON IN WARINING ZONE	47

제1장서 론

제 1 절 연구의 배경

국제연합 식량농업기구에 따르면, 세계 인구는 2050년에 90억을 돌파할 것으로 예측되며, 단위 인구별 경작 면적은 0.15ha로, 2020년도의 0.23ha에 비해 감소할 것으로 보인다. 또한 농가 인구가 감소함에 따라, 아시아 지역의 1인당 경작 면적은 2010년에는 1960년에 비해 2배 이상으로 증가하여, 농업의 노동 생산성 문제가 대두되고 있다. 농업의 지속 가능성을 도모하기 위하여, 자율주행 농업기계는 농업의 생산성을 향상시킬 기술로 주목받고 있다.

글로벌 농업기계 제조사인 Deere&Co., Kubota, Yanmar 등은 이미 GPS 기반의 자율주행 농업기계를 상용화하였으며, Topcon은 기존 농업기계에 부착하여 자율주행 기술을 적용할 수 있는 애프터 마켓 제품을 공급하는 등, 농업기계 자율주행 기술은 현재 세계 농업기계 시장에서 기술 경쟁이 첨예하게 이루어지고 있다. 따라서 자율주행 기술 고도화는 농업기계의 경쟁력을 확보하는 데에 필수적이다.

농업기계 자율주행 시스템의 구성요소로 GPS/INS 센서는 연구와 산업에도 활용되고 있다. 하지만, GPS/INS 센서는 동적 환경에 대한 인식이 어려우며, 장애물에 의한 충돌 사고의 예측 및 대응이 어렵다. 이러한 한계는 자율주행 농업기계의 무인화를 위해서는 반드시 극복해야 하는 문제로, 국내 자율주행 트랙터의 기술 단계 중 무인 자율주행 단계인 레벨 4의 기술력 확보를 위해서는 인식 시스템에 대한 연구 개발은 필수적이다.

국제 표준 ISO 18497은 고도로 자율화된 농기계의 안전 기능에 대한 표준을 다루며, 자율주행 농업기계의 인식 시스템의 구성요소에 대한 정의를 포함한다. 인식 시스템의 요소로서, 농업기계가 주행하는

환경, 인식을 위한 센서, 인식 알고리즘, 그리고 이에 대한 안전 기능을 제시한다. 따라서 목표 농작업 상황에 대한 인식 시스템의 각 요소를 구성하여 기준을 충족할 수 있는 시스템의 개발이 필요하다.

인식 시스템을 구성하기 위해서는 적용 환경을 고려하여 적절한 센서의 선정이 필요하다. 센서는 각각의 장단점을 가지며, 단일 센서로는 모든 환경에 대응하기 어렵다. 따라서 각 센서의 장단점을 고려하여, 상호 보완적인 센서 시스템을 구성할 필요가 있다.

인식 시스템에 사용되는 센서로는 비전 센서, 초음파, 레이더(radar, radio detection and ranging), 라이다(LiDAR, light detection and ranging) 등이 있다. 각 센서는 자동차와 산업용 차량에 적용되어 산업화되었고, 최근 농업기계 분야에서도 농업기계 자율주행 기술이 고도화되면서 적용 사례가 나타나고 있다.

농업기계 분야에서의 인식 시스템은 각 제조사의 장애물 인식 전략에 따라 상이한 센서를 적용하여 상용화가 이루어지고 있다. 미국의 Deere&Co.社가 CES 2022에서 무인 자율주행 트랙터는 6개의 스테레오 카메라를 적용하여 트랙터의 전 방위의 장애물을 감지한다. 또한 일본의 Kubota社는 무인 이앙기 NW8SA(2020)에는 초음파 센서를 사용하였고, 무인 트랙터 MR1000AH(2019)에는 라이다와 초음파 센서를 적용하였다. 일본의 Yanmar社는 무인 트랙터인 로봇 트랙터 시리즈(2020)에 초음파와 라이다 센서를 적용하였다.

이처럼 적용 목적과 충돌 방지 전략에 따라 다양한 센서 선정이 중요하며, 농작업에 실제로 적용될 수 있는 인식 시스템을 구성하기 위해서는 개발 시스템의 농업 환경에서의 검증이 필요하다. 또한 단순한 충돌 방지 기능을 넘어, 무인 농작업을 고려한 시스템을 개발하여 이를 적용하고 평가할 필요가 있다.

제 2 절 연구의 목적

본 연구의 목적은 자율 경운 트랙터의 안전한 무인 농작업을 위해, 인식 시스템 구성을 통한 장애물 인식 및 대응 기술을 개발하고자 함이다. 구체적인 목적은 다음과 같다.

1) 센서 융합 기반의 트랙터 전방 인식 시스템의 개발

2) 농작업을 고려한 센서 융합 기반의 장애물 인식 알고리즘 개발

3) 개발 시스템을 자율주행 트랙터에 적용하여 포장 검증 실험

본 연구에서는 무인 농기계의 안전의 최우선이 되는 사람에 대한 충돌 방지를 위하여 장애물 인식의 대상으로 사람을 선정하였다. 자율주행 트랙터가 진행 방향에 있는 사람을 인식하고 충돌을 방지하기 위하여, 카메라와 라이다 센서를 선정하여, 각 센서의 장단점을 보완할 수 있는 센서 융합 시스템을 구성하였다. 센서 융합의 방법으로, 카메라-라이다 캘리브레이션을 통해 좌표계 변환으로 센서 데이터를 융합하였다. 또한 딥러닝 알고리즘을 적용하여 영상에서의 객체를 인식하고, 센서 융합 기반의 상대 위치를 측정하여 대응하는 인식 알고리즘을 제시하였고, 이를 자율주행 트랙터에 적용하여 실제 농업 환경에서 검증하였다. 이를 통해 새로 개발된 기술이 농업 환경에서 자율주행 트랙터가 안전한 농작업이 가능함을 밝히고, 레벨 4 무인 자율주행 트랙터의 기반이 되는 안전 시스템을 제시하였다.

제 3 절 문헌 조사

Wei et al., (2005)는 스테레오비전을 활용하여 사람을 검출하는 연구를 수행하였다. 센서의 Disparity Map 데이터를 통해 장애물을 검출하였으며, 좌표 변환으로 상대 위치를 계산하였다. 알고리즘의 현장 검증을 위해 장애물과 농업기계의 위치 관계와 이동 상태를 다양하게 설정하여 평가하였으며, 거리 측정 오차는 0.3m부터 2.9m까지, 평균 1.2m로 측정되었다.

Yang and Noguchi (2012)는 전방향 스테레오비전(omnidirectional stereo vision, OSV)를 활용한 사람 인식 알고리즘을 제시하였다. OSV의 3D 파노라마 이미지에서, Lucas-Kanade법과 픽셀 차이를 이용하여 사람을 검출하였다. 알고리즘은 트랙터와 사람의 이동 상태에 따라, 3D 정보를 통해 검출 대상과의 거리를 측정하였다. RTK-GPS로 측정한 참값에 대한 오차를 측정하였으며, 측정 오차는 0.5m 이내로 나타났지만, 단일 객체만 검출이 가능한 한계를 보였다.

Steen et al., (2016)은 ISO 18497 기준에 도전하기 위하여 딥러닝을 이용한 장애물 검출 알고리즘에 대한 연구를 수행하였다. ISO 표준 장애물에 대해 RGB 카메라로 취득한 이미지를 합성곱신경망(CNN, Convolutional Neural Network)에 학습하여 실제 농지에서 검출 정확성을 평가하였다. 국제 표준이 요구하는 99.99%의 인식률에 근거하여 측정 거리에 따른 인식률을 측정하였으며, hit rate가 99.9%가 유지되는 거리가 14.56m임을 보고하였다.

Christiansen et al., (2015, 2016, 2017)은 농업 환경에서 농업기계의 장애물 인식을 위한 센서 플랫폼과 센서 융합 방안을 제시하였다. 플랫폼에 적용된 센서는 RGB 카메라, 스테레오비전 카메라, 열화상 카메라, 라이다였으며, 농업 환경에서 장애물 데이터를 수집하여

공개하였고, 센서에 대한 평가를 수행했다. 또한 발열 장치가 있는 체커보드를 활용하여 열화상 카메라와 타 비전센서를 융합할 수 있는 방법을 제시하였다. 저자는 동일 데이터를 통해 히스토그램 기반 장애물 인식(2015)과, 비정상 탐지 기법(2016)을 장애물 인식에 적용하였다.

Ji et al., (2020)은 GPS, INS, 라이다를 융합하여 농지의 3차원 맵을 생성한 후 장애물을 검출하는 연구를 수행했다. 넓은 범위에서 정밀한 감지가 가능한 라이다의 장점을 근거로 센서를 선정하였으며, 기울기와 흔들림에 취약한 단점을 GPS와 IMU를 활용하여 극복했다. 센서 데이터를 실시간으로 정합하고, 3차원 맵에서 RANSAC을 통해 지면을 제거하여 장애물의 포인트를 취득하는 알고리즘을 통해 장애물을 검출하였다. 알고리즘이 생성한 3차원 맵의 정확도를 비교하기 위해 고정밀 지형 인식 센서를 활용하여 성능을 측정하였다.

Ball et al., (2015)은 전기 트랙터에 장애물 인식을 포함한 자율주행 시스템에 대한 연구를 수행했다. 전기 트랙터에 ROS 기반 주행 알고리즘을 적용하였으며, 장애물 인식 및 회피는 스테레오 카메라를 사용하여 구성되었다. 하지만 당시 기술의 한계로 전기 플랫폼의 발열 문제를 제기하였으며 실험은 야간에 수행되었고 주간에서는 실험하지 못하였다.

Li et al., (2019)은 자율주행 콤바인에 깊이 카메라를 적용하여 사람에 대한 인식 및 대응 기술에 대한 연구를 수행하였다. 기존의 객체 인식 경계 박스가 가진 한계를 극복하고자 의미론적 분할(semantic segmentation)을 사용했으며, 임베디드 PC에서의 실시간 영상 처리 성능을 개선하기 위해 Network Pruning을 수행했다. 하지만 역광 및 그늘진 환경에서 인식 기술의 한계가 나타났고, 장애물과의 정확한 거리 추정에는 한계를 보였다.

Skoczeń et al., (2021)은 자율 제초 로봇에 스테레오비전 센서를 적용한 장애물 인식 연구를 수행하였다. 멀티 모달 영상 처리 파이프라인을 제시하였으며, RGB 데이터에서 의미론적 분할을 통해 분리된 장애물을 포인트 클라우드로 투영하여 격자 맵을 생성하고 상대 위치를 측정하였다. 인식 정확도는 98.11%, 평균 위치 측정 오차는 38cm로 보고하였다.

위 선행연구에서 활용된 센서와, 인식 대상, 자율주행 농기계에서의 실험 여부를 표로 도시하면 Table 1-1과 같다. 선행 연구에서 농업 환경에서 발생할 수 있는 장애물을 트랙터, 베일러 등으로 다양하게 적용하였지만, 공통적으로 선정된 객체는 사람이었다. Steen et al., (2016)은 ISO 표준 장애물을 사용하였지만, 표준 장애물 역시 사람을 형상화한 것으로 해당 연구 역시 사람을 대상 객체로 선정했음을 알 수 있다. 이처럼 자율주행 농업기계의 윤리 문제와 직결될 수 있는 사람에 대한 인식은 장애물 인식 연구에서 우선시되어 다루어졌다.

또한 선행 연구에서는 주로 이미지 처리 방법과 인식 성능 평가만 이루어졌고, 실제 자율주행 농업기계 시스템에 적용하여 평가한 연구는 상대적으로 적다. 알고리즘의 현장 적용 실험은 기술의 실용성과 산업적 유용성을 판단할 수 있는 근거가 될 수 있기 때문에 자율주행 농업기계의 기술 수준 발전을 위해 수행되어야 한다.

	Sensors	Object for Detection	Detection Method	Autonomous Driving Test
Wei et al., 2005	Stereovision	Human	Disparity Map	Х
Yang and Noguchi, 2012	OSV	Human	Optical Flow	Х
Steen et al., 2016	Monocular camera	ISO Test Object	Deep Learning	Х
Christiansen et al., 2015	Stereovision, thermal camera, LiDAR, webcam	Human	Gradient Histogram	Х
Christiansen et al., 2016	Monocular camera	Human	Anomaly Detection	Х
Ji et al., 2020	LiDAR	Human, agricultural vehicles	RANSAC	Х
Ball et al., 2015	Stereovision	Human, agricultural vehicles, branches, bales, etc	Novelty Detection	Ο
Li et al., 2019	Depth Camera	Human	Deep Learning	0
Skoczeń et al., 2021	Depth Camera	사람	Deep Learning	

Table 1–1. Summary of obstacle detection sensors and methods in previous studies

제 2 장 재료 및 방법

제 1 절 인식 시스템 구성 및 센서 융합

제 1 항 설계 요건

설계 요건을 선정하기 위해서는 안전 시스템의 윤리 가이드라인 등의 정책에 근거하여 설계하여야 하나, 자율주행 농업기계의 시장 도입 단계인 국내에는 아직 관련 표준이 제정되지 않았기 때문에, 설계 요건은 국제 표준과 해당 표준에 근거하여 시험 및 인증 제도를 도입한 일본의 가이드라인을 참조하였다. 국제 표준 ISO 18497(2018)은 고도로 자율화된 농업기계의 인식 시스템의 설계 요건들에 대해 설명하였다. 해당 표준에서 요구하는 보호 원칙 여섯 가지는 다음과 같다.

- 인식 시스템은 사람 혹은 다른 장애물을 인식하여야 하며,
 농업기계와 상대적 위치를 추정할 수 있어야 한다.
- ② 인식 시스템은 농업 기계의 위치를 추정하여, 작업 구역을 벗어나지 않도록 해야 한다.
- ③ 위험 구역 내에 장애물이 없다고 인식한 상태에서 거동해야 한다.
- ④ 위험 구역 내에 장애물을 감지하면, 자율 주행 상태에서 안전 상태로 전환해야 하며, 청각 경고 혹은 시각 경고를 내려야 한다.
- ⑤ 농업기계 내부 혹은 외부의 작업자는 작업을 정지/재개할 수 있어야 한다.
- ⑥ 농업기계 내부 혹은 외부의 작업자는 작업 상태를 감독할 수 있어야 한다.

보호 원칙에서 본 연구의 설계 요건으로 ①, ③, ④, ⑥ 항목을 선정하였다. 본 연구에서 사용된 자율주행 플랫폼은 GPS/INS 상태로 작업 위치의 벗어남을 알 수 있기 때문에 ② 번 항목은 본 연구의 범위에서 제외되었으며, 자율주행 플랫폼 내부의 수동으로 작동 가능한 자율주행 멈춤/재개 기능인 ⑤번 역시 제외되었다. 설계 요건을 고려하여 이를 충족시킬 수 있는 인식 시스템 및 충돌 방지 시스템을 설계하였다.

설계 요건 ① 항목은 장애물과의 인식만 아니라 거리 추정을 요구한다. 이에 따라 인식과 거리 추정이 가능한 인식 시스템을 구성하여야 하며, 이는 본 연구에서 개발한 센서 융합 기반의 인식 시스템으로 충족하고자 하였다.

설계 요건 중, ③과 ④번 항목에서는 위험 구역을 언급하고, 이후 문서의 상세 내용에서는 전방 장애물을 인식하여 경고음을 발생하는 경고 구역(Warning Zone)과 충돌 위험을 판단하고 작업을 정지하는 위험 구역(Hazard Zone)을 설정하도록 요구하였다. 이에 기반한 일본의 인증 시험 방법에서는 경고 구역과 위험 구역의 설정을 농업기계 제조사의 설정에 일임하여, 실제 시험에서는 Figure 2-4와 같이 트랙터 폭을 고려한 경로 위의 장애물과 충돌이 발생하지 않으면 인증을 부여하는 방식으로 적용되고 있다. 이에 따라 본 연구에서 활용된 자율주행 플랫폼의 실제 주행 거동을 분석하여 경고 구역과 위험 구역을 설정하였다.

국제 표준은 평가 시험에서의 인식 대상으로 녹색 원통형 장애물을 제시하였다. 이는 앉아있는 사람의 모습을 형상화한 것으로, 빠른 이동이 불가한 사람 혹은 작은 어린이의 크기를 나타내기 위함이다. 하지만 이 형상만으로는 이동하는 동적인 사람과 쓰러져 이동이 불가한 사람 등 다양한 상황을 대표하지 못하며, 기존의 딥러닝 알고리즘이나 보행자 인식 알고리즘으로 인식할 수 없는 등의 한계를 지니기 때문에 국제 표준의 실제 산업에 적용되기 위해서는 강인한 사람 인식 알고리즘이 필요하며, 이를 위해 본 연구에서는 실제 사람을 대상으로 인식 알고리즘을 개발하였고, 현장에서 시험하였다.



Figure 2-1. ISO Test Object



Figure 2-2. Japanese autonomous tractor test method

제 2 항 센서 선정

환경 인식을 위한 센서는 RGB 카메라와 라이다를 선정하였다. RGB 카메라는 다양한 분야에서 CNN에 기반한 객체 인식에 대한 연구가 진행되었으며, 이에 따라 객체 인식 및 분류에 강점을 가진다. 또한 자율주행 트랙터의 무인화를 고려하였을 때, RGB 카메라 데이터는 원격의 사용자에게 풍부한 색상 정보를 제공하기 때문에 사용자에게 농기계의 상황에 대한 핵심적인 시각 정보를 제공할 수 있다.

하지만 RGB 카메라는 영상으로부터 정확한 거리 측정을 하는 데에 한계를 가진다. RGB 영상 정보로부터 물체의 거리를 측정하기 위한 방법으로는 거리 측정 원리에 스테레오비전, 구조광, ToF(Time of Flight)이 있지만, 각 방식의 한계가 있다. 공통적으로 가진 한계는 거리가 멀수록 정확도가 떨어진다는 것과, 거리 측정 성능이 외부 조명 환경에 민감하다는 것이다. 따라서 장애물의 위치 정보를 취득할 수 있는 보조적인 센서의 선정이 필요하다.

라이다는 레이저 펄스를 쏘아 물체에 반사되어 돌아오는 시간을 측정하여 거리를 측정하는 대표적인 ToF 센서다. 라이다는 타 센서 대비 넓은 범위에서 정확한 거리 인식이 가능하다. 그러나 낮은 수직 방향 해상도로 인해 라이다 센서는 객체와의 거리가 멀어질수록 포인트 클라우드의 밀도가 낮아져 객체 인식 및 분류가 어렵다. 이를 개선하기 위해서 다채널 라이다를 사용하지만, 채널 수에 비례하여 가격이 상승하여 비용 효율이 떨어지는 단점이 있다.

또한 라이다는 장애물과 무관한 환경의 데이터까지 취득되기 때문에, 장애물의 데이터를 분리하기 어렵다. 장애물 포인트의 분리 방법으로는 RANSAC을 통해 지면의 평면 방정식을 구하여 분리하는 방법과 SLAM(simultaneous localization and mapping)을 활용한 방법이 다양한 연구에 활용되었으나, 환경의 변화가 많고 지면이 평평하지 않은

농업 환경에서의 적용이 어려운 단점이 있다. 따라서 농업 환경에서 라이다 센서를 효율적으로 활용하기 위해서는, 보조적인 센서를 통해 라이다 데이터를 선택적으로 사용할 수 있는 센서 융합 시스템이 필요하다.

각 센서의 장단점을 고려하여, 객체 인식 및 분류에 강점을 가지는 RGB 카메라와 넓은 범위의 거리를 정확하게 인식하는 라이다를 통해 장애물 인식 및 상대 위치 추정이 가능한 센서 융합 시스템을 구성하였다.

본 연구에서는 RGB 카메라로 Intel社의 D435i를 선정하였다. 센서는 최대 1920*1080 해상도 60fps 영상을 지원하나, 임베디드 PC에서의 연산 부하를 고려하여 임베디드 환경에서 실시간으로 처리가 가능한 848*480 해상도의 30fps 영상을 사용하였다.

라이다 센서는 Velodyne社의 16채널 라이다인 VLP-16을 사용하였다. VLP-16은 360°* 30° 영역에서 수평방향 해상도 0.1°, 수직 방향 해상도 2°의 거리 데이터를 10Hz로 제공한다.



Figure 2-3. Intel Realsense D435i camera



Figure 2-4. Velodyne VLP-16 LiDAR

Table 2-1. RGB camera specification

Maximum Resolution	1920 x 1080
Frame Rate	30fps
Field of View(H*V)	87° x 58°
Shutter Type	Rolling Shutter
Connector	USB Type-C 3.1
Mechanical(L*D*H)	90mm x 25mm x 25mm

Table 2-2. LiDAR specification

Maximum Range	100m
Range Accuracy	3cm
Output Rate(pts/sec)	≒ 3,000,000
Field of View(H*V)	360° x 30°
Rotation Rate	10Hz
Vertical Resolution	2°
Horizontal Resoultione	0.1°
Laser Wavelength	905nm
Operating Temperature	-10° to +60°
Environmental Protection	IP67
Weight	830g
Power Consumption	8W

제 3 항 하드웨어/소프트웨어 구성

임베디드 PC는 Nvidia社의 Jetson Xavier NX를 사용하였다. Jetson Xavier NX 모듈은 Seeed Studio社의 A205 캐리어 보드에 장착되었으며, 방수/방진을 지원하는 알루미늄 방열 케이스를 사용했고, 구성된 PC의 단자는 총 4개의 USB 3.0 단자와 2개의 이더넷 단자, 2개의 디스플레이 단자를 지원한다. RGB 카메라는 USB 3.0 단자를 사용하며, 라이다는 이더넷 단자, 통신 포트는 이더넷 단자를 사용하였다. 임베디드 PC는 트랙터의 캐빈 내부에 설치되었으며, 카메라와 라이다는 자율주행 트랙터의 진행 방향의 장애물을 인식하기 위해 트랙터의 무게추 위에 설치되었다.



Figure 2-5. NVIDIA Jetson Xavier NX PC



Figure 2-6. Seeed Studio A205 Carrier Board

СРИ	6-core ARM 64-bit
GPU	384-core NVIDIA Volta
Memory	16 GB LPDDR4x
Storage	16 GB eMMC 5.1
Power	10W~20W
Mechanical	69.6mm x 45mm

Table 2–3. Embedded PC specification

Table 2-4. Carrier board specification

PCB size	170mm x 100mm
Display	2x HDMI
Ethernet	2x Gigabit Ethernet
USB	4x USB 3.0 type-A, 1x type-C
SATA	1x5 SATA
Power	13V~19V DC
Operating Temp.	-25° to +80°

트랙터 전방을 감지할 수 있는 다른 설치 위치는, 본 연구에서 설치한 무게추 위 이외에도 트랙터의 캐빈 위와 트랙터의 본닛 위, 무게추 아래가 있다. 트랙터의 캐빈 위는 설치 위치가 높아 라이다 센서의 수직 방향 해상도가 낮기 때문에 트랙터 전방을 인식하기 위해서는 지면을 향한 방향으로 설치해야 하며, 지면을 향해 설치되면 전방 방향 감지 영역이 제한되는 한계가 있다. 또한 본닛 위는 카메라의 시야가 가려지는 단점이 있으며, 무게추 아래는 농작업 중 지면에서 발생하는 흙으로 인해 라이다 렌즈부가 가려질 수 있다는 한계를 가진다. 이에 따라 트랙터의 진행 방향에 대한 풍부한 영상 정보를 제공할 수 있고 안정적으로 고정이 가능한 무게추 위에 설치하였다.

Component	Model Name	Price (\$)
Embedded PC	Jetson Xavier NX	399
Carrier Board	A205	399
LiDAR	Velodyne VLP-16	3999
RGB Camera	Intel D435i	345

Table 2-5. Perception system hardware configuration and cost

소프트웨어 구성요소로 OS는 우분투 18.04 기반의 Jetpack 4.4가 사용되었고, 개발 코드는 OS 내부에 설치된 ROS Melodic 환경에서 C++ 언어로 개발되었다. ROS는 로봇을 제어하기 위한 오픈소스 로봇 미들웨어로, 소프트웨어의 모듈 단위인 노드(node)로 구성되어 토픽(topic)을 발행/구독 방식으로 데이터를 송수신한다. 각 실험의 토픽 데이터는 rosbag 형식으로 저장하고 분석하였다.



Figure 2-7. ROS node diagram

ROS 내부의 노드 구성도는 Figure 2-9와 같다. RGB 노드는 카메라의 데이터를 수신하여 토픽으로 발행하는 노드이고, LiDAR 노드는 라이다 데이터를 포인트 클라우드 토픽으로 발행하는 노드이다. Detection 노드는 이미지 토픽에서 장애물을 인식하고 장애물의 경계 박스를 반환하는 역할을 수행하며, Distance Measurement 노드는 카메라와 라이다 데이터를 융합하여 장애물의 위치를 추정하여, 충돌이 예상될 시에 TCP 노드로 불리언 토픽을 발행한다. TCP 노드는 자율주행 트랙터의 제어 PC와 TCP 통신을 수행하는 노드로, 긴급 정지시에 TCP 통신으로 제어 명령을 송신한다.



Figure 2-8. Interface between components



Figure 2–9. The installation of components

트랙터 상위 레벨 제어기의 경로 추종 알고리즘 내부에는 Jetson PC와 TCP 통신을 하는 블록과, TCP 통신의 긴급 제동 명령으로 자율 작업을 정지하는 긴급 제동(Emergency Stop) 블록을 구성하였다. 긴급 제동 블록은 제어 명령을 트랙터로 송신한다. 작업 중에 내려진 작업기의 상승, 경로 추종 알고리즘 정지, 좌 우 브레이크 가동, 전후진 셔틀 중립, 입력 속도 삭제로, 정지에 필요한 제어명령을 내린다.

	Emergency stop		10- 🔊
		F → hamplement down	
		0 + ● Driving mode(1 : Low 2 : High 0 : none)	
l		100 ⁻	
l		-1 → Mar_vel	
l		II → Right brake on	
l		■ → ALeft brake on	
l		■ → Shuttle neutral	
l			
		B	STOP

Figure 2–10. Emergency stop block diagram of tractor controller



Figure 2–11. TCP block diagram of tractor controller

제 2 절 인식 알고리즘 구성

제 1 항 카메라-라이다 캘리브레이션

카메라와 라이다의 센서 융합을 위한 방법으로 카메라-라이다 캘리브레이션을 사용하였다. 이는 카메라의 기구적 특징에 의해 나타나는 내부 파라미터와, 카메라와 라이다의 위치 관계를 통해 구할 수 있는 외부 파라미터의 행렬 연산으로 라이다의 데이터를 카메라 영상 위에 투영하는 방법이다.

$$s \begin{bmatrix} u \\ v \\ 1 \end{bmatrix} = \begin{bmatrix} f_x & 0 & c_x \\ 0 & f_y & c_y \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} r_{11} & r_{12} & r_{13} & t_1 \\ r_{21} & r_{22} & r_{23} & t_2 \\ r_{31} & r_{32} & r_{33} & t_3 \end{bmatrix} \begin{bmatrix} x \\ y \\ z \\ 1 \end{bmatrix} \qquad \cdots \text{ Equation 1}$$

외부 파라미터를 구하기에 앞서 카메라의 내부 파라미터를 구하고, 카메라 렌즈에 의한 왜곡을 보정하는 카메라 캘리브레이션을 수행하였다. 카메라 왜곡 보정을 위해 45mm 정사각형이 6*4로 배치된 A4 크기 체커보드를 사용하였다. 오픈소스 비전 라이브러리인 OpenCV 라이브러리의 카메라 보정 툴을 사용해 영상의 체커보드를 캡처하여 초점거리 f_x , f_y 와 주점(principal point) c_x , c_y , 그리고 왜곡 보정 행렬을 구한다. 왜곡 보정 변수 행렬인 Distortion_{coefficients} 행렬을 구해야 한다. 왜곡 보정 변수 행렬은 방사 왜곡 보정 변수 k_1 , k_2 , k_3 과 기울기 왜곡 파라미터 p_1 , p_2 로 이루어진 1*5 행렬이다.



Figure 2–12. Checkerboard capture for camera calibration

카메라 보정 툴은 체커보드를 이미지를 캡처하여 왜곡 보정 행렬을 구하고, 아래의 연산을 통하여 이미지의 왜곡을 보정한다.

 $\begin{aligned} x_{corrected} &= x(1 + k_1 r^2 + k_2 r^4 + k_3 r^6) \\ y_{corrected} &= y(1 + k_1 r^2 + k_2 r^4 + k_3 r^6) \\ x_{corrected} &= x(2p_1 x y + p_2 (r^2 + 2x^2)) \\ y_{corrected} &= y + (p_1 (r^2 + 2y^2) + 2p_2 x y) \end{aligned}$

 $Distortion_{coefficients} = [k_1 \ k_2 \ p_1 \ p_2 \ k_3] \ \cdots$ Equation 2

외부 파라미터를 구하기 위해 Verma et al.,(2019)의 연구에서 개발된 ROS 패키지를 활용하였다. 제시된 방법은 카메라와 라이다로 체커보드를 동시에 캡처하여 센서의 상대 위치를 측정하여 외부 파라미터를 구한다. 캡처에 사용한 캡처보드는 85mm의 정사각형이 9*6으로 배치된 A1 크기의 판이다.

각 캡처 과정에서 라이다로 캡처한 체커보드의 포인트 군집의 평면 좌표는 random sample consensus (RANSAC)을 통해 평면의 중점과 법선 벡터를 구하고, 카메라가 캡처한 평면과의 위치 관계를 연산한다. 각 캡처에서 구한 롤, 피치, 요, X, Y, Z 값은 유전 알고리즘을 통해 최적화하여 외부 파라미터 행렬을 구한다. 총 32회의 캡처를 진행하였으며, 위치 관계 최적화 결과는 Figure 2-17 이며, 라이다 데이터를 RGB 영상에 투영한 결과는 Figure 2-18 와 같다. 그리고 각 점의 거리를 가까운 점부터 먼 점까지 빨간색부터 파란색으로 도시하면 Figure 2-20와 같다.



Figure 2-13. Checkerboard for capture



Figure 2-14. Checkerboard captured by LiDAR



Figure 2-15. Checkerboard captured by RGB Camera



Figure 2-16. LiDAR data projected on RGB image



Figure 2-17. Optimization result of external parameters



Figure 2–18. Camera-LiDAR calibration result on the agricultural field

제 2 항 인식 및 거리 추정 알고리즘

장애물 인식 알고리즘은 RGB 카메라의 장애물 인식과 라이다의 거리 측정으로 구성된다. RGB 카메라의 장애물 인식 알고리즘은 CNN에 기반한 객체 인식 모델인 YOLO를 사용하였다.

YOLO는 기존의 경계 박스 탐지와 객체 분류로 이루어진 2단계 인식 방법의 실시간성을 개선한 알고리즘으로, 하나의 합성곱 신경망이 경계 박스와 객체 분류를 수행하는 1단계 인식 알고리즘이다. YOLO 알고리즘은 Redmon and Farhadi(2018)에 의해 YOLO v3가 제시되었고 이는 COCO 데이터셋을 기반으로 학습되어 80 종의 객체에 대한 분류를 수행할 수 있다.

하지만 YOLOv3 모델은 실제 자율주행 트랙터에 적용하기 위해서는 모델의 연산 부하로 인해 실시간성이 떨어지기 때문에 본 연구에서 사용한 모델은 YOLOv3의 경량화 모델인 YOLOv3-tiny를 적용하였으며, 해당 모델은 Jetson Xavier NX에서 848*480 해상도의 영상을 초당 약 24개의 영상을 실시간으로 처리한다.

YOLO 모델은 RGB 영상에서 객체의 경계 박스 픽셀 좌표를 반환하며, 초당 24개의 영상을 처리하므로, 신호 주기가 10Hz인 라이다와 시간 동기화되어 초당 10개의 카메라-라이다 캘리브레이션 데이터에서 장애물과의 거리를 측정한다. 카메라-라이다 캘리브레이션을 통해 YOLO가 반환한 경계 박스 내부에 투영된 라이다 점의 거리 값을 중 장애물과의 거리는 경계 박스 내부의 거리 데이터 중 최소 거리를 가진 점의 위치를 기반으로 추정하였다. 무게추 위에 정면으로 설치된 라이다의 전방 방향 x 좌표는 트랙터의 방향각과 동일 선상에 있기 때문에, 라이다의 x 값을 전방 방향 거리, y 방향을 횡방향 거리로 설정하였다.



Figure 2-19. Object Detection by YOLOv3-tiny



Figure 2-20. The algorithm flow chart

전방 방향 거리와 횡방향 거리를 측정한 뒤에, 해당 장애물의 위치가 위험 구역 내부로 인식되면 충돌 위험 상황으로 판단하여 작업을 정지한다. 정지 신호를 받은 자율주행 트랙터는 비상 정지 명령이 실행되며, 액셀러레이터 스로틀 모터 풀림, 기어 중립, 브레이크 작동을 실행하여 작업을 정지한다. 정지 이후 위험 구역에 장애물이 사라졌다고 판단하면 작업 재개 명령을 송신한다. 위험 구역에 장애물이 30회 이상 인식되지 않으면 다시 작업을 시작하여 트랙터가 다시 자율주행 작업을 시작한다.

제 3 절 자율주행 플랫폼

본 연구에 사용된 자율주행 트랙터는 TYM社의 85마력 TX853 트랙터를 기반으로 선행연구(Jeon, 2022)에서 개발된 자율주행 플랫폼을 사용하였으며, 주요 센서는 Dual GPS 센서, IMU 센서, 조향각 센서를 활용하여 구성되었다. 자율주행 트랙터의 주요 제원은 다음과 같다.



Figure 2-21. SNU Autonomous Tractor

Table 2–6. Components of SNU autonomous tractor

Base ModelTYM TX853Controller PCADLink MXE-5501GPSSBG Systems Ellipse-DNetwork-RTK DeviceSynerex MRD-1000TAngle SensorComsys Steer SensorElectric Power Steering DeviceUnmanned Solution EPSAcceleration Valve MotorDynamixel MX-106RSteering TypeHydrostatic power	SNU Autonomous Tractor			
Controller PCADLink MXE-5501GPSSBG Systems Ellipse-DNetwork-RTK DeviceSynerex MRD-1000TAngle SensorComsys Steer SensorElectric Power Steering DeviceUnmanned Solution EPSAcceleration Valve MotorDynamixel MX-106RSteering TypeHydrostatic power	Base Model	TYM TX853		
GPSSBG Systems Ellipse-DNetwork-RTK DeviceSynerex MRD-1000TAngle SensorComsys Steer SensorElectric Power Steering DeviceUnmanned Solution EPSAcceleration Valve MotorDynamixel MX-106RSteering TypeHydrostatic power	Controller PC	ADLink MXE-5501		
Network-RTK DeviceSynerex MRD-1000TAngle SensorComsys Steer SensorElectric Power Steering DeviceUnmanned Solution EPSAcceleration Valve MotorDynamixel MX-106RSteering TypeHydrostatic power	GPS	SBG Systems Ellipse-D		
Angle SensorComsys Steer SensorElectric Power Steering DeviceUnmanned Solution EPSAcceleration Valve MotorDynamixel MX-106RSteering TypeHydrostatic power	Network-RTK Device	Synerex MRD-1000T		
Electric Power Steering DeviceUnmanned Solution EPSAcceleration Valve MotorDynamixel MX-106RSteering TypeHydrostatic power	Angle Sensor	Comsys Steer Sensor		
Acceleration Valve MotorDynamixel MX-106RSteering TypeHydrostatic power	Electric Power Steering Device	Unmanned Solution EPS		
Steering Type Hydrostatic power	Acceleration Valve Motor	Dynamixel MX-106R		
	Steering Type	Hydrostatic power		

TYM TX853 Specifications			
Engine Type	3.3L 4-cyl diesel		
Power	85hp		
Displacement Cubic	402.5 ci		
Fuel Tank Capacity	110.1L		
Battery Capacity	12V 65AH		
Alternator	12V 65A		
Number of gears/speeds	24 fowrad and reverse		
Steering Type	Hydrostatic power		
Brake Type	Wet disc°		
Dimensions	3.93*1.94*2.71m,		
Weight	3064kg		
Power Consumption	8W		

Table 2-7. Tractor Model Specification



Figure 2-22. Diagram of SNU Autonomous Tractor Components

SNU 자율주행 트랙터의 경로 추종 알고리즘은 선행연구(Han et al., 2019)에서 개발된 슬립 예측 기반 경로 추종기를 적용하였다. 경로 추종기는 자율 경운 트랙터의 작업 경로 생성 알고리즘(Han et al., 2021)을 통해 생성된 경로 정보인 RDDF(Route Data Definition File)에서 경로점과 제어 정보들을 읽고, 경로점을 추종하였다. 상위 제어기는 경로 추종 알고리즘을 통해 실시간으로 GPS, INS 센서의 위치와 자세 정보를 기반으로 계산된 조향 각, 주행 속도, 작업기 제어 정보로 작동기를 제어하였다.

제 4 절 현장 평가

제 1 항 정적 상황에서의 장애물 감지

정적 상황은 자율주행 트랙터가 정지한 상태에서 전방 0m~20m 거리를 움직이는 장애물에 대한 인식 성능을 평가한다. 실험은 2022년 10월 18일 14시에 서울대학교 수원농장에 있는 사각형 농지에서 수행되었다.

알고리즘의 성능은 인식 성공률과, 거리 측정 오차, 위치 추정 성능을 평가하였다. 장애물과 트랙터의 위치는 RTK-GPS를 사용하여 측정하였으며, 장애물로 설정된 사람은 ublox社의 F9P GPS 센서를 부착하여 이동하였다. 장애물의 GPS 데이터는 알고리즘의 데이터와 시간 동기화를 통해 저장되었다.

인식된 장애물의 위치 오차 범위 1m이내에 측정된 경우를 성공한 경우를 인식 성공으로 판단하였으며, 인식 성공 영상 프레임 수를 센서 융합 노드가 처리한 영상 프레임 수로 나누어 인식률을 측정하였다. 장애물과의 거리에 따른 인식률을 비교하여 거리에 따른 인식률 변화를 측정했다.

Success Rate(%) = $100 \times \frac{(Number of Detection Success frames)}{(Number of frames processed by algorithm)}$... Equation 3

거리 측정 오차는 장애물과 트랙터의 RTK-GPS 위치 값의 차이로 계산하였다. 타 센서와의 거리 측정 성능의 비교를 위해 Stereolabs社의 스테레오비전 카메라인 ZED2의 거리 측정 알고리즘과 비교하였으며, 장애물과 거리에 따른 오차를 측정하였다. ZED2 스테레오 비전 카메라의 인식 알고리즘은 제조사에서 제공하는 개발자 도구의 사람



Figure 2-23. Coordinate transformation between lidar and GPS

 $X_{obstacle} = X_{Tractor} + distance \times \cos(heading)$

Y_{obstacle} = Y_{Tractor} + distance × sin(heading) … Equation 4 위치 측정은 알고리즘이 측정한 위치를 트랙터 위치의 GPS값과 방향각을 통하여 장애물 위치를 추정하고, 이를 RTK-GPS 값과 비교하였다.

제 2 항 동적 상황에서의 알고리즘 평가 평가

개발한 인식 시스템의 현장 적용성을 평가하기 위해 실제 자율주행 농작업 상황에서의 장애물 인식 및 대응에 대한 실험을 진행하였다. 자율주행 트랙터는 자율 경운 경로를 따라 주행하며, 경로 위에 장애물이 나타나는 상황에 대응하여 작업을 정지 및 재개한다.

먼저 경고 구역과 위험 구역의 설정을 위하여, 인식 알고리즘이 자율주행 트랙터의 상위제어기로 정지 명령을 보낸 시점부터 트랙터가 완전히 정지하는 시점까지의 지연 시간을 측정하였다. 인식 시스템 PC와 트랙터 상위제어기는 시간 동기화되어 정지 명령 후 트랙터의 위치와 속도 정보를 GPS 데이터에서 취득하였다.

현장 실험에서 RTK-GPS 센서를 부착한 사람이 이동하며

자율주행 트랙터의 진행 경로 위의 위험 구역에 위치하였다. 실제 농작업 상황에서 자율주행 트랙터가 사람을 마주하는 상황은 사람이 충분히 주의를 기울이지 않고 있거나, 이동 불능인 상태일 수 있다는 것을 가정하여, 장애물의 역할을 수행한 사람은 기립한 자세 이외에도, 앉은 상태와 쓰러진 자세를 취하였다.

현장 실험은 서울대학교 수원 농장 자율주행 실험 농지에서 진행되었다. 자율주행 트랙터는 로터리 경운 작업기를 장착하였고, 벼농사 환경에서 수확 후 경운 작업을 하는 가을갈이 시기인 2022년 10월 28일 오후 2시부터 5시까지 진행되었다. 전체 경로를 주행하는 실험은 총 2회 진행하였으며, 각 주행은 약 22분 소요되었다. 첫번째 주행에서는 위험구역 내 장애물 등장이 28회, 두번째 주행에서는 35회 나타났다.



Figure 2-24. Tillage path for SNU autonomous tractor

제 3 장 결과 및 고찰 제 1 절 정적 상황에서의 장애물 감지

제 1 항 거리 측정 및 위치 추정 성능



Figure 3-1. Detection algorithm field test - static case

정적 상황에서 RTK-GPS로 측정한 거리와 알고리즘이 추정한 거리를 비교했을 때, 약 17m까지 평균 오차 0.24m, RMSE(평균 제곱근 오차) 0.24m로 고른 오차를 보였다. 라이다 센서의 거리 측정 성능인 0.03m보다 오차가 크게 나온 이유는, 알고리즘은 장애물 경계박스 내부의 모든 점에서 최소 거리를 장애물의 위치로 추정하기 때문에, 실제 사람에 부착된 GPS 안테나의 위치와 차이가 발생했기 때문이다.

거리에 따른 인식률은 장애물과의 거리 2m~13m까지 98%이상의 성능을 보였다. 1~2m 구간에서 인식률이 낮게 나온 이유는 장애물이 너무 가까이에 위치하면 RGB 카메라 영상에 객체의 형상이 일부만 담기기 때문에, YOLO 알고리즘이 객체를 인식하지 못했기 때문이다. 또한 13m 이상에서의 인식률 저하는 영상에서 객체의 크기가 너무 작아 인식률이 낮아짐을 보였다.



Figure 3-2. Distance measurement performance comparison



Figure 3-3. Detection success rate by distance

인식률이 가장 높은 2m~13m 구간에서 인식률은 98% 이상이지만, 국제 표준이 요구하는 99.99%의 인식률에는 미치지 못했다. 하지만 선행연구(Steen, 2016)에서도 국제 표준 요구사항의 인식률 99.99%의 불분명함을 지적했듯, 실제 자율주행 시험에서 알고리즘의 인식률과 안전 기능의 성공률의 연관성을 확인해볼 필요가 있다.

제 2 항 스테레오 비전 센서와의 비교

스테레오비전은 장애물과의 거리 측정 평균 오차는 0.28m, RMSE 0.68m로 나타났다. 평균 오차는 개발 알고리즘과 0.04m로 근소하지만, 이는 원거리에서 인식률이 떨어져 오차가 큰 구간에서의 데이터의 개수가 적기 때문이며, 장애물과의 거리가 5m 이상에서는 1m이상의 오차를 보였다. 또한 8m 이상의 거리에서는 오차가 2m이상 나는 등, 개발 알고리즘에 비해 낮은 결과를 보였다.

스테레오 비전의 인식률이 낮게 나타난 원인은, ZED2의 경우 화각이 D435i에 비해 넓어 동일한 크기의 객체여도 영상에서의 크기가 작게 나타났기 때문에 동일한 다크넷 기반 인식 알고리즘을 사용하여도 인식률이 낮게 나타난 것으로 추정하였다.

장애물의 GPS상의 좌표를 추정하는 위치 추정식은 실험에서 RMSE 0.37m로 나타났고, GPS 데이터와 함께 도시하였을 때 Figure 3-5와 같이 나타난다. 이는 센서가 평지에서 정지 상태에서 측정한 것으로, 실제 농업 환경에서는 트랙터의 자세에 따라 라이다 센서의 자세도 바뀌어 안정적인 위치 추정이 어려울 것으로 예상된다. 안정적인 장애물의 위치 추정 알고리즘을 위해서는 IMU 센서를 통해 라이다 데이터의 보정 알고리즘이 필요하다.



Figure 3-4. Distance error comparison with stereovision



Figure 3-5. Object position estimation



Figure 3-6. Object Detection at far distance



Figure 3-7. Object Detection at close distance

제 2 절 동적 상황에서의 장애물 감지

제 1 항 경고 구역과 위험 구역의 설정

경고 구역과 위험 구역을 설정하기 위하여 실제 자율주행 트랙터의 비상 정지 시의 거동을 확인하였다. 정지한 사람을 인식하고 비상 정지 작동을 5회 반복하여 데이터를 분석하였으며, 이에 대한 결과로 통신 지연 시간은 평균 0.329초, 감속 시간은 2.375초, 정지 거리는 56.39cm로 나타났다. SNU 자율주행 트랙터의 평균 경운 작업 속도는 약 1.8km/h로 저속이지만, 작동기가 브레이크와 클러치 모두 가동할 때까지 2초 이상의 시간이 지연되었다.

총 5회의 비상 정지 시험 중 최대 지연 시간은 3.157초, 최대 정지 거리는 59.98cm로 나타났다. 이를 고려하여 비상 정지하는 트랙터와 사람의 상대적인 움직임을 가정하면, 부주의한 상태로 농업기계로 접근하는 사람의 속력을 일반적인 보행 속도인 4km/h로 고려하였을 때, 트랙터가 정지할 때까지 사람의 이동 거리는 약 3.51m이다. 이를 산술적으로 더하여 최대 접근 거리를 4.11m 로 판단하였고, 안전을 위한 여유 거리를 추가하여 전방 방향 위험 구역을 5m까지로 설정하였다.

수평 방향 위험 구역은 트랙터의 폭이 2m인 점을 고려하였다. 경로 추종 알고리즘에서 발생할 수 있는 횡방향 오차는 알고리즘과 GPS 센서의 한계로 수 cm 발생할 수 있기 때문에, 안전을 위한 여유 거리를 고려하여 3m로 설정하였다.

경고 구역은 장애물이 위험 구역에 진입할 수 있는 가능성이 있는 영역으로, 위험 구역에서 전방 방향으로 10m까지를 확장하여 설정하였다.



Figure 3-8. Warning zone and hazard zone

Table 3-1. Lag time and running distance of emergency stop

	Communication (s)	Deceleration (s)	Distance (cm)
Test 1	0.313	2.137	54.24
Test 2	0.325	2.122	54.28
Test 3	0.372	2.785	59.98
Test 4	0.311	2.282	55.72
Test 5	0.323	2.547	57.71
Mean	0.329	2.375	56.39



Figure 3-9. Velocity change of emergency stop

제 2 항 자율주행 상태에서의 장애물 충돌 방지 실험

자율 경운 경로에서의 평가 실험에서는, 자율주행 상태에서 총 63회의 장애물 등장 상황에서 62회 충돌 방지에 성공하였다. Test 1에서는 28회 장애물 등장 시나리오에서 충돌 방지에 성공하였으며, Test 2에서는 정지에 1회 실패하였다.

장애물 인식 및 자율주행 정지 기능은 Figure 3-10과 같이 앉아 있는 장애물이 등장한 상황에서도 성공적으로 수행되었으며, Figure 3-11와 같이 선회 상황에서도 성공적으로 수행되었다. 카메라는 전방을 주시하기 때문에 선회 시에 선회 반경 내에 있는 장애물은 급작스럽게 카메라 영상에 등장할 수 있지만, 알고리즘이 실시간으로 동작하였기 때문에 빠른 반응으로 정지 기능이 작동하였다. 또한 Figure 3-12와 같은 경로 밖의 장애물을 인식하여 정지를 하지 않는 경우는 충돌 방지 성공률에 포함되지 않지만, 경로 내부로 오인하지 않고 주행 상태를 유지하였다.

1회의 충돌 방지 실패는 장애물 인식 후 정지에는 성공했으나 재시작의 오류가 발생한 경우였다. 선회 상황에서 등장한 장애물을 전방 1.85m 거리에서 정지했으나, 임베디드 PC에서 개발 코드 이외의 데이터 저장을 위한 연산 부하에 의해 프레임 누락이 발생하여 전방에 장애물이 있던 상황에서 다시 주행을 시작하였고, 충돌 위협이 발생한다고 판단하여 실험자가 직접 브레이크 페달을 작동하였다.

이는 하드웨어적 한계로 인한 오작동으로, 자율주행 트랙터의 상위제어기가 인식 시스템의 작동 상태를 감시하여 오류를 최소화할 수 있는 보조적 안전 시스템의 구성이 필요함을 알 수 있다.

	Number of Times a Person has Appeared (#)	Detection Fail Rate (%)	Number of Collision Avoidance Failure (#)
Standing	16	1.23	0
Sitting	9	1.24	0
Fallen	3	2.71	0
Overall	28	1.28	0

Table 3-2. Test 1 results by human posture

Table 3-3. Test 1 results by relative position of obstacle

	Number of Times a Person has Appeared (#)	Detection Fail Rate (%)	Number of Collision Avoidance Failure (#)
On-path	24	1.26	0
Off-path	4	1.38	0
Overall	28	1.28	0

	Number of Times a Person has Appeared (#)	Detection Fail Rate (%)	Number of Collision Avoidance Failure (#)
Standing	18	4.72	0
Sitting	12	5.14	0
Fallen	5	8.55	1
Overall	35	6.24	1

Table 3-4. Test 2 results by human posture

Table 3-5. Test 2 results by relative position of obstacle

	Number of Times a Person has Appeared (#)	Detection Fail Rate (%)	Number of Collision Avoidance Failure (#)
On-path	28	5.81	1
Off-path	7	7.77	0
Overall	35	6.24	0



Figure 3-10. Sitting person detection



Figure 3-11. Safeguard function at turning path



Figure 3-12. Off-path person detection

제 2 항 조명 환경의 영향

Test 2의 인식률이 떨어지는 이유는 장애물이 역광을 받는 방향으로 주행할 때, 하늘과 지면의 노출 대비로 인해 인식률이 떨어지는 현상이 발생했기 때문이다. Test 2는 오후 5시경 수행되어 해의 위치가 낮아 역광이 발생하였는데, D435i의 자동 노출 조절은 이미지 화상 전체의 밝기를 기준으로 노출을 조절하는 평가 측광 방식을 사용하기 때문에 하늘과 지면의 밝기 대비가 큰 상황에서 지면 위 객체와 지면이 모두 어두워져 인식 알고리즘이 분리하기 어려웠던 것으로 추정된다. 역광 환경에서 인식률을 개선하기 위해서는 카메라의 노출 조절 알고리즘의 개발이 필요하다. 본 연구에서 활용된 D435i 카메라의 경우, 내부 캡처보드의 노출 조절 알고리즘은 평가 측광 방식이 기본으로 설정되어 있지만, 제조사에서 제공하는 개발용 패키지를 이용하여 수동으로 노출 조절이 가능하다. 노출 조절의 기준이 되는 측광 영역을 지면의 영역으로 설정하는 부분 측광 방식으로 노출을 조절하면, 조명 환경에 더 강인한 알고리즘을 기대할 수 있다.



Figure 3–13. Detection Failure by counter light

제 3 항 쓰러진 사람의 검출

Table 3-1과 Table 3-3에서 쓰러진 사람을 인식할 때는 다른 자세의 경우에 비해 인식 실패가 많이 발생하였다. 지면에서 약 0.3m의 높이를 가진 쓰러진 사람을 인식하는 상황에서 YOLOv3-tiny 알고리즘은 장애물이 5m 거리에 있을 때 인식하지 못하였다. 쓰러진 사람의 형상이 사람이라고 판단하기에 일반적인 형태가 아니었기 때문으로 추정된다. 이 경우 인식률은 다른 자세에 비해 낮았지만, 쓰러진 사람이 전방 3m에 위치할 때, 사람을 인식하였으며 2m 앞에서 정지하여 충돌 방지에 성공하였다.

쓰러진 사람을 인식하는 장애물과 지면과의 높이가 차이가 작아 라이다만을 활용하여 검출하기 어렵기 때문에 본 알고리즘의 강점을 보였지만 장애물이 앞서 설계한 위험 구역(Hazard Zone)인 전방 5m에 도달했을 때 즉각적으로 대응하지 못했다는 한계가 있다.

이는 개발 알고리즘의 인식 성능이 RGB 영상의 딥러닝 알고리즘 성능에 의존적이라는 한계에 의해서 나타난 현상으로, 다양한 자세의 사람에 대한 더 좋은 인식 성능을 가지는 딥러닝 모델을 적용하면 인식 성능이 개선될 수 있다. 하지만 딥러닝 모델의 경우 본 연구에서도 역광 등 다양한 조명 상황에서의 인식 성능이 상이하게 나타나는 등 모든 상황에서의 적용성을 보장하지 못하기 때문에, 딥러닝 알고리즘 이외의 독립적으로 작동하는 보조적 인식 센서 혹은 알고리즘을 적용하여 전체 인식 시스템의 중복성(redundancy)을 확보하는 방법으로 개선할 수 있다.



Figure 3-14. Fallen person detection



Figure 3-15. Safeguarding fallen person against collision



Figure 3-16. A person entering warning zone



Figure 3-17. A person in warning zone

제 3 절 설계 요건 기반 알고리즘 평가

제 1 항 사람 및 장애물 인식과 상대 위치 추정

개발 알고리즘은 RGB 카메라로 사람을 인식하며 라이다 센서로 상대 위치를 추정하였다. 농업 환경에서 알고리즘의 거리 측정 성능은 평균 오차 0.24m, 평균 제곱근 오차 0.24m로 상대 위치를 고르게 측정하며 약 13m 거리까지 98% 이상의 인식률을 보였다.

본 연구에서는 윤리적 문제와 직결되어 안전의 최우선이 되는 사람만을 인식하였지만 국제 표준은 사람 이외의 장애물 역시 인식할 것을 요구한다. 농업 환경에서의 장애물은 사람 이외에도 철탑, 농업기계, 농기구, 베일 등 지면 위의 사물이 있고, 사물 이외에도 논둑 같은 지면의 요철, 토양 상태에 의해 자율주행 농업기계가 충돌, 전복, 기능 이상을 일으킬 수 있다. 따라서 자율주행 농업기계의 완전한 무인화를 달성하기 위한 안전 기능은 복합적인 인식 성능을 요구한다.

이와 같이 다양한 농업 환경에서 인식 시스템의 인식 객체를 선정하기 위해선, 사람 다음으로 우선될 수 있는 장애물을 선정할 필요가 있다. 현재 국내에 상용화된 자율주행 농업기계에 작업자는 탑승한 상태로 환경을 항상 주시하고 있기 때문에, 일반적으로 사물이 있는 환경에서 자율주행 농업기계를 운용할 가능성은 희박하다. 농촌진흥청의 농업기계 사고 사례에 따르면, 트랙터의 주요 사고 원인으로는 전체 사고 사례 중 42% 이상인 전복, 전도 사고가 있다. 특히 트랙터가 농지의 출입구와 논둑을 타고 주행하다 전복이 발생할 수 있으며 이는 농지 내의 자율주행 트랙터의 주요 사고 원인이 될 수 있다. 따라서 추후에는, 농지 지형의 형태를 인식하여 전복 발생 위험이 있는 구역으로의 진입을 방지하는 인식 시스템의 개발이 필요하다.

제 2 항 장애물 감지 시 작업 정지와 재개

개발 알고리즘을 실제 자율주행 트랙터에 적용하고 경운 경로를 주행하며 장애물 감지 및 경고음 발생, 주행 정지 및 재개에 대한 실험은 총 63번의 경우 중 62번 성공하였다. 사람과의 충돌 방지 성공률은 98%로 보고하였지만 사람에 대한 안전 시스템 성능은 더욱 강인해야 한다. 이에 따라 앞서 서술한 더 강인한 딥러닝 모델의 개발, 안전 시스템의 다중성의 확보 등으로 개선할 필요가 있다.

국제 표준에서 요구하는 작업 정지를 넘어 완전 무인화를 고려한다면 트랙터의 회피 기동에 대한 개발도 필요할 수 있다. 하지만 현재의 자율주행 수준과 농업 환경을 고려하면 농업 환경에서 장애물 감지 시, 트랙터가 장애물을 회피한다면 트랙터의 바퀴에 의해 작업 구역이 훼손될 가능성이 있고, 논둑을 타는 등의 사고의 가능성이 있다. 따라서 회피 기동의 개발에 앞서 복합적인 환경에 대한 인식 시스템과 자율주행 트랙터의 의사 결정 트리가 개발되어야 할 것이다.

제 3 항 작업 상태의 감독

본 연구에서는 RGB 카메라를 통하여 인식 시스템의 감지 상태를 트랙터 내부에서 감독할 수 있게 하였고 또한 작업자는 캐빈 내부에서 직접 작업 상태를 직접 감독할 수 있다. 감독 기능은 트랙터 캐빈 내부의 작업자에게만 적용되었지만, 원격의 작업자에게 이를 알리기 위해서는 RGB 카메라의 영상을 실시간으로 알릴 수 있어야 한다. 이는 MQTT 통신 등 사물 인터넷 기능으로 구현 할 수 있으며, 작업자가 트랙터에 직접 탑승하지 않는 수준의 자율주행 기술을 달성하기 위해서는 필수적인 기능이다.

실시간 감독 이외에도 안전 시스템에는 영상을 기록하는 기능이 필요할 수 있다. 타 산업인 자율주행 자동차 분야에 적용되는 자동차손해배상법은 자율주행 자동차에 자율주행 정보 기록장치의 부착을 의무화하고 있으며 자율주행 자동차 사고위원회로 사고 원인 규명과 정보 제공을 하도록 한다. 마찬가지로 자율주행 농업기계의 사고시 중요한 정보가 될 수 있는 RGB 카메라는 필수적인 장치이다.

제 4 항 자율주행 농업기계의 안전 시험 방법

현재 국내에는 자율주행 농업기계의 안전 인증 시험 방법에 대한 규정이 없지만, 일본에서는 ISO 표준 장애물을 대상으로 충돌 방지 인증 시험을 시행하고 있다. 일본의 인증 시험은 이는 멈추어 있는 80cm 높이의 장애물만을 인지할 뿐 본 연구에서 다루었던 쓰러진 사람, 움직이는 사람 등에 대한 대응은 다루고 있지 않다. 이에 따라 현재 일본의 자율주행 농업기계에 대한 규정은, 자율주행 농업기계의 안전 기능에만 의존하지 않으며 작업자는 반드시 작업 영역을 주시해야 하고 사고 발생 위험을 항상 대비하고 있어야 한다는 제한을 두고 있다.

국내 역시 자율주행 농기계가 먼저 상용화된 일본의 사례를 참고하여 ISO 표준 시험을 근거로 유사한 수준의 안전 인증 시험 방법과 규정이 시행될 것으로 예측되지만, 미래에 레벨 3, 레벨 4 수준의 자율주행 기술이 상용화기에 앞서 농업 환경을 고려하여 더 안전한 자율 작업이 가능한 시험 평가 방법을 구성할 필요가 있다.

제 4 장 결론

자율주행 트랙터의 기술이 고도화됨에 따라, 무인화를 위해서는 안전 기능이 필수적이다. 자율주행 트랙터의 안전한 농작업을 위해서는 인식 시스템의 구성이 필요하며, 농업 환경에서 강인한 성능을 보이는 인식 시스템의 구성이 중요하다. 본 연구에서는 자율 경운 트랙터에 적용하기 위해 국제 표준에 근거하여 설계 요건에 근거하여 인식 시스템을 설계하였고, 인식의 대상으로 사람을 선정하였다. 또한 센서 퓨전 기반의 인식 시스템을 개발하여 자율주행 트랙터에 적용하고, 이를 농업 화경에서 현장 검증하였다. 카메라와 라이다의 데이터 융합에는 카메라-라이다 캘리브레이션을 활용하였고, 영상에 투영된 라이다 데이터를 통해 영상에서 거리 정보를 얻을 수 있었다. 이를 기반으로 딥러닝 알고리즘으로 인식된 장애물의 거리정보를 통해 장애물이 작업 경로 상에 있는지 여부를 판단하였으며, 위험 구역에서 장애물이 발견되면 작업을 정지하고, 장애물이 제거되었다 판단하면 작업을 재개하는 안전 기능을 제시하였다. 개발 알고리즘은 기존의 스테레오카메라 대비 더 넓은 영역에서 더 정확하게 장애물을 인식하였으며, 자율 경운 경로를 자율 주행하는 상황에서 다양한 자세의 사람을 인식하고 충돌 사고를 방지하였다.

본 연구에서 개발된 인식 시스템은, 현재 장애물 인식에만 적용되었지만, 추후 연구에서는 다양한 목적으로 활용될 수 있을 것으로 기대된다. 카메라 영상에서 라이다 센서의 정밀한 거리 정보를 취득할 수 있기 때문에, 현재는 수동 조작으로 취득하는 농지 경계 GPS 좌표 취득에도 적용되어 자율주행 트랙터의 기술 수준을 레벨 4단계로 고도화하는 데에 기여할 수 있을 것으로 기대된다.

참고 문헌

- Ball, D., Upcroft, B., Wyeth, G., Corke, P., English, A., Ross, P., ... & Bate, A. (2016). Vision-based obstacle detection and navigation for an agricultural robot. Journal of field robotics, 33(8), 1107-1130.
- Steen, K. A., Christiansen, P., Karstoft, H., & Jørgensen, R. N. (2016). Using deep learning to challenge safety standard for highly autonomous machines in agriculture. Journal of Imaging, 2(1), 6.
- Christiansen, P., Kragh, M., Steen, K. A., Karstoft, H., & Jørgensen, R. N. (2017). Platform for evaluating sensors and human detection in autonomous mowing operations. Precision agriculture, 18(3), 350-365.
- Christiansen, P., Hansen, M. K., Steen, K. A., Karstoft, H., & Jørgensen, R.N. (2015). Advanced sensor platform for human detection and protection in autonomous farming. In Precision agriculture'15 (pp. 1330–1334). Wageningen Academic Publishers.
- Christiansen, P., Nielsen, L. N., Steen, K. A., Jørgensen, R. N., & Karstoft, H. (2016). DeepAnomaly: Combining background subtraction and deep learning for detecting obstacles and anomalies in an agricultural field. Sensors, 16(11), 1904.
- Yang, L., & Noguchi, N. (2012). Human detection for a robot tractor using omni-directional stereo vision. Computers and Electronics in Agriculture, 89, 116-125.
- Ji, Y., Li, S., Peng, C., Xu, H., Cao, R., & Zhang, M. (2021). Obstacle detection and recognition in farmland based on fusion point cloud data. Computers and Electronics in Agriculture, 189, 106409.

- Reina, G., Milella, A., & Galati, R. (2017). Terrain assessment for precision agriculture using vehicle dynamic modelling. Biosystems engineering, 162, 124–139.
- ISO/DIS 18497:2018: Agricultural machinery and tractors Safety of highly automoated machines – Principles for design. Retrieved 2022, 3 January
- Li, Y., Iida, M., Suyama, T., Suguri, M., & Masuda, R. (2020). Implementation of deep-learning algorithm for obstacle detection and collision avoidance for robotic harvester. Computers and Electronics in Agriculture, 174, 105499.
- Verma, S., Berrio, J. S., Worrall, S., & Nebot, E. (2019, October). Automatic extrinsic calibration between a camera and a 3D Lidar using 3D point and plane correspondences. In 2019 IEEE Intelligent Transportation Systems Conference (ITSC) (pp. 3906-3912). IEEE.
- 12. Rovira-Mas, F., Reid, J. F., & Han, S. (2005). Obstacle detection using stereo vision to enhance safety of autonomous machines. Transactions of the ASAE, 48(6), 2389-2397.
- Rovira-Más, F., Zhang, Q., & Reid, J. F. (2008). Stereo vision three-dimensional terrain maps for precision agriculture. Computers and electronics in agriculture, 60(2), 133-143.
- 14. Xu, H., Li, S., Ji, Y., Cao, R., & Zhang, M. (2021). Dynamic obstacle detection based on panoramic vision in the moving state of agricultural machineries. Computers and Electronics in Agriculture, 184, 106104.
- 15. Li, Y., Li, M., Qi, J., Zhou, D., Zou, Z., & Liu, K. (2021). Detection of typical obstacles in orchards based on deep

convolutional neural network. Computers and Electronics in Agriculture, 181, 105932.

- Reina, G., Milella, A., & Galati, R. (2017). Terrain assessment for precision agriculture using vehicle dynamic modelling. Biosystems engineering, 162, 124–139.
- Kragh, M., Jørgensen, R. N., & Pedersen, H. (2015, July). Object detection and terrain classification in agricultural fields using 3D lidar data. In International conference on computer vision systems (pp. 188–197). Springer, Cham.
- Korthals, T., Kragh, M., Christiansen, P., Karstoft, H., Jørgensen, R. N., & Rückert, U. (2018). Multi-modal detection and mapping of static and dynamic obstacles in agriculture for process evaluation. Frontiers in Robotics and AI, 5, 28.
- Kragh, M., & Underwood, J. (2020). Multimodal obstacle detection in unstructured environments with conditional random fields. Journal of Field Robotics, 37(1), 53-72.
- 20. Kragh, M. F., Christiansen, P., Laursen, M. S., Larsen, M., Steen, K. A., Green, O., ... & Jørgensen, R. N. (2017). Fieldsafe: dataset for obstacle detection in agriculture. Sensors, 17(11), 2579.
- Han, X., et al., Application of a 3D tractor-driving simulator for slip estimation-based path-tracking control of autoguided tillage operation. Biosystems Engineering, 2019. 178: p. 70-85.
- 22. Han, X., Kim, H. J., Jeon, C. W., Moon, H. C., Kim, J. H., & Seo,I. H. (2021). Design and field testing of a polygonal paddy infield path planner for unmanned tillage operations.

Computers and Electronics in Agriculture, 191, 106567.

 Skoczeń, M., Ochman, M., Spyra, K., Nikodem, M., Krata, D., Panek, M., & Pawłowski, A. (2021). Obstacle detection system for agricultural mobile robot application using RGB-D cameras. Sensors, 21(16), 5292.

Abstract

Development of Sensor Fusion-based Obstacle Detection and Collision Avoidance Technology for Autonomous Tractor

Ye Been Hwang Biosystems Engineering The Graduate School Seoul National University

Collision avoidance systems are essential for unmanned autonomous agricultural tractors. The autonomous tractor should detect obstacles on the path and respond appropriately to the relative location of the obstacles to avoid collisions. Although obstacle detection and classification algorithms based on the use of various cameras have been being developed, the accurate measurement of distances to various objects in real-time is limited due to a difficulty in discriminating the objects under the varying illumination conditions. Since a LiDAR can determine the relative location of obstacles over a wide detection range, it is possible to compensate for the shortcomings of the monocular camera by using 3D information from LiDAR. The purpose of this study is to develop a collision avoidance technique for autonomous tractors. An obstacle detection algorithm was designed based on sensor fusion of a camera and a LiDAR sensor. In principle, the camera performs obstacle detection based on YOLO, and the LiDAR determines the relative distance to the obstacle detected by the camera through coordinate transformation. In field

experiments, the proposed algorithm was applied to an autonomous tractor to verify the object detection and collision avoid performance. The autnomous tractor drove along the cultivation path, and stopped when the collision with an obstacle was predicted. The detection performance was over 97% and the success rate of collision avoidance was over 98%.

Keywords : Autonomous Tractor, Sensor Fusion, LiDAR, Collision Avoidance, Machine Vision Student Number : 2021-24813