

# 자율주행 트랙터 경로 추종을 위한 영상 기반 경계검출기술 개발

서 다 슴\*, 원 진 호\*, 양 창 주\*, 김 국 환°, 권 경 도\*, 김 경 철\*, 홍 영 기\*, 류 희 석\*

## Development of Boundary Detection Methods Based on Images for Path Following of Autonomous Tractor

Dasom Seo\*, Jin-Ho Won\*, Changju Yang\*, Gookhwan Kim°, Kyung-Do Kwon\*,  
Kyoung-Chul Kim\*, Youngki Hong\*, Hee-Seok Ryu\*

### 요 약

본 논문은 기존 GNSS 기반 연구와 달리 영상 인식 기반 트랙터 자율주행 방법론을 제안하였다. CNN 기반 차선 검출 모델인 LaneNet의 과생영역(branch)중, 목적에 맞게 일부만 사용하는 형태로 수정하여 논, 밭이라는 특수한 농작업 환경에서 사용할 수 있는 모델을 개발하였다. 학습에 필요한 논, 밭에서의 경운/미경운 경계에 대한 영상 데이터셋을 직접 수집하고 이를 이용하여 학습된 모델로 경운/미경운 영역 간 작업 경계를 검출하였다. 검출된 경계선을 이용하여 트랙터가 자율 주행할 수 있도록 경계선과 주행 기준선 사이의 간격을 일정하게 유지하기 위한 조향각을 산출하였다. 산출된 조향각은 CAN 통신을 통해 트랙터로 실시간으로 전송되어 트랙터 조향 제어에 활용되었다. 제안한 모델을 기반으로 직진구간에 대해 조향 제어를 수행한 결과, 최대  $\pm 9.51\text{cm}$  이내의 오차로 자율주행이 가능함을 확인하였다.

**키워드** : 자율주행, 농업기계, 경계 검출, 합성곱 신경망, 조향제어

**Key Words** : autonomous traveling, agricultural machinery, boundary detection, CNN, steering control

### ABSTRACT

This paper proposes the autonomous traveling methodology of tractors based on an image recognition unlike existing GNSS-based tractor studies. Among the branches of LaneNet, which is a CNN-based lane detection model, we have developed a model that can be used in special agricultural work environments such as paddy or dry fields by modifying it to use only a part considering to the purpose. Image datasets for tillage/untilled boundaries in the fields required for learning were collected directly, and the working boundaries between tilled/untilled areas using the learned model were detected. The steering angle to keep the distance between the boundary and the reference line was calculated so that the tractor can autonomously travel using the detected boundary line. The calculated steering angle was transmitted to the tractor in real time through CAN communication and used it for steering control of the tractor. As a result of performing steering control for the straight section based on the proposed model, it was confirmed that autonomous traveling was possible with an error of up to  $\pm 9.51\text{cm}$ .

※ 본 성과물은 농촌진흥청 연구사업(세부과제번호:PJ01393801)의 지원에 의해 이루어진 것임.

• First Author : National Institute of Agricultural Sciences, ssomncandy@gmail.com, 정희원

° Corresponding Author : National Institute of Agricultural Sciences, meceng93@korea.kr, 정희원

\* National Institute of Agricultural Sciences,

논문번호 : 202109-257-0-SE, Received September 7, 2021; Revised October 19, 2021; Accepted October 27, 2021

## I. 서 론

최근 농업 인구의 고령화 여성화로 인한 노동력 감소와 기후변화, 생산량 감소 등에 따른 식량 안보 문제는 세계적으로 큰 화두가 되고 있다. 그 해결책의 하나로 실시간 센싱, 데이터 분석 및 제어 기술을 통한 농업 생산 자동화, 자율화 시스템을 활용한 무인화 농업이 기술적 대안으로 제시되고 있다.

트랙터는 대표적인 농업기계로 최근 기계식에서 전자 제어가 가능한 파워 셔틀, 파워 시프트 모델을 기반으로 자율주행 기술과 접목한 무인 트랙터 개발을 위한 핵심기술 확보 및 제품화가 활발히 추진되고 있다<sup>1)</sup>. 자율주행 기술은 무인 트랙터의 핵심 기술 중 하나로 작업할 환경에 대한 경로를 사전에 설정, 인식하고 이를 추종하는 기술로 농업용 트랙터의 경우 1950년부터 관련 연구가 꾸준히 수행되고 있다<sup>2)</sup>. 대부분의 자율주행 트랙터 기술 연구는 위항법시스템(GNSS, Global Navigation Satellite System) 기반의 사전 경로 생성 및 이를 추종하는 방식으로 트랙터 조향 제어를 수행하는 방식이다<sup>3-5)</sup>. 하지만 고정밀 GPS의 높은 가격과 작물 환경에 따른 위성 신호 수신 불확실성 등으로 인해 그 한계에 직면해 있다.

본 논문에서는 GPS 기반의 무인 트랙터 기술의 한계를 극복하기 위해 기계 시각(Machine Vision)을 이용한 실시간 환경 인식 및 경로 추종 기술을 제안하고자 한다. 실시간 환경 인식을 위해 다채널 레이저 센서인 LiDAR를 활용하거나 스테레오 비전 등 3D 영상을 이용하는 등 다양한 영상인식 연구가 진행되고 있다<sup>6,7)</sup>. 농업 분야에서도 병해충 및 질병 인식을 위해 심층 학습(Deep Learning) 기반의 분류 알고리즘<sup>8)</sup>을 적용한 연구도 활발히 진행되고 있는데, 대부분 객체 검출에 관련된 연구를 목적으로 수행되고 있다. 본 논문에서는 영상 정보를 기반으로 심층 학습 알고리즘을 활용하여 트랙터가 경운 작업 시 생성되는 경계를 자동으로 검출하는 기술을 제안하고자 한다. 이는 심층 학습 기반 영상 학습을 통해 트랙터 전면부에 장착된 카메라로부터 얻어진 영상의 경계(경운 전, 후 및 배경)를 분류한 후, 이들의 경계를 검출하고 이를 작업 폭을 고려한 주행 기준선과 비교하여 트랙터를 자동으로 조향하는 기술을 개발하였다. 주행 기준선과 검출된 경계선의 오차를 활용하여 실제 트랙터에 적용하여 조향제어를 수행하였고, 그 성능을 평가하였다.

## II. 재료 및 방법

### 2.1 트랙터 경운 영상 특징

트랙터를 이용하여 경운 작업을 하였을 때 주행 정면의 영상은 일반적으로 그림 1과 같이 경운 전, 후 및 배경의 3가지 영역으로 크게 구분할 수 있다. 경운 전의 농지는 수확 후 남은 작물의 일부, 잡초 등이 존재하는 반면에 경운 이후의 영역에서는 쟁기나 로터 베이더 등의 작업기의 쇠토로 인해 토양 표면이 경운 전과 비교하였을 때 색상, 질감 등의 차이를 보여준다. 본 논문에서는 이러한 경운 전, 후의 토양 패턴 및 색상 등의 차이로 발생되는 경계를 검출하고 이를 주행 기준선으로 판단하여 일정한 간격을 유지하도록 추종 제어하는 방식으로 트랙터 조향제어를 수행하고자 하였다.



그림 1. 밭 경운 시 RGB 카메라에 의해 얻어진 영상 개요  
Fig. 1. Image obtained by RGB camera while tractor tillage operation

### 2.2 시스템 개요

본 논문에서는 기존의 트랙터 자율주행 연구에서 GPS를 기반으로 주행경로를 설정하고 카메라가 보조 역할을 했던 것과 달리 카메라만을 이용해 트랙터 주행에 필요한 정보를 얻고자 하였다.

그림 2에서 보는 바와 같이 트랙터 상단부 중앙(일반적인 블랙박스 장착 위치)에 RGB 카메라(RealSense D435, Intel)를 장착하여 트랙터가 이동 시, 카메라로부터 RGB 영상을 취득하여 실시간으로 경로 추종을 위한 경계선을 검출한다.

경계선 검출은 심층 학습 기반의 영상 분할(Image segmentation) 모델을 사용하였다. 이렇게 검출된 경계선과 주행 기준선을 비교하여 바퀴 조향각을 산출하고 이를 CAN(Controller Area Network) 통신을 통해 트랙터로 전송하여 트랙터 조향 제어를 수행한다. 이때, 상황에 따라 트랙터의 조향각, 엔진 RPM 및 기어 상태를 상황에 맞게 변환이 가능하도록 구성되어 있다. 시스템 개략도는 그림 3과 같다. 이때, 카메라로



그림 2. 트랙터 상단부에 장착된 카메라  
Fig. 2. RGB camera mounted on the front side of a tractor




그림 3. 시스템 개략도  
Fig. 3. System Schematic Diagram




그림 4. 실시간 추종선 검출 조향각 제어 시스템  
Fig. 4. Real-time line detection and tractor control system

부터 입력받은 영상을 실시간으로 처리하는 알고리즘은 크게 추종선 검출부와 조향각 추정부로 나눌 수 있는데, 그 개략도는 그림 4와 같다. 본 장에서는 그림 4의 알고리즘을 자세히 기술한다.

### 2.3 CNN 기반 경계선 검출(Tracking line detection)

#### 2.3.1 모델 개요 및 적용 방법

논, 밭은 도로와 달리 차선, 중앙선 등의 구역에 대한 구분선이 없다. 하지만, 트랙터로 경운 작업을 하는 경우, 경운한 영역과 경운하지 않은 영역 사이에 경계가 생기게 된다. 본 논문에서는 카메라를 통해 실시간으로 얻어지는 영상을 통해 이 경계를 구분선으로 검출하여 이를 추종하도록 하고자 하였다. 경계 검출을 위해 합성곱 신경망(Convolutional neural network, 이하 CNN) 기반 차선 검출(Lane detection)

모델 중 하나인 LaneNet<sup>[9]</sup>을 본 연구에 맞게 수정하여 적용하였다.

LaneNet은 CNN 기반 의미론적 분할 모델(Semantic segmentation)인 인코더-디코더 형태의 네트워크인 ENet<sup>[10]</sup>에 기반한 차선 검출 모델로, 그림 5는 LaneNet의 구조를 보여 주고 있다. LaneNet은 ENet을 인코더와 디코더로 균형을 맞추고 이진 분할 영상(binary segmentation image)과 인스턴스 분할 영상(instance segmentation image)의 두 가지 파생영역(branch)으로 수정한 모델이다<sup>[9]</sup>. 그림 5에서 보는 바와 같이, 이진 분할 파생영역은 도로 영상을 입력하였을 때, 차선에 해당하는 영역을 이진 분할 해주며 1채널 영상을 출력한다. pixel embeddings 파생영역은 차선의 인스턴스를 나누는 역할로, embedding 차원에 따라 n-채널 영상을 출력한다. 각 파생영역의 손실함수를 반복적으로 클러스터링하여 검출된 차선 부분들(segments)에 인스턴스를 부여(중앙선, 실선, 점선 등 세부적으로 분류하여 각 부분별로 지정함을 의미)하는 인스턴스 분할 영상을 최종적으로 출력한다. 도로 주행의 경우, 자기 차선과 다른 차선의 구별이 필요하기 때문에 검출된 결과에서 차선을 각각 구분할 수 있도록 인스턴스 분할이 필요하지만, 밭 포장 작업의 경우 경운 영역과 미경운 영역 사이의 경계 한 줄, 즉 하나의 객체만 검출하기 때문에 이진 분할 과정만 있으면 가능하다. 그렇기 때문에 실시간으로 영상 처리 속도를 고려하여 본 논문에서는 그림 5의 음영 처리된 부분과 같이 LaneNet의 pixel embedding 파생영역과 클러스터링 과정을 생략한 구조의 모델만을 사용하였다.

그림 6에서 보는 바와 같이, 모델은 다섯 개의 인코더 블록과 네 개의 디코더 블록, 그리고 1x1 합성곱층(convolution layer)으로 이루어져 있으며 각 층 블록은 Vgg-16<sup>[11]</sup>의 구조를 따른다. 층 블록은 2개의 3x3 합성곱 층과 2 stride 간격의 2x2 맥스 풀링(Max pooling) 층으로 이루어져 있다. 각 합성곱 층에는 배치 정규화를 적용하고 활성화함수(Activation function)로 ReLU (Rectified Linear Unit)를 이용하였다.




그림 5. LaneNet 모델 구조  
Fig. 5. The LaneNet Architecture




그림 6. LaneNet 이진 세그멘테이션 브랜치 상세 모델 구조  
Fig. 6. Specific architecture of binary segmentation branch of LaneNet

2.3.2 이진 분할 영상 후처리

설계된 모델로부터 검출된 이진 분할 영상의 경우, 경로 추종을 위한 경운 영역과 미경운 영역의 경계선 (boundary segment) 외에도 잡음(noise segments)이 존재할 수 있다. 트랙터 조향 제어를 위해서는 잡음을 제거하고 필요한 경계선만 선택하는 것이 중요하다. 또한, 심층 학습 모델로부터 검출된 경계선 영역 내에 생기는 작은 공백(hole)들에 대해 영역의 연속성을 갖기 위해 전통적인 방식의 영상 기법을 활용하여 후처리 하였다.

본 논문에서 검출 영역의 연속성을 확보하기 위해 모폴로지(Morphology) 연산<sup>12)</sup>을 이용하였다. 영상에서 모폴로지 연산 중 닫힘 연산 기법은 객체에 팽창(dilation) 후 침식(erosion)을 하는 방식으로 끊긴 객체를 연결하거나 구멍을 메우는 데 효과적이다. 본 논문에서는 설계된 모델로부터 얻어진 출력 영상에 닫힘 연산을 적용하여 작은 공백이나 잡음들을 제거하였다.

잡음 제거를 위해서는 영상의 각 세그먼트를 연결 성분(Connected components)<sup>13)</sup>으로 구분하고, 구분된 각 세그먼트는 고유의 영역 특성(Region property)을 가지며 각 영역에 대한 면적을 구할 수 있는데, 영역의 면적을 비교하여 최대 면적을 갖는 세그먼트를 제외한 나머지 영역을 모두 제거하는 방식으로 잡음을 제거하였다. 최종적으로 출력 영상에는 가장 큰 영역인 경계선 세그먼트만 남게 된다. 그 과정은 표 1과 같다.

모델을 통해 검출된 경계선과 트랙터 사이의 관계를 이용하기 위해 경계선 영상을 그대로 사용하지 않고 입력 영상과 알파-블렌딩(Alpha-blending)을 하였다. 입력 영상은 3채널 RGB 영상이기 때문에 채널 별로 경계선 세그먼트와 혼합해준다. 각 채널에 대한 알파-블렌딩 과정은 수식 (1)과 같다.

$$I_b = (1 - \alpha) \times I_{in} + \alpha \times I_{seg} \quad (1)$$

표 1. 잡음 제거  
Table 1. Noise cancelling

Algorithm. Noise Cancelling	
1:	<b>Input:</b> binary image $i$ , contour function $f_c$
2:	contours group $c_1, c_2, \dots, c_n = f_c(i)$
3:	the area of contour $a$ = the number of pixels in $c$
4:	$c_{max} = \text{argmax}(a)$
5:	$i' = i$
6:	$i'(x, y \in c_{max})$
7:	<b>Output:</b> contour $c_{max}$ , processed image $i'$

입력영상  $I_{in}$ 의 각 픽셀에  $I_{seg}$ 의 값을  $\alpha$ 의 비율로 적용해 혼합영상  $I_b$ 를 구한다. 이때, 세그먼트 혼합 비율  $\alpha$ 가 커질수록 세그먼트 강도가 높게 혼합된다.

2.4 트랙터 조향 제어를 위한 조향각 추정

본 논문에서는 심층 학습 모델을 사용하여 검출된 경계선 세그먼트에서 조향 제어를 위한 제어 입력(control input)과 선회 지점을 결정하였다.

영상을 통해 트랙터의 기준점(중심)을 결정하기 위해 카메라를 트랙터 전면 상단에 장착 시, 영상 하단에 트랙터 엔진룸의 일부가 상시 촬영되도록 하였다. 엔진룸 패치 영상과 입력 영상 간의 템플릿 매칭(Template matching)을 이용해 엔진룸의 좌표를 구하였다. 템플릿 매칭은 패치와 원 영상 간의 유사도를 픽셀 간 거리로 나타내며, 본 논문에서는 픽셀 평균 값을 제외한 곱의 전체 합을 정규화하고 그 값을 거리로 환산하여 사용하는 정규화 상관 계수 템플릿 매칭(Normalized correlation coefficient template matching)을 이용하였다. 템플릿 T와 입력 영상 I 사이의 거리 R은 수식 (2)와 같다.

$$R(x,y) = \frac{\sum_{x',y'} (T(x',y') \cdot I(x+x',y+y'))}{\sqrt{\sum_{x',y'} T(x',y')^2 \cdot \sum_{x',y'} I(x+x',y+y')^2}} \quad (2)$$

정규화 상관계수 템플릿 매칭 결과는 유사도가 가장 큰 위치의 좌표를 반환하며, 이를 트랙터의 위치 기준점  $P_t(x_t, y_t)$ 로 한다.  $P_t(x_t, y_t)$ 와 수평으로 연장선을 그었을 때 마주치는 경계선 위의 한 점  $P_0(x_0, y_0)$ 를 결정하고 두 점 사이의 거리를 일정 간격을 유지할 수 있도록 조향 제어 입력값을 산출한다. 검출 결과가 점이나 선의 형태가 아닌 세그먼트 형태로 검출되기 때문에  $P_0$ 는 세그먼트 영역의 중앙

점으로 결정하였다. 즉,  $x_0$ 는 식 (3)과 같이 정의된다.

$$x_0 = \text{median}(\{x \in (y_t)\}) \quad (3)$$

이 때, 검출된 경계선이 잡음 등으로 인해 경계선 세그먼트가 제대로 검출되지 않아  $P_t(x_t, y_t)$ 과 수평한 위치에서의  $P_0(x_0, y_0)$ 가 존재하지 않을 수도 있다. 이러한 경우를 대비하여 검출된 경계선 위의 두 점  $P_1, P_2$ 를 결정하고 이를 지나는 직선을 구하고 그 직선과  $y = y_t$ 와의 교점을  $P_0(x_0, y_0)$ 로 결정한다. 이렇게 구해진  $x_0$ 를 활용하여 조향 제어를 수행한다.

영상 내 트랙터의 중심점  $P_t$ 와 경계선 세그먼트의 중심점  $P_0$  간 거리를 일정하게 유지하도록 기준 거리를 정하고 이를 기반으로 조향 제어를 위한 제어 입력값을 산출하였다. 트랙터가 경운 작업 영역을 10% 이하의 중복률로 작업할 때의  $P_t$ 와  $P_0$  사이의 기준 거리  $D_{ref}$ 와 심층 학습 모델을 통해 구해진 경계선 세그먼트로부터 얻어진 산출 거리  $D_{bottom}$ 을 이용하여 오차  $L_{dev}$ 를 구해 이를 최소화하는 방향으로 조향 제어를 위한 제어 입력값  $Val_{wheel}$ 을 결정한다. 그 수식은 아래와 같다.

$$D_{bottom} = |x_t - x_0| \quad (4)$$

$$L_{dev} = D_{ref} - D_{bottom} \quad (5)$$

$$Val_{wheel} = Val_0 - PID(L_{dev}) \quad (6)$$

이 때,  $PID(L_{dev})$ 는 결정된 오차를 활용하여 PID 제어를 수행함을 의미한다. 또한,  $Val_0$ 는 트랙터를 조향 제어할 때, 트랙터의 핸들 조향각이 0도일 때의 제어값을 의미한다.

조향 제어를 위한 실험에 이용된 트랙터의 앞바퀴의 유효 회전 각도와 그에 따른 조향 제어 값은 그림 7에서 보는 바와 같이  $\pm 45$ 도 내에서  $\pm 100$  디지털 수 (digit number, 정수형)로 환원하여 제어에 활용하였다. 직진 주행 시의 기준 값  $Val_0$ 은 100으로 설정되어 있다. 조향 제어 값 산출 시, 추종 기준 거리  $D_{ref}$ 를 100 디지털수로 설정하였다.




그림 7. 트랙터의 바퀴 각 및 조향 제어 값  
Fig. 7. The angle of tractor wheels and wheel control value.

### III. 실험 및 결과

#### 3.1 로컬 데이터셋 구축

자율주행 기술을 위한 심층 학습 연구에서 차선 검출(Lane detection), 도로 분할(Road segmentation), 보행자 검출(Pedestrian detection) 등은 주로 KITTI<sup>[14]</sup>, CULane<sup>[15]</sup>, BDD 100K<sup>[16]</sup>, TuSimple<sup>[17]</sup> 등의 도로 영상 오픈 데이터셋을 이용한다. 예의 데이터셋은 날씨, 장소, 시간에 따른 다양한 환경에서 구축되었으며, 차선 검출 및 의미론적 분할(Semantic segmentation) 모델 개발에 주로 이용된다. 최근에는 Udacity 등에서 제공하는 자율주행 시뮬레이터로 가상의 도로 주행 데이터셋을 수집하기도 한다<sup>[18,19]</sup>.

본 논문의 경우는 차선이 아닌 논, 밭에서의 경운 작업 경계를 검출해야 하기 때문에 관련 데이터셋이 필요하다. 그러한 이유로 오픈 데이터셋을 이용하지 않고 연구 과정에서 적합한 형태의 데이터셋을 직접 수집, 구축하였다. 연구기관에 할당되어있는 0.5ha(50m x 100m)의 실험용 밭 포장에서 실제 경운 작업을 진행하면서 주행 영상을 취득하고 학습에 사용할 영상을 대상으로 레이블 작업을 진행하였다. 레이블은 그림 8과 같이 작업 경계에 해당하는 영역을 녹색 선으로 표시하였다.

영상 데이터 취득 및 조향 제어를 위해 그림 2와 9



(a) RGB 영상과 레이블링(녹색선)

(b) 모델 적용 후, 경계 검출

그림 8. 레이블된 데이터셋과 모델 적용 후, 경계선 검출 결과  
Fig. 8. Labeled dataset and the result after applying the algorithm




그림 9. 밭 주행 데이터셋 수집 환경  
Fig. 9. Field driving dataset collecting environment


(a)와 같이 트랙터 전면 상단 중앙부에 카메라를 설치하였다. 그림 9 (a)에서 보는 바와 같이 카메라로부터 사선으로 가리키는 굵은 점선은 카메라의 하단 시야각을 나타내고 있고, 카메라로부터 수평으로 3.64m 떨어진 지점부터 인식 영역이 된다. 이는 트랙터 엔진룸 일부를 카메라 시야(Field of View, 이하 FoV)에 들어오도록 하여 영상에서 트랙터의 위치 기준으로 활용하기 위함이다. 영상 취득 및 조향 제어를 위해 68마력급 트랙터 XU6168(LS엘트론) 모델을 사용하였다.

데이터셋 영상 및 조향 제어를 위한 트랙터 주행은 실제 밭 경운 작업과 동일한 형태로 진행하였다. 경운 작업 방식에는 키 턴(Key turn), K 턴 등 다양한 방식이 있으나 향후 제어 편의성을 고려하여 작업영역 바깥부터 소용돌이 형태로 들어가는 방식으로 진행하였다(그림 9 (b)).


경운 작업을 위해 2150mm 폭의 로타베이터를 트랙터에 장착하였다. 다양한 환경에서의 데이터를 얻기 위해 맑은 날 오전, 오후와 흐린 날 오전 총 3회에 걸쳐 영상을 취득하였다. 이 중 2,682개 프레임을 샘플링해 데이터셋을 구축하였고, 데이터셋의 환경에 따른 구성은 표 2과 같다.

표 2. 데이터셋 구성 (단위: 프레임)  
Table 2. Dataset configuration (unit: frame)

	맑음	흐림	계
오전	1,242	893	2,135
오후	547	-	547
계	1,789	893	2,682



(a) Training loss trend



(b) Validation loss trend

그림 10. 학습 주기에 따른 정확도 그래프 및 손실 그래프  
Fig. 10. The accuracy and loss along the epochs

### 3.2 경계선 검출기 학습 및 성능 평가

앞에서 설명한 LaneNet 기반 트랙터 경로 추종을 위한 경계선 검출 모델을 위에서 구축한 데이터셋으로 학습시켰다. 충분한 모델 학습을 위해 데이터셋을 영상 회전, 반전 등의 데이터 증식(data augmentation)을 통해 10,728장으로 늘려 훈련(training)에는 85%인 9,119장을 사용하였다. 학습에는 Intel Core i9-7920X CPU와 GeForce RTX 2080ti GPU 두 대가 장착된 Ubuntu 16.04 데스크탑 환경에서 진행하였다. 총 40,010 epoch를 학습하는 데 3시간 21분을 소요하였다. 학습 결과는 표 3과 같으며 검증 정확도 97.36%라는 높은 성능으로 학습되었다.

그림 10은 학습 주기에 따른 학습집합 및 검증집합에서의 모델 성능 변화를 보여준다. 학습집합과 검증집합 모두 손실 그래프에서 Epoch에 따른 손실 값이 0으로 수렴하며, 검출 모델이 데이터셋에 과적합

표 3. 검출기 학습 결과  
Table 3. The result of trained classifier

	Train	Validation
Accuracy	98.37	97.36
Loss	0.1029	0.09621




그림 11. 경운/미경운 경계선 검출 결과  
 Fig. 11. The results of boundary line detection between tilled and untilled area

(over-fitting) 되지 않고 잘 학습되었음을 알 수 있다. 검출기 출력은 이진 추종선 영상으로 로타리 작업 시 마커가 지나간 자취를 검출한다. 그림 11은 입력 영상, 정답(Ground truth) 영상 및 결과 영상을 나타내고 있다. 결과 영상은 원본 영상과 모델 출력 결과인 차선 세그먼트 영상을  $\alpha = 0.3$ 로 알파 블렌딩 하였다.

### 3.3 실시간 검출 및 조향 제어

실제 밭 현장에서 경운한 영상으로 실시간 추종선 검출 및 조향 제어 시스템 검증을 진행했다. 현장 실험에는 Intel Core i5-8400T CPU와 GeForce RTX 2070 GPU가 탑재된 베어본 컴퓨터와 데이터셋 구축에 사용된 것과 동일한 LS엠트론 사의 XU6168 트랙터를 사용하였다. 실시간으로 프레임으로부터 추종선을 검출하고 이를 따라 주변속 2단, 부변속 2단에서 1500RPM으로 주행하도록 하였다.

그림 12는 본 연구에서 제안한 심층학습 기반 학습 모델을 활용하여 검출한 경로 추종 경계선 위치 값으로

직진 구간에 대해 트랙터 조향 제어를 수행한 결과를 나타내고 있다. 빨간 선은  $L_{dev}$ 를 의미하는데 첫 5프레임은 카메라 오픈 시 프레임 입력이 불안정하기 때문에  $Val_{wheel}$ 에 null 값을 부여하여 제어하지 않았다.

PID 제어를 위한 제어 게인 값은




그림 12. 모델 기반 추종 경계선을 활용한 트랙터 조향 제어 결과  
 Fig. 12. The result of tractor steering control using boundary line detected by the model




그림 13. 결과 영상과 Ground truth 영상 간 오버랩 영상  
Fig. 13. The overlap image between ground truth and the result image of detection line by the model)

$k_P = 0.5, k_D = 0, k_I = 0$ 으로 설정하여 주행시킨 결과, 최대  $\pm 9.51$  cm 이내의 오차( $I_{dev}$ )로 주행함을 알 수 있다. 경운 작업은 그림 9(b)와 같은 형태로 진행되어 추종을 위한 경계선은 항상 트랙터 오른쪽에 위치한다. 검출이 되지 않거나 잡음으로 인해 값이 갑자기 튀는 경우와 오류로 인해 이전 프레임과 10픽셀 이상 차이가 나면 이전 값을 사용하도록 하였다.

그림 13은 그림 12의 GT 영상과 추종선 검출 출력 영상(result image)을 오버랩한 결과 영상을 나타내고 있다. 결과 영상이 GT 영상을 포함하고 있는 것을 정성적으로 확인할 수 있다. 이는 심층학습을 통해 검출된 경계선, 즉 결과 영상이 기준값을 벗어나지 않음을 의미한다. 또한 두 세그먼트 간의 포함 관계를 정량적으로 평가하는 평균 Recall 성능은 0.58을 기록하였다. 이와 같이 정성적, 정량적 평가 결과를 통해 검출된 경계선에 대한 결과의 안정성이 높다는 것을 알 수 있다.

#### IV. 결 론

본 논문은 기존 GNSS 기반 연구와 달리 영상 인식 기반 트랙터 자율주행 방법론을 제안하였다. CNN 기반 차선 검출 모델인 LaneNet의 파생영역(branch)중, 목적에 맞게 일부만 사용하는 형태로 수정하여 논, 밭이라는 특수한 농작업 환경에서 사용할 수 있는 모델을 개발하였다. 논, 밭의 환경은 도로의 차선과 같이 뚜렷이 구별할 수 있는 경계를 검출할 수 있는 방법이 없다. 본 논문에서는 먼저 트랙터를 활용하여 경운 작업을 할 때, 경운한 곳과 경운하지 않은 곳에 대한 경계를 검출하는 방법을 개발할 목적으로 학습에 필요한 논, 밭에서의 경운/미경운 경계에 대한 영상 데이터셋을 직접 수집하였다. 이를 이용하여 학습된 CNN 기반 모델로 경운/미경운 영역 간 작업 경계를 검출하고, 트랙터가 검출된 경계선을 추종하여 자율주행 할 수 있도록 경계선과 주행 기준선의 간격을 일정하게

유지하도록 조향각을 산출하였다. 산출된 조향각은 CAN 통신을 통해 트랙터로 실시간으로 전송되어 트랙터 조향 제어에 활용되었다. 제안한 모델을 기반으로 직진구간에 대해 조향 제어를 수행한 결과, 최대  $\pm 9.51$ cm 이내의 오차로 주행이 가능함을 확인하였다.

이 시스템의 핵심은 CNN 기반 경계선 검출 모델의 확장성과 유연성이다. 그러나 97.36%라는 높은 검증 데이터셋 성능에도 불구하고 실제 현장 테스트에서는 다수 프레임에서 경계선을 제대로 검출하지 못하거나 경계선 세그먼트가 끊겨서 잡음으로 간주되는 경우가 많았다. 또 직진 구간 대비 선회 구간의 인식률이 현저하게 떨어졌다. 이는 모든 실험이 실외 환경에서 이루어지는 도메인 특성 상 학습 데이터와 시험 데이터 상의 환경이 다르고 데이터셋 내의 구간별 구성 비율 차이가 크기 때문이다.

이 시스템의 성능을 좌우하는 것은 모델 학습에 이용되는 데이터셋이다. 추종선 검출 모델의 안정적인 성능 향상을 위해서는 날씨, 작업 시간 등에 따른 다양한 환경에서의 데이터셋 수집과 직진구간과 선회구간 데이터의 밸런스가 필요하다. 향후 좀 더 상세한 구성의 데이터셋 구축을 통해 학습된 모델을 적용하여 농가 현장 시험에서도 안정적인 경계선 검출이 가능하도록 보완할 계획이다.

#### References

- [1] Y. J. Kim, S. O. Chung, and C. H. Choi, "Development of automation technology for manual transmission of a 50 HP autonomous tractor," *IFAC-PapersOnLine*, vol. 51, no. 17, pp. 20-22, 2018.
- [2] L. Ming, K. Imou, K. Wakabayashi, and S. Yokoyama, "Review of research on agricultural vehicle autonomous guidance," *Int. J. Agric. and Biol. Eng.*, vol. 2, no. 3, pp. 1-16, 2009.
- [3] T. S. Stombaugh, E. R. Bensen, and J. W. Hummel, "Guidance of agricultural vehicles at high field speeds," *Trans. ASABE*, vol. 42, no. 2, pp. 537-544, 1999.
- [4] T. Bell, "Automatic tractor guidance using carrier-phase differential GPS," *Comput. and Electr. in Agric.*, vol. 25, no. 1-2, pp. 53-66, 2000.
- [5] T. Bakker, K. van Asselt, J. Bontsema, J.



- Müller, and G. van Straten, “Autonomous navigation using a robot platform in a sugar beet field,” *Biosyst. Eng.*, vol. 109, pp. 357-368, 2011.
- [6] F. B. P. Malavazi, R. Guyonneau, J. B. Fasquel, S. Lagrange, and F. Mercier, “LiDAR-only based navigation algorithm for an autonomous agricultural robot,” *Comput. and Electron. in Agric.*, vol. 154, pp. 71-79, 2018.
- [7] Z. Wang, J. Underwood, and B. Walsh, “Machine vision assessment of mango orchard flowering” *Comput. and Electron. in Agric.*, vol. 151, pp. 501-511, 2018.
- [8] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, “Gradient-based learning applied to document recognition,” in *Proc. IEEE*, vol. 86, no. 11, pp. 2278-2323, 1998.
- [9] D. Neven, B. D. Brabandere, S. Georgoulis, M. Proesmans, and L. V. Gool, “Towards end-to-end lane detection: An instance segmentation approach,” *2018 IEEE IV Symp.*, pp. 286-291, Changshu, 2018.
- [10] A. Paszke, A. Chaurasia, S. Kim, and E. Culurciello, “Enet: A deep neural network architecture for real-time semantic segmentation,” arXiv:1606.02147, 2016.
- [11] K. Simonyan and A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” *ICLR*, pp. 1-14, 2015.
- [12] R. M. Haralick, S. R. Sternberg, and X. Zhuang, “Image analysis using mathematical morphology,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 9, pp. 532-550, 1987.
- [13] M. B. Dillencourt, H. Samet, and M. Tamminen, “A general approach to connected-component labeling for arbitrary image representations,” *J. ACM*, vol. 39, no. 2, pp. 253-280, 1992.
- [14] A. Geiger, P. Lenz, C. Stiller, and R. Urtasun, “Vision meets robotics: The KITTI dataset,” *Int. J. Robotics Res.*, vol. 32, no. 11, pp. 1231-1237, 2013.
- [15] X. Pan, J. Shi, P. Luo, X. Wang, and X. Tang, “Spatial as deep: spatial CNN for traffic scene understanding,” *Conf. Artificial Intell. (AAAI)*, 2018.
- [16] F. Yu, W. Xian, Y. Chen, F. Liu, M. Liao, V. Madhavan, and T. Darrell, “BDD100K: A diverse driving video database with scalable annotation tooling,” arXiv: 1805.04687v1, 2018.
- [17] *The tuSimple lane challenge*, <http://benchmark.tusimple.ai/>
- [18] A. Buyval, A. Gabdullin, R. Mustafin, and I. Shimchik, “Realtime vehicle and pedestrian tracking for didi udacity self-driving car challenge,” *IEEE ICRA*, pp. 2064-2069, 2018.
- [19] M. Zhang, Y. Zhang, L. Zhang, C. Liu, and S. Khurshid, “DeepRoad: GAN-based metamorphic testing and input validation framework for autonomous driving systems,” in *Proc. 33rd ACM/IEEE Int. Conf. Autom. Softw. Eng.*, pp. 132-142, 2018.


서 다 슝 (Dasom Seo)



2019년 2월 : 전북대학교 컴퓨터 공학전공 공학석사  
 2019년 6월~현재 : 국립농업과학원 스마트팜개발과 전문연구원  
 <관심분야> 인공지능, 컴퓨터비전, XAI

[ORCID:0000-0002-4654-9846]

원 진 호 (Jin-Ho Won)



2017년 2월 : 충북대학교 바이오시스템공학 석사  
 2019년 9월~현재 : 전북대학교 농업기계공학 박사과정  
 2019년 6월~현재 : 국립농업과학원 농업공학부 석사후연구원

<관심분야> 스마트팜, 농기계 자율주행, 농업로봇  
 [ORCID:0000-0001-6568-2098]

**양 창 주 (Changju Yang)**



2014년 8월 : 전북대학교 전자공학 박사  
2016년 11월~2018년 6월 : 전북대학교 전자공학부 연구교수  
2020년 3월~현재 : 국립농업과학원 농업공학부 박사후연구원

<관심분야> 인공지능, 영상처리, 스마트팜  
[ORCID:0000-0003-4909-2578]

**홍 영 기 (Youngki Hong)**



2004년 3월 : 일본 동경농업대 생물환경조절학전공 박사  
2007년 3월~2021년 2월 : 국립농업과학원 농업연구사  
2021년 3월~현재 : 국립농업과학원 농업연구관

<관심분야> 영상처리, 기계학습, 인공지능  
[ORCID:0000-0002-9772-9820]

**김 국 환 (Gookhwan Kim)**



2010년 2월 : 경희대학교 일반대학원 기계공학과 (공학박사)  
2010년 3월~2014년 12월 : 농촌진흥청 국립농업과학원 PostDoc.  
2015년 1월~현재 : 농촌진흥청 국립농업과학원 재직  
<관심분야> 농업 로봇, 자율항법 기술

[ORCID:0000-0002-7278-3476]

**류 희 석 (Hee-Seok Ryu)**



1998년 2월 : 서영대학교 환경위생과 졸업  
2017년 6월~현재 : 국립농업과학원 농업공학부 공업서기  
<관심분야> 농업로봇, 노지농업기계, 스마트팜

[ORCID:0000-0001-9633-9284]

**권 경 도 (Kyung-Do Kwon)**



2017년 2월 : 충남대학교 일반대학원 농업기계공학과 (공학석사)  
2020년 9월~현재 : 농촌진흥청 국립농업과학원 농업연구사  
<관심분야> 영상처리, 인공지능

[ORCID:0000-0003-1794-3438]

**김 경 철 (Kyoung-Chul Kim)**



2015년 8월 : 전북대학교 정밀기계공학과 (공학박사)  
2016년 7월~2019년 1월 : 농업기술실용화재단 연구원  
2019년 2월~현재 : 국립농업과학원 스마트팜개발과 연구사

<관심분야> 농업 로봇, 농업 인공지능  
[ORCID:0000-0001-6699-881x]