

논문 2021-2-9 <http://dx.doi.org/10.29056/jsav.2021.12.09>

보행자검출을 통한 상권 분석 알고리즘

이승익*†

Algorithm for the Analysis of business district using Pedestrian-Detection

Seung-Ik Lee*†

요 약

본 논문에서는 특정지역의 보행자들의 검출을 통한 분석으로, 특정시간 동안의 보행자 수를 분석해 원하는 지역의 상권을 과학적이고 체계적으로 분석하여 사업을 하고자 하는 수요자에 대한 서비스 제공을 목적으로 하는 알고리즘을 제안한다. 본 논문을 통해 특정지역에 분포해 있는 다양한 영상획득 장치를 통해 우선 영상에서의 보행자 수를 딥러닝 기법중 하나인 YOLO를 통해 검출하여 알고리즘을 이용하여 분석하고, 관심지역에서 획득된 영상을 활용하여, 분당 한 장의 영상정보를 활용하여 딥러닝 네트워크를 활용하여 보행자수를 파악한 후 특정지역 및 시간대별로 보행자수를 분석하여 상권분석을 체계적이고 객관적으로 수행하는 알고리즘을 제안하였다. 제안한 방법을 통해 보다 객관적인 상권을 분석하여 다양한 방법을 통해 사용자가 원하는 지역의 상권 분석을 위한 모델을 제안하였다.

Abstract

In this paper, we propose an algorithm that provide services to consumers who want to conduct business by scientifically and systematically analyzing the number of pedestrians in a specific area over a specific period of time. In this paper, we proposed the algorithm to analyze the commercial area using the pedestrian-detect algorithm in the particular region using YOLO, one of the deep learning techniques. And with one image per minute in the images, the number of pedestrians is identified and this information is used for the analysis of business district on interesting area and time, systematically and objectively.

한글키워드 : 보행자 검출, YOLO, 상권, 빅데이터, 딥러닝

keywords : Pedestrian-Detection, YOLO, business district, big data, deep learning

1. 서 론

딥러닝을 이용한 실시간 보행자 검출알고리즘은 자율주행 자동차와 관련된 기술의 발달로 인

해 매우 정확도가 높으며 또한 실시간검출이 가능한 다양한 알고리즘[1]이 개발되고 있다.

특히 실시간 처리가 가능한 다양한 검출알고리즘의 연구로 인해 현재 다양한 분야에 사용되어 있으며 특히 5G의 등장으로 인해 이러한 기술들은 그 사용분야가 매우 다양하다. 특히 5G의 상용화로 인해 VR, AR등의 기술에 실시간 적용

* 연암공과대학교 스마트소프트웨어학과

† 교신저자: 이승익(email: seungik@yc.ac.kr)

접수일자: 2021.08.12. 심사완료: 2021.08.22.

게재확정: 2021.12.20.

YOLO의 신경망 구조[10]는 총 24개의 컨볼루션 계층과 2개의 전결합 계층으로 구성되어 있으며, 입력단으로 사용되는 모든 이미지는 448 × 448의 형태를 가지며, 이 네트워크의 최종 단은 7 × 7 × 30의 형태로 되어 전결합 계층으로 이용된다.

마지막 계층에서의 활성화함수는 선형 활성화함수를 적용하였으며, 나머지 모든 계층에는 leaky ReLU 함수를 적용하였다. leaky ReLU의 함수정의는 식 2에서 나타내었다.

$$\Phi(x) = \begin{cases} x & , \text{if } x > 0 \\ 0.1x & , \text{otherwise} \end{cases} \quad (2)$$

그림 2는 YOLO를 이용한 검출결과를 보여주고 있다. 여기서는 단일 컨볼루션 네트워크를 통해 입력영상은 그림 1에서 나타난 바와 같이 448 × 448로 하여 단일 컨볼루션 네트워크를 입력영상에 대해서 수행한다. 여기서 다중 검출박스 중 문턱값에 의해서 가장 확률이 높다고 판단되는 한 개의 박스로 결과 값을 나타낸 것이다.




그림 2. YOLO를 이용한 보행자 검출예시
Fig. 2. The example of pedestrian detection using YOLO

YOLO의 가장 큰 장점은 처리속도가 다른 알고리즘에 비해 매우 빠르며 기존의 실시간 검출 시스템보다 2배정도의 빠른 mAP(mean Average Precision)[2][7]을 가진다. 또한 영상 전체에 대한 배경오차가 다른 알고리즘[11][12]에 비해 매

우 낮음을 알 수 있다.

본 논문에서는 YOLOv3를 이용하여 획득된 영상을 분석하여 특정 관심지역에 대한 보행자 수를 측정된 데이터를 이용하여 상권을 분석하는 알고리즘을 제안한다. 이러한 결과값을 이용하여 특정지역의 상권을 보다 객관적이고 체계적으로 분석하여 시간별, 주별, 월별로 나누어 분석할 수 있는 알고리즘을 제안한다.

표 1은 YOLO 네트워크의 종류를 나타내며, 필요에 따른 다양한 네트워크를, 하드웨어 특성 및 검출속도, 검출 정확도 등을 고려하여 구현이 가능하도록 제공하고 있다.[3] 성능평가는 다양한 dataset으로 평가되고 있는데 표1은 COCO dataset[6]으로 평가된 각각의 네트워크의 결과 [7]를 나타낸다.

표 1. COCO dataset에 대한 성능평가
Table 1. Performance on the COCO Dataset

Model	Train	Test	mAP	FPS
YOLOv2 608x608	COCO trainval	test-dev	48.1	40
Tiny YOLO	COCO trainval	test-dev	23.7	244
YOLOv3-320	COCO trainval	test-dev	51.5	45
YOLOv3-416	COCO trainval	test-dev	55.3	35
YOLOv3-608	COCO trainval	test-dev	57.9	20
YOLOv3-tiny	COCO trainval	test-dev	33.1	220
YOLOv3-spp	COCO trainval	test-dev	60.6	20

2.2 보행자 분포를 이용한 상권분석

본 논문에서는 CCTV를 통해 획득된 영상을 YOLO 알고리즘을 이용하여 보행자를 검출하고, 보행자를 시간별 및 위치별로 검출하여 지도상에서 비교적 정확한 보행자 분포를 유추할 수 있다.

그림 3은 본 논문에서 제안한 결과를 이용하여 지도상에 그 결과 값을 보여주는 것이며, 획득된

영상으로부터 얻은 정보를 이용하여 보행자수를 추출하고, 지도상에서 보행자수를 활용함으로써 시간별, 주별, 월별 그리고 특정 시간대 등에 대한 정확한 보행자들의 분포를 나타냄으로써 관심 지역에 대한 상권을 분석하여 보다 정확하고 객관적인 데이터를 활용하여 분석할 수 있다.

이렇게 획득된 영상은 서버로 전송되고, 전송된 정보는 서버에서 보행자 검출과 위치정보를 이용하여 지도상에 실시간으로 데이터를 축적하고 그 결과 값을 분석하여 특정지역의 시간별 상권을 분석하여 사용자에게 서비스를 제공한다.




그림 3. 지도를 통한 보행자 분석
Fig. 3. The example of pedestrian analysis on maps

또한 그림 3과 같이 시각적으로 지도상에 시간별, 주별 또는 월별로 분석결과를 나타냄으로써 서비스 이용자는 보다 직관적이고 편리하게 그 데이터를 사용할 수 있다. 또한 서버는 실시간 데이터 처리는 불필요함으로써 데이터베이스에 획득된 영상을 축적하여 YOLO를 통해 영상분석을 실시하여 그 데이터를 축적함으로써 분기별 또는 계절별에 따른 빅데이터 자료로도 활용될 수 있다.

본 논문에서는 카메라로부터의 입력영상을 1분에 한 장씩 입력받아 저장하여 위치별 및 시간별로 분석하였다. 우선 CCTV로부터 입력된 영상을 매 1분마다 한 장씩 획득하여 YOLO 네트워크를 통해 한 프레임마다 보행자 수를 모두 카운트하였다. 이렇게 누적된 보행자수를 바탕으로 하여 데이터에 근거한 특정위치에 대한 상권을

시간별 및 위치별로 분석할 수 있었다. 아래 그림 4는 제안한 알고리즘의 블록도를 나타낸다.

아래 그림에서 보는 바와 같이 각각의 관심영역에서 획득된 영상을 매 1분 마다 한 장씩 데이터를 저장하여 서버에서는 각 영역별 및 시간별로 데이터를 저장한다. 이렇게 저장된 데이터를 이용하여, YOLO 네트워크를 이용하여 보행자를 검출하고, 검출된 보행자들을 분석하여 상권분석 서비스를 제공할 수 있다




그림 4. 제안한 알고리즘의 블록도
Fig. 4. The block diagram of the proposed algorithm

3. 실험 결과 및 분석

본 논문에서는 실험결과를 검증하고 분석하기 위해 서로 다른 세 장소에 대해 영상을 획득하여 이용하였다.

또한 실험을 위해 YOLO 네트워크를 이용한 결과분석은 NVIDIA Jetson AGS Xavier 모델에서 수행되었다. 실시간을 요구하는 결과 분석이 아님으로 인해 저장된 영상을 통해 분석하였으며, 보행자 수의 카운트는 영상 한 장당 평균 14ms정도의 속도를 나타내었다.

표 3은 NVIDIA jetson AGS Xavier[9]의 주요 특성을 나타낸다. 또한 OS는 NVIDIA에서 제공하는 우분투 리눅스 시스템을 활용하고 있으며 강력한 GPU성능으로 인해 복잡한 텐서를 처리하는 연산 능력이 매우 우수한 딥러닝 전용 하드

웨어 성능을 탑재하고 있음으로, 실시간 영상처리에도 많이 이용되어 지고 있는 임베디드 시스템이다.

표 2. NVIDIA Jetson AGX Xavier 주요 사양
Table 2. Spec. of NVIDIA Jetson AGX Xavier

GPU	512-core Volta GPU with Tensor Cores
CPU	8-core ARM v8.2 64-bit CPU, 8MB L2 + 4MB L3
Memory	32GB 256-Bit LPDDR4x 137GB/s
Storage	32GB eMMC 5.1
DL Accelerator	(2x) NVDLA Engines
Vision Accelerator	7-way VLIW Vision Processor
Encoder /Decoder	(2x) 4Kp60, HEVC/(2x) 4Kp60, 12-Bit Support
Size	105 mm x 105 mm x 65 mm
Deployment	Module (Jetson AGX Xavier)

입력 영상의 저장기간은 월요일부터 일요일까지 일주일 동안의 데이터를 저장하여 활용하였으며, 입력카메라의 화소는 1280 × 720의 크기를 가지는 HD급으로 영상을 저장하여 활용하였다. 표 2는 세 장소에 대한 서로 다른 시간대별로 측정하여 보행자수를 카운트한 결과를 보여주고 있다.

그림 5에서 보는 바와 같이, 본 실험을 위해 본 논문에서는 크게 모두 5 부분으로 시간대를 나누어 보행자 수를 분석하였다. 첫 번째 시간대는 아침시간대인 오전 8시부터 11시까지를, 두 번째 시간대는 점심식사 시간대인 11시부터 1시까지, 그리고 세 번째 시간대는 1시부터 5시까지로 구분하였으며 네 번째는 5시부터 7시까지로 나누었으며, 마지막으로는 7시부터 10시까지로 시간대를 나누었다. 이렇게 구분한 이유는 아침, 점심 및 저녁식사와 커피타임 그리고 저녁시간 후에 대한 시간대별로 나누어 다양한 상권에 대한 분석정보를 제공하기 위해서 이다. 이러한 시간대는 특정 상권분석을 위해 매시간 또는 분 단

위로도 설정가능하며 특성에 맞게 조정할 수 있다.

실제 영상을 통해 분석한 결과, 일정 지역에서 머물러 있는 보행자는 매분마다 분석되는 영상에서의 보행자 수에 포함되어 카운트되는 결과를 보여주지만, 이 또한 특정 지역에 대한 보행자 분포에 포함되어 있다고 가정하였다.




그림 5. 특정지역 및 시간별 보행자 분포수 예
Fig. 5. The example of pedestrian distributions by specific region and time

그림 5에서 A지역 및 C지역은 주말에서의 보행자수는 급격히 감소함을 알 수 있으며, 특히

시간대를 불문하고 모두 인원이 감소함을 알 수 있다. A지역은 공공기관이 위치한 지역이며, 이 지역은 목요일 및 금요일의 점심시간대 보행자수가 매우 높음을 알 수 있다. 하지만, 주말에는 지역특성상 대부분 본가로 귀가함으로 인해 보행자의 인원수가 감소함을 알 수 있으며, 이로 인해 이 지역의 상권분석을 위해 이러한 데이터를 충분히 활용하여 서비스를 제공할 수 있다.

이에 비해 B지역은 아파트 단지가 인접한 도로이며 이 지역은 금요일 저녁시간대 역시 매우 높은 보행자 분포를 알 수 있으며, 이는 귀가 후 이 지역 근처에 위치한 상권을 이용할 가능성이 매우 높음을 알려준다. 그리고 C지역은 중학교가 위치한 지역이며, 그림 5에서 나타난바와 같이 특정 시간, 즉 등교 및 하교시간대에 보행자의 수가 증가함을 알 수 있다. 또한 점심시간대에는 대부분 학교 급식을 이용함으로 인해 이러한 분포를 나타내는 것으로써, 저녁시간대도 마찬가지로 하교하여 대부분 다른 곳에서 식사시간을 가진다고 유추할 수 있다.

본 실험에서는 일주일 동안 세 곳에서의 데이터를 활용하여 분석을 하였으며, 실제 다양한 지역 내에서 이러한 데이터를 수집하여 분석함으로써, 실제 지도상에서 시간대별로 다양한 분석을 수행함으로써 객관적이고 데이터에 근거한 상권을 분석하여 그 서비스를 제공할 수 있다.

그림 6은 실험에서 보여준 데이터를 활용하여 특정시간대에 대한 서로 다른 지역에서의 분포도를 활용하여 맵핑한 그림을 보여준다. 시간대는 화요일 11시부터 13시까지의 분포도를 맵을 활용하여 보여준 것으로 이를 통해 다양한 지역별 및 시간대별 분포를 맵을 통해 보여줌으로써 관심지역에 대한 상권분석을 객관적으로 서비스하여 나타낼 수 있다.



그림 6. 지도상에서의 특정지역 및 시간별 보행자 분포수

Fig. 6. The example of pedestrian distributions by specific region and time on map

4. 결론

본 논문에서는 딥러닝에서 널리 사용되는 YOLO 네트워크를 이용한 실시간 보행자 검출기술을 이용하여 상권분석을 위한 알고리즘을 제안하였다.

보행자 검출 알고리즘을 이용하여 관심지역에서 획득된 영상을 활용하여, 분당 한 장의 영상정보를 활용하여 딥러닝 네트워크를 활용하여 보행자수를 파악한 후 특정지역 및 시간대별로 보행자수를 분석하여 상권분석을 체계적이고 객관적으로 수행하는 알고리즘을 제안하였다. 이러한 상권분석 알고리즘을 활용하여 관심지역에 대한 다양한 정보를 바탕으로 하여 업종선택 등의 상권분석을 통해 체계적인 접근을 할수 있는 정보를 제공하도록 하였다. 또한 이러한 데이터를 활용하여 많은 데이터가 수집되어 일별, 월별 및 계절별로 특정지역에 대한 분석이 가능할 수 있음으로 인해 다양하게 그 정보를 활용할 수 있는 알고리즘을 제안하였다. 앞으로 이러한 데이터를 바탕으로 하여 다양한 서비스 체계를 수립

하여 공인증개사 등이 사용가능한 상용화 서비스 모델을 개발할 수 있도록 추후 연구 과제를 진행할 예정이다.

참 고 문 헌

[1] J. Yan, Z. Lei, L. Wen, and S. Z. Li. The fastest deformable part model for object detection. In Computer Vision and Pattern Recognition (CVPR), 2014 IEEE Conference on, pages2497 - 2504. IEEE, 2014. 5, 6

[2] J. Redmon, S. Divvala, R. Girshick, and A.Farhadi, "You only look once: Unified,real-time object detection", Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 779-788, 2016.

[3] R.Girshick, "Fast r-cnn", ICCV,pp.1440-1448, 2015. https://openaccess.thecvf.com/content_iccv_2015/papers/Girshick_Fast_R-CNN_ICCV_2015_paper.pdf

[4] S. Ren, K. He, R. Girshick, and J. Sun,"Faster rcnn: Towards real-time object detection with region proposal networks", NIPS,pp.91-99,2015. <https://doi.org/10.1109/TPAMI.2016.2577031>

[5] W Liu, D Anguelov, D Erhan, C Szegedy, "SSD: Single Shot MultiBox Detector", European Conference on Computer Vision, pp.21-37, 2016. <https://arxiv.org/pdf/1512.02325.pdf%EF%BC%89>

[6] <https://cocodataset.org/>

[7] J. Redmon. Darknet: Open source neural networks in c. <http://pjreddie.com/darknet/>, 2013 - 2016. 3

[8] <https://developer.nvidia.com/embedded/jetson-agx-xavier-developer-kit>

[9] D.Kim, S.Lee, S.Kang, "Implementation of a Face Authentication Embedded System Using High-dimensional Local Binary

Pattern Descriptor and Joint Bayesian Algorithm", Journal of the Korea Institute of Information and Communication Engineering, vol. 21, no. 9, pp. 1674-1680, 2017. <https://doi.org/10.6109/jkiice.2017.21.9.1674>

[10] Z. Shen and X. Xue. Do more dropouts in pool5 feature mapsfor better object detection. arXiv preprint arXiv:1409.6911, 2014. 7

[11] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich. Going deeper with convolutions. CoRR, abs/1409.4842,2014. 2

[12] J. R. Uijlings, K. E. van de Sande, T. Gevers, and A. W. Smeulders. Selective search for object recognition. International journal of computer vision, 104(2):154 - 171, 2013.

저 자 소 개



이승익(Seung-ik Lee)

1994.2 경북대학교 전자공학과 학사 졸업
 2002.8 콜로라도주립대학교
 전기컴퓨터공학 석사 졸업
 2005.8 경북대학교 전자공학과 박사 졸업
 2008.4-현재 : 연암공과대학교 스마트소프트웨어학과 교수
 <주관심분야> 머신러닝, 얼굴인식