

Ա.Կ. ԿԱՐԱՊԵՏՅԱՆ

CNN ԵՎ SSD ՄԵԹՈԴՆԵՐԻ ԹԵՍԱՎՈՐՈՒՄԸ ՕԲՅԵԿՏՆԵՐԻ ՀԱՅՏՆԱԲԵՐՄԱՆ ՀԱՎԵԼՎԱԾՆԵՐՈՒՄ

Օբյեկտների հայտնաբերմամբ զբաղվողները հաճախ դժվարանում են համակարգի ինքնաուսուցման օպտիմալ ալգորիթմի ընտրության հարցում, քանզի հենց այդ ընտրությունից են կախված համակարգի օբյեկտների հայտնաբերման և ճանաչման ճշտագրությունն ու արագությունը: Աշխատանքում դիտարկվում են CNN և SSD մեթոդները, որոնց հիման վրա ստեղծվել և իրական պայմաններում թեստավորվել է ծրագրային ապահովումը:

Առանցքային բառեր. օբյեկտների հայտնաբերում և ճանաչում, արհեստական բանականության ինքնաուսուցման մեթոդներ, Tensorflow, CNN, SSD:

Ներածություն. Օրեցօր աճող հետաքրքրությունը ինքնակառավարվող և ինքնուրույն որոշումներ կայացնող համակարգերի նկատմամբ հանգեցնում է արհեստական բանականության զարգացմանը: Արդեն իսկ բազմաթիվ ընկերություններ լրջորեն զբաղվում են արհեստական ինտելեկտի նորանոր ալգորիթմների հայտնաբերմամբ ու փորձարկմամբ: Այս պահի դրությամբ ամենից մեծ տարածում են գտել CNN [1] և SSD [2, 3] ալգորիթմները:

Խնդրի դրվածքը. CNN (Convolutional Neural Network) ալգորիթմը առաջին անգամ աշխարհին է ներկայացրել Յան Լեկունը 1988 թվականին [4]: Փաթոյթային նեյրոնային ցանցի աշխատանքը հիմնված է մարդու աչքի աշխատանքի սկզբունքի վրա, համաձայն որի տեսողական համակարգն իր կազմում պարունակում է, այսպես կոչված, «տեսողական կեղև», որն էլ իր հերթին բաղկացած է պարզ և բարդ բջիջներից [5]: Պարզ բջիջները արձագանքում են ուղիղ գծերին տարբեր անկյունների տակ, իսկ բարդ բջիջների աշխատանքը կախված է պարզ բջիջների որոշակի խմբի արձագանքից: Փաթոյթային նեյրոնային ցանցի աշխատանքի ալգորիթմը հաճախ բնութագրվում է պատկերի կոնկրետ առանձնահատկություններից ավելի վերացարկված առանձնահատկություններին անցմամբ: Ցանցն ինքնուրույն է կառուցում այդ հատկանիշների աստիճանակարգումը, զտում համեմատաբար քիչ կարևորություն ներկայացնող հատկանիշներն ու ավելի ընդգծելով կարևորները:

CNN մեթոդը լայնորեն դիտարկվում է արհեստական բանականության գրեթե բոլոր խոր ուսուցման ալգորիթմներում: Սակայն այս մեթոդը, բավականին ծավալուն մաթեմատիկական հաշվարկների պատճառով, դանդաղ է մշակում

ստացվող ինֆորմացիան և հազիվ թե կարող է օգտագործվել օբյեկտների իրական ժամանակում ճանաչման համար՝ առանց կից նպաստող մեթոդների:

SSD (Single Shot MultiBox Detector) մեթոդը հանրությանն է ներկայացվել 2016 թվականի նոյեմբերին՝ անմիջապես գրանցելով ռեկորդային 74% միջին ճշտագրություն, մշակելով 59 պատկեր վայրկյանում: SSD մեթոդի առանձնահատկությունները հետևյալ են [2, 6, 7]՝

- օբյեկտի տեղայնացման և դասակարգման խնդիրները լուծվում են պատկերի վրայով ցանցի միայն մեկ անցմամբ,
- պատկերի վրա կարող է ճանաչվել միանգամից մի քանի օբյեկտ,
- ցանցը ինքը հանդիսանում է օբյեկտի դետեկտոր, որը նաև դասակարգում է հայտնաբերված այդ օբյեկտները:

SSD մեթոդում մեծ դերը ունի MultiBox-ի կորուստի հաշվարկի ֆունկցիան, որը բաղկացած է հետևյալ երկու կոմպոնենտներից.

1) Վստահություն. ցույց է տալիս, թե համակարգը որքանով է ճիշտ որոշել պատուհանի վրա գտնվող օբյեկտը:

2) Տեղանքի սխալ. ցույց է տալիս, թե օբյեկտի դիրքը որոշող պատուհանը որքան է սխալվել:

Ընդհանուր սխալանքը հաշվարկվում է հետևյալ բանաձևով՝

$$\text{Ընդհանուր_սխալանք} = \text{Վստահություն} + X * \text{Տեղանքի_սխալ},$$

որտեղ X-ը տեղանքի սխալի գործակիցն է:

Ընդհանուր դեպքում նորմալ է համարվում, երբ ցանցի հայտնաբերված և իրականում գոյություն ունեցող օբյեկտի պատուհանների ընդհանուր մակերեսի հարաբերությունը դրանց համադրման մակերեսին կազմում է առնվազն 0.5, լավ կարելի է համարել, երբ այդ թիվը հասնում է 0.7-ի իսկ 0.9 և ավելի բարձր գործակիցը համարվում է գերազանց արդյունք (նկ.1): Նկ.2-ում պատկերված է պատկերների համընկնման մի քանի դեպք:



Նկ. 1. Իրական և հայտնաբերված պատուհանների համընկնման և միավորման մակերեսները



Նկ. 2. Իրական և հայտնաբերված պատուհանների համընկնման և միավորման դեպքերը

Ուսուցման համար ընտրվել է բաց հասանելիությունում գտնվող, համաշխարհային ճանաչում ունեցող Google կազմակերպության կողմից առաջարկվող Tensorflow [8] գրադարանը: Հարկ է նշել, որ Tensorflow գրադարանը իր վրա է վերցնում ցածր մակարդակի բոլոր հաշվարկներն ու բարդությունները, օգտատիրոջը տրամադրելով բավականին պարզ և հասկանալի ինտերֆեյս: Այդ ամենը հնարավորություն է տալիս նույնիսկ ծրագրավորումից չհասկացող մարդկանց, վերոնշյալ գրադարանից օգտվելով, ստեղծել ինքնաուսուցվող նեյրոնային ցանց: Գրեթե ամեն ինչ իր վրա է վերցնում Tensorflow-ի կողմից առաջարկվող TensorFlowInferenceInterface կլասը, որի feed, run և fetch մեթոդների միջոցով կարելի է գրադարանին փոխանցել և այնուհետև նաև ստանալ ինֆորմացիայի մշակման արդյունքները:

Համակարգին ուսուցման համար, որպես նախնական տվյալների բազա, տրվել է մոտավորապես 1000 դրոնի պատկեր և ևս 300 պատկեր, որոնցում

դրոն չկա: Այստեղ պետք է նշել, որ ընդհանրապես խորհուրդ է տրվում ուսուցման համար ունենալ օբյեկտի առնվազն 3000 պատկեր և օբյեկտի բացակայությամբ՝ 1000 պատկեր: Պարզ է, որ որքան մեծ լինի նախնական ուսուցման պատկերների քանակը, այնքան համակարգը հետագայում ավելի հեշտ և ճշտագրիտ կկայացնի որոշումները:

Ցանցի թեստավորման ընթացքում ստացվել են հետևյալ արդյունքները՝

- մեկ պատկերի (կադրի) մշակման ժամանակը – 35 միլիվայրկյան, որը նշանակում է, որ մեկ վայրկյանում հնարավոր է մշակել 28 կադր,
- որոշումների ճշտագրտությունը – միջինը 88% (նկ.3), որը համարվում է ոչ այնքան լավ արդյունք:



Նկ. 3. Թեստարման արդյունքները

Եզրակացություն. Աշխատանքի ընթացքում ստեղծվել և փորձարկվել է ներդրոնային ցանց, որը վարժեցվել է դրոնների հայտնաբերման համար: Փորձարկումը արվել է տեսախցիկի համար բարենպաստ պայմաններում, այսինքն՝ լուսավոր, անամպ ու պարզ եղանակային պայմաններում: Հետևաբար, կախված օրվա ժամից և եղանակից, հնարավոր է, որ համակարգի ճշտագրտությունը ավելի նվազի: Փորձնական տվյալներից ելնելով՝ պարզ է դառնում, որ պետք է աշխատել ցանցի ճշտագրտության ավելացման ուղղությամբ, որին հասնելու համար անհրաժեշտ է ավելացնել նախնական վարժեցման համար տրամադրվող պատկերների քանակը: Դա կհանգեցնի նաև ընդհանուր համակարգի արագագործության ավելացմանը: Պետք է փնտրել նաև վարժեցման համար ավելի հարմար մեթոդներ, որոնք կլինեն ավելի օպտիմալ դրոնների հայտնաբերման համար:

Հարկ է նշել, որ որպես հիմնական խնդիր հանդես է գալիս նաև եղանակային պայմաններից համակարգի խիստ կախվածություն ունենալը:

ԳՐԱԿԱՆՈՒԹՅՈՒՆ ՑԱՆԿ

1. https://ru.wikipedia.org/wiki/Свёрточная_нейронная_сеть
2. SSD: Single Shot MultiBox Detector / **W. Liu, D. Anguelov and D. Erhan et al** // ECCV, arXiv. -2016.- P. 1512-02325.
3. **Чуйков Р.Ю., Юдин Д.А.** Обнаружение транспортных средств на изображениях загородных шоссе на основе метода SINGLE SHOT MULTIBOX// ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ. -2017.- Том 2, выпуск №4.
4. Backpropagation Applied to Handwritten Zip Code Recognition /**Y. LeCun, B. Boser, J. S. Denker et al** //Neural Computation. -Winter 1989.- 1(4).- P. 541-551.
5. **Matusugu, Masakazu.** Subject independent facial expression recognition with robust face detection using a convolutional neural network// Neural Networks.- 2003.- 16 (5).- P.555–559.
6. <https://towardsdatascience.com/understanding-ssd-multibox-real-time-object-detection-in-deep-learning-495ef744fab>
7. **Szegedy C., Reed S., Erhan D. and Anguelov D.** Scalable, high-quality object detection arXiv preprint arXiv.- 2014.- P. 1412-1441.
8. <https://www.tensorflow.org/>

Ա.Կ. ԿԱՐԱՊԵՏՅԱՆ

ТЕСТИРОВАНИЕ МЕТОДОВ CNN И SSD В ПРИЛОЖЕНИЯХ ОБНАРУЖЕНИЯ ОБЪЕКТОВ

Те, кто занимается обнаружением объектов, часто испытывают трудности при выборе оптимального алгоритма самообучения системы. От этого выбора зависят точность и скорость обнаружения и распознавания объектов системы. В работе используются методы CNN и SSD, на основе которых создано программное обеспечение, которое было протестировано в реальных условиях.

Ключевые слова: обнаружение и распознавание объектов, методы самообучения для искусственного интеллекта, Tensorflow, CNN, SSD.

A.K. KARAPETYAN

TESTING THE METHODS CNN AND SSD IN THE APPLICATIONS OF OBJECT DETECTION

Those who are involved in object detection, often encounter difficulties at choosing the optimal algorithm for self-learning of the system. The precision and speed of the detection and recognition of the system objects depend on that choice. The CNN and SSD methods are used, based on which a software has been created and tested in real conditions.

Keywords: object detection and recognition, self-learning methods for the artificial intelligence, Tensorflow, CNN, SSD.