



АҚПАРАТТЫ ӨНДЕУ ЖӘНЕ ІЗДЕУ ҚҰРАЛДАРЫ
СРЕДСТВА ОБРАБОТКИ И ПОИСКА ИНФОРМАЦИИ
INFORMATION PROCESSING AND SEARCHING TOOLS

DOI 10.51885/1561-4212_2021_1_79
МРНТИ 20.53.19

Ж.Б. Есентай¹, Б.С. Омаров²

әл-Фараби атындағы Қазақ ұлттық университеті, Алматы қ., Қазақстан

¹E-mail: esentayzhalgas@gmail.com *

²E-mail: batyahan@gmail.com

ТЕРЕҢ ОҚЫТУ НЕГІЗІНДЕ ЖОЛ БЕТІНІҢ САПАСЫН АНЫҚТАУ ЖҮЙЕСІН ӨЗІРЛЕУ
РАЗРАБОТКА СИСТЕМЫ ОПРЕДЕЛЕНИЯ КАЧЕСТВА ДОРОЖНОГО ПОКРЫТИЯ
НА ОСНОВЕ ГЛУБОКОГО ОБУЧЕНИЯ
DEVELOPMENT OF A SYSTEM FOR DETERMINING THE QUALITY OF THE ROAD
SURFACE BASED ON DEEP LEARNING

Аңдатпа. Қалалық инфрақұрылымның бір бөлігі болып табылатын жолдар қала өмірі үшін өте маңызды. Жолдар тозуға немесе сыртқы факторлардың әсерінен бұзылуына байланысты үнемі тексеріп отыруды және жөндеуді қажет етеді, бірақ оны қолмен жасау қымбатқа түседі. Жолды сапасын уақтылы бағаламау құрылымдық және қаржылық инфрақұрылымның қатты шығындарына және толық жаңартуларға әкелуі мүмкін. Компьютерлік тексеріс жолдың бұзылу заңдылықтары мен орналасу орындары туралы мәліметтер базасын ұсына алады. Бұл мақалада нақты уақыт режимінде мобильді құрылғылардың көмегімен түсірілген жол кескіндерін өңдеуге негізделген терең оқыту жүйесі ұсынылған.

Түйін сөздер: Терең оқыту, аналитикалық жүйе, жол жамылғысы, деформацияның жіктелуі.

Аннотация. Дороги, являющиеся частью городской инфраструктуры, очень важны для городской жизни. Дороги требуют регулярного осмотра и ремонта из-за износа или повреждения, вызванного внешними факторами, но строительство вручную требует больших затрат. Несвоевременная оценка качества дороги может привести к значительным затратам на структурную и финансовую инфраструктуру и полную модернизацию. Компьютерное сканирование может предоставить базу данных о картинах и местах повреждений на дорогах. В статье представлена система углубленного обучения, основанная на обработке изображений дорог, сделанных в реальном времени с помощью мобильных устройств.

Ключевые слова: Глубокое обучение, аналитическая система, дорожное покрытие, классификация деформации.

Abstract. Roads, which are part of urban infrastructure, are very important to urban life. Roads require regular inspection and repairs due to wear or damage caused by external factors, but building by hand is expensive. Failure to assess the quality of the road in a timely manner can lead to significant costs for structural and financial infrastructure and complete modernization. Computer scans can provide a database of paintings and damage locations on the roads. The article presents an in-depth training system based on the processing of images of roads taken in real time using mobile devices.

Keywords: Deep learning, analytical system, road surface, strain classification.

Кіріспе. Жол – қаланы жоспарлау мен дамытудағы маңызды инфрақұрылымдарының бірі. Мысалы, адамдар, әдетте, оларды бір жерге саяхаттау үшін немесе өз өмірін байыту

үшін жерді пайдалануды жоспарлау үшін пайдаланады. Алайда көптеген жолдар жөнделуді қажет етеді, өйткені олардың көпшілігі жедел экономикалық өсу кезеңінде салынған және содан бері нашарлап кетті. Осылайша, жолдарды жөнделуге олардың жағдайын тексеру үшін қала әкімдігі арнайы мамандарды тұрақты жұмыспен қамту керек. Алайда жолдарды қолмен тексеру қымбатқа түседі және көп уақытты алады; мысалы, бүлінген немесе бұлыңғыр жол белгілерін анықтау үшін адамдар оларды көзімен тексеруі керек, олардың мүмкіндіктері белгілі бір шектеулерге ие. Сондықтан соңғы жылдары жолдағы зақымдану түрлерін автоматты түрде анықтау және жіктеу танымал болды. Сонымен қатар, соңғы жетістіктерімен тереңдетіп оқыту кең өріс алуда және компьютерлік көзқарастың әртүрлі міндеттерінде ең заманауи нәтижелер береді [1].

Жол экономикалық даму мен әлеуметтік жеңілдіктерден бастап, қауіпсіздікке дейінгі өмірдің әртүрлі салаларында өте маңызды. Сондықтан жолдарды күтіп ұстау әлемдегі барлық елдер үшін өте маңызды. Жолдарды күтіп ұстаудың қиыншылықтарының бірі – бүлінген жерлерді дәл анықтау және уақытында тиімді жөнделу. Алайда, көптеген елдер үшін жол жарықтарын анықтау және жіктеу қазіргі уақытта адамның қол еңбегіне немесе қымбат датчиктерге негізделген.

Бағалаушылар қолмен жүргізілген тексеру кезінде жол жамылғысының бетін немесе оның бойымен жүргенде немесе баяу қозғалатын көлік құралының алдыңғы әйнегін тексергенде көзбен шолуды жүзеге асырады. Жол жамылғысын визуалды тексеру инспекторлардың субъективті пікірінен зардап шегеді. Бұл адамның айтарлықтай араласуын қажет етеді, бұл жол желісінің кең ауқымын ескере отырып, көп уақытты қажет етеді [2].

Сонымен қатар, инспекторлар көбінесе жүріс бөлігіне физикалық түрде қатысып, өздерін қауіпті жағдайларға душар етуі мүмкін. Жол жамылғысын жартылай автоматты бағалау кезінде жол кескіндері жылдам қозғалатын көлік құралдарынан автоматты түрде жиналады, бірақ апатты анықтау кеңседегі жұмыс орындарында жұмыс істейтін автономды процесс болғанға дейін кешіктіріледі. Бұл тәсіл қауіпсіздікті жақсартады, алайда әлі күнге дейін апатты қолмен анықтауды қолданады, бұл өте көп уақытты алады. Қазіргі уақытта мемлекеттік жол агенттіктерінің көпшілігі жартылай автоматты әдісті қолданады, бұл адамның белгілі бір дәрежеде араласуын болжайды.

Материалдар және зерттеу әдістері. Сапаны бағалау үшін толығымен автоматтандырылған, күрделі және қымбат датчиктермен жабдықталған көлік құралдары жиі қолданылады. Содан кейін жиналған деректерді өңдеу апатты анықтау және сандық бағалау үшін суретті өңдеу және үлгіні тану бағдарламалық жасақтамасын қолдану арқылы жүзеге асырылады. Көлік тасымалдау агенттіктері қол жетімді деректерді жинаудың алдыңғы қатарлы технологиялардан айырмашылығы, үлгіні тану бағдарламалық жасақтамасы агенттіктер үшін қолайлы дәлдік деңгейіне дейін әртүрлі жол төсемдерінің беткі қабаттарының зақымдануын анықтау және жіктеу үшін одан әрі жетілдіруді қажет етеді [3].

Бірнеше жол агенттіктері ғана желілік деңгейде деректерді жинау үшін толық автоматтандырылған жарықтарды анықтау жүйесін енгізді. Тәжірибеге сүйене отырып, сапаны басқарудың жүйелі процесі сәтті іске асырудың орталық факторы болып көрінеді. Жолдың зақымдануын анықтау және жіктеу үшін тереңдетілген оқытуды қолдану көбінесе үш кіші тапсырманы қамтиды:

- кескін деректерін жинау;
- мәліметтерге этикеткалар құру;
- белгіленген мәліметтерден терең оқыту модельдерін құру.

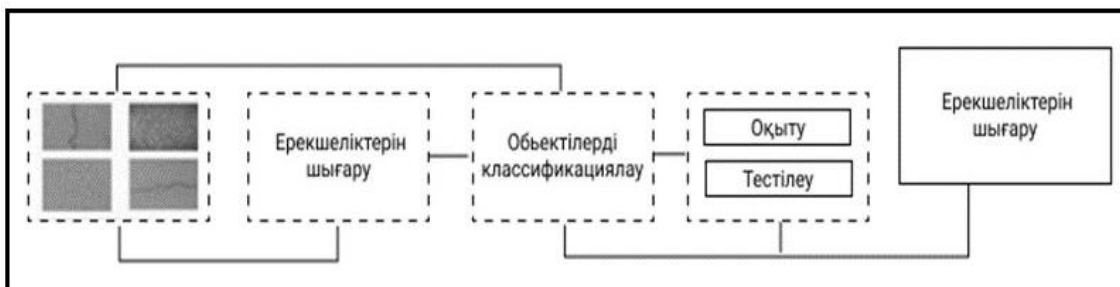
GPS және камерасы бар мобильді құрылғылардың көмегімен деректерді жинау тиімді жүргізілуі мүмкін, тегтеу процесі көп уақытты қажет етеді және анықтау, жіктеу нәтижелері әлі де шектеулі. Сонымен қатар, бір елдің деректерінен алынған модельдер көбінесе әртүрлі елдерге ауыса алатындай дәрежеде қорытыла бермейді [4].

Сонымен қатар, шекті қораптар мен жолдың зақымдануы туралы жапсырмаларды орнату қателікке ұрындырады және дәл нәтижеге жету үшін адамның орасан зор күш-жігерін қажет етеді. Осылайша, осы жұмыста объектілерді анықтаудың заманауи әдістері әртүрлі аумақтарда қолдануға болатын жолдың зақымдануын анықтау мен жіктеудің жалпы моделін табу мақсатында зерттелген. Содан кейін біз таңдалған тәсілдерді Global Road Damage Detection Challenge 2020 жиынтығындағы трекке қолданамыз [5].

Терең оқыту әдістері жол жамылғысының ақауларын анықтау және жіктеу мәселелерін шешу үшін кеңінен қолданылады. Терең оқыту әдістерінің тиімділігі келесі критерийлер бойынша бағаланады: орындалу уақыты, теңгерімсіз мәліметтер үшін жүйенің тұрақтылығы (мысалы, ақаулардың сирек типтерінің болуы), жанама факторларға (шу, жарық, т.б.) қарсы жүйенің тұрақтылығы, нәтижелерді түрлендіру [6].

Терең оқыту әдістері мен алгоритмдері жолдың ақауларын автоматты түрде анықтау және жіктеу үшін бейімделген және қолданылады, 1-суретте көрсетілгендей жалпы құрылымға ие.

Біз жолдың бұзылуын нақты уақыт мезетінде автоматты түрде анықтау үшін нейрондық желі моделін үйрету үшін Жапонияда түсірілген жол бейнелерін қолдандық. Фотосуреттер автокөлік жүріп жатқан кезде бір ракурстан түсірілген. Фотосуреттер смартфоннан арнайы компьютер құралына жіберіліп, сонда алдағы оқыту процесіне қарастырылған.



1-сурет. Бейнені өңдеу процесі

Бұл жұмыста пайдаланылған деректер жиынтығы Global Road Damage Detection Challenge 2020 бағдарламасынан алынған. Жапондық Maeda нұсқаулығы жол дефектілерінің сегіз зақымдану санатын бөліп қарастырады және 1-кестеде көрсетілген. Бұл классификация жол тозуының екі түрін бөліп, D индексі бойынша нөмірлеген. Бірақ, әртүрлі елдердің жол жүру арнайы белгілері мен формалары бірдей емес, сондықтан бұл зерттеуде қарастырылған жүйе бейнелердегі зақымды табуға және оны жол бетіндегі арнайы белгілерден бөліп қарастыруға негізделген [7].

1-кесте. Зақымданудың сегіз санаты

Бөлігі	Класс
--------	-------

Доңғалақтың белгі бөлігі	D00
Құрылыс бөлігі	D01
Тең аралық	D10
Құрылыс бөлігі	D11

1-кестенің соңы

Жартылай жабын, жалпы жабын	D20
Шұңқыр, ойық	D40
Жаяу жүргіншілер өткелі бұлыңғыр	D43
Ақ/сары сызықтың бұлыңғырлығы	D44


Бұл мәліметтер базасы бір жаттығу жиынтығынан және екі сынақ жиынтығынан тұрады. Дәлірек айтсақ, жаттығулар мен сынақ жинақтарында үш елдің (Чехия, Үндістан және Жапония) жолдардың бұзылу суреттері, шекара қораптары және зақымдану түрлері бар. Сонымен қатар, бұл деректер жиынтығына жолдың зақымдануының төрт түрі бар, олар бойлық сызық, көлденең жарық, алигатор жарықшасы және шұңқыр (сәйкесінше D00, D10, D20 және D40 деп белгіленеді) (2-сурет) [8].

Бұл тапсырма баллдық әдіс дәлдікті (p) және пікір (r) теңгерімдеу үшін орнатылған $f1$ ұпайына негізделген. Олар келесідей анықталады:

$$p = \frac{C_d}{P_d} \quad (1)$$

$$r = \frac{C_d}{A_d} \quad (2)$$

$$f1 = \frac{2pr}{p+r} \quad (3)$$



2-сурет. Зақымданудың мысалы

Мұндағы C_d , P_d және A_d – дұрыс болжамдалған зақымданудың, болжамды бүлінудің және бағалау жиынтығынан барлық жарамды зақымдардың саны. Сонымен қатар, дұрыс болжамдалған зақымды анықтау екі критерийден тұрады. Олар:

- болжанған шектеу терезесі сәйкес келуі керек;

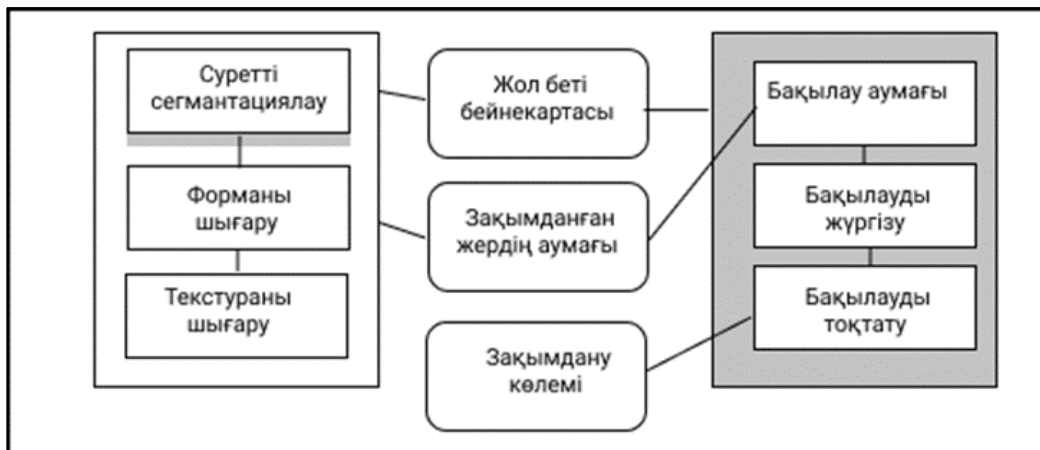
- болжамдалған белгі дұрыс.

Соңғысы айқын, ал біріншісі қиылысу ұпайы арқылы анықталады (IoU), ол келесідей анықталады:

$$IoU = \frac{area(P_b \cap G_b)}{area(P_b \cup G_b)} \quad (4)$$

мұндағы P_b және G_b – болжанған қорап және жердегі шындық терезесі.

Ақпараттық жүйе алдыменен керекті деректер көзінің адресін компьютерден анықтап алады. Ол үшін 3-суретте көрсетілген RoadDamageDataset папкасының орналасу орны белгіленді. Мұндай сондай-ақ, Жапон моделіндегі ақаулар типін класстарын, керекті деректердің қала атаулары папкалары негізделген. Сондай-ақ, жүйені үйретуге керекті барлық суреттер мен заттаңба мөлшерін шығару қарастырылған.



3-сурет. Бейнені өңдеу процесі

Нәтижелері және оларды талқылау. Біз мәліметтер жиынтығын қолдана отырып оқыту және бағалау жүргіздік. Жоғарыда сипатталған терең оқыту модельдерін келесі әдісті қолданып оқыттық. Белгіленген деректер жиынтығы кездейсоқ түрде араластырылады және жаттығулар жиынтығы мен растау жиынтығына бөлінеді, әр сыныптың 30% суреттері жаттығу үшін пайдаланылған, ал модель оны асырып жібермеуін қамтамасыз ету қажет; осы мақсат үшін біз деректерді жою және түпнұсқалық деректер қоры бойынша ұлғайтуды қолдандық (әртүрлі кескін түрлендірулерін қолдану арқылы, мысалы, қию, қиыстыру, айналдыру және басқалар) [12]. Деректерді ұлғайту – бұл қолданыстағы жаттығу мысалдарынан қосымша дайындық деректерін шығаратын «синтетикалық» әдіс, соңғысын әртүрлі кездейсоқ түрлендірулерге итермелейтін көріністер тудырады. Деректерді ұлғайту процесі валидация шығындарын едәуір төмендетуі мүмкін [13].

Негізгі оқу деректері жиналған арналған RoadDamageDataset атты папка құрылды. Жүйе осындағы деректермен жаттығып, керекті функцияларын жүргізе алады. Мұнда негізгі деректер қала атауларымен аттас папкалардан құралған. Әрбір қала атаулы папкада Annotations, Imagesets, Jpegimages, Labels папкалары бар.

Жүйе алдыменен керекті деректер көзінің адресін компьютерден анықтап алады. Ол үшін 4-суретте көрсетілген RoadDamageDataset папкасының орналасу орны белгіленді.

Мұнда Жапон моделіндегі ақаулар типін класстарын, керекті деректердің қала атаулары папкалары негізделген. Сондай ақ, жүйені үйретуге керекті барлық суреттер мен заттаңба мөлшерін шығару қарастырылған.

```
B [6]: base_path = "C:/RoadDamageDataset/"

      damageTypes=["D00", "D01", "D10", "D11", "D20", "D40", "D43", "D44"]


      # gavs corresponds to municipality name.
      gavs = ["Adachi", "Chiba", "Ichihara", "Muroan", "Nagakute", "Numazu", "Sumida"]

B [7]: # the number of total images and total labels.
      cls_names = []
      total_images = 0
      for gov in gavs:

          file_list = [filename for filename in os.listdir(base_path + gov + '/Annotations/') if not filename.startswith('.')
```

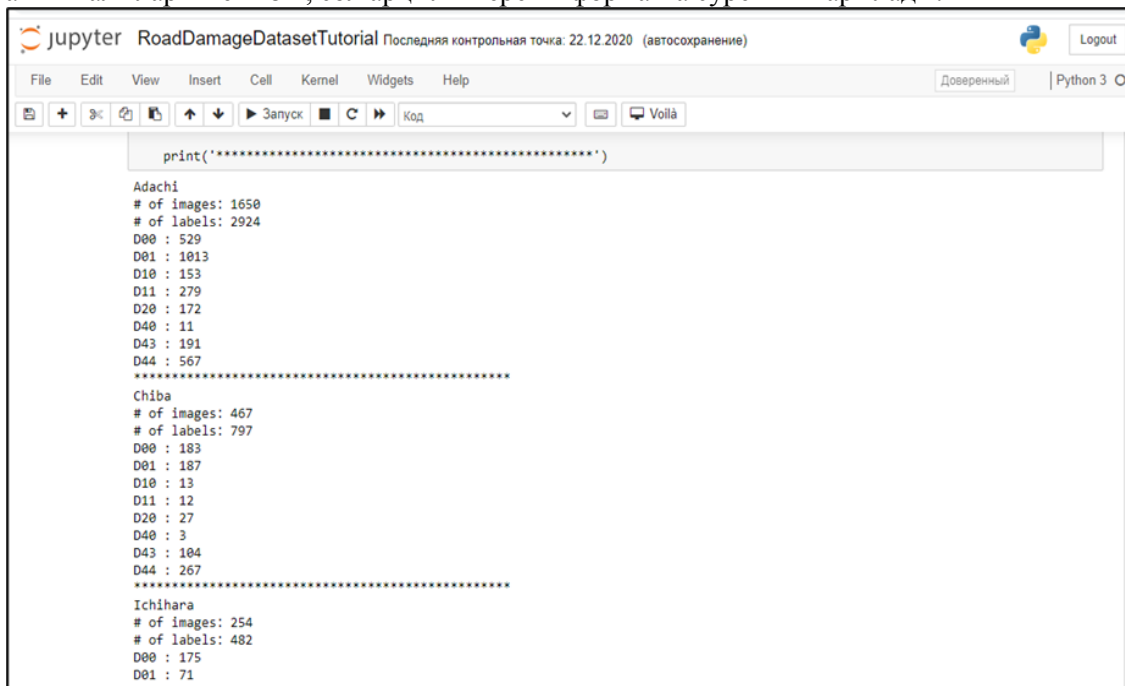
4-сурет. Зақымдануды анықтау көрсеткіштері

Жүйедегі әрбір суреттердегі қандай да бір ақау бар екендігін санау үшін collections кітапханасының counter функциясы арқылы есептелінеді. Ол үшін массив құрылып, әр класс үшін жеке-жеке есеп жүргізіледі. Шығыс жауап ретінде 5-суретте көрсетілген диаграмма ұсынылады.



5-сурет. Қала папкасындағы деректер статистикасы диаграммасы

Компьютердегі Jpegimages папкасындағы суреттерді және сол суреттерге сәйкес атаулы Annotations папкасындағы файлдарды тартылды. Содан кейін, xmax, xmin, ymax, ymin айнымалыларын енгізіп, сол арқылы керекті форматта сурет шығарылады.



```
print('*****')
Adachi
# of images: 1650
# of labels: 2924
D00 : 529
D01 : 1013
D10 : 153
D11 : 279
D20 : 172
D40 : 11
D43 : 191
D44 : 567
*****
Chiba
# of images: 467
# of labels: 797
D00 : 183
D01 : 187
D10 : 13
D11 : 12
D20 : 27
D40 : 3
D43 : 104
D44 : 267
*****
Ichihara
# of images: 254
# of labels: 482
D00 : 175
D01 : 71
D10 : 10
```

6-сурет. Бейнені өңдеу процесіндегі суреттер статистикасы

Жүйеде 7-суреттерде көрсетілгендей цикл құрылды. Цикл жүру барысында өлшемі 1-ге тең суреттерді анықтауға негізделген. Содан кейін, plt.imshow функциясы арқылы суреттер экранға шығарылады.

```
B [12]: for damageType in damageTypes:
        tmp = []
        for gov in gov:
            file = open(base_path + gov + '/ImageSets/Main/%s_trainval.txt' % damageType, 'r')

            for line in file:
                line = line.rstrip('\n').split('/')[-1]

                if line.split(' ')[2] == '1':
                    tmp.append(line.split(' ')[0]+'.xml')

        random.shuffle(tmp)
        fig = plt.figure(figsize=(6,6))
        for number, image in enumerate(tmp[0:1]):
            img = draw_images(image)
            #plt.subplot(1,1,number)
            plt.axis('off')
            plt.title('Мына суретте мына қате бар ' + damageType)
            plt.imshow(cv2.cvtColor(img, cv2.COLOR_BGR2RGB))
```

Мына суретте мына қате бар D00

7-сурет. Ақаулары бар суреттерді цикл арқылы тексеру



8-сурет. Әрбір ақау класына мысалдарды шығару

Roaddamagedetector папкасында орналасқан барлық суреттерге талдау жүргізу үшін, цикл жүргізіп, өлшемін 12-8 форматында print функциясы арқылы экранға шығарылады. Шығыс мәні ретінде, осы папкадағы барлық сәйкес сурет атаулары көрсетіледі. Содан кейін, сессия жүргізіп, ішінде керекті айнымалыларды белгіленіп алынады. detection_scores, detection_classes, num_detections айнымалылары ақаулардың мәнін, клас-

сын және дәлдігін айқындау үшін құрылған.

Жүйенің бейнероликтермен бірге жұмыс істеуі үшін cv2 кітапханасының videowriter функциясы керек. Дәл фотосуретпен жұмыс секілді алдыменен сессия жүргізіледі. Содан кейін, detection_scores, detection_classes, num_detections айнымалылары ақаулардың мәнін, классын және дәлдігін айқындау үшін құрылған.



9-сурет. Бейнеден ақауды анықтау моменті

Көлемі 40 секундты құрайтын video1 тест видеоны сараптап, экранға шығарды. D20 және d44 ақаулары анықталды. Видеоны өңдеу жиілігі 0,1 с-ті құрайды.

Қорытынды. Терең оқыту – бұл компьютерлендірудің болашағы. Мәселелерді шешу, сондай-ақ өндірісті оңтайландыру үшін оқыту жүйелерін пайдалану қателіктерді, шығындарды, адами факторларды азайтуға әкеледі.

Бұл зерттеуде біз активтерді басқарудың цифрлық құралы үшін бірінші блокты, қозғалыссыз кескіндерден немесе нақты уақыттағы бейнеден жолдың зақымдануын анықтауға және жіктеуге үйретілген әмбебап объект детекторын енгіздік. Біз бұл мәселені шешу үшін дәстүрлі есептеу тәсілдеріне және жақында тереңдетілген оқыту архитектураларына негізделген әртүрлі модельдер мен тәсілдерді сынап көрдік. Деректерді тексеру жиілігі 0,1 секундты құрады.

Бұл жұмыс келесідей үлес қосады. Біріншіден, ол басқа елдер үшін жапон моделін қолданудың ыңғайлылығын бағалайды. Екіншіден, ол смартфондардың көмегімен жиналған 10000-нан астам суретті қамтитын ауқымды, гетерогенді жол шығыны туралы мәліметтер жиынтығын ұсынады. Үшіншіден, болжам бойынша жүйе веб-ортаға веб-қосымша ретінде енгізілетін болады, ол елдің әртүрлі облыстарындағы жолдар сапасының рейтингін жасауға көмектеседі, осылайша ол автомобиль жолдарының жағдайын жақсы деңгейде ұстап тұруға мүмкіндік береді.

Список литературы

1. Alfarrarjeh A. et al. A deep learning approach for road damage detection from smartphone images // 2018 IEEE International Conference on Big Data (Big Data). – IEEE, 2018. – pp. 5201-5204.
2. Everingham M. et al. The pascal visual object classes (voc) challenge //International journal of computer vision. – 2010. – Т. 88. – №. 2. – Pp. 303-338.
3. Girshick R. Fast r-cnn //Proceedings of the IEEE international conference on computer vision. – 2015. – Pp.

- 1440-1448.
4. Maeda H. et al. Road damage detection and classification using deep neural networks with smartphone images //Computer- Aided Civil and Infrastructure Engineering. – 2018. – Т. 33. – №. 12. – Pp. 1127-1141.
 5. Zhang L. et al. Road crack detection using deep convolutional neural network //2016 IEEE international conference on image processing (ICIP). – IEEE, 2016. – Pp. 3708-3712.
 6. Salman M. et al. Pavement crack detection using the Gabor filter //16th international IEEE conference on intelligent transportation systems (ITSC 2013). – IEEE, 2013. – Pp. 2039-2044.
 7. Schnebele E. et al. Review of remote sensing methodologies for pavement management and assessment //European Transport Research Review. – 2015. – Т. 7. – №. 2. – Pp. 1-19.
 8. Koch C. et al. A review on computer vision based defect detection and condition assessment of concrete and asphalt civil infrastructure //Advanced Engineering Informatics. – 2015. – Т. 29. – №. 2. – Pp. 196-210.
 9. Mohan A., Poobal S. Crack detection using image processing: A critical review and analysis // Alexandria Engineering Journal. – 2018. – Т. 57. – №. 2. – Pp. 787-798.
 10. Абрамов Н. С., Хачумов В. М. Распознавание на основе инвариантных моментов //Discrete and Continuous Models and Applied Computational Science. – 2014. – №. 2. – С. 142-149.
 11. Нгуен Т. Л., Нгуен Т. Х. Анализ антрометрических признаков с использованием методов машинного обучения // Междисциплинарные исследования в области математического моделирования и информатики. – 2015. – С. 204-210.
 12. Нгуен Т. Х., Нгуен Т. Л. Алгоритмическое и программное обеспечение автоматического обнаружения и классификации дефектов дорожного покрытия с помощью метода разреза графов и алгоритма случайных лесов // Вестник Иркутского государственного технического университета. – 2016. – Т. 20. – №. 10. – С. 111-118.
 13. Abebe G., Cavallaro A., Parra X. Robust multi-dimensional motion features for first-person vision activity recognition //Computer Vision and Image Understanding. – 2016. – Т. 149. – Pp. 229-248.
 14. Domínguez A. R., Corkidi G. Automated recognition of oil drops in images of multiphase dispersions via gradient direction pattern //2011 4th International Congress on Image and Signal Processing. – IEEE, 2011. – Т. 3. – С. 1209-1213.
 15. Radopoulou S. C., Brilakis I. Patch detection for pavement assessment // Automation in Construction. – 2015. – Т. 53. – С. 95-104.

References

1. Alfarrarjeh A. et al. A deep learning approach for road damage detection from smartphone images // 2018 IEEE International Conference on Big Data (Big Data). – IEEE, 2018. – Pp. 5201-5204.
2. Everingham M. et al. The pascal visual object classes (voc) challenge //International journal of computer vision. – 2010. – Т. 88. – №. 2. – Pp. 303-338.
3. Girshick R. Fast r-cnn //Proceedings of the IEEE international conference on computer vision. – 2015. – Pp. 1440-1448.
4. Maeda H. et al. Road damage detection and classification using deep neural networks with smartphone images // Computer-Aided Civil and Infrastructure Engineering. – 2018. – Т. 33. – №. 12. – Pp. 1127-1141.
5. Zhang L. et al. Road crack detection using deep convolutional neural network // 2016 IEEE international conference on image processing (ICIP). – IEEE, 2016. – Pp. 3708-3712.
6. Salman M. et al. Pavement crack detection using the Gabor filter //16th international IEEE conference on intelligent transportation systems (ITSC 2013). – IEEE, 2013. – Pp. 2039-2044.
7. Schnebele E. et al. Review of remote sensing methodologies for pavement management and assessment // European Transport Research Review. – 2015. – Т. 7. – №. 2. – Pp. 1-19.
8. Koch C. et al. A review on computer vision based defect detection and condition assessment of concrete and asphalt civil infrastructure //Advanced Engineering Informatics. – 2015. – Т. 29. – №. 2. – Pp. 196-210.
9. Mohan A., Poobal S. Crack detection using image processing: A critical review and analysis // Alexandria Engineering Journal. – 2018. – Т. 57. – №. 2. – Pp. 787-798.
10. Abramov N. S., Hachýmov V. M. Raspoznvanie na osnove invariantnyh momentov //Discrete and Continuous Models and Applied Computational Science. – 2014. – №. 2. – S. 142_149
11. Nguen T. L., Nguen T. H. Analiz antropmetricheskikh priznakov s ispolzovaniem metodov mashinnogo obucheniia // Mejdistsiplinarnye issledovaniia v oblasti matematicheskogo modelirovaniia i informatiki. – 2015. – S. 204-210.

12. Nguen T. H., Nguen T. L. Algoritmicheskoe i programmnoe obespechenie avtomaticheskogo obnaruzheniia i klassifikatsii defektov dorojnogo pokrytiia s pomoiu metoda razreza grafov i algoritma slychainyh lesov // Vestnik Irkutskogo gosudarstvennogo tehnikeskogo universiteta. – 2016. – T. 20. – №. 10. – S. 111-118.
13. Abebe G., Cavallaro A., Parra X. Robust multi-dimensional motion features for first-person vision activity recognition // Computer Vision and Image Understanding. – 2016. – T. 149. – Pp. 229-248.
14. Domínguez A. R., Corkidi G. Automated recognition of oil drops in images of multiphase dispersions via gradient direction pattern //2011 4th International Congress on Image and Signal Processing. – IEEE, 2011. – T. 3. – C. 1209-1213.
15. Radopoulou S. C., Brilakis I. Patch detection for pavement assessment // Automation in Construction. – 2015. – T. 53. – C. 95-104.