

FTAXP 28.23.15

ӘОЖ 51-76: 004.9

<https://doi.org/10.55452/1998-6688-2024-21-4-81-90>

¹**Омаров Б.С.,**

PhD, доцент, ORCID ID: 0000-0002-8341-7113,

e-mail: batyahan@gmail.com

^{1,2*}**Зиятбекова Г.З.,**

PhD, доцент м.а., аға ғылыми қызметкері, ORCID ID: 0000-0002-9290-6074,

*e-mail: ziyatbekova1@gmail.com

¹**Батыр Ж.А.,**

магистр, ORCID ID: 0009-0006-5384-1497,

e-mail: zhan.batyr01@gmail.com

³**Майлыбаева А.Д.,**

физ.-мат.ғ.к., қауымдастырылған профессор, ORCID ID: 0000-0003-0598-4806,

e-mail: mjkka@mail.ru

⁴**Бидахмет Ж.,**

PhD, қауымдастырылған профессор, ORCID ID: 0000-0002-7667-5464,

e-mail: zhanar.18.05@gmail.com

^{1,4}**Шаметова Г.К.,**

докторант, аға оқытушы, ORCID ID: 0009-0001-4099-0112,

e-mail: gauharshametova@gmail.com

⁵**Войчик В.,**

профессор, e-mail: waldemar.wojcik@pollub.pl

¹әл-Фараби атындағы Қазақ ұлттық университеті, Алматы қ., Қазақстан

²ҚР ҒЖБМ ҒК Ақпараттық және есептеуіш технологиялар институты,
Алматы қ., Қазақстан

³Халел Досмұхамедов атындағы Атырау университеті, Атырау қ., Қазақстан

⁴Ғ. Дәукеев атындағы Алматы энергетика және байланыс университеті,
Алматы қ., Қазақстан

⁵Люблин техникалық университеті, Люблин қ., Польша

ЖОЛ БЕЛГІЛЕРІН АВТОМАТТЫ ТҮРДЕ КОНВОЛЮЦИЯЛЫҚ НЕЙРОНДЫҚ ЖЕЛІЛЕР КӨМЕГІМЕН АНЫҚТАУ ЖӘНЕ ТАЛУ

Аңдатпа

Бұл зерттеу ауа райының қолайсыз жағдайларында жол белгілерін тану жүйелерін жақсарту мақсатында конволюциялық нейрондық желілерді (CNN) пайдалануға арналған. Жұмыста CNN негізінде құрылған жаңа модель қолданылып, неміс жол белгілерін тану тестінің (GTSRB) кеңейтілген деректер жиынтығы қарастырылады. Аталған деректер жиынтығында қырықтан астам класты қамтитын жазбалары бар 50 мыңнан астам кескіндер жинақталған. Ұсынылған модель жаңбыр, тұман және қар сияқты ауа райы факторларының көріну сапасына тигізетін әсерін төмендетуге арналған объектілерді бөлудің бейімделу қабаттарын пайдаланады. Әртүрлі ауа райы сценарийлерін модельдеу үшін деректерді көбейтудің озық әдістері қолданылады, бұл оқыту жиынтығының әртүрлілігін арттырады. Зерттеу барысында CNN-нің қолайсыз жағдайларда жол белгілерін анықтаудағы теориялық және практикалық жақсартулары талданып, модельдің тиімділігі дәлдік, жауаптылық және F1 көрсеткіші сияқты метрикалар арқылы тексерілді. Нәтижелер модельдің жалған позитивтер санын азайтуда және жол белгілерін дәл анықтауда тиімді екенін көрсетті. Мақалада деректер жиынтығын мұқият дайындаудың, модельдерді оңтайландырудың және анықтау жүйесінің жұмысын жақсарту үшін оқытуды жетілдірудің маңыздылығы айқындалады. Бұл зерттеу интеллектуалды көлік жүйелері, автономды көлік жүргізу және жол қауіпсіздігі салаларындағы сенімді жол белгілерін тану технологияларының болашақтағы дамуына оң ықпалын тигізеді.

Тірек сөздер: CNN, жол белгілерін анықтау, жасанды интеллект, кескінді талдау, жіктеу.

Кіріспе

Жол белгілерін тану интеллектуалды көлік жүйелері мен автономды автомобильдерді дамытудың маңызды құрамдас бөлігі. Жол белгілерін дәл анықтау және түсіндіру автоматтандырылған жүйелерге негізделген шешімдер қабылдауға мүмкіндік береді, осылайша жол қозғалысының қауіпсіздігі мен тиімділігін арттырады [1]. Дегенмен жол белгілерін танудағы қиындықтар негізінен жарықтың құбылмалы жағдайларына және жол белгілерінің көрінуін айтарлықтай нашарлататын ауа райы жағдайлары сияқты қоршаған орта факторларына байланысты туындайды [2].

Бұл зерттеудің негізгі мақсаты конволюциялық нейрондық желілер (CNN) арқылы қолайсыз ауа райында жол белгілерін тану жүйелерінің дәлдігін арттыру болып табылады. Мұнда жаңбыр, тұман және қар сияқты қолайсыз ауа райын тиімді жеңе алатын CNN негізіндегі модельді әзірлеу және сынау туралы ой қозғалады. Зерттеу әртүрлі ауа райы сценарийлерін модельдеу үшін белгілерді алудың адаптивті қабаттарын және деректерді толықтырудың озық әдістерін енгізуге бағытталған, бұл нақты жағдайларда жол белгілерін анықтау жүйелерінің тұрақтылығы мен сенімділігін арттыруға мүмкіндік береді.

Зерттеу барысында жаңбыр, тұман және қар сияқты ауа райының күрделі жағдайларына сәйкес келетін модельдеу әдістері әзірленді. Конволюциялық нейрондық желілерді ауа райының нақты әсеріне бейімдейтін адаптивті қабаттарды қолдану жаңалық болып табылады. Зерттеудің мақсаты – конволюциялық нейрондық желілерінің қиын жағдайларда жол белгілерін дәл тану қабілетін жетілдіру. Бұл мақсатқа жету үшін зерттеу деректерді толықтыру және бейімделгіш белгілерді алу қабаттарын қолдану арқылы модельдің әртүрлі ауа райы сценарийлерінде жұмыс істеу қабілетін жақсартуды көздейді. Жаңа әдіс жаңбыр, қар, тұман әсерінен туындайтын көріну мәселелерін азайтуға бағытталған. Қолайсыз ауа райында жол белгілерін танудың жоғары дәлдігі интеллектуалды көлік жүйелерінің және автономды көліктердің қауіпсіздігі мен сенімділігін арттырады. Бұл зерттеу көлік саласында жол қауіпсіздігін жақсарту тұрғысынан өзекті болып табылады.

Зерттеудің нәтижелері автономды көліктерде қолданылатын жол белгілерін тану жүйелерінің қауіпсіздігі мен сенімділігін арттыруға, сондай-ақ интеллектуалды көлік жүйелерін дамытуға үлес қосады. Бұл зерттеу тұрақты жол қозғалысын қамтамасыз ету үшін ауа райының әртүрлі жағдайларына бейімделетін модельдер құрудың маңыздылығын айқындайды және жол қозғалысы қауіпсіздігін қамтамасыз етуге бағытталған.

Конволюциялық нейрондық желілер (CNN) кескінді тану саласындағы стандартқа айналды және визуалды деректерден жоғары деңгейлі сипаттамаларды алу қабілетіне байланысты жол белгілерін тану үшін көбірек қолданылуда [3]. Қырықтан аса топқа қатысты елу мыңнан астам кескінді қамтитын немістің трафикті қайта тану German Traffic Sign Recognition Benchmark (GTSRB) деректер жинағы жол белгілерін тану жүйелерін оқыту мен бағалаудың сенімді негізін қамтамасыз етеді [4].

Соңғы онжылдықта жол қозғалысын тану жүйелерінің көптеген модельдері ұсынылды [5–7]. Әдетте, бұл жүйелер анықтау және тану кезеңдерінде жұмыс істейді. Стандартты жағдайларда CNN өте жақсы жұмыс істегенімен, олардың тиімділігі жаңбыр, тұман және қар сияқты қолайсыз ауа райында төмендейді, бұл белгілердің көрінуін бұлыңғыр етіп төмендетеді әрі оларды өзгеше етіп көрсетуі мүмкін [8]. Бұл түйткіл мәселені шешу қоршаған ортаның тосын жағдайларына бейімделе отырып, оларды реттей алатын тиімді модельдерді әзірлеуді талап етеді.

Бұл зерттеу ауа райының қиын жағдайында тану дәлдігін жақсарту үшін CNN архитектурасын жақсартатын қолданыстағы әдістерге сүйенеді. Ауа райының бұзылуына қарай жылдам бейімделетін белгілерді алудың адаптивті қабаттарын біріктірудің арқасында бұл зерттеу әртүрлі жұмыс жағдайларында автономды жүргізу технологияларының сенімділігін арттыруға айтарлықтай үлес қосады [9]. Сонымен қатар ол модельдерді мұқият оқытудың және деректер

жиынтығын өңдеудің маңыздылығын атап көрсетеді, өйткені бұл өнімділікті оңтайландыру және жүйенің нақты уақытта қолданылуын қамтамасыз ету үшін өте маңызды.

Бұрынғы зерттеулерде қолайлы жағдайларда CNN моделінің жоғары дәлдігі көрсетілгенімен, олардың көпшілігі жол белгілерінің көрінуін нашарлататын жаңбыр, қар және тұман сияқты күрделі жағдайларда төмен нәтижелер көрсетеді. Бұл мәселені шешу үшін әртүрлі әдістер, соның ішінде деректерді толықтыру және модельді әртүрлі жағдайларға бейімдеу, ұсынылған. Мұндай зерттеулерде белгілерді алудың адаптивті қабаттары және қолайсыз ауа райы жағдайларын имитациялау арқылы деректер жиынтығын кеңейту әдістері қолданылады [10].

Ағымдағы зерттеулерде бейімделгіш белгілерді алу қабаттарын қолдану арқылы CNN тиімділігін арттыру, сонымен қатар деректерді толықтыру әдістерін оңтайландырудың маңыздылығы көрсетілген. Бұл зерттеу әртүрлі ауа райы сценарийлерінде нақты жұмыс істей алатын CNN моделін әзірлеуге бағытталған, бұл өз кезегінде автономды көлік жүйелерінің сенімділігі мен қауіпсіздігін арттыруға ықпал етеді.

Материалдар мен әдістер

Берілген зерттеу үшін пайдаланылған GTSRB деректер жинағында 1-суретте көрсетілгендей 43 жол белгілері класына бөлінген 51893 сурет бар. Деректер жиынтығындағы кескіндердің мөлшері 15x15 тен 222x193 пиксельге дейін өзгереді. Бұл суреттердің барлығы ауа райының қолайсыздығы мен әртүрлі жарықтандыруды қоса алғанда, нақты әлемде түсірілген. Кейбір суреттердің көріну сапасы төмен және оларды тану да қиын болуы мүмкін.



Сурет 1 – Деректер жиынтығындағы жол белгілерінің 43 класы

Қолданыстағы деректер жиынтығы олардың мөлшері мен күрделі жағдайларды қамту тұрғысынан шектеулі, бұл бізді суреттерді толықтыру әдістерімен қамтуға мәжбүр етті. Ауа райының қолайсыздығын имитациялау үшін жасанды жаңбыр, тұман және қарды қолдану сияқты суреттерді алдын-ала өңдеудің қосымша әдістері бастапқы деректер жиынтығына қолданылды. Бұл қосымша нақты міндеттерді көрсететін оқу бейнелерінің әртүрлі жиынтығын жасауға бағытталған. Нейрондық желілерді оқыту үшін кескін массивін үлкейтуге қолданылатын кескін қондырмаларының әр алуан түрлері бар [11].

OpenCV кітапханасын пайдалана отырып, суреттерді өңдеу және оларға ауа райы сүзгісін қолдану үшін кескінді үлкейту әдістері жасалды. Бұл толықтырулар жаңбыр, тұман, қар,

көлеңке және жарықтың өзгеруі сияқты жол белгілерін тануға кедергі келтіруі мүмкін нақты экологиялық әсерлерді имитациялайды. Бұл толықтырулардың мақсаты – модельге қолайсыз ауа-райына тән әртүрлі визуалды кедергілерге үйренуге және бейімделуге мүмкіндік беретін түрлі оқу жиынтығын жасау.

Жаңбыр қосымшасын жасау үшін OpenCV line функциясы бүкіл кескінге шағын сызықтар жасау үшін қолданылды. Жаңбыр тамшыларының кездейсоқ қисаюын қосу және кескіннің жарықтығын азайту арқылы жаңбырға немесе тіпті қатты нөсерге келтіруге болады. Бұл әдіс модельге камера объективіндегі жаңбырдан туындаған ықтимал дақтар мен бұлыңғырлықтары бар белгілерді тануды үйренуге көмектеседі. Қар эффектiсi кескіннің қараңғы жерлерін ағарту арқылы суреттің түс кеңістігіндегі жарық арнасының пиксель мәндерін өзгерту арқылы қосылды. Тұман кескіндерге біркелкі немесе градиентті бұлыңғырлық қосу арқылы имитацияланды, көптеген ақ түсті қабаттасу қарқындылығын қолданды. Мөлдірлік деңгейі әртүрлі тығыздықтағы тұманды жасау үшін реттелді, яғни жеңіл тұманнан қалың тұманға дейінгі өзгеріс, бірақ ол жол белгілерінің көрінуін жасыруы мүмкін. Ауа-райының нақты жағдайларына байланысты толықтырулардан басқа да кездейсоқ толықтырулар құбыры жүзеге асырылды, онда әрбір сурет жоғарыда аталған әсерлердің тіркесімінен өтуі мүмкін. 2-суретте осы жинақтау әдістерін қолдану мысалдары көрсетілген. Осы кеңейту әдістерін қолдана отырып, CNN моделін әртүрлі және болжанбайтын нақты әлем жағдайларында сенімді жұмыс істеуге дайындай отырып, оқыту деректерінің жиынтығын әртүрлі күрделі шарттармен байытылды.




Сурет 2 – Жол белгісінің кескініне күшейтуді қолдану

Бұл толықтыру әдістері оқыту деректерінің жиынтығын әртараптандырып қана қоймай, сонымен қатар модельдің әртүрлі қолайсыз жағдайларда сенімді жұмыс істей отырып, оқу деректерін нақты сценарийлерге жалпылау қабілетін айтарлықтай жақсартты. Бұл тәсіл автономды жүргізу және онымен байланысты қолданбалар үшін жетілдірілген компьютерлік көру жүйелерін әзірлеу кезінде деректерді жан жақты және шынайы толықтырудың маңыздылығын көрсетеді. Деректер жиынтығы Python scikit-learn кітапханасына кіретін жіктеу функциясы арқылы жіктелді. Деректердің 80%-ы оқыту үшін және 20%-ы тестілеу үшін пайдаланылды.

3-сурет 12 қабаттан тұратын желі құрылымын көрсете отырып, жол белгілерін тану үшін ұсынылған конволюциялық нейрондық желінің (CNN) архитектуралық дизайнын көрсетеді.

Бұл модельдің бастапқы материалы 30x30 пиксельді түрлі түсті кескіндер. CNN моделінде 4 конволюциялық қабат, максималды біріктіру, төгілу және тегістеу қабаттары бар. Соңғы толық байланысқан қабаттың шығысы 43 жолақты softmax-қа беріледі, ол жол белгілерінің 43 класы бойынша таралады. CNN архитектураларында қабаттарды біріктіру кіріс кескінінің өлшемін кішірейту үшін пайдаланылуы мүмкін, осылайша ол есептеу жылдамдығын тездетеді. Бұл процесс екі маңызды параметрді орнатуды қамтиды: «f» деп белгіленген сүзгі өлшемі және «s» деп белгіленген қадам. Қабаттарды біріктіру пикселдердің орналасу сезімталдығының төмендеуіне әкеледі, сондықтан $f=2$ және $s=2$ сияқты жалпы мәндер жиі қолданылады [12]. Алайда, бұл мөлшердің азаюы есептеу ресурстарына байланысты тексерілетін коэффициент-

тер санының азаюына сәйкес келетінін ескеру қажет. CNN архитектурасында конволюциялық сүзгілердің ядролары белгіленген мысалдар жиынтығынан білім ала отырып, бақыланатын мәліметтер негізінде оқытылады. Әрбір иерархиялық деңгейде CNN іргелес пикселдердің жауаптарын біріктіру үшін іріктеу операцияларын орындайды. Бұл операциялар CNN-ге суреттердегі объектілердің орналасуына тәуелді емес кеңістіктік-инвариантты функцияларды игеруге мүмкіндік береді [13].




Сурет 3 – Жол белгісінің бейнесіне толықтыруларды қолдану

Машиналық оқыту және жіктеу міндеттері саласында модельдің өнімділігі мен тиімділігін өлшеу үшін бағалау көрсеткіштері қажет. Дәлдік, еске түсіру және F-score сияқты көрсеткіштер модельдің болжамды күшін және оның жаңа деректерді жалпылау қабілетін анықтау үшін негіз болып табылады. Бұл параметрлер модель бұрын кездеспеген деректерді қаншалықты тиімді өңдей алатынын және болжай алатынын анықтауда шешуші рөл атқарады [14].

Нәтижелер мен талқылау

Желі 0,001 оқу коэффициенті бар Adam оптимизаторын қолдана отырып, TensorFlow машиналық оқыту шеңберінде үйренді. Партияның мөлшері 32-ге белгіленді, ал артық мөлшерді азайту үшін алғашқы екі толық байланысқан қабатқа оқудан шығаруды регуляциялау қолданылды. Ұсынылған CNN моделі 15 дәуірде сыналды. Оқытудан кейінгі нейрондық желінің тиімділігін бағалау үшін модель жол белгілерін анықтауға және тануға арналған 12 қабатты конволюциялық нейрондық желіні пайдаланады. Бастапқы қабатқа RGB түс форматында 30x30 пиксель ажыратымдылығы бар сурет келеді. Содан кейін екінші қабатта relu белсендіру функциясы бар Conv2D операциясы қолданылады. Үшінші деңгей stride, ядро өлшемі, padding және қайтару индекстерін қоса алғанда, әртүрлі параметрлерді қабылдайтын максималды біріктіру операциясын (MaxPool2D) пайдаланады. Осыдан кейін төртінші қабатта relu белсендірілген Conv2D де қолданылады. Бесінші қабат қайтадан Max Pool 2D. Алтыншы қабат кірістерді сызықтандыру үшін тегістеу қадамын қамтиды, содан кейін тығыз байланыс қабаты немесе әрбір нейрон алдыңғы қабаттағы барлық нейрондармен толық байланысқан тығыз қабат орналасады. Ақырында, дәлдікті арттыру және тамаша нәтижеге жақындау үшін шығыс тығыз қабаты softmax функциясын пайдаланады, ол танылған жол белгісін анықтайтын әрбір класстар ықтималдығын береді. 4-суретте модельдің дәлдігі мен жоғалуы көрсетілген.



Сурет 4 – Оқытудан кейінгі модельдің дәлдігі мен жоғалуы

1-кестеде модельді оқыту кезеңінде сынақ деректерін бағалау үшін қолданылатын кейбір сапа көрсеткіштері келтірілген. Жалпы тиімділік көрсеткіші ретінде жаһандық дәлдік көрсеткіші сынақ деректері контекстінде орта есеппен 95% құрайтын жоғары жетістіктерді көрсетті.

Кесте 1 – Оқу кезеңінен кейінгі бағалау көрсеткіштері

	Дәлдік	Қарау	F1-ұпай	Қолдау t
1 класс	0,98	0,95	0,97	60
2 класс	0,85	0,97	0,91	720
3 класс	0,98	0,89	0,94	750
4 класс	0,88	0,85	0,87	450
5 класс	0,99	0,89	0,94	660

Сонымен қатар, жол белгілерін жіктеу мәселесінде бірінші класқа арналған метрику мұқият бағалау келесі маңызды нәтижелерге қол жеткізді:

F1-score көрсеткіші, recall және precision көрсеткіштері арасындағы тепе-теңдікті қамтамасыз ететін 97 %-ға жеткен керемет кешенді көрсеткіш. Бұл жетістік жалған позитивтер санын азайтуда және тиісті жағдайларды дұрыс анықтауда модельдің жоғары тиімділігін көрсетеді.

Бұл нақтыланған нәтижелер жол белгілерін жіктеу мәселесінде модельдің тиімділігі мен сенімділігін көрсете отырып, машиналық оқыту және жіктеу туралы білім қоржынын толықтырады.

Ұсынылған CNN моделінің дәлдігі мен беріктігі интеллектуалды көлік инфрақұрылымы мен автономды жүргізу жүйелерін дамыту үшін практикалық маңызы зор. Автономды көліктер нақты жағдайларда қауіпсіз және ақылға қонымды шешімдер қабылдау үшін ауа райының қолайсыздығында жол белгілерін дәл анықтай алуы керек. Мұндай сенімділік әсіресе, қиын ауа райында жүргізушіге көру қиын болған кезде апатты азайту және жалпы қозғалыс қауіпсіздігін жақсарту үшін өте маңызды болып табылады.

Сонымен қатар, деректерді кеңейту әдістері мен адаптивті белгілерді алу қабаттарын қолданатын тәсіл жолақты тану және жаяу жүргіншілерді анықтау сияқты басқа автономды жүргізу элементтері үшін пайдаланылуы мүмкін әрі оның негізін қалайды. Бұл икемділік интеллектуалды көлік жүйелерінің бірқатар қосымшаларында CNN-нің жалпы

пайдалылығын арттырады. Бұл нәтижелердің практикалық маңызы зор, өйткені олар автономды автомобильдердің сенімділігі мен өнімділігін арттыра алады, нәтижесінде жол-көлік оқиғалары азаяды және көлік желілерінің тиімділігі артады.

Эксперименттік кезеңнің нәтижелері конволюциялық нейрондық желі (CNN) архитектурасының әртүрлі қолайсыз ауа райы жағдайында жол белгілерін танудағы тиімділігін дәлелдейді. Адаптивті белгілерді алу қабаттары мен теңшелетін толықтыру әдістерін реттеуді қолдану модельдің тұрақтылығы мен дәлдігін айтарлықтай жақсартты.

Қолайсыз ауа райының әсерінен болатын визуалды бұрмалануларды жеңілдетуде бейімделгіш белгілерді алу қабаттары шешуші рөл атқарады. CNN-дегі адаптивті әдістер, алдыңғы жұмыстарда айтылғандай, қоршаған ортаның нақты айнымалыларына жауап беру арқылы сүзгілерді икемді түрде өзгертуге мүмкіндік береді [15]. Қардың, тұман мен жаңбырдың жол белгілерінің көрінуіне әсерін азайту қабілеті нақты жағдайларда зерттеудің бейімделу тәсілдерінің артықшылығын көрсетеді [16].

Қазіргі зерттеулерде сипатталған негізгі модельдермен салыстыру олардың ауа райына байланысты нашар құбылмалы кескіндермен жақсы жұмыс істейтінін көрсетті. Бұл салыстырулар модель дизайнының дұрыстығын растайды және оның қолайсыз жағдайларда дәлдігі мен сенімділігі бойынша қолданыстағы жүйелерден асып түсу мүмкіндігін көрсетеді [17].

CNN моделінің тиімділігі жол белгілерін тану кезінде 95% дәлдікке қол жеткізумен расталады, бұл ұқсас контексттерде қолданылатын әдеттегі CNN модельдеріне қарағанда айтарлықтай жоғары. Еске түсіру және F1-score сияқты стандартты бағалау көрсеткіштерімен өлшенетін бұл жоғары өнімділік деңгейі модельдің болжамдық мүмкіндіктері мен жалпылау қабілетін бағалау үшін маңызды дәлдік болып табылады [18]. Дәлдік модель жасаған оң болжамдардың дәлдігін өлшейді, ал есте сақтау модельдің барлық тиісті жағдайларды анықтау қабілетін көрсетеді. F1-score модельдің тиімділігі туралы тұтас түсінік бере отырып, дәлдік пен кері байланыс арасындағы тепе-теңдікті қамтамасыз етеді [19–20].

Осылайша, зерттеу жоспарланған архитектуралық жақсартулар оқу деректер жиынтығын дәл сәйкестендірумен бірге жол белгілерін тану сияқты нақты қолданбаларда CNN өнімділігін айтарлықтай жақсарту алатынын көрсетеді. Жасанды түрде жасалған күрделі жағдайларда қолданылатын әдістер сенімділік пен қауіпсіздік маңызды болатын автономды жүргізу жүйелерінде пайдалану үшін жаңа перспективаларды ашады.

Қорытынды

Бұл зерттеу конволюциялық нейрондық желінің (CNN) модификацияланған архитектурасы ауа райының қолайсыздығында жол белгілерін дәл және тиімді түсіндіре алатынын көрсетті. Деректерді кеңейтудің маңызды әдістерін және белгілерді алудың адаптивті қабаттарын қолдана отырып, осы зерттеу модельдің сыртқы әсерлерге төзімділігін арттырды, бұл әдетте визуалды тану жүйелерінің дұрыс жұмыс істемеуіне әкеледі. Істен шығаруды реттеуді қолдану арқылы модель шамадан тыс сәйкестіктің алдын алып, жаңа, тексерілмеген деректерде жалпылауды жақсы сақтай алды.

Алынған нәтижелер жоспарланған архитектуралық жақсартулардың оқу деректер жиынтығын дәл сәйкестендірумен бірге CNN өнімділігін жол белгілерін тану сияқты нақты қолданбаларда айтарлықтай жақсарту алатынын көрсетеді. Бұл әдістерді күрделі жағдайларда тиімді пайдалану автономды жүргізу жүйелерінде қолдануға жаңа бағыт береді. Онда сенімділік пен қауіпсіздік маңызды болып табылады.

Қорыта келе, зерттеу жұмысы автономды көліктердің дамуына ықпал етеді деп айтуға болады, бұл қоршаған орта мәселелеріне қарамастан жақсы жұмыс істей алатын жол белгілерін танудың тұрақты және сенімді әдісін ұсынады. Осы зерттеу кез-келген жағдайда қауіпсіз жүре алатын, тасымалдаудың тиімділігі мен жол қауіпсіздігін арттыратын толық автономды автомобильдерді құруға бағытталған қадам.

ӘДЕБИЕТТЕР

- 1 Sun Y., Ge P., Liu D. Traffic sign detection and recognition based on convolutional neural network. 2019 Chinese automation congress (CAC), IEEE, 2019, pp. 2851–2854.
- 2 Ahmed S., Kamal U., & Hasan M.K. DFR-TSD: A deep learning based framework for robust traffic sign detection under challenging weather conditions. *IEEE Transactions on Intelligent Transportation Systems*, 2022, vol. 23, no. 6, pp. 5150–5162. <https://doi.org/10.1109/TITS.2020.3048878/>
- 3 Liu Z. et al. MR-CNN: A multi-scale region-based convolutional neural network for small traffic sign recognition. *IEEE Access.*, 2019, vol. 7, pp. 57120–57128.
- 4 Lin C. et al. Transfer learning based traffic sign recognition using inception-v3 model. *Periodica Polytechnica Transportation Engineering*, 2019, vol. 47, no. 3, pp. 242–250.
- 5 Eskandarian A., Wu C., Sun C. Research advances and challenges of autonomous and connected ground vehicles. *IEEE Transactions on Intelligent Transportation Systems*, 2019, vol. 22, no. 2, pp. 683–711.
- 6 Janai J. et al. Computer vision for autonomous vehicles: Problems, datasets and state of the art // *Foundations and Trends® in Computer Graphics and Vision*, 2020, vol. 12, no. 1–3, pp. 1–308.
- 7 Singh I. et al. Dropout-VGG based convolutional neural network for traffic sign categorization. *Congress on Intelligent Systems: Proceedings of CIS 2021*, Singapore Springer Nature Singapore, 2022, vol 1, pp. 247–261.
- 8 Dang, T.P., Tran N.T., To V. H., & Tran Thi M.K. Improved YOLOv5 for real-time traffic signs recognition in bad weather conditions. *The Journal of supercomputing*, 2023, vol. 79, Issue. 10, pp. 10706–10724. <https://link.springer.com/article/10.1007/s11227-023-05097-3>.
- 9 Puli M. S., Sunitha M., Aluri O. S. B., Jain D.R., Rayabharapu M., & Venkatesh M. Deep Learning-Based Framework For Robust Traffic Sign Detection Under Challenging Weather Conditions. *Journal of Survey in Fisheries Sciences*, 2023, vol. 23, Issue. 6, pp. 5150–5162. <https://doi.org/10.1109/TITS.2020.3048878>.
- 10 Qian R., Yue Y., Coenen F., & Zhang B. Traffic sign recognition with convolutional neural network based on max pooling positions. In *2016 12th International conference on natural computation, fuzzy systems and knowledge discovery (ICNC-FSKD)*, 2016, pp. 578–582. *IEEE*. <https://doi.org/10.1109/FSKD.2016.7603237>.
- 11 Xu M. et al. A comprehensive survey of image augmentation techniques for deep learning. *Pattern Recognition*, 2023, vol. 137, p. 109347.
- 12 Cong S., Zhou Y. A review of convolutional neural network architectures and their optimizations. *Artificial Intelligence Review*, 2023, vol. 56, no. 3, pp. 1905–1969.
- 13 Tian Y. Artificial intelligence image recognition method based on convolutional neural network algorithm. *Ieee Access.*, 2020, vol. 8, pp. 125731–125744.
- 14 Yacoubby R., & Axman, D. Probabilistic extension of precision, recall, and f1 score for more thorough evaluation of classification models. In *Proceedings of the first workshop on evaluation and comparison of NLP systems*, 2020, pp. 79–91. <https://doi.org/10.18653/v1/2020.eval4nlp-1.9>
- 15 Yao Z., Song X., Zhao L., & Yin Y. Real-time method for traffic sign detection and recognition based on YOLOv3-tiny with multiscale feature extraction. *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, 2021, vol. 235, Issue. 7, pp. 1978–1991. <https://doi.org/10.1177/0954407020980559>.
- 16 Yucong S., & Shuqing, G. Traffic sign recognition based on HOG feature extraction. *Journal of Measurements in Engineering*, 2021, vol. 9, Issue. 3, pp. 142–155. <https://doi.org/10.21595/jme.2021.22022>.
- 17 Feng L., & Jia Y. Traffic sign recognition based on YOLOX in extreme weather. In *2022 Global Conference on Robotics, Artificial Intelligence and Information Technology (GCRAIT)*, 2022, pp. 299–303. <https://doi.org/10.1109/GCRAIT55928.2022.00070>.
- 18 Feng D. et al. Deep multi-modal object detection and semantic segmentation for autonomous driving: Datasets, methods, and challenges. *IEEE Transactions on Intelligent Transportation Systems*, 2020, vol. 22, no. 3, pp. 1341–1360.
- 19 Lin Z., Yih M., Ota J.M., Owens J., & Muyan-Ozcelik P. Benchmarking Deep Learning Frameworks and Investigating FPGA Deployment for Traffic Sign Classification and Detection. *IEEE Transactions on Intelligent Vehicles*, 2019, vol. 4, Issue. 3, pp. 385–395. <https://doi.org/10.1109/TIV.2019.2919458>.
- 20 Sun P., Zhang R.Y., Jiang T., Kong C., Xu W., Zhan M., Tomizuka L., Li Z., Yuan C., Wang & Luo, P. Sparse R-CNN: End-to-end object detection with learnable proposals, 2020. *arXiv:2011.12450* <https://doi.org/10.48550/arXiv.2011.12450>.

¹Omarov B.S.,

PhD, Associate Professor, ORCID ID: 0000-0002-8341-7113,

e-mail: batyahan@gmail.com

^{1,2*}Ziyatbekova G.Z.,

PhD, Acting Associate Professor, senior researcher, ORCID ID: 0000-0002-9290-6074,

*e-mail: ziyatbekova1@gmail.com

¹Batyr1 Zh.A.,

Master, ORCID ID: 0009-0006-5384-1497,

e-mail: zhan.batyr01@gmail.com

³Mailybayeva A.D.,

Candidate of Physical and Mathematical Sciences; Associate Professor,

ORCID ID: 0000-0003-0598-4806,

e-mail: mjkka@mail.ru

⁴Bydakhmet Zh.,

PhD, Associate Professor, ORCID ID: 0000-0002-7667-5464,

e-mail: zhanar.18.05@gmail.com

^{1,4}Shametova G.K.,

Doctoral student, Senior Lecturer, ORCID ID: 0009-0001-4099-0112,

e-mail: gauharshametova@gmail.com

⁵Wójcik W.,

Professor, e-mail: waldemar.wojcik@pollub.pl

¹Al-Farabi Kazakh National University, Almaty, Kazakhstan

²Institute of Information and Computational Technologies SC MSHE RK,
Almaty, Kazakhstan

³Khalel Dosmukhamedov Atyrau University, Atyrau, Kazakhstan

⁴Almaty University of Power Engineering and Telecommunications after Gumarbek Daukeev,
Almaty, Kazakhstan

⁵Lublin Technical University, Lublin, Poland

AUTOMATIC DETECTION AND RECOGNITION OF ROAD SIGNS USING CONVOLUTIONAL NEURAL NETWORKS

Abstract

This paper examines the use of convolutional neural networks (CNNs) to improve traffic sign recognition systems, precisely in non-weather conditions. An extended dataset of the German Traffic Sign Recognition Test (GTSRB), based on a new CNN model, is also used, which contains more than fifty thousand labeled images covering more than forty categories. The model presents adaptive object selection layers designed to eliminate visibility problems caused by weather factors such as rain, fog, and snow. Advanced data augmentation techniques are applied to model different weather scenarios, which increases the diversity of the training dataset. Through an analysis of theoretical and practical aspects, the study demonstrates how CNNs enhance the accuracy and efficiency of road sign detection systems in a different weather condition. This study not only examines the theoretical and practical improvements provided by CNNs for traffic sign detection in unfavorable conditions, but also verifies the effectiveness of the model through metrics such as accuracy, responsiveness, and F1 score. The results confirm the effectiveness of the model in minimizing false positives and accurately identifying traffic signs. The paper emphasizes the importance of careful dataset preparation, model optimization and improved training to enhance the performance of the detection system. This has positive implications for intelligent transportation systems, autonomous driving and road safety, indicating future progress in robust traffic sign recognition technologies.

Key words: CNN, traffic sign detection, artificial intelligence, image analysis, classification.

¹**Омаров Б.С.,**

PhD, доцент, ORCID ID: 0000-0002-8341-7113,

e-mail: batyahan@gmail.com

^{1,2*}**Зиятбекова Г.З.,**

PhD, и.о. доцента, с.н.с., ORCID ID: 0000-0002-9290-6074,

*e-mail: ziyatbekova1@gmail.com

¹**Батыр Ж.А.,**

магистр, ORCID ID: 0009-0006-5384-1497,

e-mail: zhan.batyr01@gmail.com

³**Майлыбаева А.Д.,**

к.ф.-м.н., ассоц. профессор, ORCID ID: 0000-0003-0598-4806,

e-mail: mjkka@mail.ru

⁴**Бидахмет Ж.,**

PhD, ассоц. профессор, ORCID ID: 0000-0002-7667-5464,

e-mail: zhanar.18.05@gmail.com

^{1,4}**Шаметова Г.К.,**

докторант, ст. преподаватель, ORCID ID: 0009-0001-4099-0112,

e-mail: gauharshametova@gmail.com

⁵**Войчик В.,**

профессор, e-mail: waldemar.wojcik@pollub.pl

¹Казахский национальный университет имени аль-Фараби, г. Алматы, Казахстан

²Институт информационных и вычислительных технологий КН МНВО РК,

г. Алматы, Казахстан

³Атырауский университет имени Х. Досмухамедова, г. Атырау, Казахстан

⁴Алматинский университет энергетики и связи имени Г. Даукеева, г. Алматы, Казахстан

⁵Люблинский технический университет, г. Люблин, Польша

АВТОМАТИЧЕСКОЕ ОБНАРУЖЕНИЕ И РАСПОЗНАВАНИЕ ДОРОЖНЫХ ЗНАКОВ С ПОМОЩЬЮ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ

Аннотация

В работе рассматривается использование сверточных нейронных сетей (CNN) для улучшения систем распознавания дорожных знаков именно в непогодных условиях. Также используется расширенный набор данных немецкого теста распознавания дорожных знаков (GTSRB), основанного на новой модели CNN, который содержит более пятидесяти тысяч изображений с надписями, охватывающих более сорока категорий. В модели представлены адаптивные слои выделения объектов, предназначенные для устранения проблем с видимостью, вызванных такими погодными факторами, как дождь, туман и снег. Для моделирования различных погодных сценариев применяются передовые методы увеличения объема данных, что увеличивает разнообразие обучающего набора данных. Это исследование не только рассматривает теоретические и практические усовершенствования, предоставленные CNNs для обнаружения дорожных знаков в неблагоприятных условиях, но и проверяет эффективность модели с помощью таких показателей, как точность, отзывчивость и показатель F1. Результаты подтверждают эффективность модели в минимизации ложных срабатываний и точной идентификации дорожных знаков. В статье подчеркивается важность тщательной подготовки набора данных, оптимизации моделей и усовершенствования обучения для повышения производительности системы обнаружения. Это положительно сказывается на интеллектуальных транспортных системах, автономном вождении и безопасности дорожного движения, что свидетельствует о будущем прогрессе в области надежных технологий распознавания дорожных знаков.

Ключевые слова: CNN, распознавание дорожных знаков, искусственный интеллект, анализ изображений, классификация.

Мақаланың редакцияға түскен күні: 13.05.2024