

Közüti, dinamikus parkolásellenőrzés mesterséges intelligencia támogatásával

AI-powered dynamic on-street parking control

NÁDAS Martin¹, HORVÁTH Viktor¹, Dr. SZÁNTÓ Mátyás¹

¹the urban institute Magyarország, 1111 Budapest, Egry József utca 18. V.1. ép. C. lház., (+36 1) 463-3419,
[keresztnev.vezeteknev]@urban-software-institute.hu

Abstract

Traditional parking enforcement methods are becoming increasingly ineffective in large cities due to growing traffic and congestion. CheckEye is a fully autonomous, vehicle-mounted device that leverages advanced sensors and artificial intelligence to detect, recognize, and localize license plates in real time, even at speeds of up to 50 km/h. The system's performance was evaluated on a custom dataset collected in urban environments, consisting of images from more than 3,000 parked vehicles, and was compared against a widely used baseline method. Under constrained computational resources, we found that CheckEye achieved higher accuracy while maintaining nearly deterministic inference times.

Keywords: Urban Parking, Automated License Plate Recognition, Optical Character Recognition, Mobile Parking Control

Kivonat

A hagyományos parkolásellenőrzési módszerek a nagyvárosok növekvő forgalma és zsúfoltsága mellett egyre kevésbé hatékonyak. A CheckEye egy teljesen önálló, járműre szerelhető eszköz, amely fejlett szenzorjaira támaszkodva mesterséges intelligencia segítségével képes a rendszámok detektálására, leolvasására, valamint lokalizálására valós időben, akár 50 km/h mellett is. A rendszer hatékonyságát egy általunk, városi környezetben összegyűjtött, több, mint 3000 parkoló járműről készített képből álló adatbázison teszteltük és hasonlítottuk össze egy széles körben használt módszerrel. Limitált számítási erőforrásokat feltételezve azt tapasztaltuk, hogy a CheckEye közel determinisztikus futási idő mellett is jobb pontosságot ért el.

Kulcsszavak: városi parkolás, automatizált rendszámtábla leolvasás, optikai karakterfelismerés, mobilis parkolásellenőrzés

1. BEVEZETŐ

A hagyományos, gyalogos alapú parkolásellenőrzési rendszerek egyre inkább elégtelennek bizonyulnak a nagyvárosi közlekedési környezetben. E módszerek jelentős humán erőforrást igényelnek, működtetésük költséges és időigényes, továbbá korlátozott hatékonysággal képesek biztosítani a parkolási szabályok következetes betartását. A rendszer hiányosságai bevételekieséshez vezetnek az üzemeltetőknek és városoknak, miközben torzul a parkolóhelyek igazságos elosztása és csökken a közlekedés hatékonysága.

Ebben a publikációban egy dinamikus, közúti parkolásellenőrzési megközelítést mutatunk be, amely mesterséges intelligencia támogatásával képes automatizálni a folyamatot. Rendszerünk járműre szerelt kamerák segítségével, közúti haladás közben azonosítja a parkoló járműveket, valós időben felismeri a rendszámokat, és képes az adatokat továbbítani.

A rendszer megvalósítása során jelentős technikai kihívást jelent a jármű dinamikus mozgásából adódó vibráció jelensége, az emiatt és egyéb környezeti hatások miatt jelentkező elmosódott képkockák, különböző fényviszonyok és időjárás hatásai. A hardverelemek kiválasztásánál fontos volt figyelembe venni a neurális hálók jelentős számítási igényét, emellett szükséges garantálni a rendszer stabil működését képfeldolgozási

szempontból komoly kihívást jelentő környezetben is. Emellett fokozott elvárás egy ilyen rendszernél a neurális hálók magas pontossága mellett a valós idejű futásidőt biztosítása is.

A következő fejezetekben áttekintjük a témához kapcsolódó nemzetközi irodalmat, bemutatjuk a probléma megoldására fejlesztett CheckEye rendszerünk felépítését és algoritmusait, majd kísérleti eredményekkel szemléltetjük a megoldás gyakorlati alkalmazhatóságát.

2. IRODALMI ÁTTEKINTÉS

Az automatikus rendszámfelismerő rendszerek (Automatic Number Plate Recognition – ANPR) hardveres és szoftveres komponenseinek kiválasztása összefüggő feladatok, hiszen a választott algoritmikus megközelítés jelentősen meghatározza a szükséges számítási kapacitást és szenzorokat, illetve vice-versa. Az alábbiakban az áttekinthetőség érdekében először a hardveres megoldásokat, majd a szoftveres architektúrákat ismertetjük röviden.

2.1. Hardveres megoldások mobilis ANPR rendszerekben

A mobilis parkolásellenőrzési rendszerek hardveres megvalósításában két domináns irányzat azonosítható. Az első kategóriát a mobil eszközökre épülő megoldások alkotják, amelyek tipikusan okostelefonon vagy PDA-n futtatott rendszámfelismerő algoritmusokra támaszkodnak; ilyen például a Carmen® Mobile ANPR/ALPR App [1], amely valós idejű felismerést kínál hordozható eszközökön. Előnyük a kedvező beruházási költség és a rugalmasság, ugyanakkor a gyenge hardveres erőforrások és a változó környezeti viszonyok jelentős korlátokat szabnak. Gyakran felhőalapú feldolgozásra van szükség, ami növeli a késleltetést és függővé teszi a rendszert a hálózati kapcsolattól, míg lokális futtatás esetén a neurális hálók egyszerűsítése a felismerés pontosságának rovására mehet.

A második megközelítést a nagy teljesítményű, fedélzeti rendszerek képviselik. Ezekben jellemzően több, tetőre szerelt kamera és infravörös szenzor működik együtt, amelyeket erőteljes számítógépes egység egészít ki. Ilyen például a ScanCar „ScanAuto” rendszere [2], amely nagy sebesség, és eltérő fényviszonyok mellett is képes rendszámok valós idejű felismerésére, vagy az Arvo ScanGenius [3] tetőre szerelhető egysége, amely több kamerát, GPS-t és panorámaképet integrál egyetlen modulban. E konfigurációk előnye a magas pontosság és robusztusság, hátrányuk viszont a jelentős beruházási költség, amely korlátozza széles körű elterjedésüket.

A CheckEye rendszerünk e két irányzat közé pozicionálható: célunk egy olyan hardverarchitektúra kialakítása volt, amely egyesíti a költséghatékonyságot a megbízható működéssel.

2.2. Szoftveres megközelítések ANPR rendszerekben

Az ANPR rendszerek szoftveres oldalán három fő feldolgozási lépés különíthető el: a rendszámtábla detektálása, a karakterek szegmentálása, majd azok felismerése. Mindhárom szakaszban számos algoritmikus megoldás született az elmúlt évtizedekben, amelyek eltérő környezeti feltételek és hardveres adottságok mellett különböző teljesítményt nyújtanak [4].

A rendszámtábla detektálására korábban jellemzően él- és színdetektálásra épülő módszereket alkalmaztak (pl. Sobel-szűrők és Canny-algoritmus, szíkontraszt alapú szegmentálás). Ezek egyszerűen implementálhatók, de érzékenyek a gyenge fényviszonyokra, szennyezett vagy ferde táblákra [5]. Később megjelentek a textúra- és jellemzőalapú módszerek, mint a HOG (Histogram of Oriented Gradients) vagy a Gabor filter [6], amelyek jobb robusztusságot kínálnak, ugyanakkor nagyobb számítási igénnyel járnak.

A karakterek szegmentálása hagyományosan képtranszformációs és morfológiai eljárásokkal történt, amelyek jól működnek szabványos rendszámformátumok esetén, de sérült, piszkos vagy nem standard táblák esetén gyakran hibás eredményt adnak. Az utóbbi években megjelentek a mély neurális hálókra épülő megközelítések, amelyek a detektálást és a szegmentálást egy folyamat során oldják meg. A YOLO (You Only Look Once) [7] és más konvolúciós neurális hálók (Convolutional Neural Network – CNN) alkalmazásával valós idejű feldolgozás érhető el nagy pontosság mellett.

A karakterfelismerés szintén több fejlődési szakaszon ment keresztül. A kezdeti template matching és egyszerű OCR (Optical Character Recognition) technikák mellett ma már elterjedtek a gépi tanuláson alapuló módszerek: SVM (Support Vector Machines) [8], rejtett Markov-modellek (HMM) [9], valamint a CNN alapú architektúrák. Utóbbiak különösen nagy előnyt jelentenek változatos betűtípusok, zajos képek és mozgás közben rögzített táblák esetén, bár jelentős adatigényt és számítási kapacitást igényelnek.

Összességében az irodalom alapján megfigyelhető trend, hogy a hagyományos képfeldolgozó eljárásokat egyre inkább kiszorítják a mélytanulás-alapú, end-to-end rendszerek, amelyek a detektálás és felismerés teljes folyamatát egy közös neurális hálóban integrálják. Ezek közé tartozik a FastPlateOCR is, amely konvolúciós tokenizálást és kompakt transzformer modulokat ötvöz, így erőforrás-hatékony, valós idejű működést biztosít magas pontosság mellett [10]. A szakirodalomban gyakran használják viszonyítási alapként különböző ANPR-megoldások hatékonyságának összehasonlítására – jelen munkánkban mi is a FastPlateOCR-rel vetjük össze a CheckEye rendszerünk sikerességét.

3. CHECKEYE BEMUTATÁSA

A valósidejű rendszámdetektálás és -felismerés dinamikus közlekedési környezetben különösen nehéz feladatnak tekinthető, ahol a változó fényviszonyok, időjárási hatások és a járműmozgás egyaránt kihívást jelentenek. Ennek leküzdéséhez elengedhetetlen a fejlett szenzorok, megbízható hardverkomponensek, valamint az optimálisan megválasztott, robusztus mesterséges intelligencia-alapú algoritmusok integrálása. A CheckEye rendszer mindezt egy kompakt, járműre szerelhető platformon valósítja meg, amely teljes mértékben önálló működésre képes.

Mivel a rendszer egy kereskedelmi forgalomba kerülő szolgáltatás alapját képezi, részletesebb műszaki ismertetésre jelen cikkben nincs módunk, ezért az alábbiakban a főbb architektúráis elemeket és azok funkcióit emeljük ki, illetve röviden ismertetjük az algoritmus koncepcióját és kitérünk a rendszer jelenlegi képességeire.

3.2. Hardverarchitektúra

A CheckEye rendszer központi feldolgozóegysége egy NVIDIA Jetson Orin Nano [11], amelyet kifejezetten gépi látási és mesterségesintelligencia-feladatokra fejlesztettek. Ez a kompakt és energiatakarékos beágyazott számítástechnikai platform akár 40 TOPS (Tera Operations per Second) számítási teljesítményre képes és 8 GB egyesített memóriával (RAM és VRAM) rendelkezik, így lehetővé teszi komplex neurális hálók valós idejű futtatását erőforrás-korlátozott környezetben is. Ennek köszönhetően a rendszámdetektálás és az optikai karakterfelismerés (OCR) teljes mértékben helyben, külső, adott esetben felhőalapú szolgáltatások igénybevétele nélkül valósítható meg. A nagy számítási kapacitás és az energiatakarékos ARM-alapú architektúra révén az Orin Nano ideális választás mobilis, beágyazott környezetben történő telepítésekhez.

A rendszámok kamerához viszonyított térbeli pozíciójának meghatározását egy mélységkamera biztosítja, amely akár tíz méteres távolságig képes megbízható mélységinformációt szolgáltatni. A kamera RGB és mélységadatainak szinkronizálása lehetővé teszi a rendszám táblák térbeli lokalizációját, amely kulcsfontosságú a rendszer által nyújtott relatív és abszolút pozíciódetektáló funkciókhoz.

A rendszámdetektálás képforrását egy speciális lencsével ellátott kamera biztosítja, amely kimagasló teljesítményt nyújt gyenge fényviszonyok mellett is – ezzel lehetővé téve a rövid záridővel készített képek előállítását, ami nélkülözhetetlen a dinamikus környezetből adódó elmosódások minimalizálásához. A kamera nagy fényérzékenysége, alacsony zajszintje és széles dinamikatartománya révén a YOLO objektumdetektáló algoritmus éjszakai és rossz megvilágítású környezetben is megbízhatóan képes a rendszámok azonosítására.

A rendszer geolokációs pontosságát egy többfrekvenciás GNSS modul biztosítja, amely több műholdrendszer jeleit is képes venni – ez fokozott helymeghatározási pontosságot eredményez. Az integrált gyorsulásmérő lehetővé teszi a dead reckoning funkció implementációját, így a pozíció meghatározása városi kanyonokban vagy akár rövid ideig műholdjel nélküli környezetben is minimális hibaszinten tartható. Ennek köszönhetően a detektált rendszámok mindig pontos földrajzi koordinátához rendelhetők.

Az eszköz részét képezi egy 650 nm hullámhosszú infravörös reflektor is, amely kulcsszerepet játszik a rendszám detektálásában és lokalizálásában. A rendszám táblák anyagának és bevonatának sajátosságai miatt az infravörös tartományban visszavert fény javítja a karakterek kontrasztját, ezáltal növeli az olvashatóságot, valamint hozzájárul a rendszám pontosabb térbeli pozíciómeghatározásához.


3.3. Rendszámfelismerő algoritmus

A CheckEye rendszer algoritmus a folyamatosan futó, rövid iterációkból álló feldolgozási ciklusra épül, amely minden egyes lépésben beolvassa és feldolgozza a különböző szenzorok által szolgáltatott adatokat. Az iteráció elején a rendszer begyűjti a kamera által készített színes képkockát, a mélységi információt, valamint a GPS-modul és az integrált inerciális mérőegység által szolgáltatott helymeghatározási adatokat. A rendszer egy iterációs lépését az 1. ábra szemlélteti.

A képfeldolgozás első lépéseként a YOLO, valós idejű objektumdetektáló neurális háló nagy pontossággal azonosítja a képen megjelenő járművek rendszámtábláit. A detektált objektumok közül egy utófeldolgozó logikai modul kiszűri a redundáns vagy alacsony magabiztossági szinten azonosított találatokat, ezzel növelve a felismerés robusztusságát.

A szűrést követően az algoritmus a detektált régiók kivágott képein futtatja a saját fejlesztésű karakterfelismerő (OCR) modellt, amely a rendszámtábla alfanumerikus tartalmát állítja elő. Az OCR által adott választ reprezentáló valószínűségi vektorra épülő logisztikus regresszió modell egy magabiztossági értéket rendel a kiolvasott rendszámhoz.

Ezt követően a rendszer a mélységi információt felhasználva meghatározza a rendszám relatív pozícióját, amelyet kombinál a GPS-modul abszolút helyzetével. Az eredmény a jármű pontos világkoordinátája (WGS84 rendszerben), amely alkalmas közvetlen térinformatikai felhasználásra.




1. ábra. Rendszámfelismerő algoritmus egy iterációjának folyamatábrája.

3.3. Neurális hálók és tanításuk

A rendszámok valós idejű detektálását egy YOLOv8 nano architektúrájú modell végzi. A 30 epochon keresztül futó tanításhoz 100 000 felannotált, főleg magyar rendszámokból álló adathalmazt használtunk fel, amelyet 80-20%-os arányban osztottunk fel tanító- és tesztadathalmazra. A neurális háló csökkentett komplexitásának jelentős szerepe van a dinamikus működtetés futási időre vonatkozó követelményeinek teljesítésében. A végleges YOLOv8n modell a mérsékelt számítási igény ellenére nagy megbízhatósággal detektálja a rendszámtáblákat a sikeres működtetéshez elvárt távolságokon és szögtartományokon belül változatos fényviszonyok mellett is.


A karakterek kiolvasását végző neurális háló sebességére vonatkozó megkövetések hasonlóan szigorúak. Ezek teljesítése érdekében egy saját architektúrát dolgoztunk ki a stabil, megbízható működés érdekében. A tanításhoz felhasznált adathalmaz összeállításánál különös hangsúlyt kapott, hogy a tanítás eredményeként előálló algoritmus képes legyen a dinamikus környezetből adódó változatos szögekben előforduló, illetve különböző formátumú rendszámok leolvasására. A CheckEye elsősorban Magyarországon várható alkalmazása miatt a tanítóhalmaz túlnyomó részt magyar rendszámokat tartalmaz, de előfordulnak benne más, hasonló betűtípust alkalmazó, elsősorban európai országok rendszámai is. A tanítás során tapasztalt hiba és pontosságértékeket a 2. ábra szemlélteti.



2. ábra. Az OCR modell hibájának (bal) és pontosságának (jobb) alakulása a 30 epoch hosszú tanítása során.

4. EREDMÉNYEK

A CheckEye rendszer teljesítményének objektív értékelése érdekében összehasonlítottuk saját modellünket egy elterjedt megoldással, a FastPlateOCR algoritmussal. A kísérlethez egy 3088 különböző rendszámból álló tesztadatbázist hoztunk létre, amelyet a CheckEye prototípusával rögzítettünk valós közúti környezetben Budapest VII., VIII., IX. és XI. kerületében. A tesztadatbázisban található detekciók térbeli eloszlását a 3. ábra szemlélteti. A referenciaadatok előállításakor a képek annotációját félautomata eljárással végeztük, amely során egy neurális háló előzetes javaslatait manuálisan validáltuk és pontosítottuk.



3. ábra. A CheckEye prototípusával regisztrált rendszámok elhelyezkedése.

Az összehasonlítás során a feladat szempontjából legfontosabb teljesítménymutatókat vizsgáltuk, többek között a rendszámolvasás (predikció) futási idejét és a karakterfelismerés megbízhatóságát. Az 1. táblázatban bemutatott kísérleti eredmények rámutattak arra, hogy a CheckEye által alkalmazott, erőforrás-korlátozott környezetre optimalizált architektúra képes a valós idejű működés biztosítására, miközben pontosságban is versenyképes marad a referenciamegoldással.

1. táblázat. A saját modell és a FastPlateOCR teljesítményének összehasonlítása.

Modell	Pontosság	Predikció átlagos ideje [ms]	Predikciós idő szórása [ms]
Saját OCR	97,47%	10	0,7
FastPlateOCR	96,21%	10	2,5

A saját modell a budapesti közúti környezetben készített 3088 rendszámból álló adathalmazon 97,47%-os pontosságot, míg a FastPlateOCR európai országok rendszámaira specializált modellje 96,21%-os pontosságot ért el. A predikciók átlagos ideje mindkét modell esetén 10 ms volt, azonban a saját modell a predikciós idők szórását tekintve jóval kiegyensúlyozottabb működést mutatott: míg a saját modellünk futási idejének szórása 0,7ms, addig ez a FastPlateOCR rendszer esetén több, mint 2ms. Ez különösen fontos egy valós idejű, időkritikus alkalmazás esetében, ahol a stabil és kiszámítható működés alapvető feltétele a megbízható rendszámfelismerésnek és lokalizációnak.

5. ÖSSZEFOGLALÓ

A fenti publikációban bemutattuk a CheckEye-t, egy kompakt, járműre szerelhető ANPR-rendszert, amely képes valós időben leolvasni és georeferálni a parkoló járművek rendszámait dinamikus közúti haladás közben. A munkánkban három fő fejlesztésünket mutattuk be:

1. Egy hordozható, fedélzeti hardverarchitektúrát, amely költséghatékonyság mellett képes megfelelő erőforrásokat és stabilitást biztosítani;
2. Egy lokálisan, valós időben futtatható képfeldolgozó algoritmusláncot, amely alacsony erőforrásigénye mellett kiemelkedően magas pontosságot képes biztosítani;
3. És az ezek köré épülő informatikai keretrendszert, amely biztosítja az adatok kezelését, egymáshoz rendelését és azok továbbítását.

A rendszer gyakorlati alkalmazhatóságát bemutatva, valós közúti mérés során készítettünk egy több, mint háromezer rendszámból álló tesztadatbázist. Ezen az adathalmazon összevetettük a CheckEye modelljét egy elterjedt, nyílt forráskódú, modern modellel. Az eredmények azt mutatják, hogy valós idejű, erőforrás-korlátozott környezet ellenére a rendszer pontosságban is versenyképes marad, a nagyobb számításigényű és kevésbé determinisztikus futásidővel rendelkező modellel szemben.

A CheckEye bevezetése egy terület parkolászemeltetési folyamataiba több szinten is mérhető előnyöket kínál. Az automatizált, valós idejű parkolásellenőrzés növeli a szabálytalanságok feltárásának hatékonyságát, ezzel közvetve hozzájárul a forgalombiztonság és a közterületi rend javításához. A rendszer emellett pontos és naprakész adatokat biztosít a parkolóhelyek kihasználtságáról, ami megalapozza a döntéshozatalt a tarifarendszerek, a parkolási zónák és az ellenőrzési útvonalak optimalizálásában. Mindez hosszú távon nemcsak a bevételek növekedését és a költségek csökkentését eredményezi, hanem élhetőbb, rendezettebb városi környezet kialakításához is hozzájárul.

KÖSZÖNETNYILVÁNÍTÁS

A kutatás az 2021-1.1.4-GYORSÍTÓSAV-2022-00033 azonosítójú, Checkeye – Komplex műszaki rendszer a városi parkolási szabályok betartásának költséghatékony ellenőrzésére megnevezésű projekt keretében valósult meg.

Dr. Szántó Mátyás a kutatás egy részét az Irányítástechnika és Informatika Tanszék, Villamosmérnöki és Informatikai Kar, Budapesti Műszaki és Gazdaságtudományi Egyetem munkatársaként valósította meg.

IRODALMI HIVATKOZÁSOK

- [1] ***, Carmen® Mobile ANPR/ALPR App, Adaptive Recognition, <https://adaptiverecognition.com/products/carmen-mobile/> (Utolsó letöltés: 2025.09.16.)
- [2] ***, Experts in digital parking enforcement, ScanCar <https://www.scanacar.com/> (Utolsó letöltés: 2025.09.16.)
- [3] ***, Scan Genius, arvoo, <https://arvoo.com/products/scangenius/> (Utolsó letöltés: 2025.09.16.)
- [4] Lubna; Mufti, N.; Shah, S.A.A. Automatic Number Plate Recognition: A Detailed Survey of Relevant Algorithms. *Sensors* 2021, 21, 3028. <https://doi.org/10.3390/s21093028> (Utolsó letöltés: 2025.09.16.)
- [5] I. S. Ahmad, B. Boufama, P. Habashi, W. Anderson and T. Elamsy, "Automatic license plate recognition: A comparative study," 2015 IEEE International Symposium on Signal Processing and Information Technology (ISSPIT), Abu Dhabi, United Arab Emirates, 2015, pp. 635-640, doi: 10.1109/ISSPIT.2015.7394415.
- [6] S. S. Teoh and T. Bräunl, "Performance evaluation of HOG and Gabor features for vision-based vehicle detection," 2015 IEEE International Conference on Control System, Computing and Engineering (ICCSCE), Penang, Malaysia, 2015, pp. 66-71, doi: 10.1109/ICCSCE.2015.7482159.
- [7] R. Laroca et al., "A Robust Real-Time Automatic License Plate Recognition Based on the YOLO Detector," 2018 International Joint Conference on Neural Networks (IJCNN), Rio de Janeiro, Brazil, 2018, pp. 1-10, doi: 10.1109/IJCNN.2018.8489629.
- [8] M. S. Al-Shemarry and Y. Li, "Developing Learning-Based Preprocessing Methods for Detecting Complicated Vehicle Licence Plates," in *IEEE Access*, vol. 8, pp. 170951-170966, 2020, doi: 10.1109/ACCESS.2020.3024625
- [9] O. Bulan, V. Kozitsky, P. Ramesh and M. Shreve, "Segmentation- and Annotation-Free License Plate Recognition With Deep Localization and Failure Identification," in *IEEE Transactions on Intelligent Transportation Systems*, vol. 18, no. 9, pp. 2351-2363, Sept. 2017, doi: 10.1109/TITS.2016.2639020
- [10] A. Hassani, S. Walton, N. Shah, A. Abuduweili, J. Li, H. Shi, "Escaping the Big Data Paradigm with Compact Transformers", arXiv:2104.05704, <https://doi.org/10.48550/arXiv.2104.05704>
- [11] ***, Jetson Orin Nano Super Developer Kit, NVIDIA, <https://www.nvidia.com/en-eu/autonomous-machines/embedded-systems/jetson-orin/nano-super-developer-kit/> (Utolsó elérés: 2025.09.19)