




Tudományos cikk

Automata forgalmi statisztika objektumdetektálás és adaptív járműtrajektória klaszterezés alapján

Beküldve: 2023.06.20.
Elfogadva: 2023.09.26.
Online közzétéve: 2023.12.18.

-  **AGG ÁRON DÁVID** PhD hallgató, Széchenyi István Egyetem, GIVK - MMTDI, aggaaron@gmail.com
-  **PÉTER BENCE GÁBOR** BSc hallgató, Széchenyi István Egyetem, GIVK, peter.bence2000@gmail.com
-  **DR. HORVÁTH ANDRÁS** egyetemi docens, minőségügyi rektorhelyettes, Széchenyi István Egyetem, GIVK - Fizika és Kémia tanszék, horvatha@sze.hu

Kivonat: Az Intelligens Közlekedési Rendszerek (ITS) dinamikusan fejlődő és széles körben kutatott terület manapság. Nagyon szerteágazó tudományterület, amelynek fontos része a forgalmi dinamikaelemzés, forgalomszámlálás és a forgalmi előrejelzések. Ebben a cikkben egy adaptív forgalmi statisztikageneráló eljárást mutatunk be. A módszer álló megfigyelő szemszögéből készült videófelveteleken YOLOv7 objektumdetektorral detektálja a közlekedő járműveket és azonosítja azok kategóriáját. A videórészleteken elvégzett detektálásokat az általunk bemutatott módszer DeepSort követő algoritmus segítségével kapcsolja össze, aminek eredményeként előállnak az elhaladó járművek menetvonalai. Az útvonalak csoportokba sorolását OPTICS csoportképző (klaszterező, angolul clustering) eljárással végezzük el, aminek paraméterezésével szabályozzuk a létrejövő statisztika részletességét, ezáltal lehetővé válik akár utcafinomságú vagy sávszintű forgalmi adatok generálása ugyanabból a felvételtől. Jelen cikkünkben négy különböző helyszínen készült felvételen teszteltük az eljárásunkat, aminek eredményeként nemcsak az egyes irányok tetszőleges felbontású forgalmi statisztikáit állíthatjuk elő, hanem azok időszakok szerinti és útirány szerinti normalizáltjait is. A normalizált statisztikai adatok megmutatják a forgalom szempontjából frekvenciált időszakokat és útvonalakat. A cikk végén gyakorlati hasznosíthatóságra irányuló példákon keresztül mutatjuk be a módszer teljesítőképességét.

Kulcsszavak: járműdetektálás, járműkövetés, forgalmi statisztika, gépi látás, gépi tanulás

Automatic traffic statistics generation based on object detection and adaptive vehicle trajectory clustering

Abstract: Intelligent Transport Systems (ITS) is a dynamically growing and widely researched field today. It is a very diversified field of science, with traffic dynamics analysis, traffic counts and traffic prediction being an important part of it. In this paper, an adaptive traffic statistics generation method is presented. The method uses a YOLOv7 object detector to detect vehicles on the road and identify their category on video images from the viewpoint of a stationary observer. The detections performed on the video sequences are combined by our presented method using DeepSort tracking algorithm, which results in the trajectories of the moving vehicles. The trajectories are clustered using the OPTICS clustering method, which is parameterised to control the level of detail of the resulting statistics, allowing the generation of either street-level or lane-level traffic data from the same record. In this paper, we tested our method on videos recorded in four different locations, resulting in not only traffic statistics with arbitrary resolution for each direction, but also normalized traffic statistics by time period and by direction. The normalised statistics show the periods and routes that are most frequent for traffic. At the end of the paper, we demonstrate the performance of the method through examples of practical use.

Keywords: vehicle detection, vehicle tracking, traffic flow statistics, computer vision, machine learning

Bevezetés

A közúthálózat tervezése egy összetett folyamat, amelynek részét képezi új utak tervezése, meglévő utak fejlesztése és a közlekedési infrastruktúra optimalizálása. A tervezés során számos szempontt figyelembe kell venni, beleértve a forgalom mennyiségét és jellegét, a terület topográfiáját, a települések közötti kapcsolatokat, a környezeti tényezőket és a pénzügyi korlátokat. A közúthálózatok tervezésének alapvető fontosságú lépése egyebek mellett az adatgyűjtés és a forgalmi elemzés. Adatgyűjtés során a vizsgált területről aktuálisan elérhető információt rögzítjük strukturált formában, amely adatok vonatkozhatnak például a települések elhelyezkedésére, a meglévő úthálózatra, a közlekedési vagy a forgalmi adatokra. Emellett a forgalmi adatok elemzése segít megérteni a meglévő forgalom jellegét és mennyiségét, az utak terheltségét az adott területen, így lehetővé téve a forgalom számára optimális útvonalak és útkapcsolatok meghatározását. A közlekedési adatgyűjtés magában foglalhatja a közúti forgalom mérését, például forgalomfigyelő kamerák, forgalomérzékelők vagy kézi forgalomellenőrzések segítségével. Az adatok között szerepelhet a forgalom intenzitása, sebessége, járműtípusok eloszlása stb.

A közlekedési és utazási szokások megismerésére gyakran használnak kérdőíveket és felméréseket. Ezek az adatok segíthetnek az utazási igények és preferenciák, a célállomások és az útvonalak meghatározásában. Az összegyűjtött közlekedési adatok, például közlekedési statisztikák, közúti baleseti jelentések és városi fejlesztési tervek elemzése segíthetnek a tervezési döntések meghozatalában és a meglévő problémák feltárásában.

A forgalmi elemzés során gyakran használnak speciális szoftvereket és modellező eszközöket a szakemberek, amelyek segítségével előrejelzéseket lehet készíteni a forgalomra vonatkozóan, optimalizálni lehet a forgalmi terhelést vagy értékelni lehet az útvonaltervezési döntéseket, mindezt automatizáltan.

A forgalmi statisztika készítésének eltérő céljai lehetnek. A vizsgálat irányulhat a forgalom intenzitásának mérésére. Ez az adat azt mutatja, hogy az adott útszakaszon vagy kereszteződésben mekkora mennyiségű jármű halad át egy adott időegység alatt. Másik megközelítés alapján vizsgálhatjuk az elhaladó járművek sebességét. Összegyűjthetjük a területen érzékelhető torlódási adatokat is, ami azt mutatja meg, hogy az útszakaszon vagy kereszteződésben milyen mértékű torlódás vagy dugó alakult ki. A torlódási adatok vonatkozhatnak a torlódás időtartamára, hosszára vagy az útszakaszon várható késésre. Távolabbról vizsgálva a problémát, egyes eljárások a forgalmi statisztika időbeli mintázatát próbálják modellezni, hogy a forgalom csúcsidejait, a szezonális változásokat vagy épp a hétköznapok és a hétvégék közötti különbséget kimutassák. Végül, de nem utolsósorban, egy kutatás alapját képezhetik a baleseti adatok is. Azok súlyossága, gyakorisága a közlekedésbiztonság számára jelentenek kiemelkedően fontos információkat.

Általánosságban elmondható, hogy a forgalmi elemzések eredményei segítenek az új útvonalak tervezésében, a meglévő utak fejlesztésében, a forgalom irányításában és a közlekedési rendszer optimalizálásában. Ezáltal hozzájárulnak a hatékonyabb és fenntarthatóbb közlekedési infrastruktúra kialakításához.

A forgalomszámlálás és forgalmi statisztikakészítés gyakran alkalmazott eszközei a forgalomérzékelők, ezek olyan eszközök, amelyek a járművek mozgását érzékelik és rögzítik. Ilyen eszközök például a hurokérzékelők, amelyek az útburkolatba építve a fölöttük elhaladó járművet érzékelik elektromágneses úton. Forgalomszámlálás történhet manuálisan, kézi megfigyeléssel is. Ebben az esetben forgalomellenőrök vagy kutatók kézzel számolják össze a járműveket egy adott helyszínen és időszakban. Általában közlekedési csomópontokban, útkereszteződésekben alkalmazzák ezt a módszert. A forgalomfigyelő kamerák és a hozzájuk kapcsolódó felügyeleti rendszerek képek vagy videók feldolgozásával képesek a járművek mozgását érzékelni, ami alapján meghatározható a járművek száma, sebessége, típusa, és egyéb forgalmi jellemzők. A forgalmi adatgyűjtő rendszerek automatizálásával és hálózatba kötésével komplex forgalomfelügyeleti rendszereket hozhatunk létre. Ez alapulhat a kamerás rendszereken, GPS alapú adatgyűjtésen vagy akár mobilhálózati cellainformációk összesítésén. Az a közös mindegyik esetben, hogy a nyers adatok feldolgozását végző szoftveres algoritmus képes az adatok szűrésére, rendezésére és elemzésére.


Jelen cikk célja is egy forgalomelemzést és ezen belül a forgalmi adatgyűjtést és statisztikakészítést támogató szoftveres eljárás ismertetése. A kutatás kezdetén azt a kiinduló hipotézist állítottuk fel, hogy gépi látás segítségével és gépi tanuló módszereket alkalmazva létrehozható egy olyan eljárás, amely képes kiváltani a manuális forgalomszámlálást úgy, hogy megfelelő részletességgel hozza létre tetszőleges közúti csomópont forgalmi statisztikáját. Ezen belül megvizsgáltuk, hogy az automatikus eljárások tetszőleges csomóponti geometria esetén helyesen azonosítják-e a tipikus közlekedési útvonalakat. Megvizsgáltuk továbbá, hogy a közlekedők útvonalainak csoportosítása során alkalmazott módszerek paramétereinek állításával, az emberi gondolkodásnak megfelelő, különböző finomságú (utca vagy sávszintű) csoportosítások hozhatók létre. A módszer közlekedési csomópontokról készült

kamerák képén képes felismerni a közlekedő járműveket, azok pozícióját és mozgási irányát. A videófelvételeken összekapcsolja a detektált járműveket, ezzel létrehozva azok menetvonal-jadatait. Az eljárás a vizsgált időszakban egy helyszínen készült felvételeken felismert összes elhaladó jármű pályájának összegyűjtését követően előre beállított finomsággal csoportosítja az adatokat, és statisztikai alapon vizuálisan megjeleníti az eredményeket.

A cikk második részében a kutatáshoz kapcsolódó releváns szakirodalmakat tekintjük át, valamint a vizsgálatokhoz használt adatbázist is bemutatjuk. Ezt követően részletesen ismertetjük módszerünket, és annak gyakorlati alkalmazhatóságát. Az utolsó fejezetben összegezzük az általunk létrehozott eljárás képességeit és az elért eredményeket.

Irodalmi áttekintés

A gépi látás alapú forgalomszámlálás alapját a kamerák képén elvégzett járművek detektálása adja. A járművek mozgásának elemzéséhez és ezáltal a forgalmi statisztika létrehozásához a videó egymást követő képkockáin a detektált objektumokat szükséges összepárosítani, ezt nevezzük objektumkövetésnek. A követett járműveket az általunk készített módszer automatikusan csoportokba sorolja csoportképző (klaszterező, angolul clustering) eljárás segítségével, majd összegzi az egyes csoportokba sorolt járműpályák számát. Az eljárás működését bemutató blokkdiagram az 1. ábrán látható.



1. ábra Adaptív forgalomszámláló rendszer működése

Forrás: saját szerkesztés

Módszerünket a „Bellevue” videó adathalmazon teszteltük és a későbbiekben bemutatott eredmények ennek az adathalmaznak a forgalmi statisztikáit tartalmazzák. A Bellevue Traffic Video Dataset 1280x720 pixel felbontással, másodpercenként 30 képkockasebességgel rögzített videókat tartalmaz. Öt különböző helyszínről, összesen 101 órnyi felvétel áll rendelkezésre. A kutatáshoz 4 helyszín felvételeit használtuk fel, amelyek mindegyikéről 22 vagy 23 órnyi felvétel áll rendelkezésre. Rendszerint egy nap forgalmát rögzítették az adathalmazba 1 órás felosztással. A felvételek 2017 szeptemberben kerültek rögzítésre, későbbi felhasználásra, + gépi tanuló eljárások fejlesztéséhez és közlekedéstudományi kutatásokhoz. A felvételeket közlekedési csomópontok környezetében telepített kamerákról rögzítették (City of Bellevue, 2017). Az négy kiválasztott helyszínt ábrázoló képek láthatók a 2. ábrán. Minden helyszín hasonló kamerapozícióból és látószögéből megfigyelt csomópont. A csomópontok azonosítására, azok neveit és rövidítéseit használjuk jelen cikkünkben, amelyek a 2. ábrán is jelölve vannak: Bellevue Bellevue NE8th, Bellevue 150th Eastgate, Bellevue 150th Newport, Bellevue 150th SE38th.




2. ábra Mintaképek a vizsgált négy kereszteződésből

Forrás: (City of Bellevue, 2017)

Objektumdetektálás

Ahogy a bevezetőben is említettük, módszerünk objektumdetektálást alkalmaz a kamerafelvételeken látható járművek detektálására. A detektálás történhet klasszikus képfeldolgozási módszerekkel, például háttérleválasztás (Picardi, 2004), valamilyen vizuális jellemző alapján történő felismeréssel, például: HOG (Navneet et al., 2005), Gabor (Jain et al., 1997), Haar-like (Leinhart et al., 2002), SURF (Bay, 2006), vagy optical flow alapú eljárásokkal (Sepehr et al., 2013). A másik, manapság leggyakrabban alkalmazott eljárás a neurális hálózatokkal történő objektumdetektálás. Az általunk létrehozott módszer ez utóbbit alkalmazza.

Járműdetektálásra alkalmazható objektumdetektáló eljárások az általános célú objektumdetektorok továbbfejlesztésével vagy azok specifikus újratanításával érhető el. Az általános célú neurális hálózatok között a konvolúciós neurális hálózatokat alkalmazzák a leggyakrabban erre a célra (LeCun et al., 2015). Ezek közül néhány gyakran alkalmazott eljárás: Region-based CNN [RCNN] (Girshick et al., 2016), Fast-RCNN (Girshick, 2015), Single Shot Detector [SSD] (Wei et al., 2016), Residual networks [ResNet] (Xie et al., 2017), és a You Only Look Once [YOLO] (Redmon et al., 2018). Munkánkban a YOLO objektumdetektor hetedik verzióját a YOLOv7 (Wang et al., 2023) objektumdetektort alkalmazzuk. A detektálási pontossága minimálisan alacsonyabb, mint az SDD vagy a Faster-RCNN detektoroké, ez látható a 3. ábrán, azonban a YOLO objektumdetektorral valós idejű működés érhető el, ami a többi módszerről nem mondható el. Az ismertetett eljárás gyakorlati alkalmazásához és további kutatásokhoz nélkülözhetetlen, hogy a detektálást valós időben tudjuk futtatni megfelelő sebességgel. Összehasonlításként a YOLO akár 150 FPS-el képes elfogadható pontosságú detektálásra, míg a többi detektor ennél jóval alacsonyabb, 8 FPS mellett tudja ugyanezt a teljesítményt elérni (Farhadi et al., 2018).



3. ábra Objektumdetektáló eljárások pontosságának összehasonlítása

Forrás: Farhadi et al., 2018

Objektumkövetés

A képfeldolgozás alapú forgalomszámláló eljárások alkalmazása során az objektumkövetés az egymást követő képkockákon történt detektálás összekapcsolását jelenti. Egy jármű megjelenésétől az eltűnéséig történő követésének eredményét az adott jármű pályájának, útvonalának vagy menetvonalának nevezzük.

A követés szintén megvalósítható a járművet ábrázoló képrészlet vizuális jellemzővektorainak (HOG, Haar-like, SURF, SIFT) és ezek egymáshoz viszonyított „távolságának” meghatározásával (L1, L2 distance). Több objektumkövető eljárás épít a Kálmán-szűrő (Kalman, 1960) alkalmazására, amely során az objektum mozgásának lineáris előrejelzése alapján párosítja össze a várt és a valós pozíciókat (Li et al., 2010). Az egyik state-of-the-art módszer, amely szintén Kálmán-szűrő alapú objektumkövető eljárás, a Simple Online and Realtime Tracking [SORT] (Bewley et al., 2016). A SORT képről képre alkalmazza a Kálmán-szűrőt, valamint a magyar módszert, hogy az egyes befoglaló téglalapok közötti átfedést nagy pontossággal és valós időben kiszámítsa. A SORT-t eljárás jól működik közlekedési környezetben járművek követésére, mivel az általunk vizsgált álló megfigyelő szemszögéből készült felvételeken a járművek irányváltási lehetőségei korlátozottak. Zajosabb környezetben, gyalogosokat vizsgálva már megfigyelhetők az eljárás hibái, amelyeknek a javítására született meg a DeepSORT, amely képi információ neurális hálózat által történő feldolgozását párosította a SORT algoritmushoz, ezzel 45%-kal javítva az eredeti eljárás követési pontosságán (Wojke et al., 2017).

Menetvonalak csoportosítása

A forgalmi statisztika generálásához a kameraképen összegyűjtött adatokat szükséges strukturálni. A forgalomszámlálást jelen tanulmányban bemutatott módszer útvonalakra bontott időszakos összegzésből állítja elő. Ehhez az útvonalakra bontást szoftveresen elvégezhetjük valamilyen szabályrendszer manuális felállításával vagy automatikusan csoportképző (klaszterező, angolul clustering) eljárás implementálásával. A csoportképző algoritmusok egy nem címkézett adathalmazból, azaz ismert bemeneti értékkel és ismeretlen kimeneti értékkel rendelkező adathalmazból dolgoznak. Céljuk az adathalmazban megtalálható szabályszerűségek, kapcsolatok, esetleg függőségek feltérképezése és az adathalmaz elemeinek csoportokba sorolása ezen feltételek alapján. A kutatás során több csoportképző eljárást kipróbáltunk, többek között particionáló vagy felosztó módszerek közül előre ismert csoportszám esetén alkalmazható:

- a K-közép eljárás (Hartigan et al., 1979),
- a zajjal terhelt sűrűség-alapú térbeli klaszterezés (DBSCAN - Density-based spatial clustering of applications with noise) (Khan et al., 2014),
- a klaszterstruktúra azonosítása rendezési pontok segítségével (OPTICS - Ordering Points To Identify Cluster Structure) (Ankerst et al., 1999) vagy
- a kiegyensúlyozott iteratív redukció és klaszterezés függelmi viszonyok feltérképezésével (BIRCH - Balanced Iterative Reducing and Clustering using Hierarchies) (Zhang et al., 1996) felosztó eljárások.

A K-közép csoportképző algoritmus úgy osztja fel az adatokat, hogy n darab azonos varianciájú csoportba próbálja meg besorolni őket, minimalizálva az inerciát vagy a csoporton belüli adatpontok közötti távolság négyzetösszegét. Ez az eljárás megköveteli a csoportok számának megadását, azonban jól skálázható nagy számú minta esetén. A zajjal terhelt sűrűség-alapú térbeli klaszterezés a csoportokat úgy tekinti, mintha azok nagy sűrűségű területek lennének, amelyeket alacsony sűrűségű területek határolnak. Ennek az általános megközelítésnek az eredménye, hogy ennél az eljárásnál a csoportok alakja tetszőleges formájú lehet, ellenben a K-közép felosztó eljárással, ahol csak konvex alakú csoportok megengedettek. A klaszterstruktúra azonosítása rendezési pontok segítségével algoritmus, a zajjal terhelt sűrűség-alapú térbeli klaszterezési eljárás általánosításának tekinthető. A paraméterezése hasonló. A legfőbb különbség a két eljárás között, hogy a csoportokon belüli pontok távolságát meghatározó paraméter a klaszterstruktúra azonosítása rendezési pontok segítségével algoritmus esetén, nem egy diszkrét érték, hanem egy tartomány. A kiegyensúlyozott iteratív redukció és klaszterezés függelmi viszonyok feltérképezésével felosztó eljárás az adatok alapján egy fát épít, amelyet csoportosító jellemző fának (Clustering Feature Tree-nek, CFT) nevezünk. Az algoritmus egy tömörítő eljárásához hasonlítható, amelyben az adathalmazt tömöríti veszteségesen egy döntési fába. Korábbi vizsgálati eredményeink alapján a végső forgalomszámláló módszerünkben a klaszterstruktúra azonosítása rendezési pontok segítségével (OPTICS) csoportképző eljárást alkalmaztuk.

Forgalomszámlálás

A bevezetőben bemutattuk, hogyan kapcsolódik a forgalomszámlálás az intelligens közlekedési rendszerek (ITS) széles kutatási területéhez. A manuális forgalomszámlálás mellett rengeteg technológiai módszer áll rendelkezésre a forgalmi adatok gyűjtésére és statisztikai elemzésére.

A már említett útburkolatba telepített hurok a járművek fém szerkezetét képes érzékelni. Ezzel nem csak az elhaladó járművek darabszámára, hanem a forgalom áramlásának sebességére is tudunk következtetést adni (Gajda et al., 2012). További forgalomszámláláshoz alkalmazható szenzortechnológiák lehetnek még a Bluetooth vagy WiFi alapú rendszerek, GPS/GSM/GPRS alapú helymeghatározó rendszerek, a RADAR vagy LIDAR érzékelők és a képkalkító szenzor alapú eszközök csoportja, amelybe tartoznak a kamerák, infrakamerák, hőkamerák (Jain et al., 2019).

Fontos szempont a forgalomszámlálás megvalósításánál az alkalmazás helyszíne. Sok eljárás kifejezetten autópályák környezetében alkalmazható (Alqaness et al., 2021, Ren et al., 2020). Ezek esetében a feladat általában egy kijelölt virtuális vonalon áthaladó járművek számának meghatározása adott időszakra vonatkozóan. Ettől eltérő eset a forgalmi csomópontokban történő forgalomszámlálás, amely ennek a műnek is a fő célja (Zhang et al., 2020). Ebben az esetben a cél a kereszteződéseken és csomópontokon áthaladó járművek számának összesítése úgy, hogy azokat a belépési és kilépési pontok alapján kategorizálják. A statisztika csomópontok esetén is adott időszakra vonatkozóan kerül megállapításra. Korábbi kutatások az egyes irányokat manuálisan kategorizálták (Azimjonov et al., 2023), és ez alapján generálták a forgalmi statisztikai adatokat. Eljárásunkban ennek kiváltására alkalmazunk csoportképző eljárást, amely eredménye, hogy az összesített adathalmazból adaptívan határozhatók meg a csomópont belépési és kilépési pontjai a kameraképen látható jelentre vonatkozóan. A felosztó eljárás átparaméterezésével finomabb felbontás érhető el, így akár sávokra bontva vizsgálható a forgalmi statisztika. Míg az adatok között nagyobb távolságot engedve a csoportosító eljárás során egy elnagyoltabb, csak a főbb irányokra vonatkozó statisztika állítható elő ugyan abból az adathalmazból. A két beállítás között több beállítás, ezáltal útvo-nalszám is képezhető.

Módszertan

Ahogy az 1. ábrán is látható a forgalomfigyelő rendszerünk működési folyamatábrája, a módszertan bemutatása során a feldolgozási folyamat főbb lépésein fogunk végighaladni megfelelő logikai sorrendben.

Adathalmaz előkészítése


A megfelelő adathalmaz kiválasztása során fontos szempont volt, hogy a forgalomszámlálási problémát szemléletesen lehessen vizsgálni rajta. Ennek érdekében az általunk kiválasztott adathalmaz négy különböző helyszínről tartalmaz videófelvételeket. A felvételek mindegyike 22 vagy 23 órányi rögzített adattal rendelkezik, óránként darabolva. A helyszínek mindegyike az USA-ban található Washington állambeli Bellevue város közlekedési kamerarendszerről lett rögzítve. A városban több közlekedési kamera képe elérhető online közvetítésen keresztül. Mi egy előre rögzített adathalmazból használtuk az említett négy helyszín felvételeit. A videókat strukturáltan, helyszínenként külön kezeltük mind a tárolás, mind pedig a későbbi feldolgozás során. A videók előkészítésének feladata volt az egyes helyszínekhez tartozó videók megfelelő sorrendben történő betöltése, amely biztosítja a videók rögzítési idejében történő feldolgozást. A videók feldolgozását és a rendszer további moduljait is Python nyelven írtuk és a hozzá kapcsolódó modulokat használtuk: OpenCV, Numpy, Matplotlib, Pandas.

Objektumdetektálás

A forgalomszámlálás alapját az objektumdetektálás képezi. Az objektumdetektálás során a detektor bemene-tére egy képet adunk, ami jelen esetben a videófelvétel egy adott időpillanatban készült képkockája. Az objek-tumdetektor az előzetesen betanított objektumtípusokat felismeri a képen és meghatározza, hogy a képnek mely területén jelenik meg az objektum. A detektált objektumokat tartalmazó képrészlet leírására az objektumdetektor kimeneti értéke az aktuális képen érzékelt minden objektumra vonatkozóan tartalmazza az objektum típusát, az objektum középpontjának koordinátáit vagy az objektum befoglaló téglalapjának bal felső sarokponti koordinátá-it, az objektum szélességét és magasságát pixelszámban kifejezve, valamint egy valószínűségi értéket is rendel az

objektumhoz, amely a felismerés valószínűségét írja le. Az általunk létrehozott eljárásban a YOLOv7 objektumdetektornak az MS COCO (Lin et al., 2014) adathalmazon tanított modelljét használtuk a detektálásra. Ez a modell 80 különböző típusú objektum felismerésére képes. A közlekedők mellett például közúti jelzőtáblákat, tűzcsapokat és állatokat is detektálni tud. Mi a detektálások közül kizárólag az autó, teherautó és busz kategóriájú detektálásokat vettük figyelembe a feldolgozás során, és ezek közül is csak azokat, amelyek felismerési valószínűsége nagyobb vagy egyenlő 60%-al. Az objektumdetektor kiválasztása során fontos szempont volt a valós idejű működés, mivel a kutatás során a járművek útvonalainak modellezését és azok előrejelzését tűztük ki végső célul és mindezt szeretnénk a kamerák elő képén futtatva alkalmazni. A state-of-the-art objektumdetektorok közül a YOLO általános célú objektumdetektort választottuk, mivel pontossága és futási sebessége kielégíti az általunk támasztott követelményeket. A 3. ábrán látható összehasonlító táblázat is alátámasztja a YOLO alkalmasságát a feladatra. Kezdetben a YOLO 4-es verzióját használtuk, amely C programozási nyelven került implementálásra. A pontossága ennek a modellnek kielégítő volt, időközben bemutatásra került a YOLOv7, amely már Python alapokon működő eljárás és sebességben, valamint pontosságban is felülmúlja a YOLOv4-t. Ezek alapján a végső módszerünkben a YOLOv7 objektumdetektort alkalmazzuk.

Az detektálás kimeneti értékeit átstrukturáltuk, és további adatokkal egészítettük ki. Minden detektálási értékhez, azaz minden felismert objektumhoz, hozzárendeltük a videó azonosítóját, valamint a képkocka sorszámát, amelyen látható. A detektálás eredményét szemlélteti az 5. ábra. A képen zöld színű kereteztük be az autókat, lila színű a buszokat és rózsaszínnel a teherautókat. A keret fölé kiírtuk a jármű típusát, egyedi futósorszám alapú azonosítóját, a felismerés valószínűségét, valamint a jármű X és Y irányú sebességét pixel/szekundumban kifejezve.



4. ábra Objektumdetektálás eredménye

Forrás: saját szerkesztés

Objektumkövetés


A detektálást az egyes videóban rögzített képkockák mindegyikén lefuttattuk időrendi sorrendben. Minden detektálási lépést közvetlenül egy objektumkövetési lépés követ és ez ciklikusan ismétlődik, amíg a videó utolsó képkockáján is el nem végeztük. A detektor kimenete az objektumkövető modul bemenetére kerül. Az objektumkövető algoritmus első lépésben beállítja a kezdőértékeket. A kezdőértékek beállítása során minden detektált objektumhoz kiszámítja a követéshez szükséges változók értékét, amelyek a képen elfoglalt pozíció és a mozgási sebesség. A DeepSORT ezt követően előrejelzést készít arra vonatkozóan, hogy a detektált objektum várhatóan hol fog elhelyezkedni a képen. Az előrejelzést Kálmán-szűrő segítségével valósítja meg. A következő képkockán elvégzett detektálást követően az algoritmus frissíti a követéseket, a valós detektálások és az előrejelzések közötti távolság alapján összepárosítja az előző és az új képen detektált objektumokat. A párosítás optimális végrehajtásához a magyar módszert használja a DeepSort. Paraméterezhető határérték alapján dönti el, hogy az előrejelzett befoglaló téglalap és az új detektálás befoglaló téglalapja megfelelő mértékben átfedésben vannak-e. Amennyiben igen, úgy az előző detektáláshoz hozzárendeli az új detektálás adatait. A DeepSort az összepárosítás során még

egy jellemzővektort is készít az objektumot ábrázoló képrészletről. Ezt az előző és az új képen is végrehajtja, majd ezeknek a különbségét kiszámítva megerősíti a detektálás pontosságát. Enélkül a funkció nélkül a SORT algoritmus hajlamos az objektumazonosítók felcserélésére.

Az objektumkövető algoritmus kimenetén minden ciklusban az összepárosított objektumok, esetünkben a detektált járművek jelennek meg. Ahhoz, hogy ezt az információt hasznosítani tudjuk, további feldolgozás szükséges. Az adatokat adatstruktúrába szerveztük annak érdekében, hogy a további fejlesztés és adatfeldolgozás minél gördülékenyebb legyen. Létrehoztunk egy TrackedObject (követett objektum) nevű osztályt, amely nem csak a detektálási adatok tárolására, hanem a követés során létrejövő adatsorok kezelésére is alkalmas. Az osztály automatikusan képes kiszámítani az adott objektum X és Y irányú sebességét és gyorsulását pixel/sec, illetve pixel/sec² mértékegységekben. Az adatstruktúra külön tárolja az objektum középponti koordinátáinak X és Y komponenseit, a képkockák azonosítóit, amelyeken az objektum korábban megjelent, az objektum típusát jelző címkéket és azt is, hogy milyen régóta követjük az objektumot. Az osztályba beépítve megtalálható egy normalizáló és egy skálázó függvény is, amelyek a különböző felbontású videók esetén alkalmasak a pixelértékben kifejezett számértékek konvertálására, valamint újra felskálázására. A skálázás szükségessége a videók eltérő felbontására vezethető vissza. A későbbiekben látni fogjuk, hogy a koordináta értékekből jellemzővektorokat hozunk létre például a csoportképzéshez is. A gépi tanuló eljárások nagy része érzékeny a paraméterek értéke közötti nagyságrendi különbségre, aminek eredményeként előfordulhat, hogy a bemeneti vektor egyes értékeire érzéketlenebb lesz a végső modell. Ahhoz, hogy a jármű pozícióját leíró, a kép síkjában lévő vízszintes és függőleges koordináták közötti különbség gátló hatásától megszabaduljunk, a koordináta értékek átskálázására kerülnek 0-1 közötti intervallumra úgy, hogy a vízszintes koordináták értékeit elosztjuk a kép szélességével, a függőleges koordináta értéket pedig a kép magasságával pixelben kifejezve.

Az objektumkövetés ciklikus végrehajtásának eredményeként létrejönnek a járművek menetvonalai. Ezek a menetvonalak változó hosszúságúak attól függően, hogy milyen sokáig voltak a felvételen láthatók. A menetvonalak vizualizálhatók például úgy, hogy kirajzoljuk azokat a középponti koordinátákat, amelyekben előzetesen tartózkodott a jármű, erre mutat példát a 6. ábra. Az ábrán a videóból kivágott képkocka színeinek élénkségét csökkentettük, hogy a kirajzolt útvonal kellően kontrasztosan jelenjen meg. Jól látható, hogy a detektálások általában nem tökéletesen követik le az objektumot, ennek oka, hogy a kirajzolt menetvonalra zaj ül. Jelen tanulmányban ennek a szűrésétől és figyelembevételétől eltekintünk.

A követésnek még egy fontos paramétere van, amely az adott objektum archiválására vonatkozik. Ez a paraméter és a hozzá kapcsolódó archiválási mechanizmus lehetővé teszi, hogy a hibásan vagy egyáltalán nem detektált objektumokat a detektálási hiány után újra követhessük, és ne veszítsük el. Túl nagy értéket adva ennek a paraméternek előfordulhat, hogy egy, a képről kilépő jármű esetén összekapcsolja azt egy másik, néhány képkocka különbséggel, hasonló pozícióban megjelenő járművel. Ezt az értéket empirikus úton 10-re állítottuk be. Fontos még megemlíteni, hogy az optimális paraméterbeállítások ellenére is előfordulhatnak hibák mind a detektálás, mind pedig a követés során. Az általunk vizsgált 4 helyszínen a hibás esetek száma az összes esethez viszonyítva 4-6% között mozgott. Ezeket az eseteket egyszerű szabály alapú szűréssel leválasztottuk az adathalmazról.




5. ábra Járómenetvonal

Forrás: saját szerkesztés

A menetvonalak egyes elemei tartalmazzák azt az információt, hogy a jármű melyik időpillanatban (videó képkocka azonosító), milyen pozícióban (jármű középpontjának X és Y koordinátái) és mekkora kiterjedésben (járművet befoglaló téglalap W szélessége és H magassága) volt jelen a képen.

Csoportképzés

Forgalmi statisztika generáló eljárásunk során a csoportosító eljárás (klaszterezés, angolul clustering) alkalmazásának célja, hogy adaptívan, a vizsgált helyszínre szabva, minimális emberi beavatkozással az előzőekben létrehozott útvonalakat csoportosítsa. A megfelelő csoportképző eljárás kiválasztásához több módszert is kipróbáltunk. Kutatásunk során elvégeztük a csoportképzést egy minta adathalmazon, amely mind a négy helyszínről két órányi videórészletet tartalmaz. A csoportképzést automatikus paraméterbeállításokkal futtattuk le a DBSCAN, az OPTICS, a BIRCH és a K-közép felosztó eljárásokkal. Az előzetes teszt eredményeként az OPTICS csoportképző eljárást választottuk ki a rendszerünkbe történő integrálásra, mivel ez generálta a legkevesebb hibásan csoportosított menetvonalat. Az OPTICS (Ordering Points To Identify the Clustering Structure) a csoportosítani kívánt adatokban először olyan helyeket keres, ahol az adatok nagy sűrűséggel találhatók meg, majd ebből kiindulva építi ki a csoportokat. Mivel a járművek menetvonalai változó hosszúságúak, ezért a csoportosítás végrehajtása előtt szükséges az adatok rendezése, és minden menetvonalból egy jellemző vektor létrehozása. A forgalmi statisztika szempontjából a hasznos információ, amire kíváncsiak vagyunk, és amit összesíteni szeretnénk, az az, hogy melyik irányból érkezett a jármű és melyik irányba haladt tovább. Ez alapján kijelenthető, hogy a vizsgálat szempontjából releváns információt a jármű menetvonalának belépési és kilépési pontjai tartalmazzák, ami alapján a felosztó eljáráshoz létrehozott jellemzővektorba a járművek pályáinak belépési és kilépési pontjaihoz tartozó X és Y koordinátáinak 0-1 intervallumra normalizált értékét rendeltük. A kezdő- és végpont alapú jellemzővektor létrehozását videónként mindegyik menetvonalra elvégeztük, majd ezeket egy adathalmazba fűztük össze, így létrejött a csoportképző eljárás bemenetére adható adattömb.




6. ábra Csoportképző eljárás eredménye alapbeállításokkal: 12 eltérő útvonal-csoport

Forrás: saját szerkesztés

Az egyes helyszínekről rendelkezésre álló videókról összegyűjtött menetvonalak mindegyikéről előállított jellemzővektorokat összesítettük, majd az OPTICS csoportképző bemenetére adtuk. A csoportképző eljárás kimenetén egy listát állít elő, aminek mérete megegyezik a bemeneti tömb sorainak számával, jelen esetben az adott helyszínen rögzített menetvonalak számával. A lista elemei a bemeneti adatok sorrendjében tartalmazzák az azokhoz tartozó csoportcímkéket. A 7. ábra a címkék menetvonalakhoz történő hozzárendelésének eredményét, az útvonalcsoportok megjelenítését ábrázolja. Az ábrán 12 darab eltérő útvonalcsoport került megjelenítésre úgy, hogy a képrészletek háttéréül az adott helyszín egyik felvételéből kivágott képkockát használtuk fel. A helyszín képének színeit kifakítottuk, hogy a kirajzolt eredmények jól érzékelhetőek legyenek. A grafikonok mindegyikén egy-egy csoporthoz tartozó menetvonalak detektálási pontjait jelenítettük meg. A menetvonalak kezdőpontjait zöld színnel jelöltük, a végpontjait piros színnel, míg a menetvonalak közbenső pontjait kék színnel. Ennél a helyszínnél első megközelítésben 12 darab eltérő mozgási útvonalcsoportot sikerült szétválasztani a csoportképzés során. Az eljárás hasonló eredményt produkált mind a négy kereszteződés esetén.

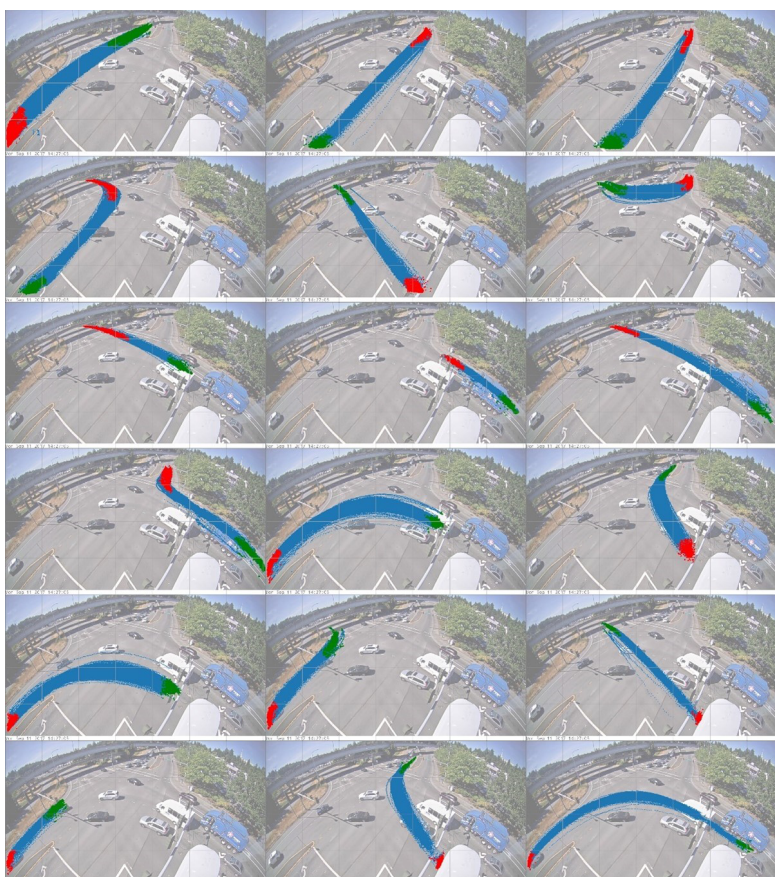
Az OPTICS csoportképző eljárás konfigurálása során több paraméter értékének beállítása lehetséges, amelyek a végeredményt befolyásolhatják, ilyen például az egy csoportba sorolt elemek minimális száma, a csoportosított elemek közötti távolság számításához használt metrika és az egy csoportba sorolt elemek közötti legnagyobb távolság értéke. Ahhoz, hogy az optimális csoportképzést elérjük vizsgálatokat végeztünk a paraméterbeállítások befolyásoló hatására vonatkozóan. A kísérlet során az OPTICS valamennyi paraméterének nagyságrendi változtatásának hatását vizsgáltuk a kimenetre, azaz a létrejött menetvonal csoportok helyességére vonatkozóan. A csoportképzés helyességét az egyes útvonal-csoportok vizuális megjelenítésével elemeztük. A kísérlet eredményeként megállapítottuk, hogy míg a távolságszámító metrika paraméterének befolyásoló hatása a mi adataink esetén elhanyagolható, addig az egy csoportba sorolt elemek minimális száma és a csoporton belüli elemek között megengedett legnagyobb távolság nagyban meghatározza a kimenet értékét. A 8. és a 9. ábrán két példával szemléltetjük a vizsgálat eredményeit. Az ábrán az előző esettől két eltérő paraméter beállítással futtatott csoportképzés eredményeit jelenítettük meg. A 8. ábra azt az esetet mutatja, amikor az egy csoportba sorolás távolságlimitjét megemeltük. Látható, hogy kevesebb csoport keletkezett, viszont az egyes csoportokba az emberi logika alapján elkülöníthető útvonalak is tartoznak, ezért ez nem bizonyult megfelelő választásnak.



7. ábra Csoportképzés eredménye: nagyobb távolságparaméter megengedésével csak hét eltérő útvonal-csoport keletkezett

Forrás: saját szerkesztés


A 9. ábrán egy szigorúbb, kisebb távolságot megengedő és a minimális elemszámhoz kisebb értéket rendelő beállítást használtunk. Jól látható, hogy az első két esethez képest több csoport keletkezett, számszerűen 18 és több, az alapbeállításokkal keletkezett útvonal-csoport tagjai itt szétváltak. Például az első sor második és harmadik képe két olyan csoportot mutat, melyek a 7. ábrán még egy csoportba voltak sorolva (lásd 7. ábra 1. sor, 2. kép), de most a finomabb felbontás sáv-szinten is elkülönítette a járműveket. A paraméterek beállítását minden esetben manuálisan végeztük el megvizsgálva az adott jelenet bonyolultságát és a csoportképzés eredményének részletességét. A célunk a csoportképzés paramétereinek vizsgálatával a forgalmi statisztika generáló eljárás adaptivitásának biztosítása volt úgy, hogy a statisztika részletessége a felhasználói igények alapján változtatható legyen.



8. ábra Csoportképzés eredménye: finomabb beállításokkal 18 eltérő útvonal-csoport keletkezik, melyek már sáv-szintű felbontást tartalmaznak

Forrás: saját szerkesztés

Elképzelhető olyan eset, amikor egy csomópont forgalmi adataira csak korlátozott részletességgel van szükség. Ehhez példának nézzük a 10. ábrán látható csomópontot. Az ábrán egy kétsávos út (A) keresztez egy másik, szintén kétsávos utat (B). Az A útvonalon jobbról érkező járművek a példában három irányban haladhatnak tovább: egyenesen tovább az A útvonalon, balra nagy ívbe kanyarodva a B útvonalon, illetve jobbra kis ívben kanyarodva szintén a B útvonal ellenkező irányába. A járművek a másik három irányból érkeve hasonlóan három lehetőség közül választhatnak a továbbhaladásra. Ez összesen 12 lehetséges útvonalat feltételez. Ha azonban részleteiben vizsgáljuk meg a csomópont forgalmát, akkor láthatjuk, hogy a B útvonallról érkeve jobbra csak a kanyarodósávból haladhatnak tovább az A úton, amely szükségessé teszi azt, hogy megkülönböztessük a jármű érkezési sávját is, ne csak az érkezési irányát. Ha ezt tovább bővítjük, akkor értelemszerűen a továbbhaladás is sávokra bontható, amelyből lényegesen több lehetséges útvonal különböztethető meg.



9. ábra Két alkalmazási példa a forgalmi statisztika változtatható felbontására. bal oldal: út szintű, jobb oldal: sáv-szintű felbontás

Forrás: saját szerkesztés

Vizsgálataink során megállapítottuk, hogy a csoportképzés paramétereinek optimális értékei az adathalmaz méretétől és a helyszín geometriai tulajdonságaitól függenek. Minél nagyobb az adathalmaz annál nagyobb értéket kell adni az egy csoporton elfogadott minimális elemszám értékének, ezt addig kell növelni amíg a be nem sorolt menetvonalak száma 4-6% alá nem kerül. Ezután a csoporton belüli elemek között megengedett legnagyobb távolság paraméterével lehet a csoportosítás finomságát csökkenteni vagy növelni.

Forgalmi statisztika


Az előző fejezetben a csoportképzéssel felosztottuk a videófelvételeken elhaladó járműveket és azok menetvonalait. A továbbiakban a csoportképzés eredményeiből generált forgalmi statisztikákat ismertetjük. A statisztika előállításához, valamint a további feldolgozásokhoz a csoportképzés legfinomabb felbontását alkalmaztuk. A forgalomszámolás célja az egyes csoportokba tartozó menetvonalak számának összesítése és strukturált megjelenítése. Ahhoz, hogy a létrejött adatok a későbbiekben széles körben hasznosíthatóak legyenek, a forgalmi statisztikát táblázatos formába rendeztük. Az eljárás a csoportképzést követően óránként, a videófelvételek szakaszoltságának megfelelően összegzi a csoportok elemszámait. Az első helyszínről készült eredmények láthatók a 1. táblázatban. A táblázat sorai az időszakokat tartalmazzák, amelyek egy-egy órányi időtartamot ölelnek fel, ezek jelölése található az első oszlopban. A további oszlopok rendre a csoportképzés során generált különböző irányokat jelölik. A táblázat elemei azoknak a járműveknek a darabszámát tartalmazzák, amelyek az adott órában és adott irányba elhaladtak.

1. táblázat Eastgate csomópont forgalmi adatai

Időszak	Útvonal-csoport 0	Útvonal-csoport 1	Útvonal-csoport 2	Útvonal-csoport 3	Útvonal-csoport 4	Útvonal-csoport 5	Útvonal-csoport 6	Útvonal-csoport 7	Útvonal-csoport 8	Útvonal-csoport 9	Útvonal-csoport 10	Útvonal-csoport 11
0-1	5	27	4	14	9	21	6	2	5	0	0	0
1-2	4	9	1	5	4	8	5	5	6	3	0	0
2-3	4	7	2	5	1	2	1	3	4	0	0	0
3-4	0	18	6	2	2	10	5	0	6	4	0	0
4-5	11	32	2	9	12	28	5	8	7	2	0	0
5-6	11	62	6	18	59	63	10	15	66	11	2	0
6-7	44	186	32	47	140	186	44	207	171	31	43	5
7-8	72	339	74	93	313	503	61	311	225	42	150	7
8-9	111	580	111	108	364	674	74	300	154	53	162	16
9-10	88	457	119	113	266	527	93	328	144	85	164	20
10-11	94	451	132	139	121	359	89	315	105	81	97	22
11-12	127	482	82	191	90	374	136	359	130	71	102	20
12-13	151	596	78	219	92	329	206	400	135	81	117	37
13-14	117	498	71	167	111	257	137	291	101	82	81	33
14-15	196	710	60	189	107	295	120	348	100	88	91	67
15-16	263	1072	71	282	95	384	144	347	114	121	91	74
16-17	293	1011	48	230	73	347	154	348	90	108	84	39
17-18	45	206	17	50	18	112	42	85	18	26	20	4
18-19	30	231	25	35	21	190	59	159	55	40	14	1
19-20	15	214	22	57	17	126	32	129	55	21	8	8
20-21	33	176	16	57	26	78	40	83	27	19	6	11
21-22	31	110	8	27	11	44	16	22	16	12	0	4
22-23	13	76	7	21	9	23	6	16	13	4	0	1


Forrás: Saját szerkesztés

A táblázat a nyers adatokat tartalmazza. A pontosabb megértéshez szükség volt olyan szemléltető ábra létrehozása, amelyen az egyes irányok egyértelműen beazonosíthatók. A táblázat értelmezéséhez kiegészítettük az eljárásunkat egy automatikus útvonal vizualizálóval, amely az adott helyszín felvételeiből kivág egy képkockát és az útvonalakat a kezdeti és végpontjait összekötő egyenessel jelöli, valamint az irányultságát az egyenes végén nyíllal szemlélteti. Ezeknek az egyeneseknek a kezdő és végpontjait az egyes csoportokba tartozó menetvonalakból számítottuk ki úgy, hogy egy adott csoportba tartozó összes menetvonal kezdő és végpontjának X és Y koordináta szerinti átlagát vettük és elneveztük őket útvonal-csoport szerinti átlagos belépési és kilépési pontoknak. A megkülönböztethetőség érdekében a vonalak közepén jelöltük az útírány azonosítóját is, valamint különböző színekkel jelöltük a vonalakat és számokat. A jelöléshez használt szín kiválasztásához egy hisztogramot hoztunk létre az útírányok összesített forgalmi adataival és az egyes útírányokhoz tartozó elhaladások darabszámai alapján normalizáltuk. Ezt követően egy színskálát rendeltünk a hisztogramhoz, amelyen a színek értéke a menetvonal normalizált forgalmi adatai alapján kerül kiválasztásra, így az ábráról első pillantásra eldönthető, hogy melyik útvonal mekkora arányban volt terhelt napi-összesítésben. A vizsgált négy helyszínhez az útvonalak értelmezését és a hisztogramjait a 11-14. ábrák tartalmazzák.



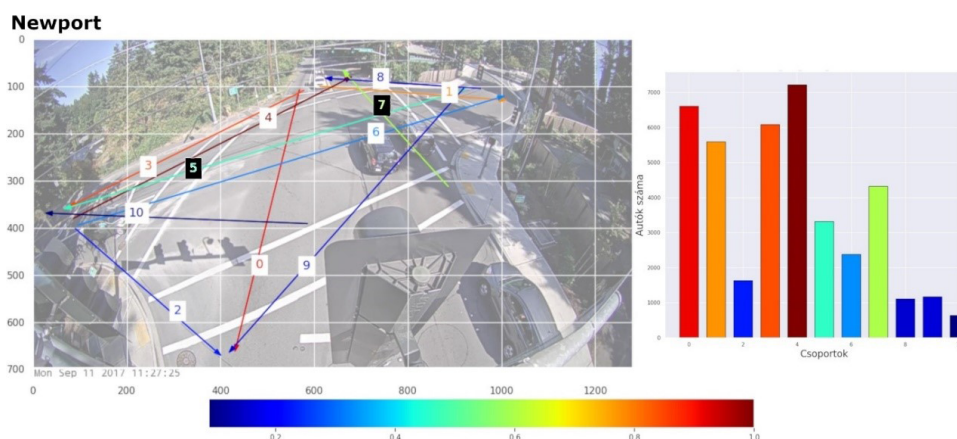
10. ábra Eastgate csomópont útvonalai és a forgalmi intenzitás hisztogramja

Forrás: saját szerkesztés



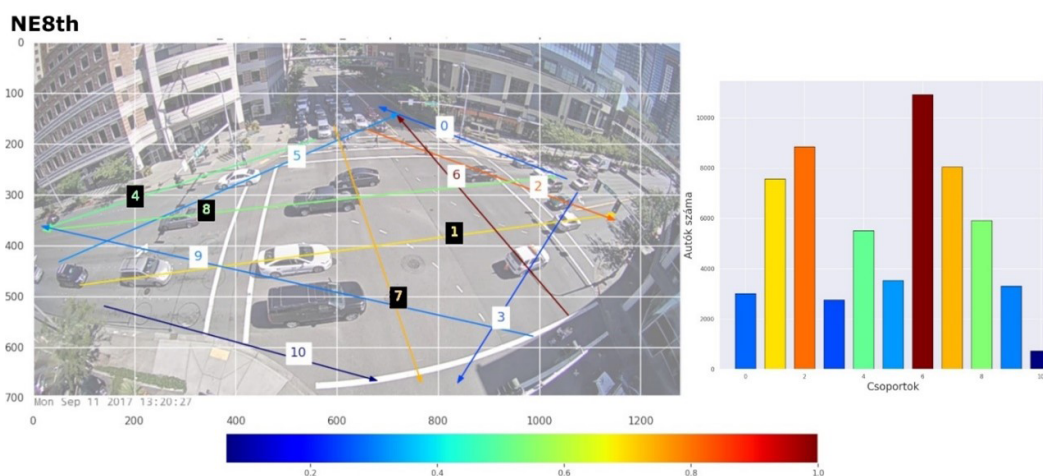
11. ábra SE38th csomópont útvonalai és a forgalmi intenzitás hisztogramja

Forrás: saját szerkesztés



12. ábra Newport csomópont útvonalai és a forgalmi intenzitás hisztogramja

Forrás: saját szerkesztés

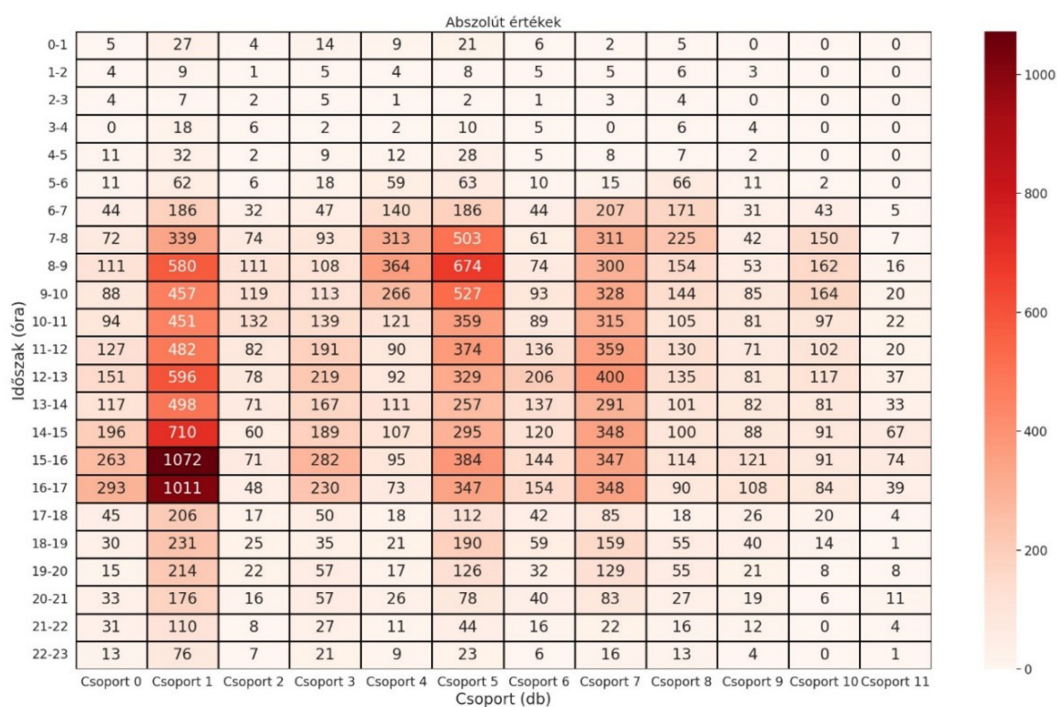


13. ábra NE8th csomópont útvonalai és a forgalmi intenzitás hisztogramja

Forrás: saját szerkesztés

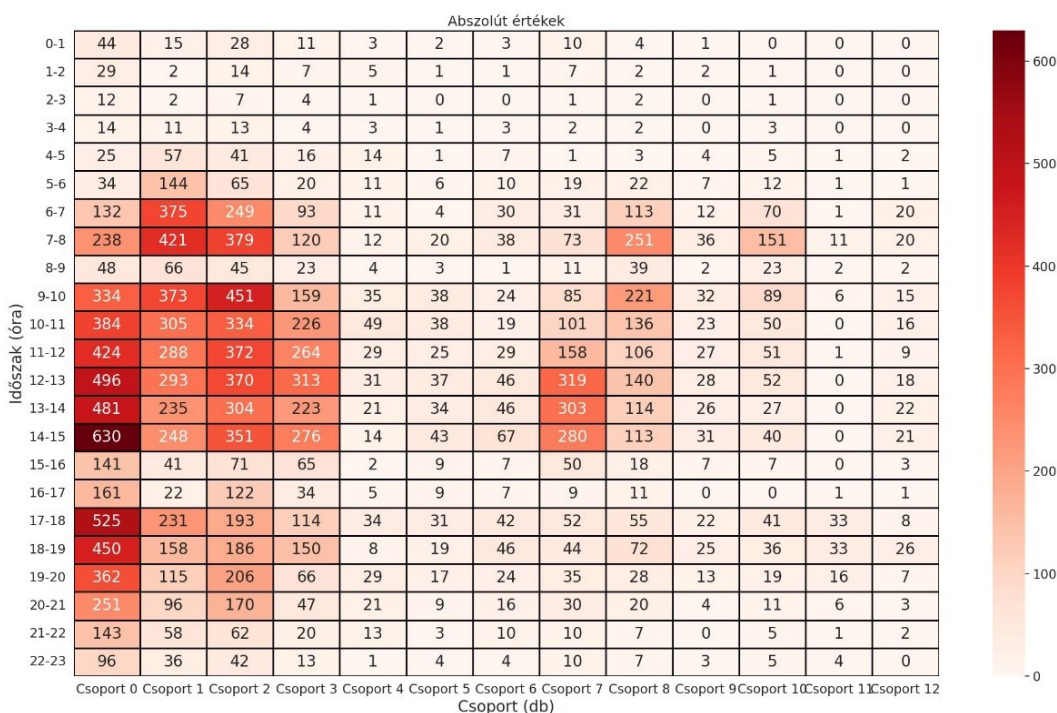
A csomópontok forgalmának további elemzéséhez automatikus hőkép generáló funkcióval egészítettük ki forgalomszámláló módszerünket. Ennek célja a forgalom dinamikájának gyors áttekintése volt. Első megközelítésben a járműelhaladás darabszáma alapján generáltuk a hőképet. Ezen a színezett táblázaton azt figyelhetjük meg, hogy globálisan melyik útvonal és melyik időszakban volt a legnagyobb mértékben terhelt a forgalom által. A 15. ábra az Eastgate csomópont globális forgalmi adatait tartalmazza. Látható, hogy a „Csoport 1” címkejű útvonal a legterheltebb, főként 14-17 óra között. (Az útvonalcsoportok elhelyezkedését a kereszteződést bemutató 11.

ábrán láthatjuk.) A 4-5. és a 7. útvonal-csoportot a reggeli és délelőtti órákban érinti sűrűbb forgalom, míg a többi irány esetén is hasonló dinamika figyelhető meg alacsonyabb maximumértékek mellett.



14. ábra Globális forgalmi „hőterkép” (Eastgate)


Forrás: saját szerkesztés



15. ábra Globális forgalmi „hőterkép” (SE38th)

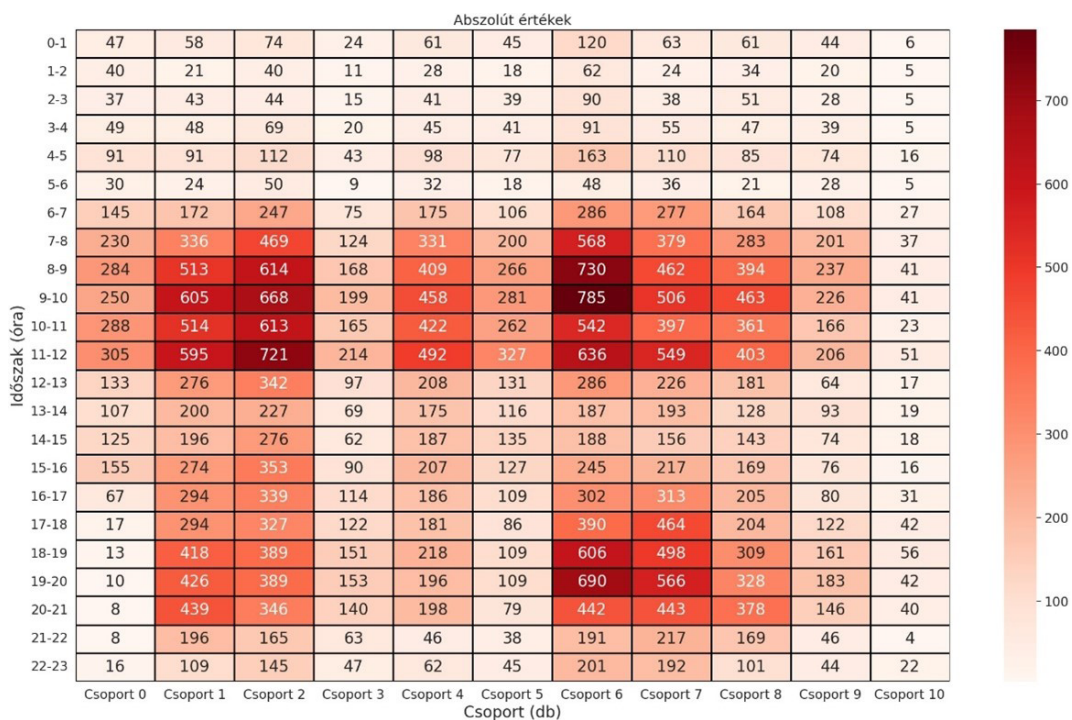
Forrás: saját szerkesztés

A második hőterképen, a 16. ábrán az SE38th csomópont eredményei láthatók. Az előző esettől teljesen eltérő viselkedést mutat, a 0-3 útvonal-csoportok fogalma a délelőtti órákban megnő és egészen estig kitar, majd fokozatosan lecseng, valamint 15-17 óra között egy kisebb visszaesés is tapasztalható.



16. ábra Globális forgalmi „hő térkép” (Newport)

Forrás: saját szerkesztés



17. ábra Globális forgalmi „hő térkép” (NE8th)

Forrás: saját szerkesztés

A Newport-i csomópont esetén, a 17. ábrán az SE38th-hoz hasonló fokozatos felfutás tapasztalható, ami 18 óra után hirtelen visszaeséssel zárul. Ennél az csomópontnál kevésbé dominál a reggel-délután pár, amikor is a reggeli órákban az egyik útvonalcsoport terheltsége jellemzően nagyobb, majd ennek az útíránynak az ellenkező irányú párja a délutáni órákban terheltebb.

Utolsó példaként az NE8th csomópontot emeljük ki a 18. ábrán, ahol a forgalmi rend az előzőektől eltérően a legtöbb irány esetén délelőtti és délutáni csúccsal is rendelkezik, valamint jóval egyenletesebb a forgalom eloszlása az irányok között.

A forgalmi hőtérképek a helyszínt ismerő közlekedésmérnököknek fontos információkkal szolgálhatnak a forgalom dinamikájának elemzéséhez. Ebben a cikkben ilyen elemzést mi nem végzünk, mert a cél a módszer használhatóságának bemutatása.

Normalizált forgalmi statisztika

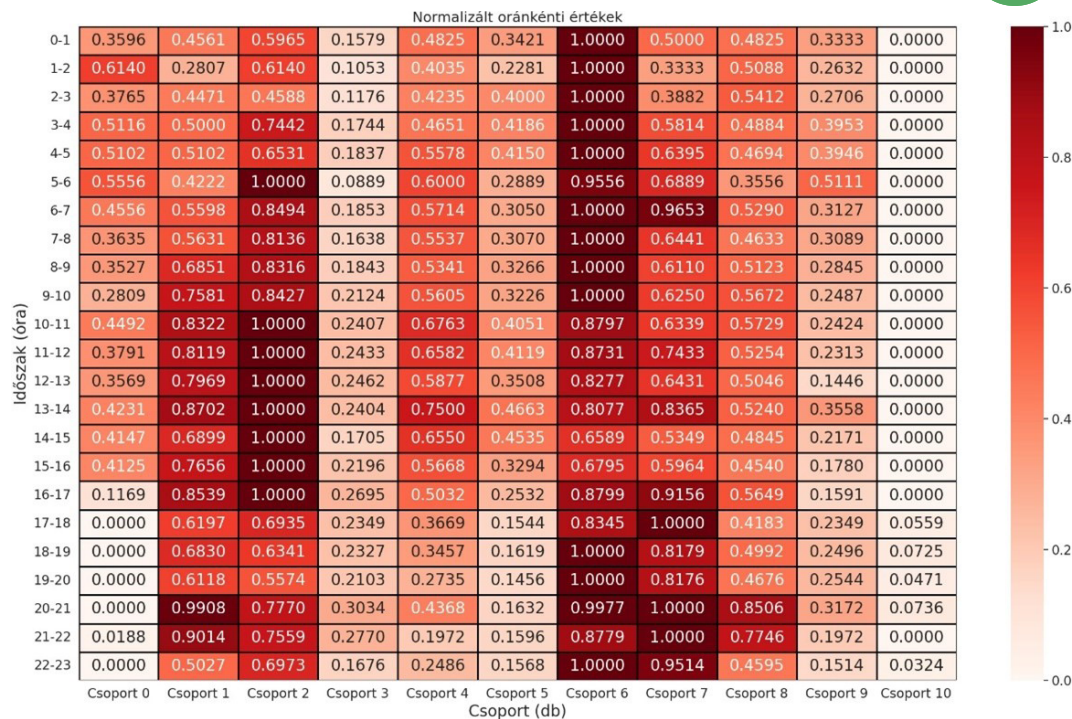
A forgalmi adatokból képzett hőtérkép rendkívül szemléletesen mutatta be a globális forgalmi csúcsok helyét és az egyéb forgalmdinamikai sajátosságokat. A mélyebb vizsgálathoz a hőtérkép speciális, normalizált változatait állítottuk elő. Először megvizsgáltuk az irányonként normalizált esetet. Ekkor minden oszlopot, azaz útirányt külön-külön normalizáltunk azért, hogy információt kapjunk arra vonatkozóan, hogy melyik időszak a legforgalmasabb az adott irányban. A 19. ábrán látható az NE8th csomópont irányonként normalizált hőtérképe. Szinte az összes útirány esetén a 8-12 óra közötti időszak erősen terheltnek bizonyult, valamint néhány esetben az esti órákban zajlott még kiemelkedően nagy forgalom.



18. ábra Irányonként normalizált forgalmi „hőtérkép” (NE8th)

Forrás: saját szerkesztés

Második esetben azt vizsgáltuk, hogy az egyes órákban mely útirányok bizonyulnak a legforgalmasabbnak. Ehhez soronként normalizáltuk a forgalmi mátrixot, aminek eredménye a 20. ábrán látható. Szintén az NE8th csomópont esetén este 18 órától kezdődően, a hajnali órákban, egészen 9 óráig a 6. útirányt találtuk a legforgalmasabbnak, míg napközben a 2. irány veszi fel a legnagyobb terhelést.



19. ábra Időszakok alapján normalizált forgalmi „hő térkép” (NE8th)

Forrás: saját szerkesztés

Eredmények összegzése

Kutatásunkban az intelligens közlekedési rendszerek (ITS) területén belül egy forgalom számláló és forgalmi statisztika generáló módszert dolgoztunk ki. Létrehoztunk egy komplex gépi látás alapú járműkövető eljárást, amely automatizáltan képes a kamera képén érzékelt közlekedőket azok mozgási pályája alapján csoportosítani. Bebizonyítottuk, hogy az OPTICS csoportképző eljárás alkalmas különböző részletességű forgalmi statisztika előállítására az általunk vizsgált adathalmazon, amellyel akár sáv-szintű forgalmi statisztika is képezhető. Módszerünkkel továbbá a forgalom szempontjából általános belépési és kilépési pontokat azonosítottunk a kamera képén látható jeleneten, amelyek az egyes csoportokba tartozó közlekedők menetvonalaiából származtatható. Kutatásunk kitért a létrehozott forgalmi statisztikák mélyebb elemzésére. A forgalmi adatokból létrehozott hő térkép alapján az egyes helyszínek vonatkozásában meghatároztuk a globális forgalmi csúcsokat, majd útirányra és időszakra bontva vontunk le következtetéseket a vizsgált adathalmazról. Kijelenthető, hogy sikeresen implementáltuk az objektumdetektáló és objektumkövető módszereket, amelyek rendkívül jó alapot adtak jelen tanulmányban ismertetett módszer létrehozásához. A korábbi forgalomszámláló eljárásoktól eltérő megközelítést alkalmazva, sikerült tetszőleges geometriájú közlekedési csomópontok forgalomszámlálására alkalmas, kamera alapú módszert létrehoznunk. Ezek alkalmazásával a már felszerelt kamerák képének alapján az igényeknek megfelelő részletességű forgalomszámlálási adatok generálhatók, akár archív adatokból, akár minimális késéssel, élőben. A létrejött módszer akár utólag is változtatható felbontása előnyt jelent a hurokérzékelőkkel szemben. Az automatizált működés a manuális forgalomszámlálás velejáráját, az emberi tényezőt kizárja a forgalmi statisztika készítés folyamatából. Valamint vizuális elemzés alapú módszerünk alkalmazása a GPS-alapú alternatívák alkalmazásával szemben pontosabb, akár sáv-szintű statisztika készítését teszi lehetővé, amely a későbbiekben könnyedén kiegészíthető a járművek típusával vagy vizuális jellemzőikkel.

Kutatásunkat a jövőben szeretnénk bővíteni a YOLO objektumdetektor által biztosított objektumkategóriákkal, amivel egy újabb forgalmi statisztikai szempontot tudunk a rendszer működésébe beépíteni és képesek leszünk részletesebb forgalmi adatokat biztosítani. Jövőbeli kutatási irány lehet, jelen munkára alapozva, a gyalogos forgalom vizsgálata is, amely nem képezte eddigi kutatásaink tárgyát.

Felhasznált irodalom

- City of Bellevue (2017): Traffic Video Dataset. <https://github.com/City-of-Bellevue/TrafficVideoDataset> (2023.április.25.)
- Picardi, Massimo (2004): Background subtraction techniques: a review, 2004 IEEE International Conference on Systems, Man and Cybernetics (IEEE Cat. No. 04CH37583) vol. 4., 3099-3104, <https://doi.org/10.1109/ICSMC.2004.1400815>
- Navneet, Dalal - Triggs, Bill (2005): Histograms of oriented gradients for human detection, 2005 IEEE computer society conference on computer vision and pattern recognition (CVPR'05), vol. 1., 886-893. <https://dx.doi.org/10.1109/CVPR.2005.177>
- Jain, Anil K. - Ratha, Nalini K. - Lakshmanan, Sridhar (1997): Object detection using gabor filters, Pattern Recognition, 30:2, 295-309, [https://doi.org/10.1016/S0031-3203\(96\)00068-4](https://doi.org/10.1016/S0031-3203(96)00068-4)
- Lienhart, Reiner - Maydt, J.: An extended set of Haar-like features for rapid object detection, Proceedings. International Conference on Image Processing, 2002. szeptember 22-25., Rochester, <https://doi.org/10.1109/ICIP.2002.1038171>
- Bay, Herbert - Tuytelaars, Tinne - Van Gool, Luc: SURF: Speeded up robust features, 9th European Conference on Computer Vision (ECCV 2006), 2006. május 5-13., Graz, 404-417. o., https://doi.org/10.1007/11744023_32
- Sepehr, Aslani - Mahdavi-Nasab, Homayoun (2013): Optical flow based moving object detection and tracking for traffic surveillance, International Journal of Electrical, Computer, Energetic, Electronic and Communication Engineering, 7:9, 1252-1256.
- LeCun, Yann - Bengio, Yoshua - Hinton, Geoffrey (2015): Deep learning, Nature 521, 436-444., <https://doi.org/10.1038/nature14539>
- Girshik, Ross et al. (2016): Region-Based Convolutional Networks for Accurate Object Detection and Segmentation, IEEE Transactions on Pattern Analysis and Machine Intelligence, 38:1, 142-158., <https://doi.org/10.1109/TPAMI.2015.2437384>
- Girshick, Ross (2015): Fast R-CNN, IEEE International Conference on Computer Vision (ICCV), 1440-1448, <https://dx.doi.org/10.1109/ICCV.2015.169>
- Liu, Wei, et al.: Ssd: Single shot multibox detector, Computer Vision-ECCV 2016: 14th European Conference, 2016. október 11-14., Amsterdam, 1:14, 21-37. o. https://dx.doi.org/10.1007/978-3-319-46448-0_2
- Xie, Saining, et al.: Aggregated residual transformations for deep neural networks, IEEE conference on computer vision and pattern recognition, 2017. július 21-26., Honolulu, 1492-1500. o. <https://dx.doi.org/10.1109/CVPR.2017.634>
- Redmon, Joseph - Farhadi, Ali (2018): Yolov3: An incremental improvement, arXiv (elektronikus kiadvány), <https://arxiv.org/abs/1804.02767> (2023.06.20.)
- Wang, Chien-Yao - Bochkovskiy, Alexey - Liao, Hong-Yuan Mark: YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors, Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023. június 18-22. Vancouver, 7464-7475. o. https://openaccess.thecvf.com/content/CVPR2023/html/Wang_YOLOv7_Trainable_Bag-of-Freebies_Sets_New_State-of-the-Art_for_Real-Time_Object_Detectors_CVPR_2023_paper.html (2023. június 20.)
- Kalman Rudolph Emil (1960): A new approach to linear filtering and prediction problems, Journal of Fluids Engineering, Transactions of the ASME, 82:1, 35-45. <https://dx.doi.org/10.1115/1.3662552>
- Li, Xin - Wang, Kejun - Wang, Wei - Li, Yang: A multiple object tracking method using Kalman filter, The 2010 IEEE International Conference on Information and Automation, 2010. június 20-23., Harbin, 1862-1866 o. <https://dx.doi.org/10.1109/CINFA.2010.5512258>
- Bewley, Alex et al.: Simple online and realtime tracking, 2016 IEEE international conference on image processing (ICIP), 2016. szeptember 25-28, Phoenix, 3464-3468 o. <https://dx.doi.org/10.1109/ICIP.2016.7533003>
- Wojke, Nicolai - Bewley, Alex - Paulus, Dietrich: Simple online and realtime tracking with a deep association metric, 2017 IEEE international conference on image processing (ICIP), 2017. szeptember, 17-20., Beijing, <https://doi.org/10.1109/ICIP.2017.8296962>
- Hartigan, J. A. - Wong, M. A. (1979). Algorithm AS 136: A K-Means Clustering Algorithm, Journal of the Royal Statistical Society, Series C (Applied Statistics), 28:1, 100-108. <https://doi.org/10.2307/2346830>
- Khan, Kamran et al.: DBSCAN: Past, present and future, The Fifth International Conference on the Applications of Digital Information and Web Technologies (ICADIWT 2014), 2014. február 17-19., Bangalore, <https://doi.org/10.1109/ICADIWT.2014.6814687>
- Ankerst, Mihael et al. (1999): OPTICS: Ordering points to identify the clustering structure, ACM Sigmod record, 28:2, 49-60. <https://doi.org/10.1145/304181.304187>
- Zhang, Tian - Ramakrishnan, Raghu - Livny, Miron (1996): BIRCH: an efficient data clustering method for very large databases, ACM sigmod record, 25:2, 103-114. <https://doi.org/10.1145/235968.233324>
- Gajda, Janusz et al. (2012): A vehicle classification based on inductive loop detectors, Transportation Research Part C: Emerging Technologies, 21:1, 57-66., <https://doi.org/10.1016/j.trc.2011.08.010>
- Jain, Neeraj Kumar - Saini, R. K. - Mittal, Preeti (2019). A review on traffic monitoring system techniques, Soft Computing: Theories and Applications, 569-577., <https://doi.org/10.1016/j.trc.2011.08.010>
- Azimjonov, Jahongir - Özmen, Aahmet - Varan, Metin (2023): A vision-based real-time traffic flow monitoring system for road intersections, Multimedia tools and applications, 1-20. <https://doi.org/10.1007/s11042-023-14418-w>
- Ren, Peiming et al. (2020): A novel squeeze YOLO-based real-time people counting approach, International Journal of Bio-Inspired Computation, 16:2, 94-101., <https://doi.org/10.1504/IJBIC.2020.109674>
- Zhang, Chuan et al. (2020): Verifiable and privacy-preserving traffic flow statistics for advanced traffic management systems, IEEE Transactions on Vehicular Technology, 69:9, 10336-10347. <https://doi.org/10.1109/TVT.2020.3005363>
- Lin, Tsung-Yi (2014): Microsoft COCO: Common objects in context, 13th European Conference, 2014. szeptember 6-12., Zurich, 740-755 o. https://doi.org/10.1007/978-3-319-10602-1_48
- Al-qaness, Mohamed et al. (2021): An improved YOLO-based road traffic monitoring system, Computing, 103, 211-230., <https://doi.org/10.1007/s00607-020-00869-8>