

Közlekedési szabálytalanságok¹

Max Gyula

Budapest Műszaki és Gazdaságtudományi Egyetem,
Automatizálási és Alkalmazott Informatikai Tanszék
1521 Budapest, Pf. 91, e-mail: max@aut.bme.hu

Abstract: Közlekedési események megfigyelésekor nemcsak a vizsgált objektumok mozgása lehet fontos tényező, hanem más mozgó objektumra gyakorolt hatása is. Bár a közúti közlekedés egy magányos szereplője is követhet el közlekedési szabálytalanságot, a szabálytalanságok nagyobbik részénél egynél több szereplő vesz részt az eseményben. A közlekedési események real-time képfeldolgozás során a hagyományos objektum szintű azonosítás mellett egyre fontosabb szerepet kell kapnia az eseményben résztvevő szereplők cselekedeteinek azonosítása. A valós idejű forgalom megfigyelő rendszerek egyik legfontosabb feladata a beavatkozás lenne, amire ezek a rendszerek még nem készültek fel. Az automatikus helyzetfelismerés ma még sok időt igényelő, bonyolult rendszert követelő feladat. A cikk az automatikus helyzetfelismerés néhány alapesetének bemutatásán keresztül igyekszik illusztrálni a feladat bonyolultságát.

1. BEVEZETÉS

Nagyforgalmú utak mentén ma már több helyen látható forgalom megfigyelő rendszer. Ma még ezek a rendszerek többnyire „kézzel”, humán megfigyelők segítségével ellenőrzik a közlekedést. Egyértelmű, hogy a közlekedési események szemmel történő ellenőrzése nagy figyelmet, és speciális megfigyelő eszközöket igényel. Mégis mindig van esély arra, hogy sürgős beavatkozást igénylő események színhelye észrevétlen marad. A balesetek automatikus észlelése nagyban hozzájárulhatna a megfelelő beavatkozások megindításához. A baleset színhelyének automatikus vizsgálata a balesetek felderítése mellett elemezhetővé is tehetné ezeket az eseményeket. De nem csak a közúti közlekedésben van szükség az események pontos követésére, mert pl. azt senki sem szeretné, ha egy több ezer m/s sebességgel mozgó űrobjektum dokkolásánál a manőverben résztvevők tartós alakítani változást szenvednének. Az ipar is egyre nagyobb figyelmet fordít arra, hogy az emberi vizuális érzékelés és értékelés képességei megjelenjenek gépjárművek biztonsági projektjeiben. A járművek közötti távolság mérése előfeltétele egy biztonságos vezetéstámogató rendszer kialakításának. A cikkben azt a gondolatmenetet követjük végig, amelyben megpróbáljuk szétválasztani a súlyos közlekedési szabálytalanságot takaró események forgalmi jellemzőit a normálisnak mondhatótól. A munka alapját a rendellenességek kimutatása jelenti, amely mellett az

esemény súlyosságát is jellemezzük. Ez a jellemző segít minket abban, hogy például egy baleset során, ha szükséges a generált riasztás minél gyorsabban eljuttassa a mentőket a baleset helyszínéhez.

A cikkben második fejezetében általános áttekintést adunk a forgalom megfigyelő rendszerek (Traffic Observation System, TOS) felépítéséről, egyes részeinek feladatairól. A részek funkcionális bemutatása során bemutatjuk az egyes rétegek feladatait, illetve az egyes rétegek közötti kommunikációs feladatokat is. Ugyancsak ebben a fejezetben mutatjuk be az automatikus esemény felismerés alapjait. A tanulási, az értékelési és az osztályozási szakasz feladatainak megadásával igyekszünk egyszerű fogalmak segítségével megadni ezeknek a rétegeknek a feladatait.

A harmadik fejezetben az előző fejezetben ismertetett rendszerek működéséhez szükséges feladatot megadása következik, amely magában foglalja a kamerák által szolgáltatott adatok előfeldolgozását, a mozgó objektumok mozgásainak felderítését, azonosítását és nyomon követését valamint magát a célfeladatot, a rendellenességek felismerését. Agyunkban egy pont két irányból történő érzékelése alapján alakul ki a látott kép (Hartley et al., 2000). Megfigyelő rendszereinkben a pozíció meghatározás folyamatában a gépi látás során a folyamat kezdeti lépéseit tekinthetjük egy sztereó fényképezőgép által készített képek sorozatának. A sztereó fényképezőgép eredetileg a két külön objektíven keletkezett képet vetíti a negatívokra. Ez teszi lehetővé, hogy a kamera szimulálja az emberi binokuláris látást, és ezzel megadja azt a képességet, hogy háromdimenziós térben láthassuk az eredményt. Legtöbb esetben azonban a többkamerás közúti megfigyelő rendszerekben nem a háromdimenziós kép kialakítása a cél,

¹ This work is connected to the scientific program of the "Development of quality-oriented and harmonized R+D+I strategy and functional model at BME" project. This project is supported by the New Hungary Development Plan (Project ID: TAMOP-4.2.1/B-09/1/KMR-2010-0002).

hanem a megfigyelt események minél pontosabb követése. Az adatok feldolgozása sok időt vesz igénybe a kezdeti lépésektől a lehetséges beavatkozásig. Bár a mai számítógéphálózatok meglehetősen gyors adatátviteli sebességet tesznek lehetővé, a képfeldolgozás még mindig időigényes feladat. A feladatok szétbontásával és az adatforgalom csökkentésével időt nyerhetünk egy real-time rendszer működtetése számára, hogy rendszerünk minél inkább az elvégzendő feladatokra tudjon koncentrálni, az időigényes adatátviteli funkciók elvégzése helyett, a járművek folyamatos mozgását figyeljük és értékeljük a vizsgált út mentén. Ha bármilyen rendellenességet észlelünk a vizsgált esemény során, az egy statisztikai elemzés folyamatát indítja el, melynek végén megtörténik az esemény súlyossági besorolása is. A negyedik fejezetben a súlyossági osztályok kialakítását mutatjuk be. A cikkben a rendkívüli eseményeket két osztályba soroltuk. Az alacsony vagy magas besorolási érték az esemény súlyossági fokát adja meg. Míg az alacsony súlyossági fokozat a rendellenes eseményekre jellemző, addig a magas súlyossági fokozat már közvetlen baleseti veszélyt mutat. Az ötödik fejezetben egy rövid összefoglalást találhatunk.

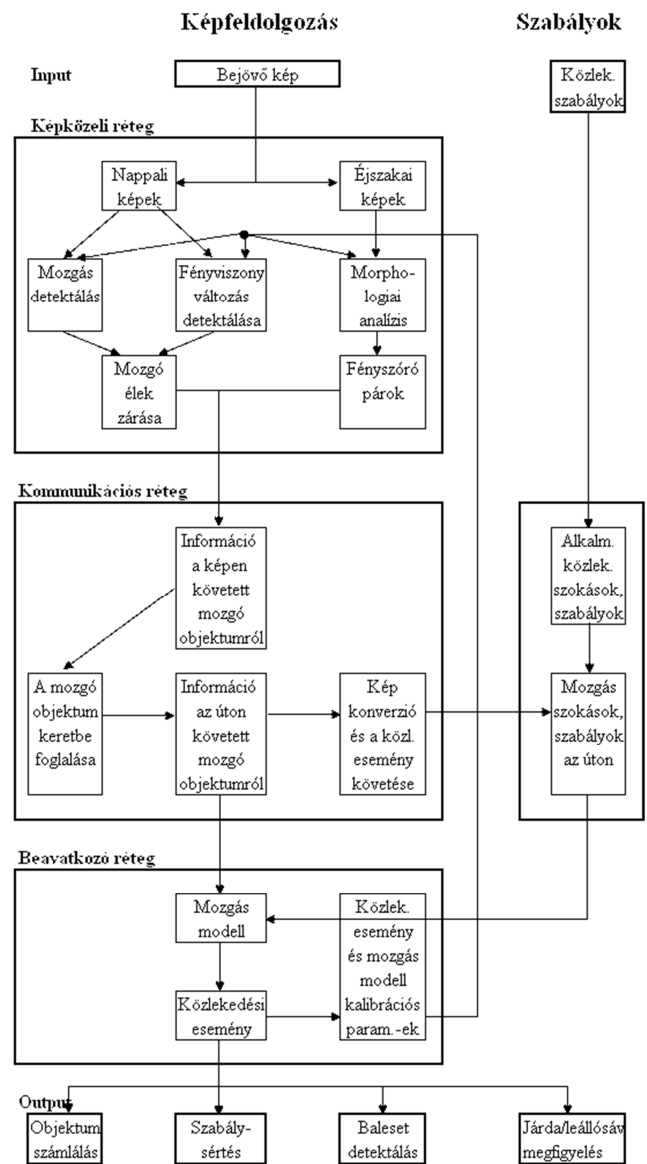
2. ALAPFOGALMAK

A forgalom megfigyelő rendszerek (Traffic Observation System, TOS) alapvető feladata a megfigyelés alá vont területen történő közlekedési események detektálása, a keletkező információk rendezése, feldolgozása valamint szükség esetén a beavatkozás (Max, 2007). Ennek a feladathármasnak eleget tevő rendszermodell felépítését az 1. ábrán kísérhetjük végig. A feladatok alapján a történésekhez legközelebb a képközeli réteg áll, amelyet a kommunikációs réteg követ, végül, amennyiben létezik a beavatkozó réteg zár le.

Az 1. ábrán látható rendszermodellben a képközeli réteg feladata a kamerák által felvett képeken a mozgó objektumok valamint a háttér szétválasztása illetve a változások detektálása. Az események feltérképezéséhez használhatunk egy, de akár több kamerát is (Horaus, 2006). A kamerák beállítása többféleképpen lehetséges. Vízszintesen többnyire akkor állítjuk be a kamerákat, ha azt szeretnénk elérni, hogy a vizsgált felület minél szélesebb legyen. Számos esetben azonban, pl. autópályaszakasz felüljáróról történő megfigyelése során, a függőleges kamera felfüggesztés több információt szolgáltat, az amúgy is egyirányba haladó közlekedésről. A terület geometria felépítésének ismerete általában nem szükséges, ha azonban rendelkezésre áll, segíthet a szokatlan közlekedési események (pl. szabálytalan sávváltás, dugó vagy baleset) felismerésénél. Általában egyszerű kocka modellt használunk hat csúcsponttal a mozgó objektumok háromdimenziós adatainak meghatározásához. Ugyanezt a modellt használjuk a járművekhez kapcsolódó árnyékok felismerésénél és/vagy eltávolításánál is (Mikic, 2003). A látási viszonyok miatt alapvetően különböző eljárást használunk a nappali és az éjszakai detektáláshoz. Ezek segítségével meghatározható az árnyék nélküli mozgó objektum geometria mérete. Az első réteg kimenete tehát a

mozgó objektum helye és mérete. Nyilvánvalóan ez a réteg szolgáltatja az adatokat a mozgó objektumok nyomvonalának meghatározásához is, amely már a második réteg feladata.

A kommunikációs réteg feladata a bejövő kép és az útfelület kapcsolatának analízise. A bejövő információk sorbaállítása után az egyes mozgó objektumok mozgástrajektóriáinak, mozgáspályáinak meghatározása következik, melyeket sokszor információhiányos környezetben kell felállítanunk. Előfordulhat például egy forgalmasabb kereszteződésben, hogy a kanyarodó járművek állandóan takarják a felfestett közlekedési sávokat. Így nem ismerjük minden sáv helyét, és csak a forgalom alapján tudunk következtetni rájuk. Ráadásul a háromdimenziós felületről készült képen a rövidülések miatt korrekciókra is szükség van.



1. ábra Közlekedés megfigyelő rendszerek általános felépítése

A korrekciók helyes kiszámításához elengedhetetlen legalább négy pontpár helyének pontos ismerete, melyek segítségével egy kétdimenziós képen látható $p_k = (x_p, y_p)$ pontot meg tudunk feleltetni az útfelszín egy valós $p_r = (x_r, y_r)$ pontjának. A korrekciós leképezés egyes fázisait a 2- ábra mutatja.



2. ábra A korrekciós leképezés lépései

Az egyik lehetséges megoldás kiindulópontja az, ha ki tudunk választani egy útjelekkel határolt téglalapot a megfigyelés alá vont út felületén. Ráadásul ez a megoldás is csak akkor használható, ha a kamera tisztán látja ezeket a pontokat. A konverziók segítségével a kétdimenziós képeinkről kapott információkat már hozzáigazíthatjuk a valós háromdimenziós világhoz. Ennek a réteg már két kimenete van. Az első a beavatkozóréteg felé adja tovább a vizsgált útfelületen követett objektum adatait (pl. nyomvonal, sebesség, irányultság). Amennyiben rendszerünkben nincs beavatkozó réteg, akkor ezeket az információkat a képközeli réteg munkájának megkönnyítése érdekében innen kell visszacsatolnunk. A réteg második feladata az adatok eljuttatása a szabályos közlekedést ellenőrző kiegészítő modul felé. Rendszerünk harmadik, talán legfontosabb rétege a beavatkozó réteg. Ez a réteg felelős, a kommunikációs réteg és a közlekedési szabályokat ellenőrző modul által összegyűjtött információk alapján, a közlekedési események azonosításáért. A szabály modul analizálja a helyszíni információkat, mint pl.: az egyes sávok helyét vagy a sávok számát, amely a továbbiakban meghatározza a szabályos közlekedés felületeit. Bár számos technika ismert a sávokra vonatkozó információk feldolgozására, az egyik legegyszerűbb módszer statisztikai alapon történik. A mozgó objektumok oldalvonalának átlagolását használjuk erre a célra, mivel a legtöbb detektált mozgó objektum útjának legnagyobb részét ugyanabban a sávban teszi meg. Miután azonosítottuk a helyszínt, a szabály modul a közlekedési szabályokat az adott helyszínhez tartozó hely és mozgás információkra fordítja le.

Két egyszerű példán - sávváltoztatás és dugó esetében - bemutatjuk az elvégzendő feladatokat. A kiválasztott mozgó objektum a fentiek szerint lesz detektálva a következő feltételek szerint:

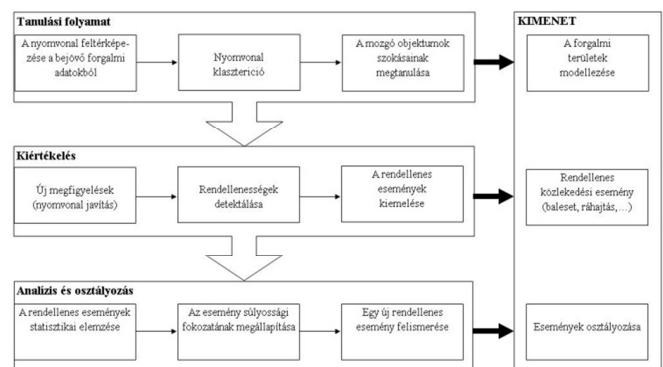
1, Minden mozgó járművek besorolunk valamelyik, a modell által detektált sávba. Ha az aktuális képen a besorolt sáv különbözik az előzőtől, akkor ez sávváltást jelent.

2, Dugót akkor detektálunk, ha a különböző sávokban mozgó objektumok átlagsebessége egy előredefiniált érték alatt marad. Bár ezt az értéket előre kell definiálni, az egyes közlekedési eseményeket már könnyű megfigyelni miután

beállítottuk ezt az értéket. Bár a határértékeket maga a réteg is generálhatja, a kapott értékeket, a kiegészítő modulon keresztül, az összes azonosított mozgó objektumra is vissza kell csatolnunk. Ha a beállított alsó sebességszűrés érték minden mozgó objektumra igazgá válik, akkor bekövetkezett a megfigyelni kívánt közlekedési esemény.

A negyedik réteg a közlekedési szabályok rétege. Ez a réteg tartalmazza egyrészt a vizsgált területen általános érvényűen alkalmazható közlekedési szabályokat. Pl. Piros lámpánál a mozgó objektumoknak meg kell állni, vagy jobbra kanyarodni csak a legszélső sávból lehet. Itt történik meg az egyes mozgásformák azonosítása, a forgalomirányító berendezések értelmezése, de a hibák azonosítása ennek a rétegnek a feladata. De ennek a rétegnek kell tartalmaznia a megfigyelt területen alkalmazott közlekedési szabályokat és szokásokat is. Az információgyűjtés után itt történik meg a szabálymintákkal történő összehasonlítás, amelyekből új mozgásformákra következtethetünk. Pl. Sarok előtt balra húzódás egy sávon belül, legtöbbször jobbra fordulási szándékot (vagy sávváltás kezdetet) jelez. Ez a réteg, a beavatkozó réteggel együttműködve, szűri ki a szabálytalanságokat.

Vegyük azonban észre, hogy még azonos típusú mozgó objektumok, pl. gépkocsik esetében is a legfőbb problémát az adott közlekedési szabálytalanság azonosítása jelenti. Ugyancsak hasonló nagyságrendű probléma magának a közlekedési eseménynek az analízise. A legtöbb forgalom megfigyelő rendszer feladata közé tartozik a járművek mozgásának hosszú távú megfigyelése a vizsgált területen. A szabálytalanságok száma, különösen a baleseteké azonban nagyon ritka. Általánosságban az is elmondható, hogy a baleseti videók csak magát a balesetet, vagy pár másodperccel a tényleges esemény előtti és utáni pillanatot örökítik meg. Az ilyen típusú felvételeket egy tanulás-alapú forgalomelemző rendszer, rövidege miatt nem tudja hasznosítani és ez akadályt jelent az eseményben résztvevő járművek viselkedésének analízisében, illetve az eseménysor megatunulásában. Ezeket az akadályokat például a 3. ábrában megadott technikák segítségével győzhetjük le.



3. ábra Az esemény felismerés lépési

Látható, hogy a tanulás a harmadik és a negyedik réteg naprakész működtetéséhez tartozó legfontosabb feladat. A

tanulási folyamat megkönnyíthető például adatbázisok használatával. Az egyik ilyen lehetőség a Next Generation Simulation Community (NGSIM) felvételei, amelyeket az Egyesült Államok Közlekedési Minisztériuma (U.S. Department of Transportation) által támogatott Szövetségi Autópálya Felügyelet, a Federal Highway Administration irányítása mellett készültek, és amelyek hozzáférhetőek a <http://ops.fhwa.dot.gov/trafficanalysistools/ngsim.htm> címen. Ezekkel az adatsorokkal lehetőségünk nyílik arra, hogy értékelhessük rendszerünk modellezési teljesítményét. Maga az adatsor hat, hosszú ideig tartó forgalmat bemutató videót tartalmaz, mellyel a járművek mozgásának szabályos viselkedését követhetjük végig. Mivel ez az adatsor nem tartalmaz baleseti eseményt, az elemzési szakaszban baleset felderítésére és elemzésére több javaslat is született az elmúlt években. (Saunier et al., 2007) egy olyan új baleseti előrejelző, megelőző módszert javasol, amely az útkereszteződésbe érkező járművek interakcióinak valószínűségét határozza meg. Cikkük jelentősége abban áll, hogy egy valós helyszín adatait használták fel a tesztelés során. Ezek alapján, felhasználva a járművek részleges pálya adatait, előrejelezték a potenciális ütközési pontokat és az ütközések valószínűségét. Egy másik munkában (Saunier és Sayed, 2006) új, belső ellenőrzést nem tartalmazó klaszterezési módszer bevezetését javasolják a közepű hiddent Markov modell alkalmazásával. Az általuk használt jármű változó hosszúságú pályákon tanulja meg a járművek együttes viselkedését, valamint a közös tevékenység minták. Egy harmadik eljárásban (Saligram et al., 2010) nemrég azt javasolta, hogy a statisztikai aktivitás elemzése nélkül, az eltérések azonosítása alapján kövessük nyomon a mozgó objektumokat. Az általuk javasolt modellben, a vizsgált terület minden pixelének mozgását egy Markov lánc statikus és mozgó átmeneti állapotaként tekintjük. Az események felderítése és elemzése mellett magára a közlekedési folyamat megtanulására, és modellezésére is figyelmet kell fordítani. (Piciarelli és Foresti, 2006) egy online pályán klaszterezési módszer kialakítását javasolja a normálistól eltérő események kimutatására. Munkájukban a mozgáspályákat klaszterezik a nyomkövető rendszer megfigyelései alapján, melynek eredményeképp egy online fa struktúrát hoznak létre. A modell frissíteni is tudja magát az új mozgáspályák megfigyelése esetén. (Aköz és Karligil, 2011) egy új forgalmi esemény besorolási módszert javasolt bizonyos megszorítások esetén a keresztezésekben. A javasolt rendszer először a járművek nyomvonalának klaszterezése segítségével megtanulja a normálisnak mondott többszereplős közlekedés folyamatát. A közös útszakaszokat folytonos HMM (Hidden Markov Model) segítségével hozza létre. A járművek rendellenes viselkedését a jármű sebességét alapul vevő közös útszakasz modelleken detektálja a jármű helyzetének valószínűségét véve figyelembe. A súlyossági fokozatok bevezetésére két súlyossági fokozatot vezet be, melyek segítségével, egyrészt kielégítő pontossággal tudja az eseményeket felderíteni, másrészt könnyen be tudja ezeket az eseményeket sorolni a súlyossági fokozatokba. (Fu et al., 2005) cikkükben javaslatot tesznek egy a hasonlóságot alapul

vevő jármű mozgáspálya klaszterezés kialakítására, melynek segítségével a rendellenességek is észlelhetők. Egyenlő hosszúságú mozgáspálya adatait felhasználva, egy kétszintű, hierarchikus pályaklaszterezési javasolnak a közös aktivitásminták feltérképezésére. Pontpáronkénti távolság hasonlósági mátrixán alapuló spektrális klasztereket használnak a mozgáspályák osztályozására. Bár jármű kölcsönhatások nem szerepel a cikkükben, mégis ígéretes eredményeket értek el a klaszterezésben és a rendellenességek detektálásában.

3. A FORGALOM MODELLEZÉSE

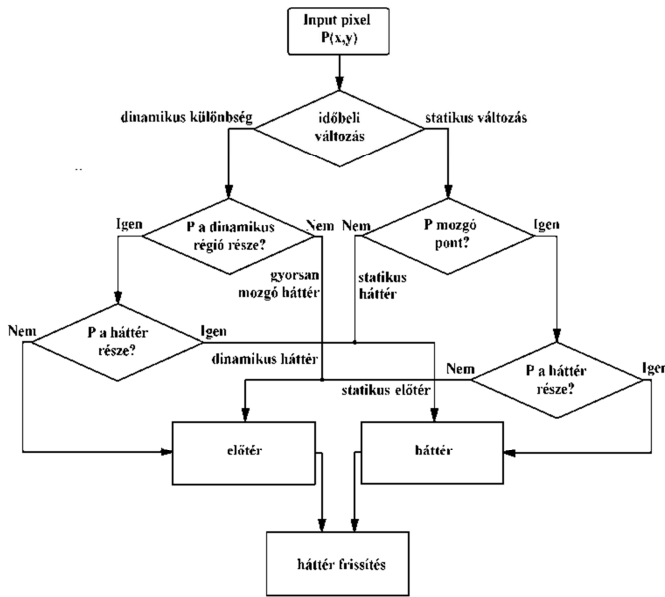
A forgalommodellezés során azt a célt tűztük ki magunk elé, hogy kiemelhessük a szabályosan viselkedő mozgó objektumokat a forgalom helyszínéből. Ezzel a módszerrel elérhető, hogy a forgalom helyszínén a szabálytalanságok felderítése során csak a szabálytalanságban résztvevő mozgó objektumok maradjanak. A továbbiakban azért használjuk többnyire a mozgó objektum kifejezést, mert ezzel azt szeretnénk kifejezni, hogy az adott forgalmi helyzet analízisében bármilyen mozgó objektum résztvehet a gyalogosoktól kezdve, a kerékpárosokon át a gépjárművekig, mindenki. Minden mozgó objektum nyomkövethető a helyszínén, nyomvonaluk alapján a megfigyelt területen feltérképezhetők a közös útvonalak. A rendszer kialakítása az alábbi lépéseket tartalmazza:

- A mozgó objektum nyers forgalmi adatait tartalmazó képi forrásokból kivesszük a jármű pályájára és időbeli mozgására vonatkozó adatokat. Ezek alapján előállítható a jármű szegmentációja és nyomvonala.
- Az útvonal modellezés fázisában, egy algoritmus segítségével csoportosítjuk a mozgáspályákat. Ehhez először le kell választanunk a háttérrel, majd meg kell határozni a mozgás helyszínét, a lehetséges mozgáspályákkal együtt.
- A klaszterezési módszer segítségével előállított modellel maximalizáljuk a normális viselkedés valószínűségét. A számítások elvégzéséhez előállítjuk a jármű mozgásához generált útvonalak Gauss-eloszlását is.

3.1 A háttér detektálása, szegmentálása

A kamerákkal felvett képek ismeretében, már a rendszer működésének inicializálásakor szükség van a háttér elkülönítésére. A háttér alatt, alapesetben a statikus, mozgásoktól mentes háttérrel értjük. A 4. ábrán a nappali és éjszakai fényviszonyok mellett elvégzendő feladatok sorát kísérhetjük végig. Nappali fényviszonyok között a mozgásdetektálással egyidőben történik meg a statikus háttér meghatározása is. Ugyanezt éjszakai körülmények között már csak morfológiai analízis segítségével végezhetjük el.

1. táblázat A háttér kialakításának algoritmusai



4. ábra A nappali és éjszakai háttér kialakításának lépései

Amennyiben nincs szükség nappali és éjszakai háttér meghatározására, akkor legegyszerűbb formában (1) szerint úgy alakíthatjuk ki a háttérünket, hogy időben egy-egy képet egymásután megvizsgálva megállapítjuk, hogy a kép melyik részén nem történt mozgás, majd ezeket a részeket átlagolva összeadjuk.

$$\text{háttér} = \sum_{k=1}^n \frac{\text{Felvétel}_k}{n} \quad (1)$$

ahol

$$|\text{Felvétel}_k - \text{Felvétel}_{k-1}| < \text{Küszöbérték}$$

A különbségeket követő háttér kezdetben egy üres képkocka. Az elképzelés az, hogy az egymás után érkező képek különbségét képezve azok a pontok fogják a háttér elemeit képezni, amelyeknél nem történt változás. A különbségképzéshez előző elemként használhatjuk a már meglévő háttérképét is, azokban az esetekben, amikor már van az adott képpontnak háttére. Többször megismételve a folyamatot előbb-utóbb eljutunk a háttér teljes kialakításához. Az eljárás alapvető lépéseit az 1. táblázatban foglaltuk össze. Az alapháttér elkészítését azonban több környezetfüggő elem nehezíti úgy, mint a fényerősség változása, a felhők mozgása, a szélerősség. A háttérképzés részletes algoritmusát az 1. táblázatban láthatjuk. Ez az eset azt mutatja, hogy ha minden a tervünk szerint történik, akkor véges időn belül eredményre juthatunk. A feladat végrehajtásánál fontos tényező a küszöbérték meghatározása. Az (1)-ből ez az érték azt határozza meg, hogy milyen eltérés mellett tekintünk két képpontot egyformának.

háttérkép = üres kép
új kép = üres kép

ismétlés

- régi kép = új kép
- új kép beolvasása
- különbségképzés a régi vagy a meglévő háttér és az új kép között
- küszöbérték különbség a vizsgált képpontok között
- az új képpontok hozzáfűzése a háttérképhez
- a háttérkép mentése

amíg már nem kell több képpontot hozzáadni a háttérképhez

3.2 Mozgó objektumok szegmentálása

Az objektumok szegmentálásánál feltételeztük, hogy nappal van, azaz a vizsgált színek valószínűségek. A háttértől való elválasztás egy egyszerű kivonásszerű művelettel megvalósítható meg, amely során az aktuális kép adataiból levonjuk a statikus háttér elemeit. Az eredményt, a változó környezeti paraméterekből eredő zajok miatt, a legtöbb esetben még korrigálni kell. Az eredmények lényegesen megváltozhatnak, ha a kamerák, pl. az erős szél miatt mozognak. Ez a módszer a mozgó objektumok durva detektálására alkalmas. Ezzel a módszerrel nem lehet elkülöníteni az egymás takarásában álló vagy mozgó objektumokat, de a vizsgálandó képterületeket jelentősen lehet csökkenteni. A finom szegmentálás során meg kell határozni az egyes objektumok éleit, körvonalait. Többféle finom élderkesési módszer létezik, hogy pl. csak a Sobel- (<http://homepages.inf.ed.ac.uk/rbf/HIPR2/sobel.htm>) vagy a (http://faculty.cs.tamu.edu/jchai/CPSC641/harris_detector.pdf) Harris-féle élderkesési eljárásokat említsük. Más alapokon (pl. szín, forma, ...) működő szegmentálási eljárások is léteznek, amelyeket feladatainktól függően, önmagukban vagy egymással kombinálva is használhatunk. A mozgó objektumok szegmentálását helyzetük (irány, orientáció, sebesség, másik objektumtól mért távolság, ...) megállapítása miatt végezzük el. A feladat real-time megvalósítása jelentős számítási feladatot ró a rendszerre, amelyet csak erős számítási kapacitással vagy jól elosztott paraméterekkel rendelkező rendszer képes elvégezni. A feladatok delegálásánál mindig figyelembe kell vennünk az aktuális berendezés korlátait.

3.3 A mozgó objektumok nyomvonalának felvétele

Ahhoz, hogy elemezni tudjuk egy mozgó objektum viselkedését, szükségünk van a mozgáspályájának ismeretére, amelyet az alábbiak szerint végezhetünk el:

- a mozgó objektumot belépéskor felvesszük a követendő objektumok közé

- amíg a vizsgált térrészben tartózkodik képkockánként gyűjtünk róla információt
- amint a mozgó objektum elhagyta a vizsgált területet, az adott objektum nyomkövetése leáll

Nyomkövetés során, a méretek mellett tároljuk a mozgó objektum pozícióját, irányát, irányultságát, sebességét és gyorsulását, mert ezek a paraméterek játszik a legfontosabb szerepeket az objektum mozgásának leírásában. Nyomkövetésre során többféle technikát használhatunk, de a legáltalánosabb módszer az objektum középpontjának vagy a 4-6 egymástól legtávolabbi pontjának követése. A technikák kiválasztásában nyilvánvalóan a feldolgozás gyorsasága a mérvadó.


A normál forgalmi viszonyok között, a járművek mozgáspályája ugyanazon az útszakaszon is különböző hosszúságú lehet, például az eltérő sebesség miatt. Ez az egyik legfontosabb forgalmi jellemzője a mozgó objektumoknak, mert ebből láthatjuk, hogy minden jármű saját viselkedési szokást mutat, és ezért egyedileg kell kiértékelni őket. A változó hosszúságú mozgáspálya klaszterezési technikákról (Morros et al., 2008)-ban olvashatunk részletesen. A modell alapú klaszterezési eljárásokat, mint például a HMM, használhatjuk változó hosszúságú időtartam klaszterezésre mindenféle normalizációs eljárás nélkül.

3.4 A mozgó objektumok szokásainak felismerése

Mozgó objektumok viselkedésének felismerése, annak az eljárásnak a megtanulását jelenti, amelyben a vizsgált térrészben található összes mozgó objektum közös aktivitás mintázatát csoportosítjuk. A valós forgalomesetén, a járművek várhatóan a bizonyos közlekedési szabályok alapján mozognak. Például, egy útkereszteződéseknél, a járművek követik a megfelelő forgalmi sávokat és figyelik a közlekedési lámpák utasításait. Ezek szabályok már a kereszteződés tervezésekor is a rendelkezésünkre állnak. Ezek alapján a kereszteződésbe érkező objektumok mozgását figyelve, a normál közlekedés folyamatát automatikusan meg lehet tanulni. Az objektumok mozgásjellemzőit valószínűségi változókként vesszük figyelembe, amit egy Markov-láncként reprezentálhatunk. Valós forgalmi környezetben az objektumok pályája egy statisztikailag jellemezhető véletlenszerű mozgás. Matematikailag ezek a mozgások egy kevert Gauss-eloszlású (Mixture of Gaussian) folytonos idejű rejtett Markov modellt eredményeznek (CT-HMM with MoG). Ez a klaszterezési eljárás alkalmas az idősoros valószínűségi változók kezelésére, és így egyben a változó hosszúságú nyomvonalak klaszterezésére is, amely segítségével meghatározható a mozgó objektumok közös aktivitási pályája. A HMM és MoG eljárásokról részletesebben a (Rabiner, 1989)-ben olvashatunk. Maga az eljárás nagyon nagy matematikai apparátust igényel, ezért a jelenleg rendelkezésre álló technikai háttérrel csak offline üzemmódban végezhető el a számítások. A számítási igények illusztrálására nézzünk egy egyszerű példát. Egy kétsávos autópálya egyik oldalának vizsgálatához

kameránkkal egy 300 méteres térrészt fogunk be. Ezt az utat egy 36 km/h sebességgel mozgó jármű 30 másodperc, egy 180 km/h órával mozgó jármű pedig 6 másodperc alatt teszi meg. Ha a modellezés szempontjából a szélsőségesen rossz 10 méterenkénti vizsgálati pontokat vesszük figyelembe, és a feldolgozás idejét 1 másodpercben határozzuk meg, akkor az utóbbi jármű esetében 6 megfigyelt és 24 rejtett állapotváltozót kell létrehozunk a CT-HMM számítás alapjául szolgáló infinitezimális Q generátor mátrix kialakításához. Bár a mátrixnak csak néhány átlója van feltöltve, ez így is egy 144 x 144-es mátrixot jelent. Gondoljuk meg, hogy mekkora számítási erőforrásra lenne szükség egy kvázi real-time, azaz nem másodpercenként 24-25, hanem csak 6-8 képkockát számítva, a létrejövő információk alapján ezt a mátrixot invertálni kellene. Ezek alapján könnyen belátható, hogy real-time üzemmódban, jelen körülmények között, ami általában PC-s környezetet jelent, a számítások nem végezhetőek el. Hasonló probléma merült már fel (Max, 2009) a háttér leválasztásánál is, ami egy bonyolultabb esetben akár 20-30 percet is igénybe vehet.

A CT-HMM-ben az emissziós valószínűségi eloszlás függvények az MoG segítségével modellezhetőek. Egy autópályarészlet HMM állapot topológiája MoG kimenettel például az 5. ábrán látható módon adható meg. A kereszteződés minden egyes régiója egy rejtett állapottal és a hozzátartozó három kevert Gauss-féle kimenettel adott. Az ábrán a Gauss állapotokat (S_j)-vel, középvektorát (μ_j)-vel, kovariancia mátrixát pedig (Σ_j)-vel jelöljük. Minden egyes μ_j középvektor a klaszter középpontját reprezentálja, és az 5. ábra szerint vannak egymáshoz kapcsolódva, hogy kialakítsák a közös útvonalat.



5. ábra Egy kétsávos autópálya külső sávjának modellje

A tanuláshoz szükséges m számú különböző útvonal modell (λ_m) esetén, minden egyes külön útvonalra az Expectation-Maximalization (EM) alapján készül el, amiről részletesebben a (Moon, 1996)-ben olvashatunk. Az EM egy interaktív eljárás, amely megbecsüli a rejtett változókon alapuló modell paraméterek maximális valószínűségét.

3.5 Rendellenes járműmozgások felismerése

Tételezzük fel, hogy rendszerünk a tanulási szakaszban már elsajátította a normális mozgáspályák felismerését. Így rendellenesség észlelése esetén a folyamat már kiemelhető környezetéből, hogy megértsük azokat a közlekedési események, amelyek a járművek rendellenes viselkedését okozzák. A CT-HMM segítségével megtanult közös mozgás modell reprezentálja a rendellenesség-mentes közlekedési folyamatot, amelyekkel megfigyeljük a mozgó objektumokat a vizsgált közlekedési területen. Amint egy új mozgáspályát észkel a rendszer, megtörténik a közös pályamodellek és az aktuális útvonal összehasonlítása azért, hogy vajon az új útvonal normálisnak mondható-e vagy sem. Erre azért van szükség, hogy a közös útvonalak ismeretében a legnagyobb valószínűséggel be tudjuk sorolni az új útvonalak a már kialakított osztályokba.

A valóságban a rendellenességek különböző típusa létezhet ugyanazon a helyszínen. A leginkább előforduló rendellenességek az ütközések és a szabálytalan előzések. Ez utóbbiak többnyire gyors sávváltással és ütközésközeli állapottal jellemezhető. Kereszteződésekben ezen kívül még gyakran előfordulnak a hirtelen fékezések vagy megállások, bár a hirtelen visszafordulások vagy a rossz irányba fordulások sem ritkák. Összefoglalva, ezek a jelenségek mindig a mozgó objektum sebességének hirtelen megváltozásával járnak. Természetesen meg kell még említeni a gyorsajtást is, amikor a jármű sebessége nagyobb, mint az az adott útszakaszon megengedett. Ennek ellentétéleként fel kell ismernünk azt az esetet is, amikor lassú vagy hosszabb ideig álló járművek okozhatnak közlekedési bonyodalmakat. Ennek felismerése különösen nehéz, mert műszaki hiba vagy közlekedési dugó miatt is állhatnak a járművek. Az alkalmazott közlekedési szabályoktól függően ezeket az eseteket el kell különíteni egymástól, hiszen ezek lehetnek megengedett vagy nem megengedett rendellenességek is. Ezek felismeréséhez általában elegendő, ha a jármű adott sávban történő sebességváltozását figyeljük. Tudjuk azonban, hogy a közúti rendellenességek és a balesetek ritka és hirtelen lejártszódo események, és a legtöbb esetben a rendellenességek csak a vizsgált pályaszakasz egy részére érvényesek. Magának a pályaszakaszoknak az összehasonlítására a HMM-et használjuk posterior Bayes valószínűségi becsléssel kiegészítve, mely során összehasonlítjuk az egyes pályaszakaszokat (σ_i) a megfigyelés során megtanult útmodellel (λ_m). Az eredmény megmutatja, hogy megfigyelt útvonal milyen valószínűséggel egyezik meg a közös pályaszakaszokkal. A számítások megkönnyítés érdekében a megfigyelt útszakasz logaritmikusan valószínűségével érdemes számolni. Ha ez nem egyezik meg a pályamodellel logaritmikusan valószínűségével egy bizonyos küszöbértéken belül, az eseményt rendellenesnek tekinthetjük. A küszöbértéket általában még empirikusan, a tesztek során kialakult értékeknek megfelelően adjuk meg. Ezek a rendellenességek többnyire ütközéseket vagy szabálytalan sávváltoztatásokat jelentenek. Ha a vizsgált pályaszakasz

logaritmikusan valószínűsége alatta van az adott pályaszakaszra jellemző logaritmikusan valószínűségnek, akkor az eseményt normálisnak tekinthetjük.

Az egyes mozgó objektumok rendellenes viselkedése egy adott t időpillanatban a jelenlegi és az előzőleg megfigyelt mozgásjellemzőktől függ. Ezek

- a mozgó objektum pozíciója és sebessége
- a megfigyelt útszakasz logaritmikusan valószínűsége megegyezik-e a közös útszakasz (λ_m) modelljével
- a mozgó objektum előző és jelenlegi pályaszakaszai rajta vannak-e az elvárt útszakaszon
- a vizsgált pályaszakasz logaritmikusan valószínűsége alatta van az összes ismert pályaszakaszra jellemző logaritmikusan valószínűségnek

Ha csak ezeket a feltételeket vizsgálnánk néhány esetben nehéz lenne megállapítani azt, hogy az objektumok mozgása normális-e vagy rendellenes. Mit mondhatunk arról az esetről, amikor egy szabálytalan fordulás közben a vezető visszarántja a kormányt a helyes irányba azért, hogy elkerüljön egy ütközést. Ezért a helyes osztályozás érdekében újabb feltételeket kell megadnunk, hogy felismerhessük a rendellenes esemény időpontját:

- a balesetekben általában egynél több mozgó objektum vesz részt.
- A baleset analíziséhez a megfigyelt területen lévő összes objektum vizsgálata szükséges.

Az analízis során egyenként eltávolítjuk a helyszínről azokat az objektumokat, amelyek nem okoznak semmilyen változást egy újabb megfigyelési állapotban. Ezzel a technikával az érhető el, hogy a folyamat végén a helyszínen csak a szabálytalanságban résztvevő – akár mozgó, akár álló – objektumok maradnak, bár a szabálytalanságot okozó és a szabálytalanságot elszenvető objektumra nézve nem kapunk információt. A tanulási szakaszban megtanult, előre meghatározott küszöbérték nagyságát figyelembe véve, ha egy mozgó objektum az újabb megfigyelési állapotban is rendellenes státuszban marad, az a rendellenesség valószínűségének növekedését jelenti.

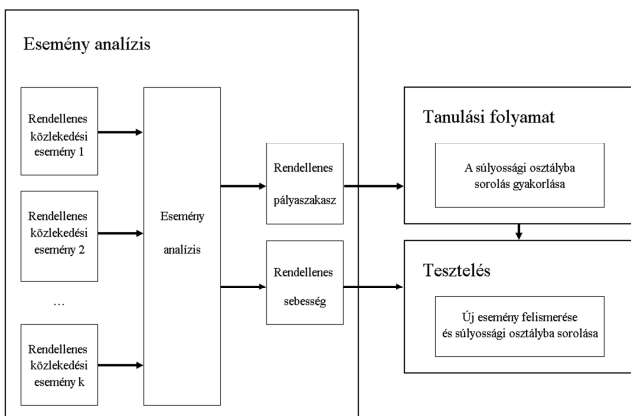
Mint azt a cikk elején jeleztük, ezeket a rendszereket leginkább a balesetek automatikus észlelésénél szeretnénk felhasználni. A rendellenességeket mozgó objektumokként mérni tudjuk. Ütközések a legtöbb esetben két vagy több jármű között történik. A legtöbb ütközésetekelő rendszer úgy működik, hogy eltávolítja a normálisan mozgó járműveket helyszínről, és a megmaradt járművek adják a rendellenesség okát. Ez több és többfajta rendellenességet is jelenthet ugyanabban az időpillanatban. Ha egyre több rendellenességet fedezünk fel ugyanabban a pillanatban, akkor ez egyre inkább növeli a baleset létrejöttének

valószínűségét. Egy baleset előrejelző modulnak tehát a következő eseteket kell felismernie:

- ha rendellenes logaritmikus valószínűség változást detektálunk és több mint egy jármű hirtelen fékezése történik ugyanebben az időintervallumban, valamint a járművek térben elég közel vannak egymáshoz, az nagy valószínűséggel fizikai ütközéseket jelent. A balesetek ezen fajtájában egy jármű megáll az ütközés után, ami a másik járművet arra kényszeríti, hogy rendellenes gyorsasággal hagyja el kiszámított pályáját.
- ha rendellenes logaritmikus valószínűség változást detektálunk ugyanebben az időintervallumban egynél több jármű esetében és a járművek térben elég közel vannak egymáshoz, az nagy valószínűséggel két jármű ütközését jelenti, amely során legalább az egyik jármű megpördült és hirtelen elhagyta előre kiszámított pályáját.

4. AZ ESEMÉNY SÚLYOSSÁGÁNAK ÉRTÉKELÉSE

Az egyes rendellenességek súlyosságának osztályozására jelen tanulmányban csak két osztályt vezettünk be, az alacsony és a magas súlyossági kategóriát. A hirtelen fékezések, megállások és a pályaelhagyások az alacsony súlyossági osztályba tartoznak, míg az ütközések a magas súlyossági osztályba tartoznak. Ez utóbbit még érdemes további csoportokra osztani, amelyben az ütközés erősségét, a jármű mozgásának irányváltozásait és sebességét mérhetjük. Minden rendellenes eseményt alacsony vagy magas súlyossági osztályba sorolunk. Az osztályozás pontosságát fokozhatjuk az események rendellenes részeinek összegyűjtésével. Ha egy újabb rendellenes eseményt észlelünk, azt a súlyossági osztályba történő besorolása után felvesszük az adatbázisunkba. Magát a folyamatot a 6. ábrán láthatjuk.



6. ábra A súlyossági osztályokba történő besorolás lépései

Egy megfigyelt útszakaszon több rendellenes eseményt is láthatunk. Az ütközések elkerülése végett a vezetők lassíthatnak anélkül is, hogy elhagynák sávjukat vagy egyszerűen hátrafelé indulnak el. De végezhetnek

szabálytalan fordulásokat vagy gyors sávváltásokat is. De ezeket az eseményeket is szigorúan rendellenes eseményeknek kell értékelnünk. Bár ezek a rendellenességek csak alacsony fokozatúak, számos a magas súlyossági osztályba sorolt közlekedési rendellenesség létezik. Idetartoznak a frontális, vagy oldalsó ütközések valamint a nem szándékos hirtelen sávellahagyások és a hirtelen megállások. Ezeket az eseményeket azért soroljuk a magas súlyossági fokozatú osztályokba, mert magas a baleseti rizikó faktoruk és azonnali válaszreakciókat igényelnek. Vegyük észre, hogy ezeket az eseteket akár manuálisan is előre két súlyossági osztályba csoportosíthatnánk. A nem manuális osztályozás lényege éppen abban rejlene, hogy minél jobban szét tudjuk választani a két osztályt. Ha ugyanis az osztályokat nem lehet egymástól elkülöníteni, akkor azt csak egy nemlineáris osztályozási módszerrel lehetne megoldani, ami még bonyolultabbá tenné az események azonosítását. Összegzésképpen nézzük végig újra a rendellenes közlekedési események osztályozásának lépéseit:

- detektáljuk a rendellenes eseményeket
- kiemeljük az eseményt okozó és az eseményben résztvevő járműveket
- megvizsgáljuk, hogy az adott eseményben résztvevő járművek melyik súlyossági osztályba tartoznak

5. ÖSSZEFOGLALÁS

A cikkben bemutattuk a rendellenes közlekedési események osztályozásának egy lehetséges metódusát. A módszer azon alapul, hogy a megfigyelt környezetből kiemeljük azokat a mozgó objektumokat, amelyek okozták vagy szenvedői voltak az eseménynek. A rendellenes közlekedési események detektálásához először megtanuljuk a normális közlekedés folyamatát. Ez magába foglalja az általános és a véletlenszerű szabályos mozgásformákat. Másodszor, az előzőleg már felismert és adatbázisunkban elraktározott rendellenes események kategorizálásával beállítjuk a megismert események súlyossági fokozatát. A mozgó objektumok rendellenes viselkedésének mértékét az események súlyossági osztályokba történő csoportosításával határozzuk meg. A kimenetként elképzelt riasztás real-time környezetben csak kevés szereplős környezetben működik még.

IRODALOMJEGYZÉK

- Hartley, R. and Zisserman, A., (2000). *Multiple View Geometry in Computer Vision*, Cambridge.
- Max, G., (2007). *Képfeldolgozó eljárások a közlekedésben*, Alkalmazott Informatikai Kongresszus, Kaposvár

- Horaud, R., Knossow, D., Michaelis, M. (2006). *Camera cooperation for achieving visual attention*, Machine Vision and Applications 16(6), pp. 331–342
- Mikic, I., Cosman, P. C., Kogut G.T., Trivedi, M.M. (2003). *Moving Shadows and Object Detection in Traffic Scenes*, Proceedings of the 15th International Conference on Pattern Recognition, Barcelona, Spain, **Vol.1**, pp. 321-324
- Saunier, N., Sayed, T., Lim, C. (2007). *Probabilistic collision prediction for vision-based automated road safety analysis*, Intelligent Transportation Systems Conference, pp. 872–878. IEEE, Seattle
- Saunier, N., Sayed, T. (2006). *Clustering vehicle trajectories with Hidden Markov models. Application to automated traffic safety analysis*, International Joint Conference on Neural Networks. IEEE, Vancouver, pp. 4132–4138.
- Saligrama, V., Konrad, J., Jodoin, P. (2010). *Video anomaly identification: a statistical approach*, IEEE Signal Process. Mag. **27**(5), 18
- Piciarelli, C., Foresti, G.L. (2006). *Online trajectory clustering for anomalous events detection*, Pattern Recognit. Lett. **27**, 1835–1842
- Aköz, Ö., Karşligil, M.E. (2011). *Traffic event classification at intersections based on the severity of abnormality*, Machine Vision and Applications, Springer-Verlag
- Fu, Z., Hu, W., Tan, T. (2005). *Similarity based vehicle trajectory clustering and anomaly detection*, IEEE International Conference on Image Processing **vol. 2**, pp. 602–605
- Morris, B., Trivedi, M. (2008). *A survey of vision-based trajectory learning and analysis for surveillance*, IEEE Trans. Circuits Syst. Video Technol. **18**(8), 1114–1127
- Rabiner, L. (1989). *A tutorial on Hidden Markov Models and selected applications in speech recognition*, Proceedings of the IEEE, **vol. 77**, no. 2
- Max, G., (2009). *Traffic events specification*, AACs-2009, Budapest
- Moon, T. (1996). *The expectation-maximization algorithm*, IEEE Signal Processing Magazine **vol. 13**, pp. 47–60