

Forgalom előrejelzés Deep Learning tanuló folyamatokkal

Max Gyula

Budapesti Műszaki és Gazdaságtudományi Egyetem
Villamosmérnöki és Informatikai Kar
Automatizálási és alkalmazott informatikai tanszék
(e-mail: max@aut.bme.hu)

Absztrakt: A cikk egy rövid távú közlekedési előrejelzés kialakítását mutatja be Deep Learning alapú rendszer felhasználása mellett, amely kétféle adathalmazt: adatfolyamokat és esemény alapú adatokat tartalmaz. A rendszer a különböző forrásokból származó heterogén adatok kezelését adatfúzió segítségével valósítja meg. Az így keletkező adatokat felhasználva igyekszünk rövidtávon előre jelezni a forgalom változását az adatfolyamok, azaz a történeti típusú forgalmi adatok és az időjárás változás, az esemény alapú adatok megfigyelésének segítségével. Az elérhető előrejelzési idő növelése érdekében a Dempster szabályt alkalmazzuk az adatfolyamok és az eseményalapú adatmodulok összehangolására. A valós adatok felhasználásával készült kísérleti eredmények az eddig alkalmazott technológiákhoz viszonyítva jobb eredményeket mutatnak.

1. BEVEZETÉS

A tervezett intelligens városok egyik várható szolgáltatása az intelligens mobilitás. Már ma is több, mint egymilliárd gépjármű mozog a világ utjain, amelyek száma 20-25 éven belül megkétszereződhet. A biztonságos közlekedés fenntartása a kor univerzális kihívásainak egyike. A megoldás egyszerű, de biztonságos navigációt, megfigyelhető és előre jelezhető közlekedést igényel, amely figyelmeztet és jelzi a várható eseményeket, megrongálódásokat, baleseteket és megfelelő alternatív javaslatokkal áll elő járművezetők számára. A célok elérésének érdekében kulcsfontosságú a pontos és megbízható információ megszerzése a jelenlegi és prediktív forgalmi adatok alapján. A várható forgalmi adatok előrejelzése igen nagy kihívást jelentő feladat, mert az utazások során nem csak a változó időjárási körülményekre – eső, vihar, hó – kell tekintettel lenni, hanem egyéb előre nem látható eseményekre is, mint pl. útlezárás, elterelés, dugó vagy baleset. Ezek a tényezők jelentősen befolyásolják az egyes járművek utazási idejét, következésképpen jelentősen befolyásolhatják a közlekedési útvonalak, hálózatok teljes forgalmi áramlását is. A késések legnagyobb részét a nem ismétlődő közlekedési események – balesetek, rossz időjárás, munkaterületek – okozzák. Ezeket az eseményeket két csoportba bonthatjuk:

- tervezett események: pl. útépités, karbantartás
- különleges események: pl. balesetek

Az elmúlt években jelentősen megnőtt az utak mellett elhelyezett megfigyelőeszközök száma. Ezek az eszközök időegységenként igen jelentős mennyiségű adat képesek különböző típusú érzékelőik segítségével begyűjteni. Már Magyarországon is több tízezer térfényképező kamerával találkozhatunk országszerte, amelyek adatokat továbbítanak a megfigyelt területről, az ott megfigyelhető objektumokról, eseményekről (Max, 2012). Egy közúti megfigyelés során, az

ott mozgó járművekről folyamatosan különféle adatok – pozíció, sebesség, orientáció, méret, szín, felhasznált üzemanyag mennyiség, stb. – generálódnak, amelyek igen jelentős adatfogalmat jelentenek a megfigyelőhely és a központ között. Az már egy másik, külön döntéshozatali mechanizmus, hogy ezeket az adatokat kik számára teszik láthatóvá, mert az itt nyert adatok egy előrejelző közlekedési alkalmazás segítségével kedvező döntéshozatali pozícióba állíthatja az egyes járművek vezetőit, akár az útvonalra, akár az indulási időre gondolván. A várható forgalmi előrejelzési adatok, kiegészítve a különleges események halmazával, már manapság is nagymértékű figyelmet kap a közösségi médiában. Az ehhez tartozó előrejelzéseket egy megfelelően megválasztott adatbázis és egy kiértékelő algoritmus segítségével lehet a kívánt valószínűségi mutatók betartása mellett megadni. Ezekhez a forgalom előrejelző rendszerekhez a forgalom már megfigyelt időszakainak (historikus adatfolyamok) felhasználása mellett az időjárási adatok és különleges eseményalapú történések ismerete adja a legfontosabb alapokat. A következtetések levonásában pl. a Dempster-Shafer Evidence Theory (DSET) adhat elméleti alapot. A DSET alkalmazott összefüggéseit az előrejelzés frissítésre használjuk, amelyhez az eredményeket az adatfolyamok és eseményalapú adatmodulok forgalmi előrejelzéseiből levont következtetések biztosítják. A cikk további részeiben a következőkről olvashatunk. A 2. fejezetben a forgalom előrejelzések háttér irodalmát mutatjuk be, majd a 3. fejezetben a javasolt forgalmi előrejelzési rendszer technikai háttéréről szólnunk, bemutatva azokat a tanuló algoritmusokat és feltételes megközelítéseket, amelyek a várható események kombinációit tartalmazzák. A 4. fejezet egy a rendszer működéséhez szükséges feltételes adatbázis felépítésének bemutatásával foglalkozik. A kísérleti eredményekről az 5. fejezetben olvashatunk, míg a 6. fejezet a következtetéseket tartalmazza.

2. IRODALMI HÁTTÉR

A historikus forgalmi adatok felhasználása a rövid távú forgalom előrejelzésben sok tanulmányt ösztönzött. A külső tényezők, például az időjárás, a tervezett vagy a nem tervezett események médiában történő megjelenésének előnyével azonban csak néhány kutatás foglalkozott. Itt azokra a cikkekre összpontosítunk, amelyek be is építették ezeket a befolyásoló tényezőket a rendszerükbe (Rehborn et al., 2014). A (Duane et al., 2013)-ban a szerzők egy neurowavelet alapú keretet javasoltak az óránkénti forgalom előrejelzésére, figyelembe véve az esők időjárásra tett hatását. Stational Wavelet Transzformációt használtak azokra a közösségi oldalakon megosztott forgalmi eseményekkel kapcsolatos releváns adatokra, amelyek felhasználhatók a forgalmi előrejelzési pontosságának a növelésére. Ez volt a célja (Jingrui et al., 2013) által készített tanulmánynak is. A Twitteren elérhető adatokat külső adatforrásként használják a hosszú távú forgalmi előrejelzés javítására. Itt azonban a forgalom és a társadalmi aktivitás intenzitását magában foglaló autó-regressziós modell nem igazodik a közlekedési rendszerek és a szociális hálózatok által generált jellemzők nagy dimenziójának összetettségéhez. A (Lei et al., 2015)-ben a szerzők Twitter alapú időjárás változókkal becsülték a lineáris regressziós modellt és ezzel egyidőben be is mutatták a lineáris regressziós modellek korlátait.

A forgalom előrejelzés témakörében is több tanulmány született. (Wenhao et al., 2014) és (Yisheng et al., 2015) –

talán módszer kevésbé elterjedt volta miatt – a Deep Learning eljárásnak szentelt különös figyelmet. Az eljárás képes nagy mennyiségű adat kezelésére és olyan funkciók nagy dimenzióinak kezelésére, amelyeket a közlekedési rendszerek intelligens városban hozhatnak létre. Ezek a közelmúltbeli tanulmányok azonban nem vettek figyelembe sem a meteorológiai tényezőket, sem a társadalmi hálózatokba bekerülő eseményeket.

3. ELMÉLETI HÁTTÉR

Ebben a részben RBM és DSET kerül bevezetésre. A RBM-ek végrehajtásával pontos rövid forgalmi előrejelzést lehet elérni. A becslés kétféle adattípust használ: adatfolyamokat, azaz forgalmi adatokat, valamint eseményalapú, azaz időjárás adatokat. A DSET-et arra használják, hogy biztosítsa, hogy a két csatornán érkező adatokból meghozott döntések minél jobb előrejelzést érjenek el.

3.1 Deep Learning

A Deep Learning az úgynevezett nem felügyelt tanulási módok egyike. A felügyelt tanulási folyamatok mellett mindig találunk egy tanárt. Ő az, aki meghatározza a tanulás folyamatát, meghatározza azt a halmazt, amely segítségével eljutunk az inputtól az outputig. A felügyelet nélküli tanulás abban segít, hogy hogyan találjunk hasonlóságokat vagy különbségeket az ún. még címkézetlen adatok között. A

felügyelet nélküli tanulási folyamatokban nincs tanár, itt magunknak kell alkalmaznunk azokat az eddigi ismereteinket, amelyek segítenek nekünk pl. képfelismerésben vagy a mintakeresésben.

Az általunk végzett kutatási területen a Deep Learning (DL) folyamatok egyik legfontosabb alapeleme a neurális hálózatok területén alkalmazott Korlátozott Boltzmann Gép (Restricted Boltzmann Machine – RBM). Az RBM egy olyan algoritmus, amely segítségével az egyszerű dimenzió csökkentés vagy regresszió számítás mellett olyan összetett műveleteket is ki tudunk alakítani, mint az osztályozást vagy szűrések együttműködését. Következésképpen az RBM-ek összekapcsolásával a szereptanulás vagy egy téma modellezési sémája is kialakítható.

Egy Deep Learning folyamatot úgy is megvalósíthatunk, hogy az RBM-ekből egy vermet képünk. Ezután pl. felügyelet nélküli algoritmusokkal egy gyors tanulási folyamatot valósítunk meg (Geoffrey, 2006), amelyben az RBM az 1. ábrán látható modell, amelyben rendelkezik a látható (v) vagy rejtett (h) egységekkel. Egy RBM energiafüggvényét az (1) szerint definiálhatjuk:

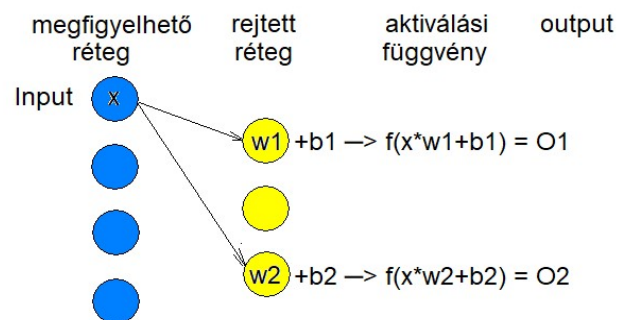
$$E(v,h)=-b^T \cdot v -c^T \cdot h -h^T \cdot W \cdot v \quad (1)$$

ahol sorrendben b és c a rejtett és látható rétegekkel társított bias vektorok, valamint W a látható és rejtett rétegeket összekötő súlymátrix. A RBM-ekben nincs kapcsolat a látható és a rejtett rétegeken belül, csak a látható és a rejtett rétegek között.

Egy egyszerű példán keresztül nézzük végig a folyamatot. Kövessünk egy x pixelértéket egy kétrétegű hálón. A bejövő érték a rejtett réteg csomópontján megszorozódik a csomópont súlyával és hozzáadódik a csomóponti b bias vagy torzítási értékhez. E két művelet eredménye lesz a csomópont aktiválási függvényének a bemenete, amelynek eredménye megadja a csomópont O kimenetét.

Aktiválás ($f((súly \cdot w + bemenet \cdot x) + bias \cdot b)) = O$

Egy bemenetű Korlátozott Boltzmann Gép




1. ábra: Korlátozott Boltzmann Gép

Az 1. ábrán a megfigyelés eloszlása a részlegesen megfigyelhető és rejtett egységek konfigurációjával a következőképp (2) adható meg:

(2)

Ahol Z a határfüggvény, ahonnan a látható egységek egy csoportjának megfigyelése a (3) egyenlet segítségével állítható elő:

A felügyelet nélküli algoritmus segítségével megtanulható paraméterek tehát a neurális hálózatok inicializálására használjuk. A feladatok az egyes utakon lévő forgalomáramlási előrejelzésből áll. Maga a tanulási folyamat többlépcsős műveleteket (Multi Task Learning - MTL) tartalmaz [11]. Ez a tanulási módszer lehetővé teszi minden feladat számára, hogy egymás közt megossza az egymásra rakott RBM-ek által létrehozott nézeteket, amelyet a regresszió számítás után aktiválási függvényként használhatunk.



2. ábra: RBM-ekből kialakított neurális háló többfunkciós regresszióhoz

Az sejthető, hogy az így kialakított hálózat több, egymáshoz kapcsolódó út forgalmi viszonyainak előrejelzésére alkalmas. A 2. ábra egy többszörös feladat regressziót ábrázol az egymásra rakott RBM-k tetején.

3.2 Dempster-Shafer Hitelesség Elmélet (DSET)

A Dempster–Shafer Hitelesség Elméletet (Dempster–Shafer Evidence Theory) azzal a céllal hozták létre, hogy megkülönböztethetővé váljon a bizonytalanság (uncertainty) és az ismerethiány (ignorance). Ez az elmélet egy állításnak nem a valószínűségét számítja ki, hanem helyette azt, hogy mennyi annak a valószínűsége, hogy a bizonyíték támogatja az állítást (Sentz et al, 2002). A bizonyosságnak ezt a mértékét bizonyosságfüggvénynek (belief function) nevezik, és $Bel(X)$ -szel jelölik. Magát az elméletet a hitelesítő funkciók elméleteként is ismerhetjük, a bayesi elmélet

szubjektív valószínűségének egyik alkalmazása. Míg a Bayes-elmélet megköveteli a valószínűségeket minden érdeklődésre számot tartó kérdéshez, a hitelesítő függvények lehetővé teszik számunkra, hogy egy kérdésre vonatkozó hitelesítési szintek valószínűségi értékeit egy kapcsolódó kérdésre alapozzuk. Ez sajnos azt is jelenti, hogy a hitelesítési szintek valószínűleg nem rendelkeznek a valószínűségek matematikai tulajdonságaival. Ez az elmélet tehát a hitelesítő funkciókra és az elfogadható érvelésre alapozott bizonyítékok matematikai elmélete, amelyet különféle információ (bizonyítékok) egyesítésére használnak egy esemény valószínűségének kiszámításához.

A különböző adatforrások felhasználásával a RBM-ek által biztosított forgalmi folyamatot a DSET segítségével összekapcsolják, hogy jobb döntéseket hozzanak a forgalomáramlás becslési pontosságával kapcsolatban. Ezt a módszert először (Glenn, 1976)-ba vezették be. A DSET kulcsfontosságú eleme a több forrásból származó bizonyítékok kombinációja a bizonyítékok közötti konfliktus modellezésével. A Bayes-hálózatokkal ellentétben a DSET a valószínűség helyett súlyokat használ. A DSET-ben Diszkréció Keret (Frame of Discretion - FD) szabályozza a döntéshozatalt, amely a felismerhető, a feladat szempontjából fontos, egymást kölcsönösen kizáró eseményekből levonható lehetséges következtetések teljes halmaza.

A Dempster-Shafer-elméletet gyakran fúziós módszerként használják. Ez a következő két elgondoláson alapul:

- egy kapcsolódó kérdésre a szubjektív valószínűségekből kialakítjuk a hitelesítési fokozatokat majd

- hogy ezek a hitelesítési fokozatok bizonyítékként kapcsolhatók össze, ha azok független elemeken alapulnak. Azaz a hitelesítési fokozat lényegében a feltételezésben rejlő, elsősorban a javaslatot tartalmazó válaszok (a kapcsolódó kérdésekre) és az egyes válaszok szubjektív valószínűségétől függ. Vannak olyan kombinációs szabályok is, amelyek hozzájárultak az adatokra vonatkozó általános feltételezésekhez. Ebben a formalizmusban a súlyozásként megadott hitelesítési változók és nem a Bayes-féle valószínűségi eloszlás jelenik meg. A valószínűségértékek inkább az egyes események helyett a lehetőségek csoportjaira vonatkoznak. Shafer kerete lehetővé teszi, hogy a feltételezésekből előálló meggyőződés két érték által jellemzett időintervallumként jelenjen meg. A két érték a hitelesség és az elfogadhatóság jellemez. A hitelesség, a hipotézisbe vetett bizalom, a (4) szerint az általa bezárt összes készlet súlyának az összegéből (vagyis a hipotézis összes részalmazainak súlya) áll. Az a bizalom mennyisége, amely legalább részben támogatja az adott hipotézist képezi az alsó határértéket.

$$\text{Hitelesség: } Bel(A) = \sum_{X \in A} m(X) \quad (4)$$

Az elfogadhatóságot pedig a (5) és (6) alapján úgy definiáljuk, mint 1 mínusz annak a készletnek az összege, amelynek a hipotézissel való metszete üres.

Elfogadhatóság:
$$PI(A) = \sum_{X \cap A \neq \emptyset} m(X) \quad (5)$$

vagy

Elfogadhatóság:
$$PI(A) = 1 - Bel(\bar{A}) \quad (6)$$

Ez a felső korlát arra vezethető vissza, hogy a hipotézis valószínűleg megtörténhet, mert csak ennyi bizonyíték van, amely ellentmond a hipotézisnek. Felhívjuk a figyelmet arra, hogy az egymásnak ellentmondó állítások valószínűségi súlyai arra is felhasználhatók, hogy konfliktusokat keressünk a rendszerben. A versengő hipotézisek között ez a keresés egyben kritériumként is szolgál a sokszor egymásnak ellentmondó bizonyítékok csoportosítására.

A Dempster-Shafer keretrendszer másik előnye, hogy a prioritásokat és a feltételeket nem kell meghatároznunk, ellentétben a bayesi módszerekkel, amelyek gyakran a szimmetriát használják fel a valószínűségeknek a véletlenszerű változókhoz való hozzárendeléséhez (pl. 0,5 bináris értéket azokra a változókra, amelyekhez nincs elegendő információ). Ebből következően a hiányzó prioritásokban és feltételezésekben szereplő információkat nem tudunk a Dempster-Shafer keretrendszerben használni, hacsak ezek közvetve nem szerezhető be, amit nagy valószínűséggel a Bayes-egyenletek segítségével számíthatunk ki. Ennek következtében a Dempster-Shafer elmélet lehetővé teszi, hogy egy bizonyos tudatlanságot határozzunk meg a vizsgált környezetben, ahelyett, hogy kénytelenek lennénk ellátni az ismeretlen részeket valamilyen hozzárendelt valószínűségi értékkel.

4. FORGALOM ELŐREJELZÉS

A Bevezetésben felvázolt forgalom előrejelző rendszerben a heterogén adatforrások két típusba vannak besorolva: adatfolyamok és eseményalapú adatok. Az adatfolyamoknak minősített adatok olyan adatok, amelyeket folyamatosan érzékelők állítanak elő, azaz a forgalomáramlást. Az eseményalapú adatok az előforduló események, azaz a közösségi médiaadatok alapján generált adatokra vonatkoznak. A 3. ábra a közúti forgalom előrejelzésének lépéseit mutatja be. Először is, az RBM-eket az adatfolyamok és az eseményalapú adatok adatforgalmának előrejelzésére elkülönítjük. A becsült forgalmi áramlásokat K-Means

klaszterezési módszerrel csoportosítjuk (Krizhevsky et al.,

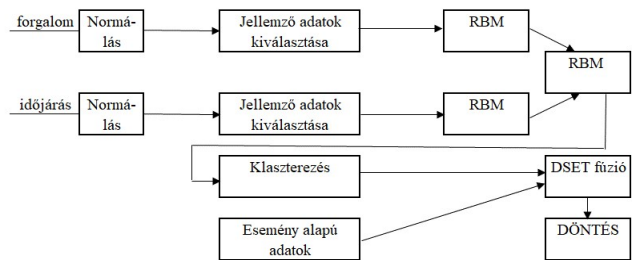
2012), majd DSET használatával összesítjük.

4.1 Forgalom előrejelzés RBM-ek használatával

Ez az alfejezet a forgalmi előrejelzés modellezését mutatja be az RBM-ek segítségével. A rendszer bemenő adatait a 3.

ábrán látható adatfolyam modulban a forgalmi és az időjárás adatok adják. Első lépésben a forgalmi és időjárás adatok [0,1] intervallumra történő normalizálása történik meg. A szolgáltatók által összegyűjtött időjárás adatokat generált puha adatoknak tekintjük. Bár az időjárás körülményt puha adatoknak tekintik, az adatok adatfolyamként kezelendők, mivel folyamatosan rendelkezésre állnak minden mintavételi időpontban. Az időjárás körülményekre 24 egyedülálló értéket vettünk fel (7) szerint, amelyek a következő viszonyokat képviselik:

$$\text{Weather} = \{\text{tisza, ködös, felhős, esős, ...}\} \quad (7)$$



3. ábra: A forgalom előrejelző keretrendszer felépítése

Annak érdekében, hogy az időjárás körülmények beépülhessenek a predikciós modellbe, az adat-ábrázolás az [1,24] tartományban egész számként történik, például tiszta = 1, ..., esős = 4.

Autókorrelációs analízis segítségével határozzuk meg a forgalom azon előző lépéseinek számát, amelyek beépülnek a predikciós modellek bemenetébe. Nagyjából 4-5 óra az az időtartam, amelyre az eredeti forgalmi értékek szignifikáns korrelációt mutatnak. Emellett a forgalmat befolyásoló legtöbb időjárás tényező kiválasztásához is korrelációs együtthatót számolunk az időjárás változók mindegyik párja és a forgalmi adatok között. Ennek során elvetik azokat az időjárás változókat, amelyek kisebb korrelációs együtthatót mutatnak az eddig meghatározott legmagasabb korrelációs koefficienssel szemben. A kiválasztott folyamatok ezután a prediktorok táplálják. Ezért a korábbi forgalmi adatok k1 lépéseit k2-lépésként a kimeneti forgalmi adatokra képezzük ki. Hasonlóan az időjáráshoz. Az aktuális időjárás adatokat k2-lépésre kipróbálják a jövő forgalmi adatainak kimenetében. Az adatfúziós lépésben a prediktorokból származó döntéseket RBM-ek segítségével a tényleges forgalmi folyamatra képezzük le kimenetnek. A 3. ábrán bemutatott eseményalapú adatmodulnál információ forrásnak a http://www.met.hu/idojaras/aktualis_idojaras/ honlapot választottuk.

4.2. Forgalom-áramlás klaszterezés és tömegosztás

Ennek a lépésnek az a célja, hogy mérni tudjuk a forgalom intenzitását. A forgalmi adatokat négy klaszterbe csoportosítjuk: alacsony (L), közepes (M), magas (H) és nagyon magas (VH) forgalom. Az adatok csoportosításához a jól ismert K-Means klaszterezés módszert használjuk, melynek az a célja, hogy az adatoknak egy olyan klaszterbe tegye bele, amelyben minden mérési adat a klaszterhez

tartozik minél közelebbi átlaggal vagy központtal. A klaszterezés során a K-Means algoritmus minden egyes adatpontot egy fürthöz rendel, és a klaszterek középpontjait a konvergenciához igazítja. Ezután a fürtek kimeneteit az egyes minta súlyának kiszámítására használjuk. Az egyes súlyok kiszámításához a következő feltevést alkalmazzuk:

A prediktorok becslési eredményeiről feltételezzük, hogy elég pontosak, úgyhogy klaszterezési hiba csak az egymás mellett található klaszterek között fordulhat elő. Ez a feltételezés fontos, mivel hangsúlyozza, hogy a becslés összetévesztése csak a klaszterek közötti határon fordul elő. Ez az állítás akkor igaz, ha elfogadható becslési pontosságú eredményekkel rendelkezünk. Ezután az előző feltételezést felhasználva kiszámítjuk a minták távolságát a központtól mért távolságait és eredményként a két legalacsonyabb távolságot választjuk ki. A kiválasztott két távolságot ezután bizonyos hitelesítési értékekkel alakítják a (8) segítségével:

ahol $C(d)$ a hitelesítési érték, d egy minta távolsága a középponttól, és α ($0 < \alpha < 1$) az exponenciális függvény súlyának szabályozására szolgál. Látható, hogy (8) a távolságot a hitelesítési érték nemlineáris függvényeként adja meg. Ha egy minta távolsága a középponttól kicsi, akkor nagy valószínűséggel kijelenthető, hogy a minta a középponthoz tartozik. Az α -t a távolság jelentőségének szabályozására használhatjuk. Miután a két legkisebb távolság hitelesítési értékeit kiszámítottuk, kiszámítjuk ezen értékek különbségét. A különbség két lehetséges esetet határoz meg:

- a különbség egy előre meghatározott kis tűrőhatáron belül van, ami klaszter hozzárendelési hibát mutat, vagy
- a különbség meglehetősen nagy, vagyis a minta biztosan az adott klaszterhez tartozik.

Az előbbi esetben a hibát a két szomszédos klaszter határainak közelében található adatok okozzák. Ezek az esetek határozzák meg a fókuszos elemek számát a teljesítménykészletben. Figyelembe véve a négy felsorolt klasztert az elemek száma a halmazban $2^4 = 16$ lesz. Az előzőekben leírtakat egy egyszerű példán keresztül vizsgáljuk meg: az alacsony (L) forgalmi adatokat tartalmazó klaszter értéke legyen $C(dL) = 0.48$, míg a közepes (M) forgalmi adatokat tartalmazó klaszter értéke legyen $C(dM) = 0.42$. Ha a két klaszter különbségtűrése 0.16, akkor az alacsony és a közepes (LM) forgalmi adatokat tartalmazó klasztercsoport hitelesítési értékét a (9) szerint számíthatjuk ki:

$$C(dLM) = C(dL) + C(dM) - |C(dL) - C(dM)| = 0.84 \quad (9)$$

Míg az összegzési kifejezés a klaszter határaitra vonatkozó hitelesítési értékeket jelöli, az abszolút különbség kifejezés a határban lévő bizonytalanságot jelöli. A három hitelesítési érték az (9) esetén ad határértékként 1-et. Amiből a végső

hitelesítési (megbízhatósági) értékek alapján már számíthatók (10):

$$C(dL)=0,2759, C(dM)=0,2414, C(dLM)=0,4827 \quad (10)$$

Ebben a példában az alacsony és a közepes forgalmi klaszterek hitelesítési értékeit állítottuk be, és a kettő közötti határhoz is rendeltünk egy hitelesítési értéket. A halmaz többi elemének súlyát nullának tekintettük. Magát a módszert az 1. algoritmus szemlélteti, megadva a súlyszabályzó α és a dt különbségtűrés valamint két távolság értéket inputként és a súlyokat megkapva eredményként. A nem vizsgált elemekhez nulla súlyt rendelünk.

1. Algoritmus: Súly hozzárendelő algoritmus

Kezdeti értékek:

a, két klaszter különbségtűrése (dt)

b, a távolság jelentőségének szabályozására szolgáló α

```
void clusterDiffTolerance(double alfa, double d1, double d2,
double dt, double* weight, int maxnum) {
```

```
    double CL, CH, CLH, m[maxnum];
    for(int i=0; i<maxnum; i++) m[i]=0;
```

```
//Két klaszter különbségtűrésének |d1,d2| meghatározása
```

```
    CL=exp(-alfa* d1);
```

```
    CH=exp(-alfa* d2);
```

```
    if(abs(d1-d2) <= dt) {
```

```
        CLH = CL + CH -abs(CL-CH);
```

```
        // normalizálás és súlymeghatározás
```

```
        m[0]=CL/(CL+CH+CLH);
```

```
        m[1]=CH/(CL+CH+CLH);
```

```
        m[2]=CLH/(CL+CH+CLH);
```

```
        //mother=0;
```

```
    }
    else
```

```
    {
        // normalizálás és súlymeghatározás
```

```
        m[0]=CL/(CL+CH);
```

```
        m[1]=CH/(CL+CH);
```

```
        //mother=0;
```

```
    }
```

```
    for(int i=0; i<maxnum; i++) weight[i]=m[i];
}
```

4.3 Dempster-Shafer hitelesítési szabályok frissítése

Mind az adatfolyamokból, mind az eseményalapú adatfeldolgozó egységekből származó döntések összefűzéséhez a Dempster frissítési szabályait használjuk. Az eseményalapú adatok egyik fő jellemzője, hogy nem folyamatosan elérhetőek. Ebben a munkában a rendelkezésre álló adatokat bizonyos időperiódusokban a http://www.met.hu/idojaras/aktualis_idojaras/ oldalairól nyerjük, amely segítségével hozzáférünk az időpont, a hőmérséklet, az átlagszél, a szellőkés, a légnyomás, a relatív nedvesség és a csapadékmennyiség adataihoz. A köztes értékeket regresszió számító algoritmussal becsüljük. Abban biztosak lehetünk, hogy a kapott adatok megbízhatatlanok. Ezért az adat- és eseményalapú adatfűző eredményét az

adatfolyamok megbízhatósági mutatójaként fogják használni. Maga az adatfúzió megvalósítása során az időjárási események által kondicionált forgalom áramlási esemény súly értékeit számítjuk ki. Ezzel a megoldással az érhető el, hogy az eseményalapú adatmodulból származó előrejelzés olyan új információnak tekintendő, amely feltételezi az adatfeldolgozási folyamatok által biztosított alapvető értékek hitelességét.

5. KÍSÉRLETEK ÉS EREDMÉNYEK ELEMZÉSE

A javasolt forgalom előrejelzés megalapozottságának vizsgálata során a kísérletekben valóságos adatokat használtuk. Esettanulmányként az M5 autópálya Budapestre bevezető szakaszát választottuk a forgalom és a DSET adatfúziós moduljának használatával történő előrejelzéshez.

5.1 Adatkészletek

Amint az a 3. ábrán látható, három adatkészletre van szükség a forgalomáramlás előrejelzés és az adatfúzió végrehajtásához az autópályáról folyamatosan érkező RBM-ek és a DSET használatához. Ebben a kísérletben a következő adatbázis kerül kiválasztásra:

- A vizsgált út forgalmát képi adatfeldolgozás alapján kapott információk alapján határozzuk meg. A forgalmi adatok folyamatosan mértük és a forgalom sűrűségi adatok percnként kerültek továbbításra, míg az időjárási adatokat az internetről töltöttük le a Budapest területére szolgáltatott hőmérsékleti, láthatósági, csapadék, szél és egyéb általános időjárási körülményekből. Mivel az időjárási adatokat minden órában generálják, ezért a köztes időtartamra egyszerű regressziós módszert alkalmazva számítottuk ki a forgalmi adatokhoz való igazítást.

5.2 Adatfeldolgozási folyamat

A forgalom előrejelzés alapfeladata a gépjárműsűrűség meghatározása. A végső cél pedig a vizsgált területen percnként áthaladó járművek számának időjárásfüggésének meghatározása, gépjármű típusok szerint. Az alapfeladat végrehajtásához nyújt segítséget a Deep Learning folyamatok. Amint azt 6. ábra is mutatja, három sáv vizsgálata folyik egy időben. A tanulási folyamat során azt kell a rendszernek megtanulnia, hogy hogy különböztetheti meg az aszfaltot (háttér) a mozgó objektumoktól. A mozgó objektum hosszát az áthaladási időből számítjuk ki. A képfeldolgozás során a kép felső, középső és alsó részén jelöltünk ki egy-egy vizsgálandó sávot. Ezekre azért van szükség, mert a mozgó objektumok számlálása során mindaddig egy objektumnak tekintünk egy belépő tárgyat, amíg az az alsó kilépési sávot el nem hagyja. Eközben vagy van újabb belépés a kép felső részén vagy nincs. Jelenleg a képméret úgy van meghatározva, hogy egy személygépkocsi hosszúságú jármű még teljes hosszában látszódjon a képen. Ebből következően mindazok a mozgó objektumok, amelyek a vizsgált sáv felső, középső és alsó vizsgálati sávjait is takarják, kamion méretűnek tekintjük. Jelenleg ennek a két objektum típusnak (gépjármű, tehergépjármű) folyik a vizsgálata.

5.3 Mérési beállítások

A forgalom előrejelzés eredményeinek bemutatásához a következő vizsgálatokat végeztük el:

- 1) Forgalomáram-előrejelzés csak történelmi forgalmi adatok felhasználásával.
- 2) Forgalmi áramlási előrejelzés történelmi forgalom és időjárási adatok felhasználásával.

5.4 A forgalmi áramlási klaszterek eredményei

Miután az előző alfejezet 1) és 2) pontjához megérkeztek az adatok - az adatáramok és szükség szerint az eseményalapú egységek előrejelzési eredményei - a következő lépés az, hogy a forgalmat az előzőleg meghatározott négy intenzitási csoportba soroljuk: L, M, H és VH. Innen az egyes szintek súlyait, beleértve a határokat, az előző alfejezetekben javasolt módszerrel számolják. A tesztadatok fűrtözését a képzési adatok csoportosításából kapott középpontok segítségével végezzük. A középpontokat a forgalom előrejelzések csoportosításában is felhasználjuk.

5.5 Forgalom előrejelzési adatok a forgalmi adatok alapján

Az RBM-ek több paramétert igényelnek, amelyeket meg kell határoznunk és hangolnunk kell. A rejtett rétegszámok 2-5 között változnak. Miután a klaszterezés során összevetjük a már meglévő és az aktuálisan érkező forgalmi adatokat, a rendszer döntést tud hozni a forgalom nagyságáról (L, M, H, VH). Erre egy RBM-eket használó döntési fúziós algoritmus alkalmazásával kerül sor. Az illusztráció érdekében a 3. ábrán vázlatosan ábrázolják az RBM-eken alapuló döntéshozatali adatfúziót alkalmazó előre jelzett forgalmi értékeket a vizsgált útszakaszon.

A folyamatot a kamerákból érkező adatok indítják el. A képfeldolgozás megkezdése előtt gondosan kiválasztottuk a vizsgált felületet, amely az M5-ös autópálya budapesti beérkező szakaszának egy része volt. A vizsgált felület magasságát 5 méterre választottuk. Ez azt jelenti, hogy egy személygépkocsi még ráfér a képre, de egy hosszabb jármű pl. kamion, már nem. 30 fps képfeldolgozási sebesség mellett a mozgó objektumok sebességét már könnyen meg tudjuk határozni. Mivel a képek felülről készültek, a rövidülésből származó méretezési hibákat jelenleg nem vettük figyelembe. A rendszer betanítása illetve használata közben a következő alapfeladatok kell elvégeznünk:

- mozgó objektum észlelése
- mozgóobjektum típusának meghatározása
- a követési távolság meghatározása
- a mozgó objektum sebességének meghatározása

Ezek az alapfeladatok határozzák meg az eredményeket. A képi adatfeldolgozást az OpenCV moduljaival végeztük el. A felületen három viszonyítási pontot helyeztünk el. Egyet legfelül, egyet középen, egyet pedig legalul. A viszonyítási pontokon történő keresztülhaladás indítja el az egyes feladatokat. A mozgó objektum észlelése a felső viszonyítási pont takarásának pillanatában indul el és felszabadulásakor áll le. A következő kép megérkezésekor meghatározzuk az objektum sebességét, amit a mérés során minden egyes újabb

kép beérkezésekor korrigálunk. A sebesség ismeretében meghatározható, hogy az objektum várhatóan hány képkocka után fogja elkezdni elhagyni a vizsgált felületet. Ha ebben a pillanatban az objektum végét még nem detektálta a rendszerünk, akkor kamion, egyébként személygépköcsi méretű tárgy van dolgunk. Az objektum mozgásirányra merőleges mérete valójában számunkra érdektelen, mert ezeket az adatokat nem használjuk fel a forgalomsűrűségi adatok meghatározásánál. A 4. ábrán végigkísérhetjük a folyamatot. Egy belépő és egy kilépni készülő gépkocsit látunk. 0,27 mp alatt tette meg az 5 méteres utat, tehát sebessége kb. 67 km/h. Mivel kilépéskor már nem takarta a felső belépési pontot, ezért személygépkocsit azonosítottunk. 1.6 mp-cel követte az előző járművet, ami kb. 30 méteres követési távolságnak felel meg.



4. ábra: Mozgó objektum a vizsgált felületen

5.6 Forgalom-előrejelzési eredmények a forgalmi és az időjárési paraméterek felhasználásával

Utolsó lépésben vizsgáljuk meg a teljes fúziós folyamatot, mint a predikciós szakasz eredményét. Az RBM-ek jelenlegi betanítási időszakában nem állt rendelkezésünkre elegendő autópálya felvétel az összes lehetséges eset lefedéséhez. Szintén nem volt elegendő időjárési típus felvételünk sem. Ezért egy szövegazonosítási eljárást alkalmaztunk, hogy megtaláljuk az RBM-ek legjobb konfigurációját időjárési adatokkal. Egyrészt az időjárési adatok letöltése során ezt egyszerűen ki lehet nyerni a kapott adatokból, másrészt az eseményalapú alapadatokat már ennek ismeretében állítottuk össze. A két prediktorból érkező elemek összekapcsolódnak az RBM-ek segítségével, ahol Dempster-Shafer alapú fúziós módszert használunk az adatok és eseményalapú adatok adatfolyamainak végső fúziójának megvalósítására. Végül az elért eredmények összehasonlítjuk az út tényleges forgalmával. Az eredményeinkből kiderült, hogy a forgalom aránylag pontosan, 80-85%-os pontossággal jelezhető előre a vizsgált 10 perces intervallumban. Bár vannak ennél jelentősebb eltérések is, melyeket két alapesetre vezethetünk vissza:

- a klaszterhatárokon elhelyezkedő adatok hibái miatt
- az időjárési adatok szűk variálhatósága miatt

6. KÖVETKEZTETÉSEK

Cikkünkben különböző forrásokból származó, heterogén adatok felhasználásával készített, rövid távú forgalmi előrejelzéseket vizsgáltunk. A közúti forgalom heterogén bemeneti adatokból történő előrejelzését Deep Learning tanuló algoritmus segítségével készítettük el és arra használtuk fel, hogy előre jelezzék az vizsgált útszakasz rövid távú forgalmát. Az adatfolyamokat képfeldolgozási

módszerek, az eseményalapú adatokat internetes adatforrásokból nyertük ki. A probléma megoldása során a neurális hálók területén alkalmazott korlátozott Boltzmann gépeket (RBM-eket), valamint a hitelesség biztosítására kidolgozott Dempster feltételes frissítési algoritmust használtuk fel. Egy esemény hitelesítését, hitelességének frissítését azért hajtjuk végre, hogy biztosítsuk az adatfolyamokból és az eseményalapú adatokból származó döntések pontosságát, vagyis, hogy jelen esetben pontosabbá tegyük a vizsgált útszakasz rövidtávú forgalom előrejelzését. Felvázoltunk néhány lehetséges forgatókönyvet arra, hogy bemutassuk a különböző típusú előrejelzések közötti különbségeket.

7. IRODALOM

- Cambridge Systematics (2004). Traffic Congestion and Reliability: Linking Solutions to Problems: Executive Summary. Federal Highway Administration.
<https://deeplearning4j.org>
- Duane, S. and Ghosh, B. (2013). Weather adaptive traffic prediction using neurowavelet models. *Intelligent Transportation Systems, IEEE Transaction on*, 14(1):370-379.
- Geoffrey, F.H., Osindero, S. and Teh, Y.W. (2006). A fast learning algorithm for deep belief nets. *Neural computation*, 18(7):1527-1554.
- Glenn Shafer et al. (1976). A mathematical theory of evidence. Princeton University Press, Princeton
- Jingrui He, Wei Shen, Phani Divakaruni, Laura Wynter and Rick Lawrence (2013). Improving traffic prediction with tweet semantics. In *Proceedings of the Twenty-Third international joint conference on Artificial Intelligence*, pages 1387-1393. AAA Press.
- Krizhevsky, A., Sutskever, I. and Hinton, G.E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. <http://www.image-net.org/challenges/LSVRC/2012/supervision.pdf>
- Lei Lin, Ming Ni, Qing He, Jing Gan, Sadek, A.W. and Transportation Informatics Tier I Director (2015). Modeling the impacts of inclement weather on freeway traffic speed: An exploratory study utilizing social media data. *to appear in Transportation Research Record: Journal of Transportation Research Board*.
- Max, G. (2012). Közlekedési szabálytalanságok, IFFK 2012, Budapest, ISBN 978-963-88875-2-8
- Max, G. (2014). Gépjárműtípus felismerés beépített SW segítségével, IFFK 2014, Budapest, ISBN 978-963-88875-2-8

Rehborn, H. and Koller, M. (2014). A study of the

influence of severe environmental conditions on

common traffic congestion features. *Journal of*

Advanced Transportation,48(8):1107- 1120.

Sentz, K. and Ferson, S. (2002). Combination of Evidence in Dempster-Shafer Theory. *Sandia National Laboratories*, SAND2002-0835

Yisheng Lv, Yanjie Duan, Wenwen Kang, Zhengxi Li and Fei-Yue Wang (2015). Traffic flow prediction with big data: A deep learning approach. *Intelligent Transportation Systems, IEEE Transactions on*, 16(2):865-873.

Wenhao Huang, Guojie Song, Haikun Hong, and Kunqing Xie (2014). Deep architecture for traffic flow prediction: Deep belief networks with multitask learning. *Intelligent Transportation Systems, IEEE Transactions on*, 15(5):2191-2201.

