

Városi járműforgalom térbeli becslése kernel módszerek segítségével

A modern, intelligens forgalomirányító rendszerek számára a közlekedési hálózat minél pontosabb valós idejű ismerete szükséges. A bemutatott módszer segítségével a detektorok nélküli útszakaszok forgalomnagysága is megbecsülhető.

<https://doi.org/10.24228/KTSZ.2021.5.3>

Dr. Varga Balázs – Dr. Tettamanti Tamás


BME Közlekedésmérnöki és Járműmérnöki Kar, Közlekedés- és Járműirányítási Tanszék
e-mail: varga.balazs@kjk.bme.hu, tettamanti.tamas@kjk.bme.hu

1. BEVEZETÉS

Egy városi közlekedési hálózatban a forgalmi állapotok minél több keresztmetszetben való pontos ismerete számos intelligens közlekedésirányítási megoldás hatékony működése számára kulcsfontosságú. Jármű szinten például az egyes útszakaszokon a késések ismeretében pontos útvonalajánló algoritmusok tervezhetők. A sebesség vagy forgalomnagyság állapotok térbeli és időbeli lefolyása segítségével adaptív forgalomirányítás hozható létre. Nagy mennyiségű adat segítségével felismerhetők a forgalmi mintázatok és a szűk keresztmetszetek. Számos tudományos munka foglalkozik a szenzorok városi hálózatban történő minél hatékonyabb elhelyezésével annak érdekében, hogy a lehető legtöbb információt nyerhessük a hálózat pillanatnyi állapotáról [1], [2], [3]. Önmagában a szenzorok hatékony elosztása nem elegendő a hálózat elvárt felbontású mérésére. Ezen felül, nagyszámú detektor telepítése, üzemeltetése és karbantartása nagyon költséges feladat. Ebből kifolyólag fontos a hálózat nem mért helyein a forgalmi állapotok becslése valami-

lyen matematikai modell vagy adatvezérelt gépi tanulási eljárás segítségével. A becslés nehézségét az adja, hogy a földrajzilag szét-szórt detektorok közötti korreláció nem egyértelmű. Hatékony becsléshez az első feladat a mérési pontok közti korrelációk meghatározása. [4] légvonalban és közúton mért távolságok alapján próbálta meghatározni a detektorok mérési eredményei közötti kapcsolatot és próbált interpolációval újabb keresztmetszetekben forgalomnagyságot becsülni. [5] szerint a forgalomnagyság predikció szempontjából nincs jelentős különbség abban, hogy a helyszínek közötti távolságot hogyan határozzuk meg. Habár az algoritmus megfelelően működött, lehetséges olyan hálózati topológia, ahol ez a fajta hasonlósági metrika pontatlan lesz. Erre az 1. ábra szolgáltat szemléletes példát. Két ellentétes irányú forgalmi sáv esetén, ha két detektor egymás mellett helyezkedik el, de az ellentétes irányt méri, akkor a két detektor mérése nem korrelál, hiába vannak egymáshoz földrajzilag közel. Hasonlóképp, ugyanabban a forgalmi sávban egymástól távolabb eső detektorok mérései nagy valószínűséggel korrelálni fognak.

1. ábra: Detektorok távolsága két ellentétes irányú forgalmi sávban



Az autópályákon a földrajzi távolság szerinti interpoláció kellően jó pontosságot biztosít [6], azonban egy városi hálózatban ez nem mindig igaz.

A pontosabb forgalombecslés érdekében olyan – adatvezérelt – hasonlósági metrikát vezetünk be, amely a fentieknél pontosabban képes az egyes detektorok mérési adatai hasonlóságának leírására. A módszer a városi hálózatban található fix mérési pontok historikus adatain, illetve a megbecsülni kívánt lokáción ideiglenesen telepített szenzorok adatain alapszik. Amennyiben a forgalmi mintázatok jelentősen nem változnak, az ideiglenesen telepített detektorok adatai jól becsülhetők térbeli regressziós eljárások segítségével.

A bemutatott két ilyen térbeli forgalombecslési eljárás: a független Gauss folyamatok sorozatának segítségével és a Kriging módszerrel. Mindkét módszer pontosabb becslést szolgáltat a földrajzi vagy közúton mért távolsággal értelmezett hasonlósági metrikákkal végzett regresszióknál. A pontosság ára, hogy a becsülni kívánt helyeken előzetes információra van szükség a múltbeli forgalom nagyságokról. Az eljárás célja és egyben a cikk kontribúciója olyan helyeken is meghatározni a forgalom nagyságát, ahol nem áll rendelkezésre pillanatnyi mérés. Ezzel a hálózat állapotai részletesebben leírhatók, javítva az intelligens forgalomirányító berendezések hatékonyságát.

2. ADATVEZÉRELT TÁVOLSÁG-METRIKA

A térbeli predikciós algoritmusok legfontosabb eleme a helyszínek mérési eredményei

közötti kapcsolatot leíró távolságmetrika. Itt a távolságmetrika a detektorok múltbeli mérési adataiból kerül meghatározásra. Legyen a hálózatban N darab útszakasz, ahol folyamatosan működnek detektorok és legyen M darab ideiglenesen telepített (mobil detektor vagy kézi forgalomszámlálás). Ezek a detektorok fix időközönként (pl. 5 percenként) mintavételezik a forgalom nagyságát az adott keresztmetszetben. A detektorok mérési eredményeinek hasonlósága az általuk mért elegendően hosszú idősorok hasonlósága alapján számítható. Egy idősor hossza lehet egy nap vagy akár egy teljes hét. Ezzel lehetséges szétválasztani eltérő forgalmi mintázattú időszakokat (pl. hétköznapok, hétvégék, ünnepnapok). Legyen két mért keresztmetszet i és j , $i, j \in 1, 2, \dots, N+M$. Ekkor a hasonlóság („távolság” d_{ij}) két detektor (i és j) között a következő módon állítható elő. Legyen $Q_i([t_a, t_b])$ és $Q_j([t_a, t_b])$ a forgalom nagyság (jármű/óra) két keresztmetszetben t_a és t_b időpontok között.

1. Normalizálás: annak érdekében, hogy két hasonló forgalmi mintázattal rendelkező, de más forgalom nagyságú hely összevethető legyen egymással, az idősorokat normalizálni kell:

$$\bar{Q}_i([t_a, t_b]) = \frac{Q_i([t_a, t_b])}{\max(Q_i([t_a, t_b]))} \quad \forall i = 1, 2, \dots, N+M.$$

2. Hasonlósági mérték: a normált forgalom nagyságokat felhasználva és az idősorok különbségének 2-es értelemben vett normáját képezve előáll egy alkalmas, múltbeli mérési adatokon alapuló távolságmetrika:

$$d_{ij} = |\bar{Q}_i([t_a, t_b]) - \bar{Q}_j([t_a, t_b])|_2.$$

A d_{ij} értékeket egy szimmetrikus hasonlósági mátrixba rendezve:

$$D = \begin{bmatrix} d_{11} & d_{12} & \dots & d_{1(N+1)} \\ d_{21} & d_{22} & \dots & d_{2(N+1)} \\ \vdots & \vdots & \ddots & \vdots \\ d_{(N+1)1} & d_{(N+1)2} & \dots & d_{(N+1)(N+1)} \end{bmatrix}$$

Ez a mátrix a detektorok egymáshoz képesti relatív hasonlóságát adja meg. A relatív metrika abszolút metrikává transzformálása több előnnyel bír. Az abszolút metrika lehetőséget ad a probléma geometriai értelmezésére és a dimenzióredukcióra.

3. Többdimenziós skálázás (multidimensional scaling) és dimenzióredukció: a többdimenziós skálázás algoritmus egy páronkénti távolságmátrixot egy olyan nagydimenziós térbe transzformál, amelyben a kapott mátrix (X) sorainak euklideszi távolsága visszaadja az eredeti D mátrixot [7]. A kapott szimmetrikus, négyzetes X mátrix legkisebb sajátértékeihez tartozó oszlopai eltávolíthatók. Ezen oszlopok bírnak a legkisebb információtartalommal a hasonlóságra vonatkozóan, így ezen dimenziók eltávolításával D továbbra is kellő pontossággal helyreállítható [8]. A dimenzióredukció megkönnyíti a térbeli forgalombecslést. Az X mátrix minden sora egy detektor ezen nagydimenziós térbeli koordinátáit reprezentálja.

4. X rögzítése: a múltbeli $[t_a, t_b]$ közötti adatok alapján kapott X a jelenbeli térbeli predikció során legyen állandó. Ha a forgalmi mintázatok nem térnek el drasztikusan a $[t_a, t_b]$ intervallumbelől, akkor X segítségével a pillanatnyi forgalomnagyság pontosan becsülhető.

Itt megjegyzendő, hogy a folyamatosan működő N detektor aktuális méréseit figyelve előfordulhatnak a múltbeli rögzítettől eltérő forgalmi mintázatok. Ekkor a forgalombecslés kevésbé megbízható. Ennek oka lehet akár valamilyen szezonális változás vagy a forgalmi rend megváltozása.

3. FORGALOMBECSLÉS GAUSS FOLYAMATOKKAL

A Gauss folyamatok (Gaussian Process, GP) segítségével függvények becsülhetők valószínűségi értelemben. Egy Gauss folyamat felfogható többdimenziós valószínűségi vektorként,

ahol a vektor minden eleme egy Gauss eloszlásból vett mintavétel. Egy Gauss folyamatot egyértelműen meghatároz a trendfüggvénye (közéérték) és egy kovariancia kernel. Függvényapproximációra ez úgy használható, hogy a tanítópontokat (méréseket) az adott helyen egy Gauss eloszlás egy mintavételeként értelmezzük. A regresszió célja olyan függvény előállítás, amely a legjobban illeszkedik a tanítópontokra [9].

Adott egy Gauss folyamat, amelynek tanítópontjai a $Q_i(t)$ forgalomnagyságok az x_i nagydimenziós térben vett helyeken t időpillanatban és $i = 1, 2, \dots, N$. Az első feladat ezen pontokra egy Gauss folyamat illesztése, majd ezen Gauss folyamattal a hiányzó M hely forgalomnagyságának becslése. Egy adott t időpillanatban a forgalomnagyságot a hely függvényében leíró függvény

$$Q^*_t(x) \sim GP(m(x), k(x, x'))$$

egy Gauss folyamat, ahol $m(x)$ a folyamat várható értéke, $m(x) = E(Q^*_t(x)) = 0$ (a Gauss folyamat nem érzékeny a trendfüggvényre), a kovarianciája pedig egy négyzetes exponenciális kernellel kerül modellezésre:

$$k(x, x') = E(Q^*_t(x) - m(x))(Q^*_t(x') - m(x')) = \sigma^2 e^{-\frac{1}{2\theta^2}(x-x')^T(x-x')} + a^2 \delta_{x,x'}$$

ahol a kernel keresett hiperparaméterei $[\sigma, \theta, a]$. σ^2 a mérési pontok közötti szórászt skálázza, θ^2 egy hosszparaméter, amely a függvény simaságát állítja, végül a^2 egy zaj, amely a becslés bizonytalanságát veszi figyelembe. $\delta_{x,x'}$ a Kronecker delta. A hiperparaméterek a negatív logaritmusos határvalószínűség minimalizálásával számíthatók [9]. A kapott függvénybe behelyettesítve a becsléni kívánt hely x koordinátáit, a forgalomnagyság egy Gauss eloszlással (várható érték, szórás) megkapható.

4. FORGALOMBECSLÉS KRIGING MÓDSZERREL

A Kriging szintén kerneleken alapuló predikciós eljárás, amit elsősorban a földtudo-

mányokban használnak a földben levő anyagok koncentrációjának térbeli eloszlásának becslésére [10]. Az eljárás hasonló a Gauss folyamatokkal történő becsléshez, viszont külön kezeli a trendet és a kovarianciát: a trend egy általánosított legkisebb négyzetek módszerével kerül meghatározásra, a maradékok pedig egy zéró várható értékű Gauss folyamattal vannak becslve. Legyen a Kriging prediktor a következő alakban definiálva:

$$Q_{|t}^*(x) = \sum_{j=1}^m \beta_j g_j(x) + GP(0, k(x, x')),$$

ahol g_j bázisfüggvények (x j -edik hatványai (x^0, x^1, \dots, x^j)) és β_j ezek együtthatói. Tehát a tendet egy polinommal közelítjük. A kovariancia kernel itt is definiálható négyzetes exponenciálisként a korábbiakban leírtak szerint. A $G_x = [g_1(x), g_2(x), \dots, g_m(x)]^T$ a keresett helyen a bázisfüggvények vektora, $G = [G_{x_1}, G_{x_2}, \dots, G_{x_N}]^T$ a mért helyek dizájn mátrixa, $K_x = [k(x_1, x), k(x_2, x), \dots, k(x_N, x)]^T$ és $K = [k(x_i, x_j)]_{ij}$, $i, j = 1, 2, \dots, N$. Ebből az ismeretlen forgalomnagyság x helyen a következőképp határozható meg:

$$Q_{|t}^*(x) = [G_x^T \quad K_x^T] \begin{bmatrix} 0 & G^T \\ G & K \end{bmatrix}^{-1} \begin{bmatrix} 0 \\ Q_{|t}([x_1, x_2, \dots, x_N], t) \end{bmatrix}$$

A becslés négyzetes középhibája pedig

$$MSE(Q_{|t}^*(x)) = \sigma_z^2 \left[1 - [G_x^T \quad K_x^T] \begin{bmatrix} 0 & G^T \\ G & K \end{bmatrix}^{-1} \begin{bmatrix} G_x \\ K_x \end{bmatrix} \right],$$


ahol σ_z^2 a folyamat szórásnégyzete [11].

5. NUMERIKUS PÉLDÁK

Ebben a fejezetben egy valós városi hálózat különböző helyein mért forgalomnagyságok alapján kerül összehasonlításra a két bemutatott algoritmus. A példákban felhasznált hálózat az olaszországi Torinó belvárosa (2. ábra). A detektor adatok $N=20$ helyről érkeznek óránkénti felbontásban, jármű/óra mértékegységgel. A cél egy további helyen ($M=1$) meghatározni az óránkénti forgalomnagyságot. Erről a helyről rendelkezésre áll a múltból forgalomnagyság mérés (ideiglenes detektoradat), és

feltételezzük, hogy a jelenlegi forgalmi mintázatok jelentősen nem térnek el a múltbelitől. Ehhez először a 2. fejezetben ismertetett módon múltbeli (2 hét hosszú) adatsorok segítségével mind a 21 detektorra meg kell határozni azok egymáshoz képesti távolságát és az X mátrixot.


2. ábra: Detektor lokációk Torinóban. A becsülni kívánt keresztmetszet GPS koordinátái: lat: 45.095, lon: 7.6954. Forrás: <https://snazzymaps.com>



Az első térbeli predikció független Gauss folyamatok segítségével történik. A cél egy teljes napra meghatározni az óránkénti forgalomnagyságot. Ehhez 24 független Gauss folyamatra van szükség, amely a nap minden órájában az adott órában mért forgalomnagyságokra egy-egy térbeli Gauss folyamatot illeszt. A becsülni kívánt helyen az approximált függvények segítségével megállapítható az egy napra vonatkozó forgalom lefolyása (3. ábra). Az eredmények azt mutatják, hogy ez a megoldás a forgalom várható értékét jól becsüli (RMSE = 99,94), viszont meglehetősen bizonytalanul, amit a nagy szórás tükröz. Ennek oka, hogy az x_i tanítópontoktól távol a becslés egyre bizonytalanabb lesz.


Kriging segítségével (elsőfokú polinomokat használva trendfüggvényként) a becslés pontos

3. ábra: Független Gauss folyamatokkal becsült egynapos járműforgalom, RMSE = 99,94



sabb (4. ábra). Itt a négyzetes középhiba (RMSE) kisebb, $RMSE = 82,42$, a predikció szórása jelentősen kisebb. Meg kell jegyezni, hogy a szórási értéke egyik esetben sem garantálja, hogy egy újabb mérési pont a szórás által meghatározott intervallumon belülre essen, viszont jó indikátora a becslés megbízhatóságának. A Gauss folyamatokhoz képesti kisebb szórás oka a trendfüggvény eltérő kezelésében keresendő. A Kriging a trendre egy regressziót illeszt, és a regresszió hibáját az additív Gauss folyamattal korrigálja. Az egyszerű Gauss folyamattal történő becslés csupán a kovarianciakernel

4. ábra: Kriginggel becsült egynapos járműforgalom, RMSE = 82,42



hiperparamétereinek hangolásával próbál minél jobb becslést adni. Mindkét esetben pontosabb értéket kapunk, mint ha a választott távolságmetrikánk sima földrajzi távolság lenne. Ekkor Kriginggel az RMSE értéke 135,1 jármű/óra.


A térbeli predikció során az X mátrix állandónak tekintett. Amennyiben a forgalmi mintázatok megváltoznak, például szezonális változások vagy for-

galmi rend változása miatt, X már nem fogja pontosan visszaadni a mért keresztmetszetek közötti hasonlóságot. Hasonlítsuk össze a rögzített X -et egy új, mozgó ablakban folyamatosan (1 napos időintervallumokban) számítottal ($X'(t)$). A két mátrix eltérését összehasonlítvá

$$e(t) = \frac{1}{N + M} \|X - X'(t)\|_2$$

mátrixnorma segítségével, az 5. ábra szerinti alakuláshoz jutunk. A vizsgált 4 hónapos időszakban $X'(t)$ minden napra kiszámításra került. Látható, hogy az idő előrehaladtával a hasonlóság csökken (e növekszik), továbbá megfigyelhető egy, a hét napjai szerinti periodikusság. Ez megfelel Weijelmars [12] eredményeinek, miszerint a vasárnapok forgalmai jelentősen eltérnek a hétköznapi és más munkaszüneti napok forgalmi mintázataitól.

5. ábra: Becsléshez használt hasonlósági metrika jósága



6. KONKLÚZIÓ, JÖVŐBENI KUTATÁSI IRÁNYOK

Olyan módszereket vizsgáltunk, amelyek segítségével méretlen útszakaszok forgalomnagyságai becsülhetők. Ehhez a különböző keresztmetszetekben mért forgalomnagyságok hasonlóságára egy új távolságmétriKA került kidolgozásra. A detektorok múltbeli idősorai alapján azok hasonlósága kvantifikálható. Az így kapott páronkénti hasonlóságokat transzformálva alkalmassá válnak a járműforgalom térbeli becslésére. Ezen metrika felhasználásával két kerneleken alapuló módszer került bemutatásra. Független Gauss folyamatok sorozatával forgalomnagyság-adatok kerültek meghatározásra egy új lokációban. Hasonlóképp, ugyanezen adatok felhasználásával Kriging módszerrel is megbecsültük ugyanitt a járműforgalmat. Szimulációs eredmények alapján az adatvezérelt távolságmétriKA mindkét módszer felhasználásával jobb eredményt ad, mint ha a detektorok hasonlóságát azok földrajzi távolsága határozná meg. A Gauss

folyamatok sorozataként végzett becslés kevésbé pontos, mint a Krigingé, és a szórása is jóval nagyobb. Ennek lehetséges oka, hogy a Kriging a trendet explicit módon kezeli.

A kutatás továbbvitelére több lehetőség van. Egyrészt a távolságmétriKA a jelenlegi megközelítésben fix. Ezt új adatok beérkezésével célszerű lenne adaptív módon változtatni és monitorozni a távolságmétriKA jóságát. Egyszerű megoldásként több X felvétele és ezek közötti kapcsolgatás a pillanatnyi forgalmi mintázat függvényében (pl. hétköznap, hétvége, reggeli csúcs, délutáni csúcs stb.). Ezen kívül

a becslést célszerű alkalmassá tenni időbeli becslésekre is. Ehhez a felírt becslési algoritmusokba a térbeli függésen felül bele kell venni az időfüggést is.

KÖSZÖNETNYILVÁNÍTÁS

A publikáció az Innovációs és Technológiai Minisztérium ÚNKP-20-3 kódszámú Új Nemzeti Kiválóság Programjának a Nemzeti Kutatási, Fejlesztési és Innovációs Alapból finanszírozott szakmai támogatásával készült. A kutatás kapcsolódik továbbá a „Digitálisan összekapcsolt adatforrásokra alapozott, dinamikus, hangolt és adaptív városi forgalomirányítási rendszer szolgáltatások és beavatkozási, értékelési közlekedéspolitikai eszköztár kifejlesztése” c. piacvezérelt kutatás-fejlesztési és innovációs projekthez (NKFIH, 2019-1.1.1-PIACI-KFI-2019-00330).

A szerzők szeretnék köszönetet mondani a Nápolyi II. Federico Egyetem Közlekedésmérnöki Tanszékének a felhasznált adatokért.

FELHASZNÁLT IRODALOM

- [1] Lawrence A. Klein, Milton K. Mills, and David R. P. Gibson. *Traffic detector handbook: Volume I*. No. FHWA-HRT-06-108. Turner-Fairbank Highway Research Center, 2006.
- [2] Yang Liu, and Ning Zhu. "A multi-objective detector location optimization approach." In *CICTP 2014: Safe, Smart, and Sustainable Multimodal Transportation Systems*, pp. 1788-1800, 2014. DOI: <https://doi.org/gt4f>
- [3] Jianming Hu, Jingyan Song, Mingchen Zhang, and Xiaojing Kang. Topology optimization for urban traffic sensor network. *Tsinghua Science and Technology*, 13(2):229-236, 4-7 July, 2014, Changsha, China. DOI: <https://doi.org/b9xnnf>
- [4] Haixiang Zou, Yang Yue, Qingquan Li, and Anthony G. Yeh. An improved distance metric for the interpolation of link-based traffic data using kriging: a case study of a large-scale urban road network. *International Journal of Geographical Information Science*, 26(4):667-689, 2012. DOI: <https://doi.org/bd3633>
- [5] Brent Selby and Kara M Kockelman. Spatial prediction of traffic levels in unmeasured locations: applications of universal kriging and geographically weighted regression. *Journal of Transport Geography*, 29:24-32, 2013. DOI: <https://doi.org/f4vv3x>
- [6] Bumjoon Bae, Hyun Kim, Hyeonsup Lim, Yuandong Liu, Lee D Han, and Phillip B Freeze. Missing data imputation for traffic flow speed using spatio-temporal cokriging. *Transportation Research Part C: Emerging Technologies*, 88:124-139, 2018. DOI: <https://doi.org/gdbch3>
- [7] Michael A. Cox and Trevor F Cox. Multidimensional scaling. In *Handbook of data visualization*, pages 315-347. Springer, 2008. DOI: <https://doi.org/gt4h>
- [8] Ian T Jolliffe. A note on the use of principal components in regression. *Journal of the Royal Statistical Society: Series C (Applied Statistics)*, 31(3):300-303, 1982. DOI: <https://doi.org/dw25m4>
- [9] Rasmussen, C. E. "Gaussian processes in machine learning", Springer, Berlin, Germany, 2003. DOI: <https://doi.org/fhqcwv>
- [10] Noel Cressie. The origins of kriging. *Mathematical geology*, 22(3):239-252, 1990.
- [11] Michael James Sasena. Flexibility and efficiency enhancements for constrained global design optimization with kriging approximations. PhD thesis, University of Michigan
- [12] Weijermars, Wendy, and Eric Van Berkum. "Analyzing highway flow patterns using cluster analysis." *IEEE Intelligent Transportation Systems*, 2005. DOI: <https://doi.org/dswz6d>



Spatial estimation of urban vehicle traffic using kernel methods

The authors investigated methods that can be used to estimate traffic volumes on unmeasured road segments. To this end, a new distance metric has been developed based on the traffic volumes measured in different cross-sections. Based on the time series of the detectors, measured in the past, their similarity can be quantified. By transforming the pairwise similarities thus obtained, they become suitable for the spatial estimation of vehicle traffic. Using this metric, two kernel-based methods have been presented.



Räumliche Schätzung des städtischen Fahrzeugverkehrs mit Kernel-Methoden

Die Autoren untersuchten Methoden, mit denen sich das Verkehrsaufkommen auf den Straßenabschnitten, wo keine Messungen durchgeführt werden, abschätzen lässt. Zu diesem Zweck wurde eine neue Distanzmetrik entwickelt, die auf den in verschiedenen Querschnitten gemessenen Verkehrsmengen basiert. Anhand der in der Vergangenheit gemessenen Zeitreihen der Detektoren kann deren Ähnlichkeit quantifiziert werden. Durch Transformation der so erhaltenen paarweisen Ähnlichkeiten werden sie für die räumliche Schätzung des Fahrzeugverkehrs geeignet. Unter Verwendung dieser Metrik wurden zwei Kernel-basierte Methoden vorgestellt.