

## Valós idejű gyalogos mozgáspálya meghatározás lehetőségei konvolúciós neurális háló alapú eljárással, közepes forgalommal terhelt városi környezetben.

Rózsás Zoltán\*; Prof Dr. Lakatos István\*\*


\*Széchenyi István Multidiszciplináris Műszaki Tudományi Doktori Iskola, Közúti és Vasúti Járművek Tanszék  
(rozsas82@gmail.com)

\*\* Széchenyi István Egyetem, (e-mail: drlakatosi@gmail.com)

Absztrakt: Az európai unióban a lakott területen bekövetkező halálos kimenetelű balesetek jelentős része, hozzávetőleg 70%-a sérülékeny úthasználó, köztük gyalogos, motoros és kerékpáros. Ezeknek a végzetes kimenetelű eseményeknek az észleléséhez és előrejelzéséhez nyújt új lehetőséget a mély tanulás valamint konvolúciós neurális hálók alkalmazása, melyek a legkorszerűbb megoldásokat képviselik. Ezek az eljárások a pontosság szempontjából számos számítógépes látási feladathoz, például objektumészleléshez, szegmentáláshoz és képosztályozáshoz is alkalmazhatók. A korábbi érzékelési lehetőségekkel együtt alkalmazva, azokat kiegészítve robusztusabb eljárások hozhatók létre. A dokumentumban egy CNN-nel közelített gyalogos mozgáspályája modelljét vizsgálom, mellyel olyan új összefüggések ismerhetők meg, amelyek jelentősen javíthatják az előrejelzés minőségét, és ezen keresztül a közlekedésbiztonságot.

### 1. BEVEZETÉS

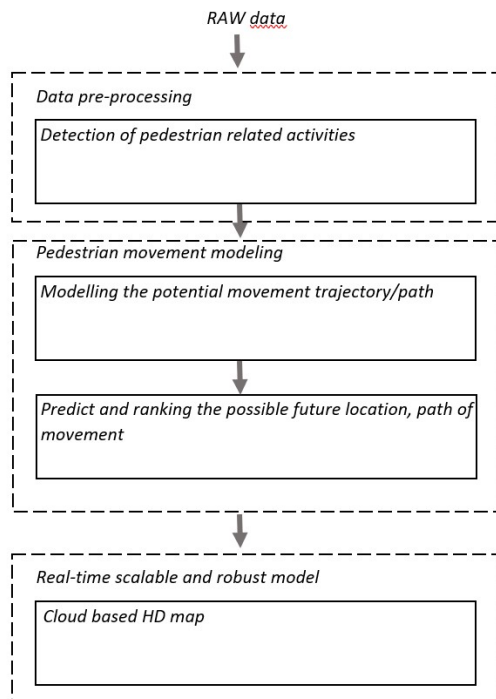
Napjaink fejlett érzékelő eljárásai számos új, a biztonságos közlekedéshez nélkülözhetetlen információ feldolgozását teszik lehetővé. A mély neurális hálók közelmúltbeli fejlődése jelentős előrelépést hozott a gyalogos észlelési módszerek terén [1–4]. Az egyik legelterjedtebb ilyen alkalmazás a YOLO v4 (1.ábra) amely az MS COCO adatkészletén, 43,5%-os AP (Average Precision) -val, és 65 képkocka/másodperc sebességgel, az egyik legjobban ilyen eszköz [5]. Míg az egyes észlelési módszerek jelentősen javultak és felgyorsultak, ennek ellenére továbbra is kihívást jelent, a kitakart részek, a sok résztvevős komplex csomópontok, valamint különböző reflexiók pontos értelmezése. A cikkben egy zalaegerszegi közepes forgalommal terhelt csomópontban felvett gyalogos mozgáspályáját elemzem, melyhez YOLO V4/Python kódkészletet használok. A felvételekből elérhető adatok tartalmazzák az objektumhoz tartozó klasszifikációt és a képen belüli helyzetet.



1. ábra. A v4-es verzió 10% jobb AP értékkel és 12% jobb FPS értékkel bír az előző verzióhoz képest, és kétszer gyorsabb feldolgozást tesz lehetővé, mint az EfficientDet [5]

## 2. Gyalogos érzékelés és előrejelzés teljes modellje

A járművek érzékelő rétegeiből, valamint az út mentén telepített statikus érzékelőkből kinyert adatok együttes feldolgozásával valós idejű, robusztus, skálázható nagyfelbontású térkép érhető el. A 2. ábrán látható Gyalogos érzékelés és előrejelzés teljes modellje, melynek a dokumentumban vizsgált mérés, teoretikusan több más méréssel együtt a bemenetét adhatja.



2. Ábra. Gyalogos érzékelés és előrejelzés teljes modell

A felvételen lefutott CNN alapú YOLOv4 deep sort kóddal kinyertem a „person 13”-hoz tartozó gyalogos becsült mozgáspálya adatsorát, ami valós időben is elérhető. A kapott trajektória laterális irányára, a mérhető folyamatképesség alapján olyan szabályzóhatárokat keresek, melyek a történelmi adatok alapján különböző események predikcióját teszik lehetővé. A szabályzóhatárok pontos definiálásához több közelítő függvényt is megvizsgállok.

## 2. KÍSÉRLETI MÉRÉSEK

A felvétel a forgalom irányító lámpa magasságában elhelyezkedő nézőpontból készült (3.ábra), 7350 mm távolságra az útburkolattól, a vizsgált kereszteződés 8 és 36 méteres távolságban van (vízszintesen vetületen mérve).



3. ábra - Adatgyűjtés: Zalaegerszeg – Rákóczi Ferenc u. Arany János u, Kert u. kereszteződés

A programból a 4. ábra szerinti formátumban nyerhető ki az adatok, melyben minden képkockához tartozik egy adatsor, amely tartalmazza a beazonosított objektum klasszifikációját, és az objektum koordinátáit. A konvencionális vonatkoztatási rendszertől eltérő megközelítésben kerülnek kiosztásra a koordináták, amelyben a 0;0 koordináta a kép bal felső sarkában van. Az egyes pontok képhez illesztéséhez egy  $X_s$  pontot hozok létre minden objektumhoz tartozó koordinátából, (1. egyenlet) amely hozzávetőleg a súlypont vetülete a felszínen.

$$X_s = \left[ X_{\min} + \frac{X_{\max} - X_{\min}}{2}, Y_{\max} \right] \quad (1)$$




4. ábra – Kinyert adatok transzformálása

A 21 másodperces felvétel feldolgozása során, amely 525 képkockát tartalmaz, több mint 5000 objektum detektálás történt valamilyen klasszifikációva. A kiértékelés során a távolabbi gyalogátelőkön az azonosítás és követés lényegesen gyengébb, még a YoloV4 CNN -amely egy valószínűségi változóval és kategorizálással azonosítja az objektumot- nagy számban ismert fel (6.ábra) a távolabbi személyeket, addig a koordináták kinyerésére is alkalmas „deep sort” többet tévesztett a távoli objektumok esetén (5. ábra). Az 5. és 6. ábrán látható, azonos képkocka esetén a kódkészletek közötti különbség.



5. ábra – YoloY4 deep sort



6. ábra – YoloV4

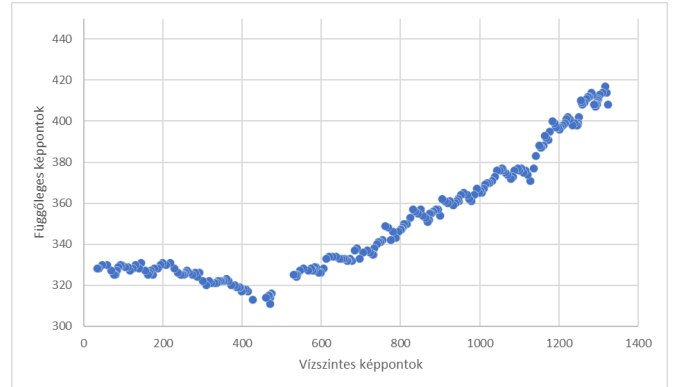
A képkockákhoz tartozó koordináták diszkrét valószínűségi változók, mivel véges számú képpont van, amelyet az  $X_s$  pont vehet fel, ebben az esetben az  $1920 \times 1080$  képpont azon része, amelyen észlelés mentes kezdeti állapotban az útburkolatot vagy a járdafelületet tartalmazza. Ez az érték az elméleti maximum. Az adatsorban 18 gyalogosátkelés valósul meg, látszólag egyenes vonalban és egyenes sebességgel haladnak. A 18-ból 5 páros átkelés történik. Az adatsorban egy képkockához tartozóan adták a koordináták (több objektum koordinátája is), ahogy a 4. ábrán is látszik, ezeket egy táblázatban rendeztem így a kiválasztott „person-13” azonosítóval ellátott személyre leszűrve, 235 pont jött így létre, amelyet a 7. ábra mutat.



7. ábra – „person 13” gyalogos pályája


## 2.1 Gyalogos észlelt mozgáspálya sajátosságai

Az  $y$  tengely az érzékelhetőbb volatilitás érdekében csak a használt tartományra koncentrál. Az  $x; y$  értékek a 8. ábrán bemutatottól eltérően a konvencionális vonatkozási rendszerben értelmezhetőek, ahol kép bal alsó sarkába eső képpont az első  $1; 1$  koordináta, az  $x$  és az  $y$  tengelyek egybeesnek a kép orientációjával.



8. ábra - A gyalogosra felvett bounding box alsó élének oldalfelező pontjai

A kiválasztott gyalogos a látó mezőben jobbról balra halad, egyenes sebességgel, irányváltoztatás nélkül, biztonságosan átkel az úttesten. Az úttestre lépés előtt a jobb vállá felett hátra tekint. Az 7. ábrából kiválasztok két részt, (9. ábra) hogy megvizsgáljam a kapott trajektória pontok tulajdonságait. Az útra lépést megelőzően növekedett a pontok „ $y$ ” irányú szórása, még az oszlop kitakarások esetében több pont is hiányzik a bejárt pályából.



9. ábra – bal oldalt a kitakart rész, jobb oldalt az útra lépés során érintett pontok láthatóak.


Az eloszlás ismeretében képet alkothatunk arról, hogy milyen valószínűséggel kapunk adott tőrészhatárok közötti koordináta pontokat, annak ellenére, hogy a valóságban a mozgáspálya paramétereinek eloszlása ismeretlen. A folyamat képesség statisztikai értelmezéséhez transzformálom az adatokat, így nem jelennek meg a megfigyelés sajátosságaiból adódó zajok. Ebben az esetben az „ $x$ ” irányú komponensek (azok különbsége), közel a gyalogos sebesség vektorát adják, és mivel ez ebben az esetben jelentősen nem változik, ezért a továbbiakban csak az „ $y$ ” értékek lehetséges paramétereivel foglalkozom, amely ebben az esetben a gyalogos oldalirányú mozgása.



A látómezőben a kiválasztott személy a horizonttal nem párhuzamosan halad, ezért az „y” értékeket az (1. táblázat) szerint korrigálom, hogy a haladás irányszöge ne legyen hatással a person 13 „y” értékeire”. Ez a 10.ábrán a narancsszínnel jelölt új pontokat eredményezi.

	Xsx	Xsy	eh.	Xsytotal korr..	Korr/pixel	Új Xsy
Frame #: 4	1323	408	87	0,5341	46,47	361,53
Frame #: 5	1320	414	86	0,5341	45,93	368,07
Frame #: 6	1316	417	85	0,5341	45,40	371,60
Frame #: 7	1309,5	414	84	0,5341	44,86	369,14
Frame #: 8	1302	413	83	0,5341	44,33	368,67
***	---	---	---	---	---	---
**	---	---	---	---	---	---
*	---	---	---	---	---	---

1.táblázat – irányszög korrekció




10. ábra – piros az eredeti, narancssárga az új korrigált „y” értékkel

### 3. GYALOGOS TRAJEKTÓRIA LEHETSÉGES KÖZELÍTŐ FÜGGVÉNYEI

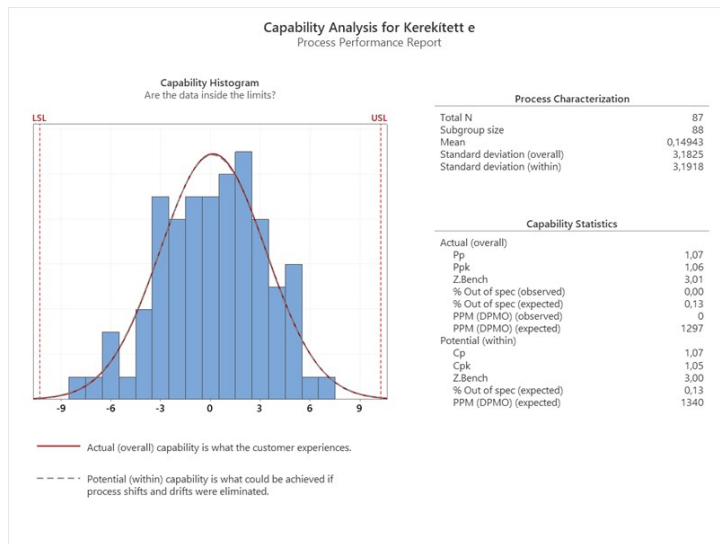
#### 3.1 Három fokszámú polinomiális megoldás

Az alkalmazott közelítő függvény az  $R^2=1$ -nél a legmegbízhatóbb, amely ebben az esetben az  $R^2=0,62$ . Szükséges pontmozgatások ebben az esetben 237 pixel az eltérések abszolút értékének az összege, amely a rendelkezésre álló 88 ponton elosztva átlagosan 2,7 pixelnyi mozgást eredményez adatonként. A gyalogos útestre lépése során az 53# képkockán kapjuk a legkisebb értéket, itt a legnagyobb az eltérés a felvett polinomiális trendvonaltól, ami ebben a pontban 12 egységnyi mozgást igényel. Itt a mért pontok optimalizált függvényről vett távolságainak szórása közel normál eloszlást mutat (12.ábra).



11. ábra – Három fokszámú polinomiális megközelítés

A 11. ábrán pirossal jelölt pontjai Xsy pontok, míg a szürke pontok narancssárgával összekötve jelzik az egyik lehetséges közelítő függvényt.



12. ábra – A függvény és mért pontok közti eltérésekre vonatkoztatott folyamatképesség

#### 3.2 Hatvány függvény

Ebben az esetben az  $R^2= 0,53$ , amely kedvezőtlenebb az előbbinél, és a szükséges pontmozgás is magasabb 273, amely átlagosan 3,10 mozgatás pontonként. A mért és a javasolt megoldás pontok közötti távolságokat elemezve megállapítható, hogy az adatok nem felelnek meg a normál eloszlás kritériumának.

### 3.3. Mozgóátlag 2 periódusra


Ebben a megoldásban a szükséges pontmozgás összege 70, amely átlagosan 0,79 mozgatást jelent pontonként, ez a legkevesebb pontmozgással járó közelítő függvény (13.ábra). A mért és a javasolt megoldás pontok közötti távolságok szintén nem normál eloszlást mutatnak.



13. ábra – Két periódusos mozgóátlag és Xsy grafikus összehasonlítása

### 3.4 Mozgóátlag 5 periódusra

Ebben az esetben a szükséges abszolút pont mozgatás, vagy távolság 159, amely átlagosan 1,80 mozgatást követel meg pontonként(14.ábra).



14. ábra – Az öt periódusos mozgóátlag és Xsy összehasonlítása

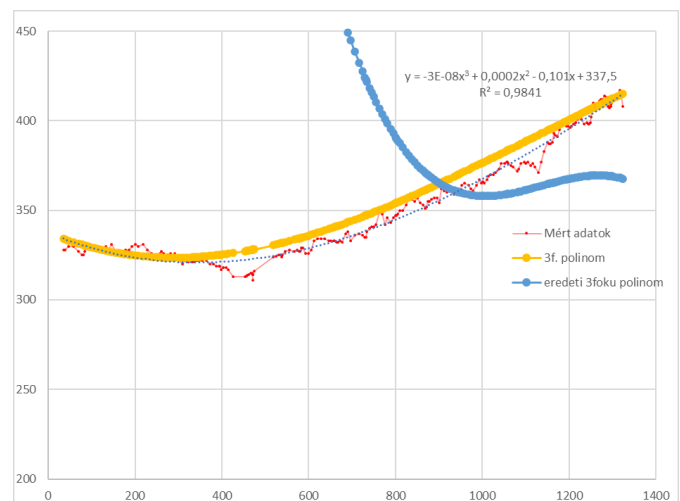
## 6.5. A VIZSGÁLT KÖZELÍTŐ FÜGGVÉNYEK ÖSSZEHAJONLÍTÁSA

A vizsgált megoldás lehetőségeket összehasonlítva (2. táblázat) megállapítható, hogy a hatványérték közelítés ebben az esetben a kevésbé alkalmazható, mivel az ahhoz tartozó  $R^2$  érték kedvezőtlen, és a szükséges pontmozgások száma is magas. A két periódusos mozgó átlag esetében a közelítő függvény szinte azonos a mért értékekkel, látható, hogy itt van szükség a legkevesebb pontmozgásra, viszont a függvény volatilitása érdemben nem változik.

	Megoldás				Mért adatok (referencia)
	Három fokszámú polinomiális	Hatvány	Mozgóátlag két periódusra	Mozgóátlag öt periódusra	
Összes pontmozgás távolsága [pixel]	237	273	70	159	0
Pontenkénti távolság [pixel]	2,7	3,1	0,79	1,8	0
$R^2$ érték	0,62	0,53	0,58	0,64	0,95
Távolságok eloszlása Normál eloszlás?	igen	nem	nem	nem	n/a


2.táblázat – lehetséges közelítő függvények összehasonlítása

A polinomiális és az öt periódusos mozgóátlag estében magasabb  $R^2$  értékeket kapunk. A vizsgált megoldások közül a három fokszámú polinomiális függvény esetében, a magas  $R^2$  érték mellett normális eloszlást mutat az eredeti mért pontok és a közelítő függvény távolságának a szórása. Emellett ez a célfüggvény jelentősen kiegyenlíti az eredeti mért értékekben tapasztalható kilengéseket. Sajnos hosszabb adatsorra kiterjesztve a polinomiális megoldás jelentősen eltávolodik az eredeti értékektől, melyet a fokszám (és egyben a számítási költség) növelésével lehet pontosítani. A 15. ábrán kézzel jelölt polinomiális függvény az úttestre lépés során felvett pontokhoz illeszkedik, jól látható, hogy a teljes adatsorra nem alkalmazható, arra új közelítő függvényt kell alkalmazni, ez a sárgával jelölt.



15. ábra – A 3 fokú polinomiális közelítő függvény kiterjesztése a teljes adatsorra

A megvizsgált lehetőségek közül az öt periódusos a mozgó átlag a legkedvezőbb, mivel ez a alkalmas egy konszolidált tartomány kijelölésére, amely további összefüggések elemzésre ad lehetőséget(16.ábra).



16. ábra –Szabályzóhatárok felvétele (x;y a képpontok)

A két jelzett helyen megfigyelhető, hogy a felvett pontok kilépnek a közelítőfüggvényhez rendelt szabályzóhatárokból. (+/-5 pixel, viszonyításként a szórás 30 pixel) A jobb oldali bekarikázott felvett koordináták esetében, a gyalogos hátratekint, majd lelép az úttestre, míg a baloldali bekarikázott koordináták a kitakart állapotot megelőző helyzetet jelzik.

## 6. KONKLÚZIÓ

A kísérleti mérés nappali fényviszonyok között és optimális időjárási körülmények közt történt, ettől akár minimálisan eltérő környezeti tényezők is jelentősen befolyásolhatják egy hasonló kísérlet kimenetelét. Az adatsor nagy számban tartalmaz különböző mozgáspálya adatokat, melyekből a cikk egyet dolgoz fel, ezért a mérés alapján nem lehet általánosan elfogadni az itt megfogalmazott következtetéseket. Mindemellett egy széleskörben használt, és az egyik legkorszerűbb eljárást alkalmazva kerültek meghatározásra az elemzéshez használt gyalogos mozgáspálya koordináták, amihez több közelítő függvény illeszkedés vizsgálata is megvalósult. A modellt felhasználva olyan szabályzóhatárokat állítottam fel, ami ebben a vizsgált esetben előre jelzi két egymástól független esemény bekövetkezését. Ahol a mért pontok kilépnek a felvett tartományból, a jelzést követően bekövetkezik valamilyen markáns változás a gyalogos haladásában.

## KÖSZÖNETNYILVÁNÍTÁS

A publikációban szereplő kutatást a Széchenyi István Egyetem az Európai Unió támogatásával valósította meg, az Autonóm Rendszerek Nemzeti Laboratórium keretében. (RRF-2.3.1-21-2022-00002)

## HIVATKOZÁSOK

- [1] Liliang Zhang, Liang Lin, Xiaodan Liang, and Kaiming He, "Is Faster R-CNN doing well for pedestrian detection?," CoRR, vol. abs/1607.07032, 2016.
- [2] J. Li, X. Liang, S. Shen, T. Xu, J. Feng, and S. Yan, "Scaleaware Fast R-CNN for pedestrian detection," IEEE Transactions on Multimedia, vol. 20, no. 4, pp. 985–996, April 2018.
- [3] Shanshan Zhang, Rodrigo Benenson, and Bernt Schiele, "Citypersons: A diverse dataset for pedestrian detection," CoRR, vol. abs/1702.05693, 2017.
- [4] T. Liu and T. Sathaki, "Enhanced pedestrian detection using deep learning based semantic image segmentation," in 2017 22nd International Conference on Digital Signal Processing (DSP), Aug 2017, pp. 1–5
- [5] Alexey Bochkovskiy, Chien-Yao Wang, Hong-Yuan Mark Liao "YOLOv4: Optimal Speed and Accuracy of Object Detection" Computer Science > Computer Vision and Pattern Recognition DOI:2004.10934