











**Térbeli mintázatok és a valós
térhasználat elemzése**
**A Space Syntax és a
Mesterséges Intelligencia
kombinált alkalmazása**

Geraszin Nikolett Kitti
BME, Építészmérnöki Kar 4. évf.

Konzulens:
Dr. Kádár Bálint, egyetemi docens,
Urbanisztika Tanszék





Tartalom

Előszó	4
Bevezető	5
Történeti és szakmai háttér	6
A Space Syntax módszer háttére	6
A Trafalgar tér áttervezése a Space Syntax segítségével.....	7
Az El-Tahrir Complex Plaza fejlesztési folyamata	9
William H. Whyte.....	11
A <i>Space Syntax</i> módszer kapcsolata William H. Whyte megközelítéséhez	11
Helyszínbemutató és lehatárolás	12
Kutatási módszertan	13
1. Space Syntax elemzés	13
2. AI-alapú videóelemzés	13
AI Modell és Platformok kiválasztása.....	13
AI kutatás elméleti háttére.....	14
A Mesterséges Intelligencia fogalma	14
Gépi tanulás és generatív tanulás	15
AI-alapú videóelemzés: emberi beavatkozás és automatizálás	15
Az "annotation" (annotáció) fogalma.....	16
A kutatás során használt térbeli annotációs formák és adataik:	17
Videóelemzés folyamatának bemutatása saját példán	20
Roboflow és Supervision.....	24
Roboflow Universe.....	25
Általánosan használt platformok és előképzett modellek.....	26
Az Adatok és Eredmények Bemutatása.....	27
Space Syntax elemzés módszertana és Eredményei.....	27
A távolság és fordulási szögek következménye a városi térhasználatban.....	34

Kombinált mérések.....	35
AI-alapú videóelemzés eredményei	37
A Keymakr cég és közös munkánk	37
Python Alapú Utómunkálatok és Elemzés	38
Roboflow platform és saját parancssorom eredményei.....	40
A két módszer eredményeinek összevetése	44
A Kossuth Lajos utca és a Vörösmarty utca kereszteződésénél lévő parkoló elemzése ..	44
Összegzés és következtetések	47
Irodalomjegyzék:.....	48

Előszó

Az OTDK formai követelményeinek megfelelése érdekében ez a dokumentum a Tudományos Diákköri Konferenciára (TDK) készített dolgozatom rövidített verziója. A kutatás az Egyetemi Kutatói Ösztöndíj Program, valamint a Kulturális és Innovációs Minisztérium Nemzeti Kutatási, Fejlesztési és Innovációs Alap támogatásával valósult meg. A kutatás során mesterséges intelligencia alapú eszközöket alkalmaztam a szöveges és videóelemzések tartalmi részének elkészítéséhez.

Bevezető

A városi terek használata és kialakítása napjaink egyik kiemelt várostervezési kérdése, mivel jelentős hatással van a városi lakosság életminőségére és közösségi élményeire. A jól megtervezett közterek elősegítik a közösségi interakciókat, hozzájárulnak a város élhetőségéhez, és fokozzák a biztonságérzetet. Ezzel szemben az alulhasznált vagy elhanyagolt terek növelhetik az elszigetelődést, a közbiztonsági aggályokat, és végső soron rombolhatják a városi környezetet. Kutatásom célja ezen városi terek felhasználásának vizsgálata, a használat módjainak és intenzitásának elemzése, valamint a biztonságra és közérzetre gyakorolt hatások értékelése egy mesterséges intelligencia és térstruktúra-alapú megközelítéssel.

A kutatásom során egy innovatív megközelítést alkalmazok, amely ötvözi a Space Syntax módszertant és az AI-alapú videóelemzést. A Space Syntax elemzés a városi térszerkezet vizsgálatában nyújt új lehetőségeket, míg a mesterséges intelligencia lehetőséget ad a térhasználati minták és emberi mozgások adatközpontú értékelésére. A két módszer kombinációja átfogó képet ad a városi terek működéséről, hozzájárulva a hatékonyabb és fenntarthatóbb várostervezési döntések meghozatalához.

Kutatásom helyszíne Budapest egyik városrésze, Pesterzsébet, ahol különböző köztereket vizsgállok meg. Az elemzés során külön figyelmet szentelek annak, hogy a városlakók hogyan és mennyi időt töltenek a terekben, valamint hogyan használják az egyes útvonalakat. Az AI-alapú videóelemzéssel nyert adatok segítenek feltárni a városrész térhasználati szokásait, míg a Space Syntax elemzés megmutatja a térszerkezeti adottságok hatását a használati módokra.

A kutatás célja egy olyan módszertani eszköztár és értékelési rendszer kidolgozása, amely lehetővé teszi a várostervezők számára a közterek hatékonyabb elemzését és optimalizálását. Reményeim szerint a kutatás hozzájárul egy átfogóbb, integrált várostervezési megközelítés kialakításához, amelyben a modern technológiai eszközök támogatják az élhetőbb és fenntarthatóbb városi környezet létrehozását.

Történeti és szakmai háttér

A Space Syntax módszer háttere

A *Space Syntax* egy térbeli analízisen alapuló elméleti és módszertani megközelítés, amelyet Bill Hillier és Julienne Hanson fejlesztettek ki az 1970-es évek végén és az 1980-as évek elején a londoni University College London (UCL) égisze alatt. A Space Syntax módszer célja annak vizsgálata, hogy a térbeli konfigurációk hogyan befolyásolják az emberek mozgási és interakciós szokásait egy adott városi vagy építészeti környezetben (Hillier & Hanson, 1984). Az elmélet abból indul ki, hogy „a tér nem csupán egy háttér, hanem a társadalmi élet meghatározó eleme” (Hillier, 1996, p. 2), amely strukturálisan elősegítheti vagy épp gátolhatja az emberek találkozásait, mozgásait és közösségi tevékenységeit.

A Space Syntax eszköztárának egyik legfontosabb eleme az úgynevezett „axial map” vagy tengelytérkép, amely az emberi mozgásra ható térbeli vonalakat, tengelyeket modellezi, lehetővé téve a térszerkezetek vizsgálatát. Az „axial line” elemzése során megállapítható, hogy melyik térszakasz milyen mértékben hozzáférhető, átjárható, és mennyire támogatja az emberi mozgást (Turner, 2001). Ezen kívül az „integrációs érték” kiszámításával a kutatók és tervezők meghatározhatják, hogy egy-egy tér mekkora közösségi aktivitást vonz, illetve hol alakulnak ki gyalogos mozgási csomópontok (Hillier, 1996).




Ábra 1: Téri szintaxis modell és vizuális gráf elemzés MDPI. (2023).
Fordítás: „3. ábra. Az axiális modell a kapcsolódó konvex terek hálózatán végigfutó egyenes vonalak sorozatával készül (balra). Ezek a vonalak a láthatóság és a mozgás kívánt vonalait ábrázolják. A modellt ezután különféle konfigurációs tulajdonságok elemzésére használhatjuk, például a közelségi központiségra, vagy ahogy a térszintaxisban nevezik, az „integrációra” (középen). A színek a legjobban elérhető (sötétvörös) és a legkevésbé elérhető (sötétkék) területek között változnak. Alternatívaként axiális vonalak helyett vizuális gráf elemzés (VGA) is alkalmazható, amely figyelembe veszi a hálózaton belüli összes nyilvánosan hozzáférhető konvex tér cellái közötti látótávolságot (jobbra). A színek a legjobban látható (sötétvörös) és a legkevésbé látható (sötétkék) területek között változnak.”

Napjainkban a Space Syntax módszer széles körben alkalmazott eszköz az építészet, a várostervezés és a közösségi közlekedés területén, különösen azokban a projektekben, ahol fontos a gyalogosforgalom elősegítése és a közösségi aktivitás maximalizálása. Például a Space Syntax elemzést gyakran használják városi központok, bevásárlónegyedek és lakóövezetek tervezése során, hogy előre modellezhessék a várható gyalogos áramlásokat és így optimalizálhassák a térhasználatot (Penn et al., 1998). Az elmélet és a kapcsolódó szoftverek segítségével a várostervezők „kvantitatív módon képesek feltárni, hogyan kapcsolódnak a terek egymáshoz, és hogy ezek a kapcsolatok hogyan befolyásolják az emberek térhasználati szokásait” (Varoudis, 2012, p. 15).


A Trafalgár tér átervezése a Space Syntax segítségével

Az 1800-as évek végére London egyik központi találkozóhelyévé vált tér a 20. századra forgalmas és kevésbé látogatott lett, mivel a közlekedési rendszer akadályozta a gyalogosok mozgását (Vaughan, 2007). A tér átalakítása kulcsfontosságúvá vált a városlakók számára, hogy a gyalogosforgalmat támogató, közösségi helyként funkcionáljon (Desyllas & Duxbury, 2001).

A Space Syntax módszertan segítségével a kutatók feltárták a tér kapcsolódását a környező utcákhoz és a gyalogosok által preferált útvonalakat. Az „axial mapping” technika segítségével a fő gyalogos útvonalakat és a tér integrációs értékeit vizsgálták, amelyek rávilágítottak, hogy a tér nyugati és déli oldala nem vonzotta a látogatókat, míg az északi oldal túlterhelt volt (Hillier, 1996; Vaughan, 2007).



axial analyses before and after



movement traces before and after

Ábra 2 Trafalgár tér Space Syntax mérései (Dursun, P. 2007)

Az elemzések alapján a tervezők új forgalmi és gyalogosrendszert dolgoztak ki, amely megszüntette az északi forgalmi sávokat és kibővítette a gyalogos területeket, lehetővé téve a közvetlen hozzáférést a tér különböző pontjaihoz. E változtatások eredményeként jelentősen megnőtt a gyalogosforgalom, és a tér közösségi találkozóhellyként kezdett újra funkcionálni (Desyllas & Duxbury, 2001).

A látótér-térképezés (visibility graph analysis - VGA) szintén fontos szerepet játszott, lehetővé téve a tervezők számára, hogy meghatározzák, mely zónák jól láthatók, így fokozva a biztonságérzetet (Turner, 2001). Az átalakítás végül a Space Syntax elemzésekre alapozva optimalizálta a tér elrendezését és visszaszorította a forgalmi problémákat (Penn et al., 1998).

Az El-Tahrir Complex Plaza fejlesztési folyamata

A projekt célja egy integrált városi tér létrehozása volt, amely biztosítja a közlekedési hatékonyságot és a közösségi interakciókat. Az El-Tahrir tér egy olyan helyszín, ahol a városi élet középpontja található, és a tervezési folyamat során fontos volt figyelembe venni a meglévő infrastruktúrát, a társadalmi szükségleteket és a környezeti szempontokat. Az első lépések között szerepelt a jelenlegi térhasználat felmérése és az emberek mozgásának megfigyelése.

A Space Syntax módszert alkalmazták a gyalogos forgalom modellezésére és a tér szerkezetének megértésére. Az elemzések a következőket tartalmazták:


- 1. Integrációs térkép:** Az összes vonalra kiterjedő integrációs térkép elemzése azt mutatja, hogy a magas integrációs értékek a tér fő utcáinál jelentkeznek, különösen az El-Tahrir utcában, Mohamed Mahmoud utcában és Merit Pasha utcában. Az El-Tahrir Komplexum fő bejárat pontja szintén magas integrációs értékeket mutat, és az integrációs térkép azt jelzi, hogy a leginkább integrált tengelyvonalak a tér mellett haladnak el, és csak néhány integrált vonal halad keresztül a téren. Ez arra utal, hogy a gyalogosok inkább a tér mellett haladnak el, mintsem átkelnének rajta egyik helyről a másikra, kivéve azokat, akik a metróállomásra mennek vagy az El Tahrir épületébe lépnek be. A korrelációs elemzés megerősítette ezt. (Abdelalim, 2022.4/a ábra).
- 2. Választási térkép:** Az összes vonalra kiterjedő választási térkép elemzése azt mutatja, hogy az El-Tahrir Komplexum Tér a legmagasabb választási értékkel rendelkezik az El-Tahrir tér és a tér közötti távolságban. Néhány átlagos érték áthalad az El-Tahrir Komplexum Terén, bár lehetséges elkülönülni a környezetétől. (Abdelalim, 2022.4/b ábra).
- 3. Vizális integrációs térkép:** Az El-Tahrir Komplexum Tér vizuális integrációjának elemzése azt jelezte, hogy a tér közvetlenül a tér leginkább integrált részén kívül helyezkedik el (piros terület). Azonban a tér északkeleti része (narancssárga és sárga terület) jelentősen magasabb vizuális integrációs értékekkel rendelkezik, mint az El Tahrir komplexum közelében lévő terület, amely zöld és kék színekben jelenik meg, jelezve az alacsony integrációs értékeket. Ez arra utal, hogy az északkeleti szakasz vizuálisan jobban hozzáférhető, és így nagyobb potenciált mutat az emberi tevékenységek számára, mint a tér többi része. (Abdelalim, 2022.4/a ábra).



a. Integration map b. Choice map c. Visual integration map
Fig. 6 Syntactical Maps of El-Tahrir Complex Plaza, processed by DepthmapX 0.8, Source: Author

Ábra 3 „A meglévő EL-Tahrir Complex Plaza szintaktikai elemzése” (Abdelalim, A. 2022)

Ezeknek a vizsgálatoknak a segítségével Abdelalim megállapította, hogy az El-Tahrir Komplexum Tér jelenlegi szerkezete nem biztosítja a gyalogosforgalom optimális áthaladását a téren belül, mivel az emberek inkább a tér körül mozognak, mintsem áthaladnának rajta. Az integrációs és választási térképek elemzése rámutatott, hogy a tér belső részének megközelíthetősége és vizuális kapcsolatai javításra szorulnak, különösen a tér északi-keleti részén, ahol a magasabb vizuális integrációs értékek nagyobb aktivitási potenciált jeleznek. Az eredmények szerint a harmadik javasolt alternatíva – amely belső gyalogosútvonalakat biztosít és megszünteti a gyalogos- és gépjárműforgalom közötti konfliktusokat hozzájárulhat a tér közösségi életének fellendítéséhez, és lehetőséget teremt a különböző aktivitások számára anélkül, hogy a forgalom akadályozná a mozgást. (Abdelalim, 2022)



Existing Plaza's layout (with fences) Plaza's layout without fences Plaza's design enhancement
Fig. 13 Enhancement Process of El-Tahrir Complex Plaza, processed by DepthmapX 0.8, Source: Author

Ábra 4 Az El-Tahrir Complex Plaza fejlesztési folyamata DepthmapX 0.8 segítségével (Abdelalim, 2022)

William H. Whyte

Várostervező és író jelentős szereplője a városi közterekről való gondolkodás átalakulásának. *The Social Life of Small Urban Spaces* című, 1980-ban publikált műve az egyik legnagyobb hatású tanulmány a közösségi terek használatáról. Whyte gondos megfigyelései révén tárta fel az emberek természetes viselkedésmintáit a városi terekben, rámutatva, hogy bizonyos térbeli hogyan serkenthetik vagy akadályozhatják a társas interakciókat (Project for Public Spaces, 2019; Urban Design Lab, 2023)

Whyte megközelítése forradalmi tényezők, például az ülőhelyek elérhetősége, az ételárusok, a napfény és a zöldfelületek volt, mivel időbeli folyamatokat rögzítő technikákat, például time-lapse kamerákat használt a közösségi terek vizsgálatára. Ezzel az eljárással sikerült hosszú időn át megfigyelnie a köztereket használók útvonalait és csoportosulásait, például a New York-i Bryant Parkban és a Paley Parkban, amelyek a későbbi várostervezők számára is alapvető tanulságokat hordoztak. (Urban Design Lab, 2023)

Whyte munkájának köszönhetően a várostervezésben egyre nagyobb hangsúlyt kaptak a „human-centered” tervezési módszerek, amelyek a közterek használóinak igényeit és szokásait állítják a középpontba (Whyte, 1980).

A TDK-m szempontjából Whyte alapelvei azért relevánsak, mert kutatásom célja a közterek emberi használatának megfigyelése és elemzése. Whyte módszereinek átvétele lehetővé teszi, hogy az AI-alapú megfigyeléseimet emberközpontú megközelítéssel egészítsem ki, ezáltal pontos képet kapva arról, hogyan lehetne a köztereket a közösségi igényekhez jobban igazítani.

A Space Syntax módszer kapcsolata William H. Whyte megközelítéséhez

Míg Whyte manuálisan, megfigyelés és időzített felvételek segítségével gyűjtött adatokat, addig a Space Syntax egy matematikai és térbeli analízisen alapuló módszertan, amely lehetővé teszi a térbeli konfigurációk elemzését és ezek hatását a társadalmi viselkedésre. A Space Syntax olyan eszközöket és algoritmusokat használ, amelyekkel számszerűsíthető, hogyan segíti elő vagy akadályozza a tér szerkezete a gyalogos mozgást, a találkozásokat és a közösségi aktivitásokat (Hillier & Hanson, 1984).

A Space Syntax módszertan különösen hasznos a városi terek hatékonyabb tervezésében, mivel lehetővé teszi a tervezők számára, hogy előre modellezzék, hogyan fognak az emberek egy

térben mozogni, találkozni és elidőzni. Azáltal, hogy vizsgálja a tér szerkezetét, a Space Syntax matematikai alapon becsülheti meg, mely útvonalak és terek lesznek a leglátogatottabbak, illetve hol valósulnak meg nagyobb interakciók. Ez a megközelítés Whyte megfigyelési módszereivel kiegészítve, AI-alapú adatelemzéssel kombinálva különösen értékes betekintést nyújthat a térhasználati szokások mélyebb megértéséhez (Hillier, 1996; Varoudis, 2012).


Jellemző	William Whyte	Space Syntax	AI-alapú Videós Térelemzés
Fókusz	Szociális interakciók és közterek használata	Térszerkezet és a közlekedési minták elemzése	Emberek mozgásának és viselkedésének automatizált elemzése
Módszertan	Megfigyelés és kézi számolás	Térbeli kapcsolatok és integrációs mutatók használata	AI modellek, mint a YOLO a személyek észlelésére
Adatgyűjtési módszerek	Kameraalapú megfigyelés, terepmunka	Számítógépes szimulációk és vizuális analízis	Videófelvételek feldolgozása, valós idejű adatelemzés
Eredmények	Az emberek közötti interakciók és a térhasználat mintázatai	A forgalmi minták és a térszerkezet optimalizálása	Az emberek által használt tér és útvonalak részletes analízise
Alkalmazás	Városi közterek, plázák, közösségi terek	Városi tervezés, közlekedési rendszerek optimalizálása	Okos városok, közterek használatának elemzése
Előnyök	Részletes megértés a szociális interakciókról	Statikus és dinamikus térstruktúrák modellezése	Gyors adatgyűjtés, automatizált feldolgozás
Példa	Bryant Park fejlesztése, New York	Trafalgar tér, London elemzése	Smart City projektelelemzés, mint pl. Helsinki

Ábra 5 Saját kép: Városi térhasználati elemző módszerek összehasonlítása

Helyszínbemutató és lehatárolás

A kutatásom helyszíne Budapest 20. kerülete, Pesterzsébet, amely a Gubacsi híd és a Soroksári út révén könnyen megközelíthető a belvárosból, miközben megőrzi külvárosi jellegét zöldőbb területeivel és családias hangulatával. Történelmileg Pesterzsébet eredetileg iparvárosként indult, szorosan kötődve a Duna-parti hajózáshoz és ipari tevékenységekhez. Az ipar hanyatlásával párhuzamosan azonban lakóövezeti karaktere erősödött, és vegyes, családi házas és lakótelepi övezetként formálódott tovább, ami jól tükrözi Budapest urbanizációjának változásait.

Kutatásom középpontjában Pesterzsébet Városközpontja melletti terei állnak. Különösen a Városháza előtti szökőkút, játszótér (és parkoló) által határolt terület. (8-as ábrán 3-sal jelölve)



Ábra 6 Pesterzsébet vizsgált területe, saját kép

Kutatási módszertan

A vizsgálat során a Space Syntax módszertant és a Roboflow mesterséges intelligencia alapú AI videóelemző eszközt kombináltam annak érdekében, hogy pontosan feltárjam a városi terek térhasználatának jellemzőit, valamint megértssem, hogyan befolyásolja a térbeli szerkezet az emberek tényleges viselkedését ezekben a terekben.

1. Space Syntax elemzés


A Space Syntax módszertan a városi terek közötti kapcsolatok vizsgálatára szolgál, és segít előre jelezni, hogy az egyes terek és útvonalak milyen mozgásmintákat generálnak. Ez a módszertan lehetőséget ad arra, hogy a térbeli elrendezés alapján következtetéseket vonjak le a terek használatának valószínűségéről és a forgalom koncentrációjáról. A módszertan az eredmények bemutatásánál részletezve.

2. AI-alapú videóelemzés

AI Modell és Platformok kiválasztása

A Space Syntax elemzést kiegészítendő, mesterséges intelligencia alapú videóelemző eszközt alkalmaztam a tényleges térhasználat megfigyelésére és elemzésére. A Roboflow nevű szoftver valós képes emberi mozgásokat és viselkedési mintákat is vizsgálni videófelvevételek elemzése révén. Az AI-alapú elemzés főbb lépései:

- **Adatbevitel:** A kutatáshoz 5 darab félórás felvételt készítettem a kiválasztott helyszínen. A videófelvevételek különböző időpontokban készültek 7 és 15 óra közötti időszávbán.



Ábra 7 A videófelvevételek készítésének helyszínei, saját kép

- **Videóelemzés:** Az AI-alapú szoftver segítségével a felvételeket elemeztem, és az adatokat feldolgoztam. Az elemzés során megvizsgáltam:
 - A gyalogosok számát és mozgásának irányát.
 - Hányan és milyen irányokból közelítik meg a tereket.
 - Mennyi időt töltenek a kiválasztott helyszíneken.
 - Milyen tevékenységeket végeznek a terekben (pl. átmenni rajta, megállni, várakozni).
- **Vizualizáció:** Az elemzések eredményeit térképes formában vizualizáltam, amely lehetővé teszi a gyalogos forgalom dinamikájának és a térkihasználtság mintázatainak bemutatását. A térképek alapján jobban láthatóvá váltak azok az útvonalak és terek, amelyeket a gyalogosok leginkább használnak, valamint az, hogy a térbeli szerkezet milyen hatással van a térhasználatra.

AI kutatás elméleti háttére

A Mesterséges Intelligencia fogalma

A mesterséges intelligencia (AI) olyan számítógépes rendszerek összessége, amelyek képesek emberi intelligenciát utánozó feladatok elvégzésére, mint például a tanulás, a problémamegoldás, a nyelvtérítés és a döntéshozatal (Russell & Norvig, 2020). Az AI területe az informatikán belül széles spektrumot ölel fel, beleértve a gépi tanulást, a természetes nyelvfeldolgozást, a számítógépes látást és az autonóm rendszereket.

A mesterséges intelligencia fejlődése az 1950-es évekre nyúlik vissza, amikor a kutatók megkezdtek az intelligens gépek létrehozását célzó kísérleteket. Turing (1950) híres írásában, „Computing Machinery and Intelligence” című tanulmányában előterjesztette a Turing-tesztet, amely az AI intelligenciájának mérésére szolgál. Turing érvelése szerint, ha egy gép képes egy emberrel való beszélgetés során elérni, hogy az ember ne tudja megkülönböztetni a gépet egy másik embertől, akkor azt a gépet intelligensnek tekinthetjük (Turing, 1950).

A mesterséges intelligencia fejlődését számos technológiai előrelépés segíti, beleértve a big data (nagy adathalmazok) használatát és a számítási teljesítmény növekedését (Mayer-Schönberger & Cukier, 2013). A gépi tanulás, amely az AI egyik fő ágának számít, lehetővé teszi, hogy a rendszerek adatokból tanuljanak és a tanultak alapján önállóan döntéseket hozzanak (Goodfellow et al., 2016).

A mesterséges intelligencia alkalmazása széleskörű, és számos iparágban megjelenik, például az egészségügyben, a pénzügyi szolgáltatásokban és a várostervezésben (Chui et al., 2018). A várostervezés területén az AI segíthet a területek optimalizálásában, a közlekedési minták előrejelzésében és a fenntartható fejlődés előmozdításában, hozzájárulva ezzel a városi környezetek intelligens kezeléséhez (Batty et al., 2012).

Gépi tanulás és generatív tanulás

A gépi tanulás (machine learning) az mesterséges intelligencia (AI) egyik kulcsfontosságú ága, amely lehetővé teszi a rendszerek számára, hogy tapasztalataikból tanuljanak és javuljanak anélkül, hogy explicit módon programozni kellene őket. A gépi tanulás célja, hogy algoritmusok segítségével modelleket készítsenek, amelyek képesek mintázatok észlelésére és előrejelzések készítésére nagy adathalmazok alapján (Bishop, 2006).

A gépi tanulás két fő típusra osztható: felügyelt (supervised) és felügyelet nélküli (unsupervised) tanulás. A felügyelt tanulás során a modellek tanítása egy címkézett adathalmazon történik, míg a felügyelet nélküli tanulás a rejtett struktúrák felfedezésére összpontosít címkézetlen adatok segítségével (Hastie, Tibshirani, & Friedman, 2009).

A generatív tanulás, amely angolul „generative learning” néven ismert, egy specifikus megközelítése a gépi tanulásnak, amely a rendszer számára lehetővé teszi, hogy új adatmintákat generáljon a tanult eloszlások alapján. A generatív modellek képesek a valós adatok eloszlását modellezni, így új, hasonló példányokat hozhatnak létre. Ezt a megközelítést gyakran alkalmazzák a képgenerálásban, a szöveggenerálásban és más kreatív alkalmazásokban (Goodfellow et al., 2014).

AI-alapú videóelemzés: emberi beavatkozás és automatizálás

Az AI-alapú videóelemzés folyamata egyaránt magában foglalja az emberi beavatkozást és az automatizált rendszerek működését. Az első lépésekben, amikor az AI rendszerek tanulnak és alkalmazkodnak, az emberi közreműködés kulcsszerepet játszik. A generatív tanulás kezdetén az emberi szakértők szükségesek az adatok előkészítéséhez, a modell architektúrájának meghatározásához, valamint a paraméterek optimalizálásához (Sutton & Barto, 2018).

A generatív tanulás során a modellek, mint például a Generative Adversarial Networks (GAN) és a variációs autoencoder (VAE), képessé válnak új, valósághű adatgenerálásra. Ezen a ponton már nem csupán az ember által biztosított adatokkal dolgoznak, hanem saját maguk is képesek új információk létrehozására a tanult minták alapján. A generatív tanulás folyamata magában

foglalja a tanulási fázist, ahol az algoritmusok az emberi beavatkozás révén építik fel a tudásukat, majd az adatok feldolgozása során autonóm döntéshozatalra képesek (Goodfellow et al., 2014).

Az emberi beavatkozás szükségessége fokozatosan csökken, amint a modellek egyre robusztusabbá válnak, és képesek kezelni a változó körülményeket és különböző adatforrásokat. Ekkor már nemcsak az adatok gyűjtése és előfeldolgozása automatizálható, hanem a videóelemzés során végzett tevékenységek is, mint például az események azonosítása és a viselkedési minták értelmezése (Khan et al., 2020). A folyamat végén, amikor a rendszer elérte a kívánt teljesítményt, az emberi beavatkozás szinte teljesen feleslegessé válik, mivel az AI képes önállóan végrehajtani a feladatokat, például a döntéshozatalt és az eredmények interpretálását.

Fontos azonban megjegyezni, hogy a teljes automatizálás nem minden esetben kivitelezhető. Az emberi beavatkozás továbbra is szükséges lehet, különösen a komplex döntéshozatali helyzetekben, ahol a kontextus, az etikai megfontolások vagy a normák figyelembevétele elengedhetetlen (Amershi et al., 2019). Az AI rendszerek által generált döntések felülvizsgálata és validálása emberi szakértők által elengedhetetlen lehet a megfelelő és etikus működés érdekében.

Az "annotation" (annotáció) fogalma

A tudományos és technológiai területeken több különböző kontextusban is használatos, de általánosan az adatok, szövegek vagy egyéb információk magyarázó jellegű megjegyzésekkel való kiegészítését jelenti. Az annotáció célja, hogy a felhasználók számára kontextust, jelentést vagy további információt nyújtson az adott adathalmazon belül.

Az annotáció különösen fontos a gépi tanulás és a mesterséges intelligencia (AI) területén, ahol a modellek tanításához szükséges adatok megjelölése alapvető lépés. Az annotált adatok lehetővé teszik a gépi tanulási algoritmusok számára, hogy azonosítsák és megtanulják a különböző mintákat és jellemzőket az adathalmazon belül. Például egy képalapú adatbázis annotálása során az emberek megjelölik a képeken található objektumokat, hogy a gépi tanulási modellek képesek legyenek azokat automatikusan azonosítani (Haque et al., 2020).

Annotációs Forma	Leírás	Használati Esetek
Bounding Box (Keret)	Négyzet vagy téglalap, amely az objektum köré van rajzolva.	Általános objektumdetektálás, pl. autók, emberek.
Polygon (Poligon)	Többszög, amely pontosan körülhatárolja az objektum alakját.	Bonyolult alakú objektumok, pl. épületek.
Mask (Maszk)	Az objektum pixel szintű maszkja, amely pontosan ábrázolja az alakját.	Orvosi képek, arcfelismerés, finom detektálás.
Keypoints (Kulcspontok)	Kiemelt pontok, amelyeket az objektumon belül jelölnek meg (pl. ízületek).	Emberi test mozgásának követése, arcfelismerés.
Line (Vonalkód)	Egy vonal, amely két pont között húzódik, például mozgás irányának jelzésére.	Közlekedési elemzés, pályák követése.
Skeleton (Váz)	Az objektum csontvázszerű vázlata, amely az összes kulcspontot és vonalat összeköti.	Emberi mozgás elemzése, sportteljesítmény nyomon követése.
Dot (Pont)	Egyetlen pont, amely az objektum egyetlen helyét jelöli.	Egyszerű objektumok nyomon követése, mint pl. labdák.

Táblázat 8 Annotációs formák és használati esetek, saját táblázat

A kutatás során használt térbeli annotációs formák és adataik:

1. **Bounding Box (Határoló keret):** Ez a technika a képeken található objektumok körüli téglalapok rajzolását jelenti, amelyek lehetővé teszik az objektumok azonosítását és követését.
 - $(x_1, y_1)(x_1, y_1)(x_1, y_1)$: a bal felső sarok koordinátái
 - $(x_2, y_2)(x_2, y_2)(x_2, y_2)$: a jobb alsó sarok koordinátái. Ily módon az annotációs rendszer képes meghatározni a téglalap helyét és méretét a képen (Haque et al., 2020).



Ábra 9 Határoló keret (Roboflow annotators)

2. **Point (Pont):** A pontok annotációja egy egyszerű forma, ahol az annotátorok egy adott helyet jelölnek meg a videón. Ez hasznos lehet például egy objektum középpontjának vagy fontos jellemzőinek az azonosításához (Zhou et al., 2020).

- $(x,y)(x,y)(x,y)$: ahol xxx a vízszintes, míg yyy a függőleges tengelyen található pixel koordináta. Ez a technika különösen hasznos, ha egy objektum középpontját kell megjelölni (Zhou et al., 2020).



Ábra 10 Pont jelölés (Roboflow annotators)

3. **Line (Vonallal történő annotáció):** Ez a technika vonalak használatát jelenti a videóban található mozgások vagy útvonalak megjelölésére. Például egy közlekedési helyzetben a vonalak segíthetnek megjeleníteni az autók által megtett utakat (Xiao et al., 2020).

- $[(x_1,y_1),(x_2,y_2),\dots,(x_n,y_n)][(x_1,y_1), (x_2,y_2), \dots, (x_n,y_n)][(x_1,y_1), (x_2,y_2),\dots,(x_n,y_n)]$: ahol minden $(x_i,y_i)(x_i,y_i)(x_i,y_i)$ egy-egy koordináta, amely a vonal mentén található pontokat képviseli. Ez lehetővé teszi az útvonalak és mozgások nyomon követését (Xiao et al., 2020).



Ábra 11 Vonal jelölés (Roboflow annotators)

4. **Polygon (Poligon):** A poligon annotáció során az annotátorok egy összetett alakzatot rajzolnak az objektum köré, amely lehetővé teszi a bonyolultabb formák, például emberek vagy állatok pontosabb körvonalazását. Ez a módszer különösen hasznos, ha az objektumok nem téglalap alakúak (Li et al., 2019).

- $[(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)]$: ahol minden (x_i, y_i) egy-egy csúcs koordinátája a poligonon belül. Ez a módszer pontosan rögzíti az összetett objektumok körvonalait (Li et al., 2019).



Ábra 12 Poligon jelölés (Roboflow annotators)


Annotációs Forma	Megadott Adatok
Bounding Box (Keret)	4 sarkának koordinátái: (x_1, y_1, x_2, y_2)
Polygon (Poligon)	Sokszög csúcsainak koordinátái: $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$
Mask (Maszk)	Bináris maszk pixelek (1: objektum, 0: háttér)
Keypoints (Kulcspontok)	Kulcspontok koordinátái: $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$
Line (Vonalkód)	Kezdeti és végpont koordinátái: $(x_{start}, y_{start}), (x_{end}, y_{end})$
Skeleton (Váz)	Kulcspontok koordinátái és kapcsolódó vonalak
Dot (Pont)	Egyetlen pont koordinátái: (x, y)

Táblázat 13 Annotációs formák és megadott adatok, saját táblázat


Videóelemzés folyamatának bemutatása saját példán

1. **Videó Elkészítése:** A videó rögzítése a legelső lépés a videóelemzés folyamatában. Az adatgyűjtés minősége kritikus, mivel a bemeneti videó minősége közvetlenül befolyásolja a későbbi feldolgozási lépéseket. Ajánlott figyelni a világításra, a kamera beállításokra és a felvétel környezetére (Soomro et al., 2012).

Ábra 2 Topánka utcai kereszteződés videófelvételének egy feldolgozott képe, saját kép




2. **AI Modell Kiválasztása:** A következő lépés a megfelelő AI modell kiválasztása, amely képes a kívánt objektumok (pl. emberek, autók) detektálására. Különböző modellek közül lehet választani, például YOLO (You Only Look Once) vagy SSD (Single Shot Detector), amelyek különösen népszerűek a valós idejű objektum detektálásban (Redmon et al., 2016).
3. **Videó Részletezése:** A hosszú videót célszerű rövidebb, kezelhetőbb részekre felosztani. Ez lehetővé teszi a könnyebb feldolgozást és csökkenti a memóriaigényt, miközben fenntartja a szükséges információt. Az optimalizált hosszúság segít a modell betanításában és tesztelésében is (Khan et al., 2020).



Ábra 3 Roboflow platform felülete, a beadott felvételt automatikusan képekre bontja, saját kép

4. **Videó Képek Képkockákra Bontása:** A videó feldolgozása során az egyes képkockák kiemelése elengedhetetlen, hogy az AI minden kockán dolgozhasson. Ez a lépés lehetővé teszi a képkockákból nyerhető információk maximális kihasználását.
5. **Modell Betanítása:** A kiválasztott AI modellt betanítjuk a felismerendő objektumokra. Ez a folyamat magában foglalja az annotált adatok használatát, ahol a modell megtanulja, hogy az adott képkockákon mi az ember és mi az autó. A betanítás során a modell paramétereit folyamatosan finomítjuk az elérhető adatok alapján.




Ábra 4 Roboflow platform felülete, az első 4 kép manuális annotálása, saját kép

6. **Validálás:** A validálás célja annak ellenőrzése, hogy a modell jól működik-e, és helyesen detektálja a kívánt objektumokat. Ekkor lehetőség van elfogadni és visszautasítani is az ajánlott képet, illetve ha szükséges javítani.

Ábra 5 Egy általam elutasított javaslat, mivel az AI nem ismerte fel a buszokat, így azokat kézzel pótoltam, saját kép




7. **Tesztelés:** Az AI teljesítményének megerősítése érdekében pár képpel próbát végez a program. A tesztelés során a modellek működését reális körülmények között vizsgáljuk, és figyeljük a valódi és a prediktált eredmények közötti eltéréseket. Az én esetemben a megadott 36 képből 25 volt a tanítás fázisban felhasználva, 7 a validálás során és 4 képet küldött vissza testeredményként, amikre ugyanúgy megvolt a lehetőségem, hogy elutasítsam és korrigáljam a képet.



Ábra 6 Roboflow platformja: képfeldolgozásnak folyamata, saját kép


8. **Integrálás a programba:** Ezen a ponton az AI modult integráljuk a feldolgozóprogramba. Ehhez én a Google Colab platformot használtam, illetve a Roboflow ingyenes oktatóvideóit.
9. **Teljes Videó Feldolgozása:** Miután az AI modult integráltuk, betöltjük az egész videót a programba, amely feldolgozhatóvá válik. Ez a lépés magában foglalja a képkockák automatikus elemzését is.
10. **Képkockák Felismerése:** A program képkockáinként elemzi a videót, és detektálja az embereket vagy más objektumokat. Ekkor a modell alkalmazza a korábban betanult algoritmusokat, hogy azonosítsa az objektumokat a videóban.
11. **Adatok mentése:** A Roboflow oldal nekem egyből állított ki elemzéseket az AI teljesítményéről, illetve képes voltam kiállítani hő térképeket a feldolgozott videó különböző észlelt tárgyainak bounding box adatainak segítségével.



Ábra 7 Roboflow platform betanított AI teljesítményének értékelése, saját kép

Annotation Heat Map

Overview of where your annotations are located in the images in your dataset.




Ábra 8-21 Roboflow platform 1. Kép: összes annotált objektum hő térképe 2. kép: gyalogosok hő térképe, saját képek

Average Precision by Class (mAP50)



Ábra 22 Roboflow platform annotált objektumok összesítése, saját kép

12. **Új videók annotálása:** Innentől képes lettem új videók kipróbálására is a betanított modul alapján. Az új videó során az AI képes volt felismerni a legtöbb autót, ami a képeken volt és bounding box annotálással (mert eredetileg ezt tanítottam neki) megadta azok adatait is.



Ábra 23 Roboflow platform új videók annotálása a betanított programmal

Roboflow és Supervision

Roboflow egy innovatív platform, amely megkönnyíti a gépi tanulás alapú projektek létrehozását és kezelését. Az eszköz célja, hogy egyszerűsíti a gépi tanulási modellek fejlesztési folyamatát, lehetővé téve a felhasználók számára, hogy gyorsan és hatékonyan készítsenek adathalmazásokat, annotációkat, és alkalmazzák azokat különböző feladatokhoz, mint például az objektumok észlelése és az arcfelismerés (Roboflow, n.d.).

A **Supervision** a Roboflow által kínált annotációs eszköz, amely lehetővé teszi a felhasználók számára, hogy képkockák és videók annotálásával hozzanak létre olyan adatokat, amelyek segítenek a gépi tanulási modellek tanításában. A Supervision eszköz intuitív felhasználói felülettel rendelkezik, amely lehetővé teszi a különböző annotációs technikák alkalmazását, mint például a bounding box, polygon, és maszk annotációk. Ezek az eszközök különösen hasznosak, amikor a felhasználóknak pontosan kell definiálniuk az észlelni kívánt objektumokat (Roboflow, n.d.).

Roboflow Universe

A Roboflow Universe egy innovatív platform a gépi tanulás és a számítógépes látás területén, amely közösségi erőforrásként működik. Célja, hogy lehetőséget biztosítson a felhasználóknak projektek felfedezésére, megosztására és közös fejlesztésére. A platform a Roboflow ökoszisztéma része, amely magában foglalja az adatok annotálását, modellek betanítását és valós idejű API-k létrehozását.

Elérhető tartalmak

- **Előképzett Modellek:** A platform különböző, előre betanított modelleket kínál, amelyek különféle feladatokra, mint például objektum- észlelés, képosztályozás és képfeldolgozás optimalizáltak. Ezek a modellek könnyen integrálhatók alkalmazásokba (Roboflow, n.d.).
- **Adathalmazon Történő Keresés:** A felhasználók annotált adathalmazon kereshetnek, így gyorsan megtalálják a releváns adatokat a modellek betanításához (Roboflow, n.d.).
- **Közösségi Projektek:** A platform lehetőséget ad a felhasználóknak saját projektjeik megosztására, inspirációt nyújtva mások számára, és elősegítve a közösségi együttműködést (Roboflow, n.d.).
- **Tananyagok és Útmutatók:** Oktatási anyagokat és útmutatókat kínál, amelyek segítenek a számítógépes látás alapjainak és a Roboflow használatának megértésében (Roboflow, n.d.).

Mások munkájának használata

- **Hozzáférés:** A felhasználók hozzáférhetnek mások által készített modellekhez és adathalmazon, így könnyebben megvalósíthatják projektjeiket anélkül, hogy mindent maguknak kellene létrehozniuk (Roboflow, n.d.).
- **Hozzájárulás:** A felhasználók saját projektjeik megosztásával hozzájárulhatnak a közösséghez, lehetőséget adva másoknak, hogy tanuljanak az ő munkájukból (Roboflow, n.d.).

Általam használt platformok és előképzett modellek

- **Roboflow:** Az AI modellek, mint például a YOLO, a Roboflow platformról származnak, amely lehetővé teszi a felhasználók számára, hogy betöltsenek előképzett modelleket, és könnyedén alkalmazzák azokat a saját projektjeikben
- **Supervision:** Ez a könyvtár segít a képkockák generálásában, amely lehetővé teszi a videó feldolgozását. A kódban a `frames_generator` használatával a videóból kinyert képkockák kerülnek feldolgozásra.
- **Ultralytics YOLO:** A YOLO egy népszerű objektumdetektáló algoritmus, amely valós időben képes azonosítani több objektumot egy képen vagy videón. Az Ultralytics által fejlesztett YOLO modellek, mint például a `yolov8x.pt`, az AI közösség egyik legfejlettebb megoldásai közé tartoznak.
- **OpenCV:** Open Source Computer Vision Library) egy nyílt forráskódú számítógépes látás könyvtár, amely lehetővé teszi a videók feldolgozását, és a képkockák sebességének kezelését a `cv2.VideoCapture` és a `cv2.CAP_PROP_FPS` használatával.

Platform	Mire Használtam	Hogyan Jelenik Meg a Kódban
Roboflow	Videók és képek előkészítése AI modellekhez	Nincs közvetlen kódmegevalósítás, de a modellek betöltése során használtam.
Supervision	Videó feldolgozása, képkockák generálása	<pre>import supervision as sv frames_generator = sv.get_video_frames_generator(video_path)</pre>
Ultralytics YOLO	Objektumdetektálás videóban	<pre>from ultralytics import YOLO model = YOLO('yolov8x.pt') result = model(frame)[0]</pre>
OpenCV	Videó képkockasebességének kezelése	<pre>import cv2 video_capture = cv2.VideoCapture(video_path) frame_rate = video_capture.get(cv2.CAP_PROP_FPS)</pre>

Ábra 24 A kutatás során használt platformok és megjelenésük a kódban, saját kép

Az Adatok és Eredmények Bemutatása


Space Syntax elemzés módszertana és Eredményei

A Városháza előtti két egymásba fonódó tér (szökőkút és játszótér) elemzése során elkészítettem egy All_line mapet, amely lehetővé tette a választás (Choice) mutató vizsgálatát különböző távolsági paraméterek mellett: R50, R100, R200, R500 és Rn.

A *Choice* mutató a „through-movement” (keresztülhaladás) lehetőségeit vizsgálja. Azt mutatja meg, hogy egy adott pont vagy útvonal milyen valószínűséggel van használatban, amikor az emberek más pontok közötti útvonalat választanak. Minél magasabb a *Choice* értéke, annál fontosabb ez az útvonal a hálózat egészében, mint „kikerülhetetlen” átjáró vagy forgalmi csomópont. R azt mutatja meg, hogy a vizsgált pontot hány méter távolságban vizsgáljuk a többi ponttól, vagyis, hogy mekkora elérhetőségi távolságot vizsgálunk. Például a *Choice* R50 azt mutatja meg, hogy a pont 50 méteren belül milyen más pontokkal van összeköttetésben. Az Rn mutató általában a maximális távolságot jelöli, amelyet a mintázat figyelembe vesz. Ez a távolság lehetővé teszi a legnagyobb perspektíva és az összes lehetséges kapcsolat átfogó értékelését.

Eredmények és Következtetések

Az elemzés során megállapítottam, hogy az R50, R100 és R200 között csak elhanyagolható eltérések vannak. Ez azt jelzi, hogy a közeli kapcsolatok a térben meglehetősen stabilak és egységesek, tehát a tér legnagyobb része jól összekapcsolt, és az emberek mozgása szempontjából kis távolságon belül hasonló lehetőségeket kínál. Az R200, R500 és Rn között pedig egyáltalán nem tapasztaltam különbséget, ami arra utal, hogy a távolság növekedésével a választási lehetőségek nem bővülnek annyira, mint a közeli kapcsolatok esetében. Ez arra enged következtetni, hogy a terek használata és a benne rejlő lehetőségek inkább a közeli környezetben található kapcsolatokra épít, míg a távolabbi területek már nem befolyásolják annyira a gyalogosok választási mintáit.




Ábra 25 Sorban Choice R50, R100 és R200-as mérések eredményei elhanyagolható különbségekkel, saját kép

Connectivity mérési eredmények értékelése


A connectivity mérés egy adott területen belüli utak és vonalak közötti kapcsolati hálózat sűrűségét és összefonódottságát vizsgálja, így lehetővé teszi a térbeli interakciók megértését és a forgalmi minták modellezését. Ezen mérés segítségével azonosíthatók azok a területek, amelyek a legmagasabb kapcsolati értékkel bírnak, vagyis ahol az emberek könnyebben közlekedhetnek.

⇒ **All Line Map:** Ez az elemzés feltárja, hogy az egyes terek és utak hány másik térhez vagy úthoz kapcsolódnak, így megmutatva a terek hozzáférhetőségét és közlekedési szerepét.



Ábra 26 Space Syntax All Line Map Connectivity mérés a Városháza előtti térről (Kossuth utca és a Vörösmarty utca kereszteződése), saját kép

⇒ **Visibility Graph Analysis (VGA):** A VGA elemzés a terek átláthatóságát vizsgálja, azaz azt, hogy mennyire látják át az emberek az egyes tereket mozgás közben, és ez hogyan befolyásolja a mozgásukat.



Ábra 27 Space Syntax Visibility Graph Analysis Connectivity mérés a Városháza előtti térről (Kossuth utca és a Vörösmarty utca kereszteződése), saját kép

Mindkét vizsgálat során azt állapítottam, hogy a Kossuth Lajos utca vonala és a Városháza előtti terek kiemelkedő kapcsolati mutatókkal rendelkeznek. Ez az eredmény összhangban áll a terület funkcionális és szimbolikus szerepével, hiszen ezek a terek a város középpontjában helyezkednek el, így vonzó célpontot jelentenek a gyalogosok számára.

Érdekes módon a Városházával szemben található kereskedelmi egységek kapcsolati értéke meglepően alacsony, amely szemben áll a várakozásokkal, hiszen egy ilyen központi elhelyezkedésnek magasabb látogatottságot kellene generálnia.


Ez a jelenség a tér kialakításának következménye lehet, hiszen a nagy zöld terület és a szökőkút elhelyezése a forgalmat befolyásolja. A szökőkút, mint fizikai akadály, blokkolja a fő bejutási tengelyt, ezzel csökkentve a közvetlen hozzáférést a kereskedelmi egységekhez. Ugyanakkor a zöld területek és víz elemek által generált vonzerő csábíthatja a látogatókat, ami a terület esztétikai élményének és funkcionalitásának szempontjából pozitív, azonban a kereskedelmi tevékenységek szempontjából hátrányos hatással is lehet.

Ez a megfigyelés aláhúzza a városi tervezés összetettségét, amely során nemcsak a kapcsolati értékek, hanem a fizikai térszervezés és a zöld elemek integrációja is jelentős hatással van a tér használatára és a forgalmi dinamikára (Hillier & Hanson, 1984; Turner, 2007).

Integrációs mérési eredmények értékelése

Az integrációs mérés célja, hogy feltárja, milyen könnyen elérhetőek a különböző városi terek a távolságok függvényében. Mivel a vizsgált területen a távolságok nem számottevőek, a városháza előtti terek és a Kossuth utca a legintegráltabb helyszínek maradtak, hiszen ezek a fő sétálóutca funkciójából fakadóan könnyen megközelíthetőek. Ezzel szemben a játszótér melletti kiszolgáló funkciók megközelíthetősége jobban korlátozott, mivel a játszótér elhelyezkedése, valamint a Kossuth utcai oldalsávon található növényzet akadályt képez a könnyű megközelíthetőség szempontjából. Ez a helyzet az integrációs eredmények szempontjából kedvezőtlen, ami a valóságban csak azt is mutatja, hogy a kiszolgáló funkciók környezete jelenleg egy csendesebb, elszigeteltebb érzést nyújt. Ez elérhetőség szempontjából hátrányos, de a felhasználók számára a nyugalmat kereső, kellemes időtöltést biztosíthat, feltéve, hogy a teret megfelelően karbantartják.

A játszótér elhelyezkedése és a környező zöldterületek közötti interakciók fokozott figyelmet és gondos tervezést igényelnek, hogy a tér a jövőben is funkcionális és vonzó maradjon



Ábra 28 Space Syntax Visibility Graph Analysis Integráció mérés a Városháza előtti térről (Kossuth utca és a Vörösmarty utca kereszteződése), saját kép

Agent Trail és Gate Counts mérési eredmények értékelése


Az **agent trail** mérések egy olyan módszertan, amelyet a tér elemzésében alkalmaznak az egyének (ügynökök) mozgási mintáinak szimulálására egy meghatározott környezetben. Ezek a szimulációk segítenek megérteni, hogyan navigálnak az emberek a városi terekben, és hogyan lépnek interakcióba a környezet különböző elemeivel. A mérések értékes betekintést nyújthatnak a gyalogos viselkedésbe, az útvonalválasztásba, valamint a közterületek általános funkcionalitásába.

Mérés beállításainak leírása

1. **Elemzési időtartam (Timesteps): 3000:** Ez a szimuláció teljes időtartamát jelöli, amely időléptékekben (timesteps) van kifejezve. Minden egyes időlépték egy diszkrét időegységet jelent, amely során az ügynökök mozgásokat és döntéseket hozhatnak.
2. **Kibocsátási arány (Agent per Timesteps): 0,1:** Ez a beállítás azt határozza meg, hogy az ügynökök milyen sebességgel kerülnek be a rendszerbe. Jelen esetben a 0,1-es érték azt jelenti, hogy minden tíz időléptékben egy ügynök kerül kibocsátásra, így fokozatosan növekszik az ügynökök száma a környezetben.
3. **Látómező (Fields of View): 15:** Ez a paraméter meghatározza az ügynökök látótávolságát. Az ügynökök 15 egység távolságra látnak előre, lehetővé téve számukra, hogy a közvetlen környezetük alapján hozzanak döntéseket.
4. **Döntés előtti lépések száma (Steps Before Turn Decision): 3:** Ez a beállítás azt jelzi, hogy az ügynökök három időlépés után értékelik a fordulási lehetőségeiket. Ez segít a realistább mozgási viselkedés szimulálásában, mivel az ügynökök először előrehaladnak, mielőtt irányt változtatnának.
5. **A rendszerben eltöltött időlépések száma (Timesteps in System): 1000:** Ez a paraméter a szimuláció során az aktív időlépések számát jelöli, amely befolyásolja, hogy az ügynökök mennyi ideig tudnak interakcióba lépni a környezettel.
6. **Nyomvonal rögzítése (Record Trail for): 50:** Ez a beállítás meghatározza, hogy az ügynökök nyomvonalát 50 egység távolságra rögzítik, lehetővé téve a pályáik elemzését.

Mérés eredményei és megfigyelések

Az agent trail mérések során öt véletlenszerű helyre helyeztem el az ügynököket, míg egy ügynököt "release from any location" beállítással működtettem. Kiemelkedő megfigyelés volt, hogy a Vörösmarty utca és a Kossuth Lajos utca kereszteződése által meghatározott helyszínen az ügynökök mindegyike magas aktivitási szintet mutatott, jelezve a terület jelentőségét a gyalogos forgalom szempontjából.



Ábra 29 Öt véletlenszerű Agent Trail mérés a Városháza előtti térről (Kossuth utca és a Vörösmarty utca kereszteződése), saját kép


A megfigyelés, miszerint ez a kereszteződés következetesen a legmagasabb mozgási sűrűséggel bír, a piros nyomvonalak jelenlétével jól látható, továbbá alátámasztja a helyszín fontosságát a gyalogos forgalom szempontjából. A nyomvonalak sűrűsége azt sugallja, hogy a terület nem csupán egy főútvonal, hanem a gyalogosok számára is vonzó célpont, ami a városi térszerkezet szerepét tükrözi. A látványosabb megfigyelés érdekében pár képen kiemeltem egy-egy ügynök útvonalát, ami világosan szemlélteti, a Vörösmarty utca és a Kossuth Lajos utca kereszteződése mekkora funkcionális jelentőséggel bír a gyalogos forgalomban, mivel a nagy forgalmi számmal jelölt útvonalak, valamint a kisebb intenzitású nyomvonalak is áthaladnak ezen a területen.



Ábra 30 Három véletlenszerű ügynök kiemelt útvonala az Agent Trail mérésben a Városháza előtti térről (Kossuth utca és a Vörösmarty utca kereszteződése), saját kép

A **Gate Counts** elemzése lehetővé teszi a városi terek csomópontjainak forgalmi mintáinak meghatározását, az ügynök térképekből származó adatok alapján. A Gate Counts tükrözi, hogy mely területek vonzzák a legnagyobb számú gyalogost, és így fontos információkat nyújt a városi tervezés szempontjából. Ebből adódóan az ügynök mérések után elkészítettem a Gate Count térképemet, amely még inkább világossá tette a Kossuth utca kiemelt szerepét.

Bemutatja, hogy a Kossuth utca gyalogosforgalma jelentős, mivel a legtöbb ügynök útvonala áthalad ezen a népszerű sétálóutcán. A Vörösmarty kereszteződésnél megfigyelhető piros terület kiterjedése illusztrálja a forgalom sűrűsödését, és alátámasztja az ügynök mérések eredményeit, amelyek alapján a területek közötti kapcsolatok és elérhetőségek szempontjából ez a csomópont kiemelkedő szerepet játszik a városi közlekedésben.




Ábra 31 Gate Counts mérés a Városháza előtti térről (Kossuth utca és a Vörösmarty utca kereszteződése), saját kép

A távolság és fordulási szögek következménye a városi térhasználatban

Angular Step Depth mérés

Az angular step depth mérés a városi tér egyes pontjai közötti vizuális összekapcsolhatóságot értékeli az elfordulások minimalizálásával. A mérés lényege, hogy egy adott kezdőponthoz viszonyítva hány fordulatot kell tennünk a célpont eléréséhez, így a legkisebb szögelfordulásokkal elérhető útvonalak kerülnek előtérbe. Ez az elemzés jól tükrözi azokat a városi útvonalakat, amelyeken a gyalogosok számára az egyszerű és folyamatos navigáció kiemelt fontosságú, például sétálóutcákban vagy zöldterületek környékén, ahol az akadálymentes látótér is szerepet játszik.



Ábra 32 Angular Step Depth mérés a Városháza előtti térről (Kossuth utca és a Vörösmarty utca kereszteződése), saját kép


Metric Step Shortest-Path Length mérés

A metric step shortest-path length ezzel szemben a legrövidebb megtett útvonalakat vizsgálja, ahol az út hossza az elsődleges szempont, függetlenül az útvonal szögbeli kanyargásaitól. Ez az elemzés leginkább a távolság alapú elérhetőséget, valamint az emberek gyalogos útvonalak választásának térbeli dimenzióját tükrözi. Az ilyen mérések különösen hasznosak a városi célpontok közelségének és elérhetőségének meghatározásában, például ha azt szeretnénk vizsgálni, hogy az egyes városi funkciók, szolgáltatások milyen közel helyezkednek el egymáshoz, és mennyire könnyen érhetők el gyalogosan.

Kombinált mérések

A kutatásom során különböző méréseket végeztem a városi térszerkezet gyalogosforgalomra gyakorolt hatásának elemzésére, a kijelölt középpontként pedig a Kossuth Lajos utca és a Vörösmarty utca kereszteződését jelöltem meg.

Megvizsgáltam az *angular step depth*angular step depth*metric step shortest-path length* mérés milyen eredményeket mutat. A nagyobb távolságokat magasabb értékek jellemzik, különösen a hosszabb, lineáris szakaszok mentén, míg a kisebb, több elfordulást igénylő útvonalaknál (mint a szolgáltató funkciók közötti részekén) alacsonyabb értékek születtek. Ez utóbbi arra utal, hogy a nagyobb összekötöttséggel rendelkező, forgalmasabb csomópontok kényelmes, folytonos elérhetőséget biztosítanak, miközben a kisebb forgalmú, több szögbeli elfordulást igénylő útvonalak az emberi mozgás dinamikájának mérsékeltebb területei közé tartoznak.




Ábra 33 *angular step depth*angular step depth*metric step shortest-path length* mérés a Városháza előtti térről (Kossuth utca és a Vörösmarty utca kereszteződése), saját kép

Ezen kívül a *metric step shortest-path length*metric step shortest-path length*angular step depth* kombinációs vizsgálatot is elvégeztem, amely a távolság és a szögbeli elfordulások együttes elemzését teszi lehetővé. Ennek az elemzésnek az eredményei azt mutatták, hogy a

kiszolgáló funkciókhoz közelebbi, de nagyobb elágazásokkal rendelkező területeken (például a szolgáltató funkciók közötti részekben) magasabb értékeket kaptam, ami arra enged következtetni, hogy az emberek gyalogos viselkedésében a megtett távolság nagyobb szerepet játszik, mint az elfordulások mértéke. Ez a vizsgálat jobban közelíti az emberi viselkedéshez kapcsolódó tényezőket, hiszen a távolság befolyása jelentősebb, bár a kényelmes haladás érdekében az elfordulások minimalizálása is szempont lehet.

Ezek a mérések együttesen arra világítanak rá, hogy a gyalogos közlekedés során a városi tér struktúrája és a közlekedési hálózat elrendezése nem csupán az elérhetőség, hanem a gyalogosok által preferált útvonalak kialakításában is kulcsfontosságú szerepet játszik, különösen a távolság és az elfordulás kombinált hatását tekintve.



*Ábra 34 metric step shortest-path length*metric step shortest-path length*angular step depth mérés a Városháza előtti térről (Kossuth utca és a Vörösmarty utca kereszteződése), saját kép*

AI-alapú videóelemzés eredményei

A Keymakr cég és közös munkánk

A kutatásomban egy rövid videós felvétel emberi tevékenységeinek pontos lekövetése is szükséges volt, olyan partnert kerestem, aki megfelelő támogatást tud nyújtani az adatok annotálásában, így találtam rá a Keymakr cégre.

A Keymakr bemutatása

A Keymakr céget 2015-ben alapították, hogy minőségi és megfizethető tanulmányokat biztosítsanak a számítógépes látás alapú mesterséges intelligencia fejlesztésekhez. Ahogyan a cég megfogalmazza: „Azzal kezdjük, amit jól ismerünk, és innen építkezünk tovább.” Az évek során szerzett tapasztalataik révén fejlesztették az annotációs technológiákat és adatok előállítási eszközeit. Ma már saját kutatás-fejlesztési csapatuk dolgozik új annotációs eszközök létrehozásán, amelyeket különféle partnereik és ügyfeleik, például a számítógépes látás területén tevékenykedő cégek vehetnek igénybe, így segítve az innovatív modellek kialakítását.

Az együttműködés és az annotációs folyamat kezdete


Miután rátaláltam a Keymakr weboldalára, kapcsolatba léptem a céggel, hogy megérdeklődjem, támogatnák-e a kutatásomat az adatanotációk terén. A cég gyorsan válaszolt, és nyitottan álltak az együttműködéshez, rendszeres email váltásokkal tudtuk tartani a kapcsolatot, majd egy online megbeszélésen pontosítani is tudtuk, mit is szeretnénk elérni. Megbeszéltük, hogy az emberek mozgását egy-egy kijelölt ponttal fogják jelölni, így a végső adatkészletben világosan láthatók lesznek a különböző útvonalak és az egyes gyalogosok tartózkodási ideje. Ez a módszer lehetővé tette számomra, hogy vizualizáljam a térhasználati mintákat, valamint mérjem, hogy az emberek mennyi időt töltenek a vizsgált területen.



Ábra 35 Mgyarázó ábra a Keymakr céggel folytatott együttműködés során, saját kép

A Video Annotálása: A közös munka gyakorlati megvalósítása


A kutatásom ezen részében használt videó egy rövid, 2 perc 26 másodperces anyag volt, amely a Kossuth Lajos sétáló utca és a Vörösmarty utca kereszteződés gyalogos forgalmát mutatta be. A Keymakr csapata végül elkészítette a videó 4-szeres gyorsítású annotációját a megbeszéltek szerint, követve az emberek mozgását a felvételen, és pontosan rögzítve az egyes gyalogosok pozícióját és útvonalát.



Ábra 36 Keymakr cég által küldött videó részlete, annotált emberek, készítő: Keymakr

Python Alapú Utómunkálatok és Elemzés


Az annotált adatokat egy JSON fájlban kaptam meg, amit egy JSON viewer segítségével tudtam olvasni, majd Excellé alakítani. Az annotálta adatok tartalmazták, a videóból kinyert összes képet és azokon található minden ember bejelölt adatait: az embereket határoló keretek széleinek koordinátáit pixelben: x_1, y_1, x_2, y_2 , valamint az embereket meghatározó csontváz pontok koordinátáit.



Ábra 37 Részlet a megnyitott JSON fájlból: annotált emberek adatainak hierarchiája, forrás: Keymakr


Ezekből nekem különböző objektumok neve, illetve az emberek koordinátái voltak fontosak. Python programozási nyelven dolgoztam fel ezeket az adatokat a Google Colab alkalmazásban, amely lehetőséget biztosított a statisztikai elemzések és vizualizációk elkészítésére is. A programsorokat nyílt adatbázisokból, illetve a ChatGPT segítségével írtam.

A koordináták segítségével meghatároztam, hogy melyik ember merre mozgott a videóban és, hogyan használta a teret. Grafikusan ábrázoltam az emberek által követett útvonalakat, amelyek egyértelműen szemléltették, hogy mely területek élveznek nagyobb népszerűséget, illetve hol koncentrálódik a gyalogos forgalom.



Ábra 38 Keymakros JSON fájlból kinyert adatok grafikus megjelenítése, saját kép

Az alapján, hogy hányszor szerepeltek az adott nevek a listában meghatároztam, hogy ez alatt a videó alatt hányszor lettek bejelölve a videóban, vagyis mennyi időt töltöttek a területen a videó készítése alatt.



Ábra 39 Emberek téren töltött ideje a videó készítése alatt, saját kép

Az adatelemzés részeként oszlopdiagramokat készítettem, amelyek azt mutatták be, hogy egy-egy személy mennyi időt töltött az adott helyszínen.

Roboflow platform és saját parancssorom eredményei

A Keymakr céggel való együttműködés után saját magam akartam leannotálni az elkészített felvételeim és ehhez a Roboflow platform és a Google Colab segítségével készítettem egy saját parancssort. Először a Roboflow segítségével olyan modellt választottam ki és tanítottam be, amely képes az emberek felismerésére és követésére a videófelveleken. A végső felvételek feldolgozása folyamán viszont a YOLO modelt alkalmaztam a pontosabb eredmények elérése érdekében. Az adatelemzési folyamat során a platform lehetőséget adott a videókból generált adatok letöltésére és feldolgozására. A Colabban végzett programozás révén pedig az adatok további elemzését végeztem el, hogy az emberek áthaladásának útvonalait és a terek kihasználtságát átlátható formában jelenítsem meg.

Ábra 40 Saját parancssor részlete: Az adatok kinyerésére és CSV formátumba generálásához használt kódom, saját kép

```
import pandas as pd
import supervision as sv
import sys
import os
import cv2

# Videó útvonalának és mentési útvonalának beállítása
video_path = '/content/drive/My Drive/Colab Notebooks/videos/'
output_path = '/content/drive/My Drive/Colab Notebooks/files/'

# Képkockasebesség meghatározása
video_capture = cv2.VideoCapture(video_path)
frame_rate = video_capture.get(cv2.CAP_PROP_FPS)
video_capture.release()

frames_generator = sv.get_video_frames_generator(video_path)
results = []
person_id_counter = 0

# Képkockák feldolgozása másodpercenként 1 képkocka
for frame_number, frame in enumerate(frames_generator):
    if frame_number % int(frame_rate) != 0:
        continue

    current_second = frame_number // int(frame_rate)
    result = model(frame)[0]
    boxes = result.boxes

    for box in boxes:
        box_data = box.xyxy[0]
        class_id = int(box.cls)


        # Objektum típusának meghatározása
        if class_id == 0:
            object_type = "person"

        results.append({
            'id': person_id_counter + 1,
            'second': current_second,
            'object_type': object_type,
            'x': box_data[0].item(),
            'y': box_data[1].item(),
        })
        person_id_counter += 1

# CSV mentése
if results:
    df = pd.DataFrame(results, columns=['id', 'second', 'object_type', 'x', 'y'])
    df.to_csv(output_path, index=False)
    print(f"Eredmények mentve: {output_path}")
```


A programozás során egyik legnagyobb kihívást a detektált személyek térképi koordinátáinak leképezése jelentette. Ennek megoldására homográfia mátrixot használtam, amelyet a Colabban, az OpenCV könyvtár segítségével hoztam létre.

Először GPS-koordináták megadásával próbálkoztam, viszont ez sajnos nem adott elég pontos megoldást, mivel a videófelvétel perspektívája és a valós térbeli koordináták között jelentős torzulások jelentkeztek.



Ábra 41 Pontok megjelenítése GPS koordináták alapján, saját kép

A GPS-adataim nem tudták megfelelően kompenzálni ezeket az eltéréseket, így nem voltak alkalmasak arra, hogy a mozgó személyek pozícióját a térképen pontosan megjelenítsem. Emiatt döntöttem a homográfia mátrix használata mellett, amely a képi sík és a térképi sík közötti összefüggéseket pontosabban modellezi. A további elemzések és a mozgási útvonalak pontos modellezése érdekében létrehoztam egy saját 50x115 egységes koordinátarendszert, amiben az egyes emberek pontos pozícióit rögzítettem, így a mozgási mintázatok vizuálisan is követhetők.




Ábra 42A saját 50*115 egységből álló koordinátarendszerem és rajta a bejelölt emberek, saját kép


AI x koordináta	AI y koordináta	Saját x' koordináta	Saját y' koordináta
1009.87	479.40	84.07	41.95
429.33	683.22	102.11	30.22
222.09	421.71	84.12	14.40
583.46	444.87	83.26	28.15
981.06	475.34	84.11	40.26
419.78	494.89	89.02	24.54
398.73	503.38	88.94	23.04
517.91	403.63	80.75	22.98
915.69	731.38	102.85	39.12
169.62	364.01	78.75	8.12
539.19	407.03	80.50	24.28
62.84	759.82	102.05	20.77

Ábra 43 Annotiált koordináták értéke a saját koordináta rendszerben, saját kép

Az első két oszlop egy adott másodpercben az AI által mért x és y koordinátákat tartalmazza (pixelekből), míg a harmadik és negyedik oszlop a saját koordináta rendszerben megállapított x' és y' értékeket. Ezzel a módszerrel képes voltam az egyes képpontokat a megfelelő térképi koordinátákra leképezni, ami lehetővé tette a mozgási útvonalak precíz ábrázolását a saját koordináta rendszerben, amely így összehasonlítható a terület eredeti térképével.




Ábra 44 Annotiált koordináták a saját koordináta rendszerben, saját kép




Ábra 45 A pontok helyes ábrázolása térképre levetítve, saját kép

Az adatok elemzése során különféle diagramokat, hőképeket és sűrűség-alapú ábrákat, készítettem, amelyek szemléletesen mutatják a terek leggyakrabban és legintenzívebben használt részeit. Az elemzés során megvizsgáltam a gyalogosok által preferált útvonalakat, és azt, hogy mely zónák vonzzák leginkább az embereket.



Ábra 46 Sűrűségkép: Legtöbb gyalogos forgalommal rendelkező pontok a vizsgált területen




Ábra 47 Legtöbb gyalogos forgalommal rendelkező pontok leképezése a vizsgált területen (Kossuth Lajos utca és a Vörösmarty utca kereszteződésében)

A két módszer eredményeinek összevetése

A Kossuth Lajos utca és a Vörösmarty utca kereszteződésénél lévő parkoló elemzése


A Kossuth Lajos utca és a Vörösmarty utca kereszteződésénél található parkoló kiváló példát nyújt a két módszer kombinált alkalmazására. A két mérés együttes ábrázolását a következő kép ábrázolja:



Ábra 48 Space Syntax Connectivity mérés és AI által készített gyalogosforgalom ábrázolásának kombinált ábrázolása


A Space Syntax mérések alapján kiderült, hogy a Kossuth utcai kiemelt tengely miatt ez a kereszteződés jelentős átjárási pontként funkcionál, viszont a parkoló területe alacsony értékekkel rendelkezik, vagyis kevésbé előnyös a geometriai kialakítása az áthaladásra.

Az AI-alapú mérések azt is megmutatták, hogy a teret használók jelentős része pontosan ezen az útvonalon kanyarodik le, azonban a helyszínen található szintkülönbségek és lépcsők miatt a jelenlegi kialakítás megnehezíti az átjárást. A tengelyben elhelyezett növényzet tovább csökkenti a tér átláthatóságát és közvetlen elérhetőségét, ami akadályozza a gyalogosforgalom zavartalan áramlását.



Ábra 49 AI által készített sűrűségterkép és a levetített pontok kombinált ábrázolása

A jelenlegi parkoló helyén érdemes lenne egy új, lejtősebb közösségi tér kialakításán gondolkodni, amely közvetlenül segíthetné az átjárást és támogatná a környező városi funkciókat. Ennek a részletesebb alátámasztásához elkészítettem a terület Agent Trail analizisét feltételezve, hogy a parkoló területén megszűnne a szintkülönbség és akadálymentessé válna a terület. A szimuláció szerint jelentősen megnövekedne az áthaladó emberek száma. Mindez egy sokkal integráltabb, a gyalogosforgalom igényeit jobban kiszolgáló terület kialakulását eredményezné, amely harmonikusan illeszkedik a város szövetébe.



Ábra 50 Space Syntax Agent Trail mérés: jelenlegi állapot és akadálymentes állapot összehasonlítása

Összegzés és következtetések





A TDK dolgozat során különféle mesterséges intelligencia és adatvezérelt módszerek alkalmazásával elemeztem a pesterzsébeti városi térhasználati mintázatokat. A kutatás alapját a Space Syntax módszer és az AI-alapú elemzések képezték, melyek kombinált alkalmazása lehetőséget adott arra, hogy a gyalogosforgalom térbeli megoszlását, valamint a közterek működését komplex, több szempontú elemzés alapján vizsgáljam.

Az adatalapú Space Syntax kutatásból megállapítható volt például, hogy a Kossuth Lajos utca és a Vörösmarty utca kereszteződése mellett található parkoló területe geometriája miatt nem ösztönzi az embereket az ott tartózkodásra. Ugyanakkor az AI-alapú térelemzés eredményei azt mutatták, hogy ez a helyszín a gyalogosforgalom kiemelt útvonala, amely a mindennapi közlekedés szempontjából alapvető fontossággal bír. A két eredmény összefüggéseiből az a következtetés vonható le, hogy a terület jelenlegi kialakítása nem felel meg a felhasználói igényeknek, és nem megfelelően támogatja a gyalogos közlekedés funkcióját.




Bár ezeket a megállapításokat helyszíni szemlével is valószínűleg azonosítani lehetne, kutatásom célja nem csupán a problémák feltárása. A vizsgálat során arra törekedtem, hogy a várostervezők számára egy olyan eszközt mutassak be, amely az emberi viselkedés adatvezérelt megfigyelésére és elemzésére épít. Ez az eszköz lehetővé teszi, hogy a tervezők objektív adatokra alapozzák döntéseiket, és a korábban gyakran megérzésen alapuló tervezési megoldásokat megalapozott érvekkel támaszthassák alá.

Fontosnak tartom kiemelni, hogy kutatásom egy történelmi térelemzési módszer, például William Whyte manuális megfigyeléseinek modern újraértelmezésére épült. A mesterséges intelligencia és a valós idejű adatgyűjtés lehetőségei révén gyorsabb és részletesebb elemzést tudtam végezni, mint korábban bármikor. Ezáltal a városi térhasználati szokások alaposabb megértésére nyílt lehetőség, amely hozzájárulhat a közterek funkcionális és élhetőbb kialakításához.

A modern technológia, különösen az AI alkalmazása a várostervezési folyamatokban, lehetővé teszi, hogy a térfigyelő rendszerekből származó adatokat valós időben elemezzük. Ez nemcsak a tervezési folyamat hatékonyságát növeli, hanem segíti a közösségek igényeinek precízebb kiszolgálását is. Az adatalapú tervezés tehát alapvető eszközzé válhat a jövő várostervezésében, elősegítve a városi terek jobb kihasználhatóságát és élhetőségét.



Irodalomjegyzék:



- Ali, H., Afzal, M. Z., & Khan, M. A. (2019). A comprehensive survey on video analysis and understanding: Issues and challenges. *Computer Vision and Image Understanding*, 183, 1-20.
- Amershi, S., Wu, T., & Betz, S. (2019). Guidelines for human-AI collaboration. *Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems*, 1-13.
- Batty, M., & Hudson-Smith, A. (2012). *The New Science of Cities*. MIT Press.
- Bengio, Y., Courville, A., & Vincent, P. (2013). Representation Learning: A Review and New Perspectives. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(8), 1798-1828. <https://doi.org/10.1109/TPAMI.2013.50>
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.
- Chui, M., Manyika, J., & Miremadi, M. (2018). Where machines could replace humans—and where they can't (yet). *McKinsey Quarterly*.
- Desyllas, J., & Duxbury, E. (2001). Axial maps and visibility analysis: A quick way of gaining insight into the configuration of the built environment. *Proceedings of the 3rd International Space Syntax Symposium*, 56-67.
- Duan, J., Zhang, L., Liu, S., & Guo, Y. (2019). A survey on deep learning techniques for object detection. *IEEE Access*, 7, 195532-195550.
- Dursun, P. (2007). Space syntax in architectural design. *Proceedings of the 6th International Space Syntax Symposium*. Retrieved from <http://spacesyntaxistanbul.itu.edu.tr/papers/longpapers/056%20-%20Dursun.pdf>
- Fischer, T., & Omer, I. (2018). Space Syntax: A Tool for Urban Planning and Design. *Journal of Urban Design*, 23(5), 686-707.
- Fridman, L., Silver, D., & O'Donnell, J. (2018). Data-efficient generative adversarial networks for time series forecasting. *Journal of Machine Learning Research*, 18(1), 1-33.
- Glenn Jocher. (2020). YOLOv5: A State-of-the-Art Real-Time Object Detection Algorithm. Retrieved from Ultralytics GitHub.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Courville, A. (2014). Generative adversarial nets. *Advances in Neural Information Processing Systems*, 27, 2672-2680.

- Haque, M. M., Mazumder, S., & Khusainov, R. (2020). A survey of image annotation and classification methods for visual recognition. *Journal of Visual Communication and Image Representation*, 71, 102721.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (2nd ed.). Springer.
- Hillier, B. (1996). *Space is the Machine: A Configurational Theory of Architecture*. Cambridge University Press.
- Hillier, B., & Hanson, J. (1984). *The Social Logic of Space*. Cambridge University Press.
- Hillier, B., Penn, A., Hanson, J., Grajewski, T., & Xu, J. (1993). Natural movement: or, configuration and attraction in urban pedestrian movement. *Environment and Planning B: Planning and Design*, 20(1), 29-66.
- Khan, M. A., Zhang, L., & Liu, C. (2020). Video object detection: A survey. *ACM Computing Surveys (CSUR)*, 53(4), 1-35.
- Koch, D., & P. M. R. (2014). The Integration of Space Syntax in the Design of Urban Public Spaces. *Journal of Urban Design*, 19(1), 80-94.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems* (Vol. 25). <https://doi.org/10.1145/2999134.2999171>
- Li, C., Zhang, Y., Wang, J., & Li, Q. (2019). Video annotation for machine learning: A survey. *ACM Computing Surveys (CSUR)*, 52(6), 1-35.
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., & Reed, S. (2016). SSD: Single Shot Multibox Detector. *European Conference on Computer Vision*, 21-37.
- Mayer-Schönberger, V., & Cukier, K. (2013). *Big Data: A Revolution That Will Transform How We Live, Work, and Think*. Houghton Mifflin Harcourt.
- MDPI. (2023). An axial model and Visual Graph Analysis. *Land*, 12(11), 2084. <https://doi.org/10.3390/land12112084>
- OpenCV. (n.d.). OpenCV Documentation. Retrieved from <https://opencv.org/>
- Penn, A., Hillier, B., Banister, D., & Xu, J. (1998). Configurational modelling of urban movement networks. *Environment and Planning B: Planning and Design*, 25(1), 59-84.
- Project for Public Spaces. (2019). The Social Life of Small Urban Spaces: William H. Whyte's Influence on Public Space Design. Retrieved from <https://www.pps.org/>
- Roboflow. (n.d.). Roboflow: Build and Ship Computer Vision Projects Faster. Retrieved from <https://roboflow.com/>

- Roboflow annotators. Roboflow: Annotators. Retrieved from https://supervision.roboflow.com/annotators/#_tabbed_1_1
- Rofo, M. W., & Kloep, M. L. (2014). Evaluating Campus Planning: Spatial Configuration and Space Syntax in University Design. *Environment and Planning B: Planning and Design*, 41(6), 1004-1021.
- Russell, S., & Norvig, P. (2020). *Artificial Intelligence: A Modern Approach* (4th ed.). Pearson.
- Sutton, R. S., & Barto, A. G. (2018). *Reinforcement Learning: An Introduction* (2nd ed.). MIT Press.
- Szeliski, R. (2010). *Computer Vision: Algorithms and Applications*. Springer.
- Turner, A. (2001). Depthmap: A program to perform visibility graph analysis. *Proceedings of the 3rd International Symposium on Space Syntax*, 31-32.
- Urban Design Lab. (2023). Understanding Human Interaction in Urban Spaces. Retrieved from <https://urbandesignlab.in/>
- Vaughan, L. (2007). The spatial syntax of urban segregation.
- Varoudis, T. (2012). Space Syntax Theory and Application. *University College London*.
- Whyte, W. H. (1980). *The Social Life of Small Urban Spaces*. New York: Project for Public Spaces.
- Yolov5. (n.d.). Ultralytics YOLOv5. Retrieved from GitHub.
- Zhang, C., Xiong, Y., & Wang, J. (2016). Understanding deep learning for image recognition: A tutorial for beginners. *Journal of Computer Science and Technology*, 31(4), 665-680.
- Zhang, Z., & Yang, Y. (2018). A review on video annotation methods. *Journal of Visual Communication and Image Representation*, 54, 271-280.
- Zhou, Z., Wang, D., & Li, W. (2020). A survey on data annotation for machine learning: Challenges and solutions. *Artificial Intelligence Review*, 53(5), 3311-3335.

