

Automatizált, állókép alapú forgalom- számlálás erdészeti utakon

A közlekedési infrastruktúra, illetve annak használata rendkívül sokszínű és szerteágazó képet mutat mind műszaki paramétereiben, mind a használat jellegét illetően. Az erdészeti utak speciális használatának bemutatásával a szélesebb körű megismertetés lehetőségét kínáljuk fel olvasóinknak.

DOI 10.24228/KTSZ.2020.6.3

Kisfaludi Balázs – Péterfalvi József – Primusz Péter

Soproni Egyetem, Geomatikai, Erdőfeltárási és Vízgazdálkodási Intézet
e-mail: kisfaludi@gmail.com, peterfalvi.jozsef@uni-sopron.hu, primusz.peter@uni-sopron.hu

1. HÁTTÉR

Az erdészeti utak nemcsak a faanyagszállítást, hanem általánosságban az erdő megközelítését szolgálják. Az úthasználóknak különböző, sokszor egymással ellentétes igénye van az úthálózattal szemben. A hálózat kezelőjének elemi érdeke, hogy az utakon áthaladó forgalomról és az úthasználók igényeiről minél több információval rendelkezzen. Az információk birtokában ugyanis megalapozott forgalomkezelést folytathat annak érdekében, hogy az erdészeti úthálózat a lehető legtöbb funkcióját ellássa.

Az erdészeti utak és úthálózatok forgalmának mérésére számos eszköz áll rendelkezésre. Az eszközök robusztusak, és általában az áthaladások darabszámának meghatározására szolgálnak. Az úthasználók típusára vonatkozó adatokat szenzor együttesekkel gyűjtik. A digitális fotók, illetve videofelvételek nagyon sokféle információt tartalmaznak, ám a kiértékelésük egészen a legutóbbi időkig élőmunka-igényes volt. A gépi tanulás és a gépi látás fejlődésével a vizuális adatok feldolgozása lényegesen egyszerűbb, gyorsabb és pontosabb lett.

A cikkben egy olyan kísérleti eszközt mutatunk be, amely erdei környezetben készült fényképekről képes az úthasználók típusának (pl. személygépkocsi, tehergépkocsi, gyalogos, kerékpáros) meghatározására.

2. IRODALMI ÁTTEKINTÉS

Az erdők látogatottságára vonatkozó statisztikák először az USA-ban jelentek meg az 1950-es évek második felében. A kimutatások a nemzeti parkok belépőszámain, személyes számláláson, illetve becslésen alapultak [6]. Az első eszközös számlálásokat a közúti gyakorlatból átvett számlálókkal végezték az 1960-as évektől kezdődően [11].

Magyarországon az 1961. évi erdőtörvény az erdők egészségmegőrző hatására hivatkozva megállapítja az erdők üdülési, pihenési funkcióját, valamint lehetővé teszi mindenki számára az erdészeti úthálózat és az erdőterület ilyen célú használatát [19]. A nagyszámú erdőlátogató megjelenése hazánkban is szükségessé tette az erdők turistaforgalmának mérését [13]. A látogatottság meghatározására az 1960-as évek elejétől kezdve folynak tudományos vizsgálatok, amelyek módszertana leggyakrabban

1. táblázat: A terepi forgalomszámlálás lehetséges módjai Cessford és Muhar (2003) nyomán, kiegészítve és átalakítva az azóta megjelent kutatások alapján

Számláló személyek	A kívánt helyszínen forgalomszámlálást végző személyek
Kamerás rögzítés	A felvételek a helyszínen készülnek, a kiértékelés utólag
Távérzékelés	Légifelvek kiértékelése
Mechanikus	Fizikai elmozdulást számláló eszközök (pl. forgókapu)
Nyomásérzékelők	Közvetlen nyomásra (pl. rálépés) számláló eszközök
Szeizmikus érzékelők	Az út burkolatába épített érzékelők, melyek az út felületén keletkezett vibrációt fogják fel
Aktív optikai érzékelők	A látogatók által megszakított fénysugár váltja ki az észlelést
Passzív optikai érzékelők	Az érzékelő által látott infravörös képből bekövetkező változás váltja ki az észlelést
Rádió sugaras	A látogatók által megszakított rádiónyaláb váltja ki az észlelést
Mágneses érzékelők	Az elhaladó fémes tárgy változást okoz a mágneses mezőben
Radar	A visszavert rádióhullámok változását érzékeli
Ultrahang	A visszaverődő, illetve detektált ultrahang változását észleli
Lézerszkennő	Másodpercenként sok pont 3D koordinátáinak meghatározása lézer-táv-méréssel

mintanapokon végzett személyes számlálást, valamint kérdőíves felmérést tartalmazott [24], [10], [25], [3], [17], [16]. Magyarországon az első publikált műszeres forgalomszámlálást 1987-ben végezték [9], és azóta csak egy vizsgálatban használtak automatikus számláló eszközt [18], ami annak tudható be, hogy a hazai körülményekhez képest az automatikus látogatószámlálók drágának bizonyultak [3].


Az 1960-as évektől napjainkig a természeti környezetben végzett forgalomszámlálásra az eszközök és módszerek széles skáláját fejlesztették ki. Az 1. táblázat mutatja be összefoglalóan a számlálási lehetőségeket.

A bemutatott automatizálható számláló megoldások közül a képrögzítéssel van lehetőség az úthasználók csoportosítására egy viszonylag egyszerű érzékelő használatával [5]. A képrögzítésen alapuló módszerek közül a legelterjedtebb a helyszínen telepített kamerás rögzítés. A kamera lehet analóg vagy digitális, és készíthet álló vagy mozgóképet. Az analóg rendszerek alkalmazása addig volt jellemző, amíg a digitális eszközök széles körben elterjedté nem váltak. Ez legfőképp a feldolgo-

zás nagy élőmunka igényének, valamint az adat-visszakérés nehézségének tudható be [26, 2, 1, 7]. A digitális kamerák tároló kapacitása sokszorosa az analóg kameráénak, emellett a digitális felvételek könnyen továbbíthatók az interneten keresztül. Ez utóbbi megoldást természeti környezetben a szélessávú internetelés hiánya korlátozhatja.

A felvételek készülhetnek folyamatosan, meghatározott időintervallumonként vagy külső jel által vezérelten. Folyamatos videofelvételt ritkán rögzítenek, ez a megoldás a video-stream alapú számlálóknál elterjedt. A time-lapse videó és fotórögzítés csökkenti a tárhelyigényt, illetve megkönnyíti az utólagos kézi kiértékelést [2]. A mozgásérzékeléshez kötött videó [12] vagy állókép tárolás [4], [7], [15] tovább csökkenti a tárhelyhasználatot, viszont a mozgásérzékelőt kalibrálni kell annak érdekében, hogy a lehető legtöbb látogatót észlelje, minimális téves észlelés mellett [5]. A kamera telepítésére vonatkozóan [1] végeztek vizsgálatot, és azt találták, hogy a 4 méter magasan elhelyezett kamera felvételein az utólagos kiértékeléskor a népes látogatócsoportok létszáma pontosabban meghatározható volt, mint

1. ábra: A kísérleti eszköz látványterve



a helyszínen végzett személyes számláláskor. A kamerát az út szélétől 1-2 méter távolságban célszerű elhelyezni úgy, hogy a mozgás irányával kb. 20°-45°-os szöveget zárjon be [7], [15].

A digitális kamerák által készített fotókat, illetve videókat napjainkban gépi látáson alapuló szoftverekkel dolgozzák fel. 2012-től kezdve az élvonalbeli képfelismerő algoritmusok döntő többsége mesterséges konvolúciós neurális hálózatokat (CNN - Convolutional Neural Network) tartalmaz a AlexNet algoritmus [14] kiemelkedően jó teljesítményének következtében. A CNN technológia különböző szűrők egymás utáni futtatásával jellegzetes mintázatokat keres egy digitális képen, majd a mintázatok összességét neurális háló segítségével sorolja be az előre meghatározott osztályok valamelyikébe. Az ilyen típusú képfelismerő rendszerek nagy mennyiségű felcímkézett képet igényelnek a megfelelő szűrők kiválasztásához, valamint az osztályozó paramétereinek beállításához. Ilyen méretű adatbázis általában nem áll rendelkezésre egy-egy felismerési feladathoz, azonban több felcímkézett képgyűjtemény is hozzáférhető az Interneten, amelyek közül a legnagyobb az ImageNet nevű adatbázis. Ez összesen 14 millió képről tartalmazza, hogy a 21 000 kategóriából mi látható rajta, ebből 1 millió képen az objektum elhelyezkedése is adott [22]. A nagyszámú kategória biztosíték arra, hogy legalább részben átfedjen az egyedi felismerési feladatok kategóriáival, ami lehető-

séget ad arra, hogy a nagy adatbázison tanított neurális háló felhasználható legyen az egyedi feladat megoldásánál.

A legismertebb CNN rendszerek az AlexNet [14], a GoogleNet [23], a ResNet [8], illetve széles körben alkalmazzák még a YOLO [21] rendszert is. A ResNet általános felismerési pontossága 96% fölött volt a 200 osztály felismerését célzó ImageNet versenyen.

Az irodalmat áttekintve azt láthatjuk, hogy természeti környezetben az egyszerűbb számlálók használata terjedt el. A fotó, illetve videó alapú számlálók adatait jórészt emberi erővel dolgozták fel, bár az általános képfelismerésre kiváló teljesítményű eszközök állnak rendelkezésre.


3. MÓDSZER

3.1. Kísérleti számláló eszköz

A kutatás kezdetekor készen kapható, offline működésre alkalmas, fotó alapú látogató felismerő, illetve számláló eszköz nem volt elérhető. Emiatt egy kísérleti eszközt fejlesztettünk ki, demonstrációs céllal (1. ábra).

A kísérleti eszközt Magyarország egyik leglátogatottabb régiójában, a Dunakanyarban helyeztük ki egy erdészeti útra. A mérési hely az egyik jelentős belépési pont az erdőbe. Az út a mérési helyen észak-dél irányú és 6 m széles

2. ábra: A kísérleti forgalomszámláló fő részei



aszfalt burkolattal ellátott, amin vegyes összetételű forgalom halad, engedéllyel még személygépkocsik is behajthatnak.

Az eszköz egy digitális kamerából, két mozgásérzékelőből és egy központi egységből áll. A mozgásérzékelők jelére a kamera 1MP felbontású állóképet készít, amit a központi egységen is tárolnak (2. ábra).

Képkészítésre egy Vivotek IP 8332 kültéri biztonsági kamerát használtunk. A kamerát Arnberger ajánlásának megfelelően 4 méter magasságban helyeztük el észak felé tájolva [2]. Az eszköz által készített fotó felbontása kellően kicsi ahhoz, hogy az arcvonások ne legyenek felismerhetők, így a látogatók személyiségi jogai nem sérülnek. Az eszköz nappal színes, míg éjjel fekete-fehér képeket készít. Az éjszakai felvételeket a kamera beépített infravakuja teszi lehetővé. A fotó mellett az eszköz regisztrálja a mozgásérzékelők megszakításának idejét is. Ezzel lehetővé válik az áthaladó látogató haladási irányának és sebességének meghatározása.

A mozgásérzékelést két darab Carlo Gavazzi PA18CAR65 típusú, retro-reflexiós optikai szenzor végzi. A szenzorok infralézerfényvel

működnek, érzékelési távolságuk 10 cm oldalhosszúságú prizmát használva 6,5 méter. A nem látható lézerhez a többi típushoz mérten rövid érzékelési távolsága ellenére a látogatók egészségvédelme érdekében ragaszkodtunk. A reflexiós megoldás kisebb távolságból és kevésbé megbízhatóan működik, mint az átmenő-sugaras érzékelők, ám használatukkal az útburkolatot nem szükséges megbontani. Az érzékelők és a hozzájuk tartozó prizmák között 6,4 m távolság volt, míg az érzékelő párok között 2 m. A prizmák és érzékelők stabil rögzítését beton alapra szerelt, egyedi tervezésű fém oszlopokkal oldottuk meg.

Adattárolásra, adatkivételre és a részegységek összekötésére miniszámítógépet alkalmaztunk. Ezt az eszközt FEZ Cobra néven a GHI Electronics fejlesztette. Egy 32 bites ARM7 mikrovezérlő köré épül, 42 pinnel, TFT érintőképernyővel, SD kártya meghajtóval és Ethernet porttal rendelkezik.

3.2. A képek automatizált kiértékelése

A kísérleti számláló eszköz digitális képeinek feldolgozására gépi tanulást és gépi látást magában foglaló eljárást használtunk.

3.2.1. Tanító/teszt adatbázis

A gépi tanulások módszerek hatékonysága a tanító adatbázisuk – felcímkézett képek – minőségén múlik. Kutatásunkban a számláló képei közül 10 800 képet választottunk ki a tanító és teszt adatbázishoz. A képeken látható úthasználók megjelölését és felcímkézését saját készítésű szoftver segítségével kiértékelő személyek végezték. Az adatbázis tartalmazta a képet, a kép készítési dátumát és idejét, a képen látható úthasználók képi helyzetét, típusát, tevékenységét, valamint haladási irányát. Az úthasználók képi helyzetét a befoglaló téglalapjuk koordinátaival adtuk meg. Az úthasználók típusa a következők valamelyike lehet: gyalogos, kerékpáros, lovas, lovaskocsi, motorkerékpár, személygépkocsi, munkagép, tehergépkocsi, busz, egyéb, ismeretlen. Egyéb kategóriába a besorolhatatlan úthasználók kerültek, mint pl. kerekesszékes, rolleres, segway-el közlekedők, állatok. Az ismeretlen kategóriába azok az úthasználók kerültek, akik besorolása a kép minősége vagy takarás miatt nem volt lehetséges. Tevékenységek közül elkülönítettük az erdészeti feladatot ellátókat, kirándulókat, sportolókat. A haladási irány megmutatja, hogy az úthasználó az erdőbe megy, vagy az erdőből jön.

Az adatbázis 10 800 képen összesen 22 500 úthasználót különítettek el a kiértékelést végző személyek. Az úthasználók típus szerinti megoszlását a 2. táblázat mutatja be.

2. táblázat: A tanító/teszt adatbázis összetétele látogatótípusok szerint

Gyalogos	13 726
Kerékpáros	3 548
Lovas	25
Lovaskocsi	132
Motorkerékpáros	140
Személygépkocsi	4 664
Tehergépkocsi	36
Munkagép	218

3.2.2. A képfeldolgozó rendszer


A kísérleti forgalomszámoló eszköz IMP felbontású digitális állólépeket készített.

E képek automatikus feldolgozhatóságát gépi tanulást alkalmazó, nyílt forráskódú szoftver segítségével szerettük volna demonstrálni. Az elérhető megoldások közül a YOLO (You Only Look Once) nevű rendszert [20] választottuk az irodalmi adatok alapján várható jó teljesítménye és az egyszerű alkalmazhatósága miatt. A YOLO egy általános célú képfeldolgozó rendszer, amelyet a minél gyorsabb objektum lokalizálásra és felismerésre optimalizáltak. A gyorsaság mellett legalább olyan pontos pozicionálást és felismerést tűztek ki célul a fejlesztők, mint ami a legmodernebb képfeldolgozó rendszerekre jellemző. A YOLO legnagyobb újdonsága az, hogy az objektum detektálási és a felismerési feladatok különálló lépéseit egy neurális hálózat segítségével oldja meg. Emellett a valószínűsíthetően objektumot ábrázoló területek meghatározásánál a teljes képet figyelembe veszi, ellentétben a legtöbb más algoritmus-sal, amelyek egyszerre csak a kép egy kisebb részletét dolgozzák fel. A YOLO a teljes képet 24 konvolúciós réteg és két teljesen összekapcsolt réteg alkalmazásával csökkenti le egy 7×7 méretű rácsra (3. ábra).


Az algoritmus minden rács cellában meghatározott számú befoglaló téglalapot, amelyek objektumot tartalmazhatnak. A befoglalók öt tulajdonságát – x,y koordináta, szélesség, magasság, megbízhatóság – megbecsüli a rendszer. Amennyiben egy cella nagy valószínűséggel objektumot tartalmaz, a rendszer kiszámítja az előre meghatározott osztályok előfordulási valószínűségét a cellában található befoglaló téglalapokra, majd ezek szorzataként magára a cellára. Így a teljes képre előállnak a lehetséges befoglaló téglalapok, valamint a 7×7-es rácsban cellánként a legvalószínűbb kategóriák. Ezek alapján adja meg a rendszer a végleges észlelési és osztályozási eredményeket (4. ábra).

A kutatók azt tapasztalták, hogy az előbbieken bemutatott rendszer teljesítménye alatta maradt a kortárs rendszerek teljesítményének. A legszembetűnőbb hibát az objektumok lokalizálásánál találták. Emiatt egy évvel később, 2016-ban bemutatták a YOLO továbbfejlesztett változatát [21], amelyet a

3. ábra: A YOLO rendszer felépítése



4. ábra: A YOLO működése



jelen kutatásban alkalmaztunk. A YOLOv2 rendszer a konvolúciós lépések közötti normalizálásnak, nagyobb kezdeti felbontású képek használatának, továbbfejlesztett befoglaló téglalap becslésnek, változó felbontású (7x7 helyett 13x13, illetve 26x26) utolsó rétegeknek, valamint egy hierarchikus osztályozó alkalmazásának köszönhetően az egyik legjobb képfeldolgozóvá vált.

A hierarchikus osztályozónak köszönhetően a tanításhoz egyszerre több adatbázis is felhasználható, mivel a különböző igényeknek megfelelő pontosságú címkék (pl. „Állat” - „Emlős” - „Kutya” - „Német juhász”) mindegyike elhelyezhető az osztályozó fogalomlistájában. A COCO (Common Objects in Context) nevű, detektálást segítő adatbázis és az ImageNet osztályozást segítő adat-

bázis kombinálásával a kutatók létrehozták a YOLO9000 nevű képfeldolgozó rendszert, amely 9000 osztály felismerésére képes. A YOLO9000 szintén szabadon hozzáférhető, használatra kész állapotban.

3.2.3. A YOLO rendszer tanítása saját adatokkal


A kutatás célkitűzésben ismertetett 8 úthasználó osztály mindegyike megtalálható a YOLO9000 előre tanított osztályai között. A kutatásban létrehozott tanító/teszt adatbázis mérete jóval kisebb, mint amin a YOLO9000-et tanították, ezért a neurális háló kimeneti rétegeinek újratanításával lehet a YOLO9000-et a kutatásunkban gyűjtött képek felismerésére adaptálni (transfer learning). A hálózat tanítása a Darknet keretrendszerben történt [20], [21] a tanító/teszt adatbázisból kiválasztott 6300 kép segítségével. A Darknet program képes a számítógép processzorán és a grafikus kártyát használva is futni, de kellően gyors működés csak a GPU-tól (Graphics Processing Unit) várható. A hálózat tanítását és tesztelését egy NVIDIA Quadro K2200 típusú grafikus kártyán végeztük, amelyben a CUDA (Compute Unified Device Architecture) platform használatával 640 grafikus processzor párhuzamos elérésére van lehetőség. A keretrendszer iterációs úton, több ciklus alatt állítja be a hálózat súlyszámait. Egy ciklusban előre megadott számú – jelen esetben 8 – képet választ ki véletlenszerűen a tanító adatbázisból, ezeket végigfuttatja az előző ciklusban vagy a kezdeti értékekkel beállított hálózaton, majd különböző mérőszámok kiszámítása után a gradiens elv szerint módosítja a súlyszámokat. Az eredmények megfelelőségét az IOU (Intersection Over Union - területmetszet / terület unió), a Precision (pontosság) és a Recall (visszaidézés) mérőszámokkal lehet jellemezni, amelyeket minden esetben a valós pozitív eredmények (a gép által meghatározott, és az adatbázisban szereplő úthasználó osztály megegyezik) alapján számít a keretrendszer.

3.2.4. A képfelismerés eredményességének értékelése

A képfelismerés eredményességének mérésére az IOU értéket használtuk, a rendszer tanításakor ennek maximalizálása volt a cél. A tanítás alatt az IOU elméletileg minden ciklussal növekszik (gradiens elv), vagyis a rendszer egyre jobban rátanul az adott adatbázisra. Fennáll a veszélye azonban annak, hogy túlságosan specialista lesz a tanítás eredménye, és az ismeretlen képeken elkezd romlani a teljesítmény. Ezt a jelenséget túltanításnak nevezik. Ennek elkerülése érdekében minden 1000. ciklus után elmentésre kerül az aktuális paraméterkészlet, amit a tesztadatbázison ellenőrizni kell. A tanítás eredményének azt a paraméterkészletet kell tekinteni, amely mellett a tesztadatbázisra a legmagasabb IOU érték adódik. A felcímkézett képek közül a tanításhoz fel nem használt 4500 kép szolgált teszt adatbázisként.

A tanítások eredményét különböző kezdeti paraméterek mellett végzett futtatásokkal vizsgáltuk. A Darknet keretrendszer 2-féle paraméter állítását teszi lehetővé: bemeneti kép első lépésben beállított felbontása azt vezérli, hogy mekkora objektumok detektálására lesz képes a rendszer. A felbontást 100 és 600 pixel között változtattuk. A konvolúciós lépések után a kapcsolt rétegek egy potenciálisan látogatót ábrázoló területről eldöntik, hogy az a kimeneti nyolc osztály közül melyikbe, mekkora valószínűséggel tartozik. A rendszernek megadható, hogy egy bizonyos legnagyobb valószínűség alatt a vizsgált területet ne fogadja el úthasználóként. Az ezt a viselkedést szabályozó megbízhatósági küszöbérték növelésével egyre kevesebb találatot kapunk, viszont azok nagyobb valószínűséggel lesznek helyesek. A megbízhatósági küszöbértéket 0,2 és 0,7 között változtattuk 0,05 lépésenként. A tanítást minden esetben 14 000 cikluson át végeztük.

5. ábra: A kísérleti forgalomszámláló működési időskálája
a naponta mentett fotók számával



4. EREDMÉNYEK

4.1. Az eszköz üzemelése

A kísérleti eszközt először 2012-ben helyeztük üzembe. 2015-ig több fejlesztést hajtottunk végre rajta, aminek következtében 2016-ban az eszköz saját hibájából adódó adathiány nem fordult elő (5. ábra).


Az üzemelés időtartama alatt 77 500 fotó készült. A későbbi feldolgozásba csak azok a fotók kerültek be, amelyek olyan napon készültek, amikor az eszköz 24 órában működött. Az adatbázisban 550 ilyen teljes nap volt, amiből 300 db 2016-ból származott.

4.2. Képfelismerés

A képfelismerés eredményességét az IOU értékkel mértük, és ennek maximalizálására törekedtünk a saját osztályok felismerésére betanított YOLO9000 rendszer paraméterezésénél.

A különböző súlyszám készletek mellett elért IOU eredményeket a 7. ábra mutatja be. Az ábra alapján megállapítható, hogy a 7000 (IOU = 59,63) és a 11000 (IOU = 58,92) ciklus alatt kiszámított súlyszámokkal működő rendszer adta a legjobb eredményt a teszt adatbázison. A két paraméterkészlet közül a 11000 ciklushoz tartozót választottuk ki a további vizsgálatokhoz, mivel az IOU értéke alig


6. ábra: A képfelismerés eredménye a teszt adatbázis egy képén




kisebb, mint a 7000-esé, viszont jóval több kép jellemzőit veszi figyelembe.

A rendszer két állítható tulajdonsága a kezdeti felbontás és a felismerési küszöbérték volt. A tesztképekre vonatkozó IOU változását a felbontás függvényében a 8. ábra mutatja be. Az ábra alapján megállapítottuk, hogy az a hálózat nyújtotta a legjobb teljesítményt, amelyik a kezdeti lépésben 288×288 pixel méretűre alakította a bemeneti képet. A megbízhatósági küszöbérték növelésével a tesztadatbázisban szereplő úthasználók közül egyre kevesebbet talál meg az algoritmus (9. ábra).


7. ábra: Az IOU érték alakulása a tanítási ciklusok számának függvényében



8. ábra: Az IOU érték alakulása a kezdeti felbontás függvényében



9. ábra: A felismert úthasználók aránya a megbízhatósági küszöbérték függvényében



Ezzel együtt csökken a tévesen osztályozott, illetve a fals pozitív találatok száma (3. táblázat) is. Az algoritmus által jelzett úthasználók közül 0,35-ös küszöbérték mellett volt a legtöbb a valós pozitív találat. A 0,35 küszöbértékhez tartozó találatok tévesztesi mátrixa (4. táblázat) azt mutatja, hogy a gyalogosok és kerékpárosok felismerése 94%, ill. 95% pontossággal történt, a személygépkocsiké pedig meghaladta a 85% ot. A többi osztály felismerési pontossága 50% alatt maradt.

5. ÖSSZEFOGLALÁS, KÖVETKEZTETÉSEK

Bemutattunk egy állóképeket készítő digitális kamerából, áthaladást érzékelő optikai szenzorból és egy központi vezérlő egységből álló kísérleti forgalomszámoló eszközt. Az eszköz az 5. ábra tanúsága szerint alkalmasnak bizonyult a hosszútávú, beavatkozás-mentes üzemelésre erdei környezetben. A rendszer legérzékenyebb eleme az optikai szenzor volt. Az érzékelő stabil rögzítése kulcsfontosságú volt az eszköz működése szempontjából. Pozitív csaldóást jelentett, hogy a 4 éves tesztidőszak alatt szándékos rongálás nem történt.

A kísérleti számláló képeinek felismerésére a YOLO9000 nevű neurális háló alapú objektum detektáló rendszert adaptáltuk. A felismerni kívánt látogató csoportokat kiértékelő személyek jelölték meg 10 800, az eszköz által készített képen. Ezt az adatbázist használtuk fel teszt és tanító képekként a neurális háló utolsó, kapcsolt réteg súlyszámainak finomhangolására. Az adaptált rendszer a gyalogosokat és kerékpárosokat 94-95%-os, míg a személygépkocsikat 85%-os pontossággal ismerte fel. A bemutatott feldolgozási módszer jó felismerési eredménye azt mutatja, hogy a szabadon hozzáférhető, modern képfelismerő rendszerek alkalmazhatóak látogató-számlálási célú képfelismerésre természeti környezetben. Ez a jó eredmény csak akkor várható, ha a képfelismerő rendszer előre kiszámított súlyszám-készlettel rendelkezik a felismerni kívánt csoportokra. Fontos tapasztalat továbbá, hogy a tanító adatbázisnak minden felismerni kívánt osztályból ezres nagyságrendű képet kell tartalmaznia az elfogadható felismerési arány eléréséhez.

KÖSZÖNETNYILVÁNÍTÁS

A publikáció elkészítését az EFOP-3.6.2-16-2017-00018 („Termeljünk együtt a természettel – az agrárerdészet mint új kitörési lehetőség”) projekt támogatta. A kutatást szakmailag segítette a Pílisi Parkerdő Zrt.

3. táblázat: A megbízhatósági küszöbérték hatása az algoritmus felismerési pontosságára

Küszöbérték	Összes találat	Jó találat	Rossz találat			
			Összes	Téveszt	Nem lát	Többet lát
0,70	4768	3491	1277	46	1230	1
0,60	4776	3740	1036	60	967	9
0,50	4801	3872	929	80	815	34
0,40	4845	3976	869	89	702	78
0,35	4876	4008	868	104	655	109
0,30	4932	4054	878	103	610	165
0,20	5209	4131	1075	133	500	442

4. táblázat: A 0,35-ös megbízhatósági küszöbértékhez tartozó tévesztési mátrix

Tényleges út-használó	db	Számított úthasználó [db]								
		Gyalogos	Kerékpáros	Lovas	Lovaskocsi	Motor	Szgg.	Munkagép	Tgk.	-
Gyalogos	700	657	7	6	0	0	1	0	0	29
Kerékpáros	489	9	464	2	0	0	1	0	0	13
Lovas	4	4	0	0	0	0	0	0	0	0
Lovaskocsi	50	0	0	0	24	1	2	0	0	23
Motor	11	2	4	0	0	4	0	0	0	1
Szgg.	3249	0	0	0	0	0	2772	0	1	476
Munkagép	18	0	0	0	1	7	3	0	0	7
Tgk.	246	3	0	0	1	0	49	0	87	106
-	109	63	10	0	1	2	28	0	5	0

FELHASZNÁLT IRODALOM

- [1] Arnberger, A., Eder, R., 2007. Monitoring recreational activities in urban forests using long-term video observation. For. Int. J. For. Res. 80, 1–15. DOI: <http://doi.org/dxq36n>
- [2] Arnberger, A., Haider, W., Brandenburg, C., 2005. Evaluating Visitor-Monitoring Techniques: A Comparison of Counting and Video Observation Data. Environ. Manage. 36, 317–327. DOI: <http://doi.org/cbm3w4>
- [3] Benkhard, B., Szabó, Bence., 2012. Do we need mapping of tourist flows? Lessons from Börzsöny Mountain, in: Fredman, P., Stenseke, M., Liljendahl, H., Mossing, A., Laven, D. (Eds.), Outdoor Recreation in Change – Current Knowledge and Future Challenges. Institute for Landscape Architecture and Landscape Management, Bodenkultur University, Stockholm, Sweden, pp. 374–375.
- [4] Campbell, M.J., 2006. Monitoring Trail Use with Digital Still Cameras: Strengths, Limitations and Proposed Resolutions, in: Siegrist, D., Clivaz, C., Hunziker, M., Iten, S. (Eds.), Proceedings of the Third International Conference on Monitoring and Management of Visitor Flows in Recreational and Protected Areas. University of Applied Sciences Rapperswil,

- Rapperswil, Svájc, pp. 317–321.
- [5] Cessford, G., Muhar, A., 2003. Monitoring options for visitor numbers in national parks and natural areas. *J. Nat. Conserv.* 11, 240–250. DOI: <http://doi.org/fj2vth>
- [6] Clawson, M., 1958. Statistics on outdoor recreation. Resources for the future Inc., Washington, USA.
- [7] Duke, D., Quinn, M., 2008. Methodological considerations for using remote cameras to monitor the ecological effects of trails users: lessons from research in Western Canada, in: Raschi, A., Trampetti, S. (Eds.), *Management for Protection and Sustainable Development - Proceedings of the Fourth International Conference on Monitoring and Management of Visitor Flows in Recreational and Protected Areas*. National Research Council, Institute for Biometeorology, Montecatini Terme, Olaszország.
- [8] He, K., Zhang, X., Ren, S., Sun, J., 2015. Deep Residual Learning for Image Recognition. *ArXiv151203385 Cs*.
- [9] Héjj, B., 1987. Az erdei kirándulóforgalom mérése elektronika felhasználásával. *Az Erdő* 36 (122), 513–514.
- [10] Héjj, B., 1986. Kik látogatják a soproni erdőket? *Soproni Szle.* 15., 69–78.
- [11] James, G.A., Ripley, T.H., 1963. Instructions for Using Traffic Counters to Estimate Recreation Visits and Use (resreport No. SE-3). U.S. Department of Agriculture, Forest Service, Southeastern Forest Experiment Station, Asheville, NC, USA.
- [12] Janowsky, D. v, Becker, G., 2003. Characteristics and needs of different user groups in the urban forest of Stuttgart. *J. Nat. Conserv.* 11, 251–259. DOI: <http://doi.org/c6m238>
- [13] Keresztesi, B., 1969. FAO-EGB értekezlet az erdők közjóléti szerepének értékeléséről. *Az Erdő*, 18. (104.) kötet, 7. szám, 298–302. o.
- [14] Krizhevsky, A., Sutskever, I., Hinton, G., 2012. ImageNet Classification with Deep Convolutional Neural Networks. *Neural Inf. Process. Syst.* 25. DOI: <http://doi.org/gbhxh>
- [15] Miller, A.B., Leung, Y.-F., Kays, R., 2017. Coupling visitor and wildlife monitoring in protected areas using camera traps. *J. Outdoor Recreat. Tour.* 17, 44–53. DOI: <http://doi.org/ggn939>
- [16] Nagy, G.M., 2015. Soproni erdei közösségi terek vonzerőleltára, in: Bidló, A., Facskó, F. (Eds.), *Nyugat-Magyarországi Egyetem, Erdőmérnöki Kar, V. Kari Tudományos Konferencia Absztraktkötete*. Nyugat-magyarországi Egyetem Kiadó, Sopron, p. 42.
- [17] Nagy, G.M., Héjj, B., 2012. A soproni “városi” erdők terhelésvizsgálatai, in: Fazekas, I., Szabó, V. (Eds.), *A Környezettudatos Települések Felé: III. Települési Környezet Konferencia*. Meridián Alapítvány, Debrecen, p. 287.
- [18] Nagy, G.M., László, R., 2014. A Hidegvíz-völgy turisztikai terhelés vizsgálata, in: Bidló, A., Horváth, A., Szűcs, P. (Eds.), *Nyugat-Magyarországi Egyetem, Erdőmérnöki Kar, IV. Kari Tudományos Konferencia*. NymE Erdőmérnöki Kar, Sopron, p. 407.
- [19] Pápa, M., 1967. Közös úton - Erdészet és turisztika. *Az Erdő* 16 (102), 206–209.
- [20] Redmon, J., Divvala, S., Girshick, R., Farhadi, A., 2015. You Only Look Once: Unified, Real-Time Object Detection. *CoRR abs/1506.02640*.
- [21] Redmon, J., Farhadi, A., 2016. YOLO9000: Better, Faster, Stronger. *CoRR*.
- [22] Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A.C., Fei-Fei, L., 2015. ImageNet Large Scale Visual Recognition Challenge. *Int. J. Comput. Vis. IJCV* 115, 211–252. DOI: <http://doi.org/gcgk7w>
- [23] Szegedy, C., Wei Liu, Yangqing Jia, Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., Rabinovich, A., 2015. Going deeper with convolutions, in: *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Presented at the 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 1–9. DOI: <http://doi.org/gftjd8>
- [24] Tóth, S., 1974. Erdészeti közvélemény-kutatás az erdők üdülési funkciójának vizsgálata céljából. *Az Erdő* 23 (109), 385–391.

- [25] Walterné, C.E., 1987. Erdei üdülési igények és szokások a Pilisben és a Budai-hegységben. *Az Erdő* 36 (122), 325–327.
- [26] Yuan, S., Maiorano, B., Yuan, M., 1995. *Techniques and Equipment for Gathering*

Visitor Use Data on Recreation Sites. United States Department of Agriculture, Forestry Service.



Counting forest road users on digital still images by machine learning

Mixed use of the forest road network is permitted by law in Hungary. Managers of frequently visited forests should know the traffic of their road network in order to minimize conflicts between the road users.

In this article an experimental traffic counter is presented. The tool takes digital still images and is able to assess road user categories and numbers by image recognition.

The counter records IMP images on the signal of a pair of retro-reflexive optical sensors mounted on the roadside. The device had been in operation throughout a year. It was learned that the stable fixing of the sensors and the elevated position of the camera is crucial for the operation.

The images were assessed by the adapted version of the YOLO9000, which is a neural net based object detection system. The YOLO9000 was parametrized by human-assessment of 10.000 images of the counter. 94-95% of pedestrians and cyclists while 85% of cars were correctly recognized by the adapted system.

Our results showed that it is possible to successfully use free, open-source image recognition tools for visitor counting in a natural environment.



Zählung von Forststraßenbenutzern auf digitalen Standbildern durch maschinelles Lernen

Die gemischte Nutzung des Forststraßennetzes ist in Ungarn gesetzlich zulässig. Manager häufig besuchter Wälder sollten den Verkehr ihres Straßennetzes kennen, um Konflikte zwischen den Verkehrsteilnehmern zu minimieren.

In diesem Artikel wird ein experimenteller Verkehrszähler vorgestellt. Das Gerät nimmt digitale Standbilder auf und kann Kategorien und Anzahl von Verkehrsteilnehmern durch Bilderkennung bewerten. Der Zähler zeichnet IMP-Bilder auf Grund des Signals von am Straßenrand montierten retroreflexiven optischen Sensoren auf. Das Gerät war seit einem Jahr in Betrieb. Es wurde festgestellt, dass die stabile Befestigung der Sensoren und die erhöhte Position der Kamera für den Betrieb entscheidend sind.

Die Bilder wurden mit der angepassten Version des YOLO9000 (eines auf einem neuronalen Netz basierenden Objekterkennungssystems) ausgewertet. Der YOLO9000 wurde durch menschliche Beurteilung von 10.000 Bildern des Zählers parametrisiert. Das angepasste System hat 94-95% der Fußgänger und Radfahrer, sowie 85% der Autos korrekt erkannt.

Unsere Ergebnisse zeigten, dass es möglich ist, kostenlose Open-Source-Bilderkennungstools für die Besucherzählung in einer natürlichen Umgebung erfolgreich einzusetzen.