

Animal welfare, etológia és tartástechnológia



Animal welfare, ethology and housing systems

Volume 18

Issue 1

Gödöllő
2022

PRECÍZIÓS ELJÁRÁSOK ÉS A MESTERSÉGES INTELLIGENCIA TECHNOLÓGIA ALKALMAZÁSA A SZARVASMARHA- TENYÉSZTÉSBN KÜLÖNÖS TEKINTETTEL A HÚSHASZNÚ SZARVASMARHÁK AZONOSÍTÁSÁRA

Tarr Bence¹, Katona Balázs², Szabó István¹, Tózsér János²

¹ Magyar Agrár- és Élettudományi Egyetem, Műszaki Tudományok Intézet

² Magyar Agrár- és Élettudományi Egyetem, Állattenyésztési Tudományok Intézet

¹Szent István Campus, 2100 Gödöllő, Páter Károly u. 1.

Received – Érkezett: 16.03.2022.

Accepted – Elfogadva: 12.05.2022.

Összefoglalás

A mesterséges intelligencia (MI) az állattenyésztés több területén vált fontos eszközzé a tenyésztési folyamatok optimalizálására. Dolgozatunkban elsősorban a szarvasmarhák azonosítására és megszámlálására mutattunk be példákat a szakirodalomból. Az állatok egyedi azonosítása és a gulya ellenőrzése, viselkedésének monitorozása számos következtetés levonását támogatja állatjóléti és állategészségügyi szempontból is. A rögzített képek feldolgozásának automatizálása is elengedhetetlenné vált. Ezt a folyamatot segíti a Mesterséges Intelligencia. A mélytanulás és a neurális hálók kiválóan alkalmasak a képek szegmentálására és különböző jellemzők alapján azok tartalmi feldolgozására. A konvolúciós neurális hálók kifejezetten az ilyen feladatokban erősek és láthatjuk, hogy ezen hálózatok továbbfejlesztései (pl. Faster R-CNN) még hatékonyabb képelemzési eljárásokat tesznek lehetővé. Az állatokról készült felvételek feldolgozása nagy lépést jelenthet az állatállomány automatikus elemzése és azonosítása tekintetében.

Kulcsszavak: képrögzítés, egyed azonosítás, mesterséges intelligencia, neurális hálózat

Precision procedures and the application of artificial intelligence in cattle breeding with special reference to the identification of beef cattle

Abstract

Artificial Intelligence (AI) has become an important tool for optimising breeding processes in several areas of animal production. In this thesis, we have presented examples from the literature, mainly for the identification and counting of cattle. The individual identification of animals, the monitoring of their behaviour and the control of their movements support a number of conclusions from both an animal welfare and a veterinary point of view. Automation of the processing of captured images has also become essential. This process is supported by Artificial Intelligence. Deep learning and neural networks are excellent tools for segmenting images and processing their content based on different features. Convolutional neural networks are specifically powerful for such tasks and we have seen that further developments of these networks (e.g. Faster R-CNN) allow even more efficient image analysis procedures. Processing animal images can be a major step forward for automatic analysis and identification of livestock.

Keywords: image capturing, individual identification, artificial intelligence, neural network

Precíziós gazdálkodás fogalma és folyamata

A precíziós gazdálkodás, mintegy 45 évvel ezelőtt kezdett fejlődni a Földön. Ezt az új elképzelést a mezőgazdaság is elkezdte alkalmazni, ugyanis ekkor már az informatika és kommunikációs technológiák eléggé fejlettek voltak. *Khosia (2017)* felhívja a figyelmet a precíziós gazdálkodás értelmezésének problémájára, nevezetesen „*Érdekes megjegyezni, hogy a két évtizedes fejlődés után a helyspecifikus gazdálkodást sokan még mindig rosszul értelmezik, komplex és nagy technológiai innovációt értve a precíziós gazdálkodás alatt, miközben az ennél sokkal egyszerűbben is értelmezhető.*”

A precíziós gazdálkodás az 5M-mel jellemezhető: megfelelő input, megfelelő időben, megfelelő mennyiségben, megfelelő helyen és megfelelő formában. A precíziós gazdálkodás tehát nem kívánja meg a nagy és összetett gépesítettséget, azaz nem szükséges hozzá nagy beruházás és új gépek kezelésének elsajátítása. A lényeg az az, hogy helyben milyen kreatív megoldásokat tudunk alkalmazni, működésben fenntartani és mindezt költséghatékonyan.

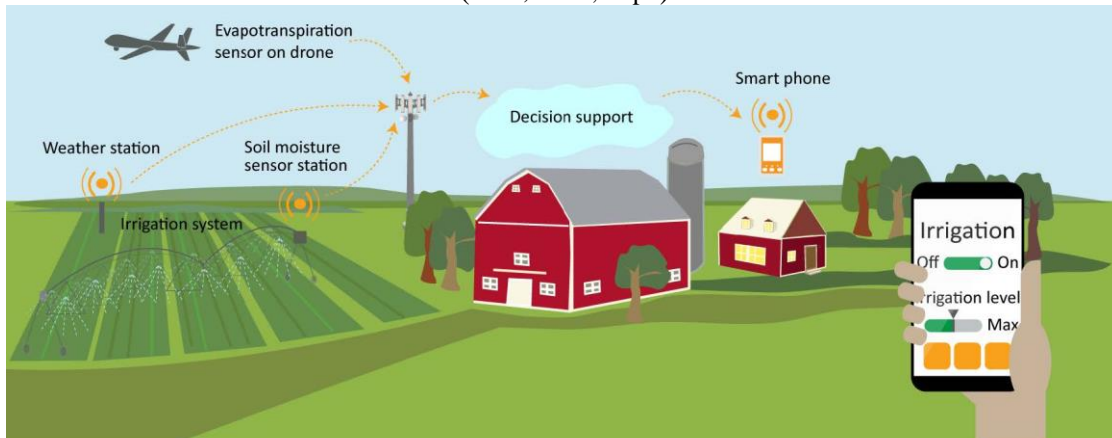
Khosia (2017) továbbá arra is utal, hogy az időben előre haladva a precíziós gazdálkodás sem kerülheti el a nagy adatbázisokkal (Big Data) való kapcsolatba kerülést. Fontos utalni arra is, hogy napjainkban annyi adat áll rendelkezésünkre, amelyeket hagyományos adatfeldolgozási módszerekkel már nem lehet hatékonyan elemezni.

Hollósi (2017) az adatalapú döntések fontosságára hívta fel a figyelmet a 2020 utáni banki finanszírozásban. „A bank számára a precíziós gazdálkodás egy fajta költségkontrollt jelent. A termésátlagok és a bevételek nőnek, ugyanakkor a költségek nem, vagy csak kisebb mértékben, így összességében javul a jövedelmezőség”.

A precíziós tenyésztési technikákat széles körben használják a kiadások optimalizálására és az állatállomány hozamának növelésére. Ettől függetlenül a heterogén szenzorok és a mesterséges intelligenciai technikák együttes használata a szarvasmarhák által esetlegesen jelentkező különböző problémák egyidejű elemzésére vagy felismerésére még nem elterjedt. Ugyanakkor az intelligens és pontos állattartási technikák egyre szélesebb körű figyelmet kaptak, mivel csökkenthetik a munkaerő igényt és növelhetik a gazdaság hatékonyságát. Az élelmiszerek iránti növekvő kereslet és az érzékelési technológia fejlődése együttesen magában hordozza a lehetőséget, hogy az állattenyésztést központosítottabbá, nagyobb léptékűvé és hatékonyabbá tegyünk. Megvan a lehetősége annak, hogy megváltoztassa az általunk ismert állattenyésztést (*Barriuso és mtsai. 2018*).

A precíziós mezőgazdaság, a műholdas gazdálkodás vagy a helyspecifikus növénytermesztés olyan gazdálkodási koncepció, amely a termények termőföldek közötti és termőföldön belüli változásainak megfigyelésén, mérésén és az azokra való reagáláson alapul (*I. ábra*). A precíziós mezőgazdasági kutatás célja egy döntéstámogató rendszer meghatározása a gazdaság egészére kiterjedő gazdálkodáshoz, amelynek célja a termelési ráfordítások megtérülésének optimalizálása az erőforrások hatékony felhasználása mellett.

1. ábra: Egy okostelefonba integrált precíziós mezőgazdasági rendszer
(GAO, 2019, http1)



Source: GAO. | GAO-20-128SP

Figure 1: Mobile application for precision farming

Evaporation sensor on drone: drónra szerelt párolgás érzékelő, weather station: időjárás állomás, soil moisture sensor station: talaj nedvesség-érzékelő szenzor állomás, irrigation system: öntöző rendszer, decision support: döntés támogatás, smart phone: okos telefon.

Az adatgyűjtésen és az adatok értelmezésén alapuló, ún. precíziós gazdálkodás több adatforrásból, részben automatikusan, állít elő információt és végez beavatkozást, valamint támogatja a gazdaság működésével kapcsolatos döntési folyamatokat (2. ábra). A technológia, egyebek mellett, abban is segít, hogy a gazdálkodási folyamat egyre több eleméről keletkezzen adat, ami a folyamatok megértését és optimalizálását segítheti. A cél, hogy az adatgyűjtés és felhasználás segítségével a hatékonyságot növelő, a gazdaság működését jobban megértő, a környezeti szempontokat is figyelembe vevő, hatékony gazdálkodás valósulhasson meg (Alföldi és mtsai. 2020).

2. ábra A precíziós gazdálkodás komponensei
(Rutter és mtsai., 2011)

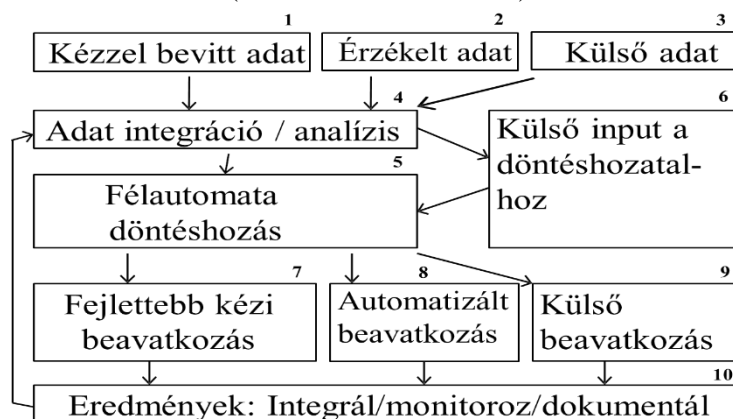


Figure 2: Components of precision farming

1) data entered manually, 2) data detected, 3) external data, 4) data integration/analysis, 5) semi-automated decision-making, 6) external input for decision-making, 7) enhanced manual interaction, 8) automated interaction, 9) external interaction, 10) Results: Integration/monitoring/documentation

Fontos kiemelni azt, hogy a kézzel bevitt adatokon a gazdaság működése során folyamatosan, vagy alkalmanként esetleg egy nagyobb adatfeltöltés részeként, más helyen, vagy nem elektronikus rendszerben keletkezett adatok bevitelét értjük. Az érzékelővel gyűjtött adatok pedig azok, amelyek valamilyen új, ún. digitális megoldáson, érzékelőn keresztül, gyakorlatilag automatikusan érkeznek. Külső adatok alatt azokat értjük, amelyek más, jórészt elektronikus rendszerben (pl. könyvelő szoftverben), vagy más eszközben (pl. munkagépben, vagy munkaeszközben) keletkeznek, és kész adatként érkeznek a rendszerbe (Alföldi és mtsai. 2020).

Az első kérdés, ami felmerülhet bennünk az MI-vel kapcsolatban, az az, hogy mit is jelent pontosan? Magát a kifejezést John McCarthy fogalmazta meg először 1956 nyarán mely után évtizedekig az ő vezetésével zajlottak a kutatások. Az akkoriban még szürreálisnak számító kijelentés manapság már szinte teljesen hétköznapiak tűnik. Ugyanakkor a nagybetűs, igazi MI-t még nem sikerült megalkotni, de az okostelefonok és önvezető autók világában nem tűnik olyan messzi álomnak, mint McCarthy idejében.

A mesterséges intelligenciát korábban úgy határozták meg, hogy olyan rendszereket hoztak létre, amelyek előre bevitt adatokból próbálják kiszámítani a várható adatokat. Most már nem szükséges, hogy minden adat és az adatok kiszámításához szükséges cél előre rögzített és ismert legyen a mesterséges intelligencia számára. Ehelyett a rendszernek ismeretlen adatokkal is tudnia kell dolgozni. Mindezt úgy, hogy magától meg kell tanulnia, hogy milyen adatokat használjon (Russel és Norvig, 2020).

Az állattenyésztés hagyományosan mindig is decentralizált volt, olyan szinten, hogy néhány ember képes volt felügyelni és irányítani. Egy évtizeddel ezelőttig pedig a legtöbb állattenyésztő nem rendelkezett olyan modern technológiákkal, mint a nagysebességű internet, az okostelefonok és az olcsó elektromos áram. Mára ezek közül az összes tényező adott. Becslések szerint a gazdáknak a következő 50 évben 70%-kal kell növelniük a termelést, hogy kielégíthessék a hús és állati termékek iránti növekvő globális igényeket. Mivel a földterület és más természeti erőforrások korlátozottak, a növekvő kereslet kielégítéséhez hatékonyabb módszereket kell találnunk. Napjainkban az olyan technológiák, mint a számítógépek, érzékelők, felhőalapú számítástechnika, a gépi tanulás (ML) és a mesterséges intelligencia (MI) már számos iparágat átalakítottak. Ezek jobb nyereségességet és hatékonyságot eredményeztek. Ezért kell megvizsgálnunk, hogy ezek a fejlett technológiák hogyan segíthetnek nagyobb hatékonyságot és nyereséget elérni az állattenyésztésben.

A mesterséges intelligencia a számítástechnika azon részének tekinthető, amely olyan folyamatokat próbál szimulálni, amelyeket az embereknél intelligens viselkedésnek neveznénk (Wikipedia). A gépi tanulás a mesterséges intelligencia egyik központi témája, mivel az intelligenciához általában az a tulajdonság társul, környezetéből vett információkból képes tanulni. Fő célja a termelés hatékonyságának és minőségének növelése a gyors döntéshozatal révén, ha bármilyen probléma merül is fel a gazdaságban. A technológiának olyan megoldásokat kell nyújtania, amelyek megkönnyítik a gazdálkodók munkáját. Az állatok betegségeit korai stádiumban felismerő rendszerek kutatása és fejlesztése létfontosságú. Számos kutatócsoport dolgozik az elektronikus rendszerek állattenyésztésben való alkalmazásán a termelékenység javítása és a működési költségek csökkentése céljából. Ez pl egy olyan szoftver lehet, ami lehetővé teszi a gazdák számára, hogy távolról hozzáférjenek az állatokra vonatkozó naprakész információkhoz. Az információs technológia és az elektronikus eszközök együttes használata lehetővé teszi az olyan adatok nyomon követését és tanulmányozását, mint a berendezések energiafogyasztása, a takarmányok mennyiségét, a világítást, a hőmérsékletet, az állatok egészségi állapotát, fizikai aktivitását stb.

Több előnye is van egy ilyen rendszernek. *Linko* (1998) ezeket az előnyöket a következőképpen foglalja össze:

- ha nem áll rendelkezésre szakértő, de szükség lenne segítségre
- nem befolyásolja emberi hiba vagy kedélyállapot
- 24 órában rendelkezésre áll
- hatalmas adatbázisokat képesek kezelni
- könnyen megérthetőek

Szarvasmarhák azonosítása

A rádiófrekvenciás egyedi azonosítás használat és elterjedése a gyakorlatban vitathatatlan. Ennek több féle elhelyezési formája lehetséges: nyakörv, füljelző, implantátum, lábszój, bendő bólusz. Korábban *Tóth és mtsai* (2019) foglalták össze a szarvasmarhák nyomon követésére használt RFID alapú technikák használatát. Itt kitértek az RFID és egyéb szenzorok (GPS) közös használatának előnyeire is.

Vannak azonban olyan egyed azonosítási módok, amelyek más módon teszik lehetővé ezt. Ezeket a megoldásokat az alábbiakban foglaljuk össze.

Szarvasmarhák azonosítása szutyak lenyomat alapján

Az állatbiometria egy feltörekvő kutatási terület, amely az állatok vizuális megjelenésének általános jellemzők és elsődleges biometrikus jellemzők alapján történő ábrázolására épül. Az egyes szarvasmarhák azonosítása világszerte fontos kérdés a különböző fajták osztályozása, nyilvántartása, nyomon követhetősége, egészségügyi menedzsmentje szempontjából (*Kühl HS, Burghardt T, 2013*). A klasszikus állatfelismerési módszereknek komoly problémái vannak, mivel ezek mind kézi azonosítási rendszerek. A klasszikus állat-azonosítási módszerek könnyen hamisíthatók a felcímkézett füljelzőkön található egyedi számok megváltoztatásával. Ezeknek a fő problémáknak a megoldására lehet alkalmas a szarvasmarhák orráról készített pontszerű képek használata. Az orrpontok (szutyak lenyomat) alapján történő azonosítás hasonló az emberi ujjlenyomatok minutiae-pontjainak felismeréséhez. A kutatásban 500 szarvasmarhát vizsgáltak, egyenként 10 darab 20 megapixeles képet készítve róluk. A képeken ezután két fő karakterisztikus bélyeg (beads, ridges) alapján azonosították az állatokat (3. ábra).

3. ábra: A két fő karakterisztikum
(Kumar és mtsai., 2017)




Figure 3: The two main characteristics

A képeket ezután megszerkesztették, úgy, hogy mérsékelték a zajokat, javították a képminőséget és láthatóbbá tették a fő jellemzőket. Az így kapott modelleket pedig egy mesterséges intelligencia fel tudta ismerni és dolgozni tudott velük (4. ábra).

4. ábra: Feldolgozás utáni modellek
(Kumar és mtsai., 2017)




Figure 4: Models after processing

A kutatás során 5000 képpel dolgoztak, amelynek a végén 96,74%-os pontossággal a program azonosítani tudta a szarvasmarhákat. Úgy gondoljuk, hogy nagy pontosság ennek az eljárásnak a megalapozottságát igazolja.

Szarvasmarhák azonosítása küllem alapján

Egy precíziós gazdálkodás megfelelő működtetéséhez szükség van olyan modern megoldásokra, mint a szarvasmarháink egyedi azonosítása. A szarvasmarhák azonosítása jelenleg vizuálisan, egyedi rádiófrekvenciával vagy füljelzőkkel történik. Ezeknek a rendszereknek a helyettesítésére pedig újból segítségül lehet hívni a mesterséges intelligenciát. Egy kutatásban pontosan erre tettek kísérletet egészen pontosan mélytanuló algoritmusok segítségével. A mélytanuló algoritmusok többszintű neurális hálókat használnak a tanuláshoz. Ebben az esetben CNN (*Convolutional Neural Network*) és LSTM (*Long Short-Term Memory*) típusú hálózatok kombinálásával értek el kimagasló eredményeket az állatokat azonosításában. A CNN és az LSTM hálózatra, azért volt szükség mivel hatékonyan tudnak vizuális forrásból térbeli információkat kinyerni majd ezeket modellezni. Összesen 516 videó felvétel készült 41 szarvasmarháról három hónapon keresztül havonta egyszer. Először a rögzített felvételeket képkockáknaként a CNN hálózat kielemezte majd minden egyes szarvasmarháról készít egy olyan adathalmazt, amelyben benne szerepelnek az állatok vizuális jellemzői, illetve az egyedi mozgásuk. Ezután a kapott CNN halmazokat beviszik az LSTM hálózatba, amely képes megtanulni majd újból felismerni a szarvasmarhákat (5. ábra).

5. ábra: A képfeldolgozás folyamata

(Yongliang Qiao és mtsai., 2019)

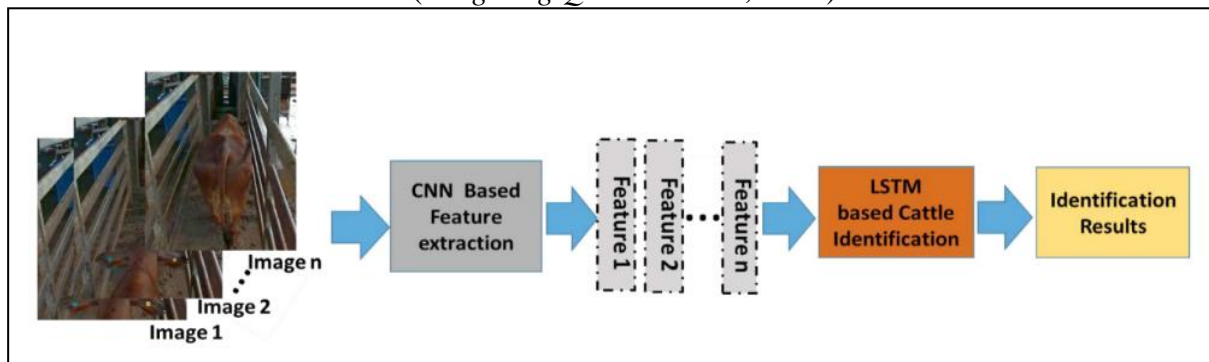


Figure 5: The process image identification

Image: Kép, CNN Based Feature extraction: CNN alapú jellemző kinyerés, Feature: jellemző, LSTM based Cattle Identification: LSTM alapú szarvasmarha azonosítás, Identification results: Azonosítás eredménye

A kísérleti eredmények azt mutatják, hogy módszerünk 88%-os és 91%-os pontosságot ért el 15 és 20 képkockás videók esetén, tehát a kísérlet mindenképpen sikeresnek mondható. Emellett pedig, ha az LSTM hálózat nélkül csak a CNN rendszerrel dolgoztak, akkor a közel 90%-os pontosság helyett 57% lett csak az eredmény. Ez is mutatja, hogy több mesterséges intelligenciára épülő modell összekapcsolása javítja az elérhető pontosságot.

Populáció méretet megfigyelő rendszerek

Szarvasmarhák UAV-képek alapján történő észlelése

A pilóta nélküli légi járművekre (UAV: unmanned aerial vehicle) egyre inkább értékes eszközként tekintenek a gazdaságok irányításában. Ez a fajta technológia különösen hasznosnak bizonyul az extenzív szarvasmarhatartás tekintetében, mivel a termelési területek általában kiterjedtek, és az állatokat lazábban felügyelik. A drónok folyamatos fejlődésével és a konvolúciós neurális hálózatok megjelenésével egyre hatékonyabban lehet releváns információkat kinyerni digitális képekből. Egy 2019-es brazil tanulmányban arra tettek kísérletet, hogy mennyire pontosan lehet egy UAV által készített digitális képek alapján felismerni az egyes állatokat. Itt a felismerésen volt hangsúly, mivel ha beazonosítottuk az egyedeket utána lehet különböző információkat kinyerni a szarvasmarhákról, mint például: állatlétszám, rendellenes események vagy a testméreteinek a felvétele. A tanulmány során 1853 képet vizsgáltak meg, amelyek Chanchim szarvasmarhákról, felül nézetből készültek (6. ábra).

6. ábra: Az állatokról készült UAV felvételek

(Barbedo és mtsai., 2020)



Picture 6: Pictures made by UAV from animals

Az állatokról nem csak hibátlan minőségű képek készültek, hanem voltak elmosódott vagy éppen túl fényes képek is. Összesen 15 különböző konvolúciós hálózati architektúrát teszteltek, hogy különféle fényviszonyok, időjárási feltételek, túl magas fényerő és elmosódás mellett milyen eredményességgel működnek. Átlagosan 95%-os pontossággal dolgoztak, közülük a NasNet Large architektúra volt a legeredményesebb 99,2%-al (1. táblázat).

1. táblázat: A különböző konvolúciós hálózati architektúrák eredményeinek összehasonlítása.
(Barbedo és mtsai., 2019)

CNN	Pontosság ¹	Precizitás ²	Visszahívás ³	F1 pont ⁴
VGG-16	0,972	0,973	0,973	0,970
VGG-19	0,973	0,973	0,973	0,975
ResNet-50 v2	0,977	0,978	0,978	0,975
ResNet-101 v2	0,983	0,985	0,985	0,985
ResNet-152 v2	0,967	0,970	0,970	0,965
MobileNet	0,983	0,980	0,980	0,983
MobileNet v2	0,787	0,855	0,790	0,778
DenseNet 121	0,852	0,895	0,868	0,865
DenseNet 169	0,935	0,943	0,933	0,935
DenseNet 201	0,935	0,945	0,938	0,938
Xception	0,969	0,968	0,968	0,968
Inception v3	0,979	0,975	0,975	0,975
Inception ResNet v2	0,983	0,983	0,983	0,985
NASNet Mobile	0,857	0,890	0,858	0,853
NASNet Large	0,992	0,993	0,993	0,995

Table 1: Comparison of the fifteen most successful CNN architectures.

1) Accuracy, 2) Precision, 3) Recall, 4) F1 score

Szarvasmarha felismerés CNN hálózattal

Az állatok azonosításának olcsó, gyors és biztonságos módszerei rendkívül fontosak a gazdálkodási rendszer számos feladata szempontjából. Ezek a rendszerek megkönnyítik az állattenyésztési folyamatokat, a tevékenységek ellenőrzését, és biztosítják a termelés számonkérhetőségét. A brazil állatállomány legelterjedtebb azonosítási rendszerei közé tartozik a forró vasalással, elektromos vagy tűztetoválassal történő megbélyegzés, a füljelzővel és a nyakörvvel történő jelölés. Az azonosíthatóság érdekében egy brazil tanulmányban 2020-ban azt vizsgálták, hogy 4 kihelyezett kamera és az általuk készített képek alapján egy CNN rendszer milyen pontosan képes felismerni az adott állatokat (a kísérletben Pantaneira szarvasmarhákat vizsgáltak). Ehhez 51 állatot vizsgáltak a NUBOPAN központban, ahol hátulról, mindkét oldalról és szemből képeket készítettek, összesen 27 849-et (7. ábra).

7. ábra: A szarvasmarhákról készített fotók
(Weber és mtsai., 2020)



Figure 7: Photos of cattles

Három különböző CNN rendszert hasonlítottak össze, melyek amint a 2. táblázatból is látszik szinte 100%-os pontossággal dolgoztak.

2. táblázat: A három rendszer teljesítménye %-ban
(Weber és mtsai., 2020)

Modell ¹	Tanítás pontossága ²	Teszt pontossága ³
ResNet50	99,20	99,78
InceptionResNet v2	98,87	99,52
DenseNet 201	99,74	99,85

Table 2: Results of the three systems in %

1) Model, 2) Accuracy Training, 3) Accuracy test

Szarvasmarhák számlálása UAV képeken

A pilóta nélküli légi járművek vagy drónok elterjedésével nagy felbontású, alacsony költségű madártávlatú képet lehet készíteni a birtokról. Bármennyire is ígéretes ez a technológia, a benne rejlő lehetőségek teljes körű kiaknázását akadályozza, hogy a releváns információk kinyerése az UAV segítségével rögzített képekből korántsem egyszerű. Az állatállomány becslése esetében nehézséget okoz az állatok mozgása, a táj változatossága (csupasz talaj, száraz legelő), az akadályok, például fák és istállók által okozott holttér, valamint az állatok csoportosulása. Egy 2020-as brazil tanulmány próbálkozást tett, ezeknek a problémáknak a megoldására (Nelore és Canchim szarvasmarhák megszámlálása volt a cél). Az első lépésben minden képet szabályos rácsháló segítségével négyzetekre osztották, és az állatok részeit tartalmazó négyzeteket egy CNN segítségével azonosították. A második lépésben szintér-manipulációkat alkalmaztak az állatok és

a háttér közötti kontraszt növelésére, és küszöbértékeket állítottak be bináris maszkok létrehozására. A bináris maszk használatával egyértelműen el lehet különíteni a rendelkezésre álló pixelek érdemi és számunkra nem releváns csoportjait. A harmadik lépésben a maszkokat bináris műveletekkel kombinálták, és morfológiai műveleteket alkalmaztak a klaszterezett állatok elkülönítésére. A negyedik lépésben a képeket összevetették a korábban osztályozott képekkel, és így megkapták a végső becsléshez szükséges információkat (8. ábra).

8. ábra: Az állatokról készült UAV felvételek feldolgozása
(Barbedo és mtsai., 2020)




Figure 8: Processing of animal photos made by UAV

Az osztályozásért felelős betanított CNN-modellek a NasNet Large modellt választották, amely 98% feletti pontosságot biztosított az állatok felismerésében.

Állatok osztályozása és számlálása drón felvételeken Mask-R-CNN rendszer alapon

A drónokkal történő állomány elemzés egy másik mód szerint mutatták be kínai és mongol szerzők egy 2020-ban megjelent cikkükben (Beibei és mtsai, 2020). Ez a kutatás egy költséghatékony megoldást mutat be az állomány számlálására és osztályozásra, amely segíti különböző mérések és állatjóléti megoldások kidolgozását. A dolgozatban alkalmazott módszer a legkorszerűbb mélytanulási technikát, az úgynevezett Mask R-CNN-t alkalmazza a tulajdonságok kinyeréséhez és a tanuláshoz.

A Mask R-CNN alapvetően egy konvolúciós neurális háló aminek az erőssége a kép szegmentálás. A mélytanuló algoritmusokhoz használt neurális hálók egy olyan változata, ami jóminőségű maszkot készít a kép minden részeltéhez és ezzel könnyíti az egyedek megszámlálását a képen.

9. ábra: A kutatásban használt Mask-R-CNN rendszer vázlata
(Beibei és mtsai, 2020)




Figure 9: Outline of the Mask-R-CNN system used in the research

RGB Image.: RGB kép, Convolutional layers: Konvolúciós rétegek, Feature map: Jellemzők térképe, ROIAlign pooling: hasznos részek értékelése, Region Proposal Network (RPN): Hasznos régió kereső háló, Fully connected layers: Teljesen összekapcsolt rétegek, Classification: Osztályozás, Localization: Lokalizáció, Mask: maszk, Object: Tárgy

A kísérlet során egyszerű, olcsó drónokkal készítették videófelvételt a mezőn legelő nyájáról. Ezeket utána azonos 510x512 pixel méretű állóképekké vágták és ezt dolgozták fel a neurális háló alapú rendszerrel.

A kísérletben használt rendszer értékelésére valós (hagyományos) számláláson alapuló rendszereket használtak, és a kísérleti eredmények azt mutatják, hogy a drónokkal készült képek kiértékelése 96%-os pontossággal képes osztályozni az állatállományt. A juhok és szarvasmarhák számát pedig 92%-os pontossággal határozta meg rendszer.

Összegzés

A mesterséges intelligencia az állattenyésztés számos területén vált fontos eszközzé a tenyésztési folyamatok optimalizálására. Ebben az áttekintésben elsősorban a szarvasmarhák azonosítására és megszámlálására mutattunk be példákat a szakirodalomból. Az állatok egyedi azonosítása és a gulya ellenőrzése, viselkedésének monitorozása számos következtetés levonását támogatja állattjóléti és állategészségügyi szempontból is. Jól látható hogy mindegyik technológia valamilyen képrögzítési és képfeldolgozási lépésekkel dolgozik. A különböző képfelvételi technológiák terjedése, a drónok egyszerű és olcsó hozzáférhetősége lehetővé tette nagymennyiségű kép és videó elkészítését szinte bárhol, bármilyen körülmények között. Ezért ezen képek feldolgozásának automatizálása is elengedhetetlenné vált. Ehhez nyújt segítséget a Mesterséges Intelligencia. A mélytanulás és a neurális hálók kiválóan alkalmasak a képek szegmentálásra és különböző jellemzők alapján azok tartalmi feldolgozására. A konvolúciós neurális hálók kifejezetten az ilyen feladatokban erősek és láthatjuk, hogy ezen hálózatok továbbfejlesztései (pl. Faster R-CNN) még hatékonyabb képelemzési eljárásokat tesznek lehetővé. Összeségében láthatjuk, hogy az állatokról készült felvételek feldolgozásával nagy lépést tehetünk az állatállomány automatikus elemzése és azonosítása felé. A jövőben akár az egyedre szabott egészségügyi vagy éppen takarmány adagolási rendszerek is kialakíthatóak lesznek ezen rendszerek segítségével.

Irodalomjegyzék

- Alföldi L.; Tarr Z.; Tőzsér J. (2020): Digitális mikroklíma mérés a tejtermelő farmon. *Animal Welfare Etológia és tartástechnika* 16 : 2 PP. 94-109., 16 P.
[HTTP://REAL.MTAK.HU/118804/1/AWETH202002094109_DOI.PDF](http://real.mtak.hu/118804/1/AWETH202002094109_DOI.PDF)
- Barbedo, J.G.A.; Koenigkan, L.V.; Santos, T.T.; Santos, P.M. (2019): A Study on the Detection of Cattle in UAV Images Using Deep Learning. *Sensors* 2019, 19, 5436.
<https://doi.org/10.3390/s19245436>
- Barbedo, Jayme & Koenigkan, Luciano & Santos, Thiago & Santos, Patrícia. (2019). A Study on the Detection of Cattle in UAV Images Using Deep Learning. *Sensors*. 19. 5436. 10.3390/s19245436.
https://www.researchgate.net/publication/337858737_A_Study_on_the_Detection_of_Cattle_in_UAV_Images_Using_Deep_Learning
- Barriuso, AL., Villarrubia González G., De Paz JF., Lozano Á., Bajo J. (2018): Combination of Multi-Agent Systems and Wireless Sensor Networks for the Monitoring of Cattle. *Sensors (Basel)*. 18(1):108. PMID: 29301310; PMCID: PMC5795335. <https://doi.org/10.3390/s18010108>
- Beibei Xu, Wensheng Wang, Greg Falzon, Paul Kwan, Leifeng Guo, Zhiguo Sun & Chunlei Li (2020) Livestock classification and counting in quadcopter aerial images using Mask R-CNN, *International Journal of Remote Sensing*, 41:21, 8121-8142,
<https://doi.org/10.1080/01431161.2020.1734245>
- Hollósi D. (2017) (szerk: Milics G.): Adataalapú döntések a 2020 utáni finanszírozásban. *Precíziós Gazdálkodás, Adat, Információ, Haszon*. Budapest, Agroinform és NAK, 26. p ISBN: 978-963-12-8921-3
- Kühl, HS, Burghardt, T (2013): Animal biometrics: quantifying and detecting phenotypic appearance. *Trends Ecol Evol* 28(7):432-441 DOI: 10.1016/j.tree.2013.02.013
- Kumar, Santosh, Singh, Sanjay (2017): Automatic identification of cattle using muzzle point pattern: a hybrid feature extraction and classification paradigm. *Multimedia Tools and Applications*. 76. 1-30. 10.1007/s11042-016-4181-9.
https://www.researchgate.net/publication/311784599_Automatic_identification_of_cattle_using_muzzle_point_pattern_a_hybrid_feature_extraction_and_classification_paradigm
- Linko, S. (1998): Expert systems-what can they do for the food industry? *Trends in Food Science and Technology* 9: 3-12. DOI:10.1016/S0924-2244(97)00002-2
- Russel, S. Norvig, P. (2021): *Artificial Intelligence: A Modern Approach*, Global Edition, Pearson Education Limited, London, 1170 p.
- Tóth, L. - Kovács, L. - Póti, P. - Alföldi, L. - Tarr, Z. - Szenci, O. - Tőzsér, J.: Korszerű információ technika (IT) a tejelő szarvasmarha tartásban. *Állattenyésztés és takarmányozás*, 2019. 68. 3. 253. o. http://real-j.mtak.hu/16047/3/att_2019_03.pdf
- Weber, Fabricio de Lima, Weber, Vanessa Aparecida de Moraes, Menezes, Geazy Vilharva, Oliveira Junior, Adair da Silva, Alves, Daniela Arestides, de Oliveira, Marcus Vinicius Moraes, Matsubara, Edson T (2020): Recognition of Pantaneira cattle breed using computer vision and convolutional neural networks. *Computers and Electronics in Agriculture*, 08., 175. 10. (1016/j.compag.2020.105548) <https://de.art1lib.org/book/82596308/fcc328>
- Yongliang Qiao, Daobilige Su, HeKong, Salah Sukkarieh, Sabrina Lomax, Cameron Clark (2019): Individual Cattle Identification Using a Deep Learning Based Framework, *IFAC-PapersOnLine*, Volume 52, Issue 30, Pages 318-323 <https://doi.org/10.1016/j.ifacol.2019.12.558>