

# Gépi tanulás és mélytanulás a geodéziában

## Machine Learning and Deep Learning in Land Surveying

dr. SIKI Zoltán

gita Műszaki Térinformatika Egyesület,  
Budapest 1111 Műegyetem rkp 3., [siki.zoltan@emk.bme.hu](mailto:siki.zoltan@emk.bme.hu)

### Abstract

*Although the basic task and purpose of our profession has not changed over the centuries, today we have to face serious challenges. Recently GIM International magazine published an article on the changing role of land surveyors. Artificial intelligence (AI) and its subfields are mentioned several times in it. Our profession must also open to this direction. This article tries to give a guideline for surveyors in the use of AI through examples.*

**Keywords:** Artificial intelligence, machine learning, deep learning, geodetic applications

### Kivonat

*Bár szakmánk alapvető feladata illetve célja nem változott meg az évszázadok során, manapság komoly kihívásokkal kell szembenéznünk. Nemrég a GIM International magazin közölt egy cikket a földmérők változó szerepéről. Ebben a mesterséges intelligencia (MI) és annak részterületei többször szóba kerülnek. Szakmánknak is nyitnia kell ebbe az irányba. Ez a cikk példákon keresztül próbál a földmérő kollégáknak irányt mutatni az MI felhasználásában.*

**Kulcsszavak:** mesterséges intelligencia, gépi tanulás, mélytanulás, geodéziai alkalmazás

## 1. BEVEZETÉS

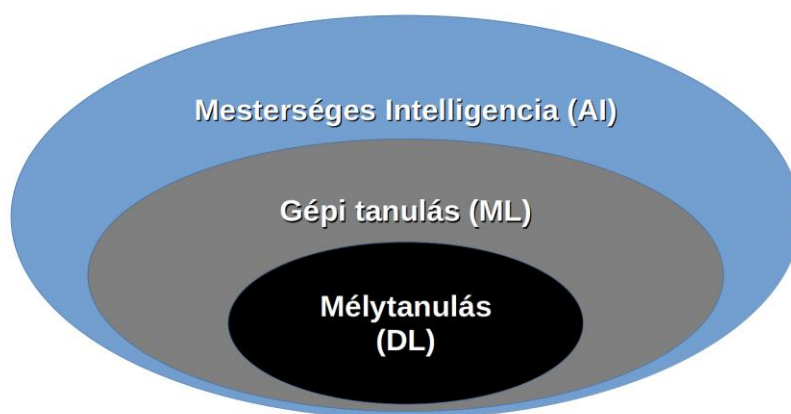
A nagy tömegű, automatizált terepi adatgyűjtés (UAV, LiDAR, IoT, stb.) nem csak a terepi munkát változtatta meg alapvetően, hanem az adatfeldolgozásban is új megoldásokat kíván [7]. A nagy tömegű, gyors adatgyűjtés gyakran jelentős zajjal párosul. Ezekben az esetekben a hagyományos feldolgozási módszereink jellemzően csődöt mondanak vagy a hatékonyságuk nem kielégítő. Itt jöhetnek szóba a gépi tanulási módszerek, melyek robusztusak (a kiugró értékekre nem érzékenyek) és megfelelő hardver esetén hatékonyak. A mesterséges intelligencia alapvető módszereinek a bemutatása mellett néhány szakmai alkalmazási példát mutatok be a következőkben.

## 2. GÉPI TANULÁS ÉS MÉLYTANULÁS

A mesterséges intelligenciának az 50-es évektől kezdődő fejlődése során számos részterülete alakult ki. Ezek közül két egymást magába foglaló részterülettel a gépi tanulással (ML) és a mélytanulással (DL) foglalkozunk (1. ábra).

A mesterséges intelligenciának egy gép, program vagy mesterségesen létrehozott tudat által megnyilvánuló intelligenciát nevezünk. A tanulást, a következtetést és az érvelést is beleértve ebbe. A gépi tanulás a mesterséges intelligencia egy implementációja, a tapasztalatból tudás generálása (adatokból tanulás). A gépi tanulási módszerek 2010-től terjedtek el szélesebb körben. Ezt anélkül végzi el az ML, hogy kifejezetten az adott problémára írják a programot. Az általánosan megírt algoritmusok közül választhatunk (pl. logisztikus regresszió, SVM, döntési fák) az egyes speciális feladatok megoldásában és az úgynevezett hiper paramétereit kell beállítanunk.

A mélytanulás a gépi tanulás egy részterülete, ahol a mesterséges neurális hálózatokat (NN) használjuk. Szintén a 2010-s években terjedt el.



1. ábra A mesterséges intelligencia területeinek kapcsolódása

A geodéziában a méréseink feldolgozása során, amikor fölös mérések is vannak, a legkisebb négyzetek (LS) módszerét alkalmazzuk, alkalmazzuk. Mennyiben mások a gépi tanulási módszerek? Mindkét esetben mérési adatokból indulunk ki és a célunk általában egy legjobban illeszkedő függvény paramétereinek a megkeresése. Amíg viszont a legkisebb négyzetek módszere lineáris függvények megoldására alkalmas, a gépi tanulás (ML) nem lineáris esetekben is használható. A gépi tanulási módszerek nagy méretű, zajos (durvahibákat tartalmazó) adathalmazok esetén is megfelelő megoldást adnak. A legkisebb négyzetek módszere zárt képletekkel dolgozik és ebből kifolyólag az előállított eredmény determinisztikus, ugyanazokból az adatokból és paraméterekkel mindig ugyanazt az eredményt adja. Ezzel szemben a gépi tanulási módszerek fokozatos közelítést (iterációt) alkalmaznak és sztochasztikus elemeket is tartalmaznak. Az azonos paraméterekkel megismételt feldolgozás kisebb-nagyobb mértékben eltérő eredményeket adhat. (1. táblázat)

Legkisebb négyzetek és gépi tanulási módszerek összehasonlítása

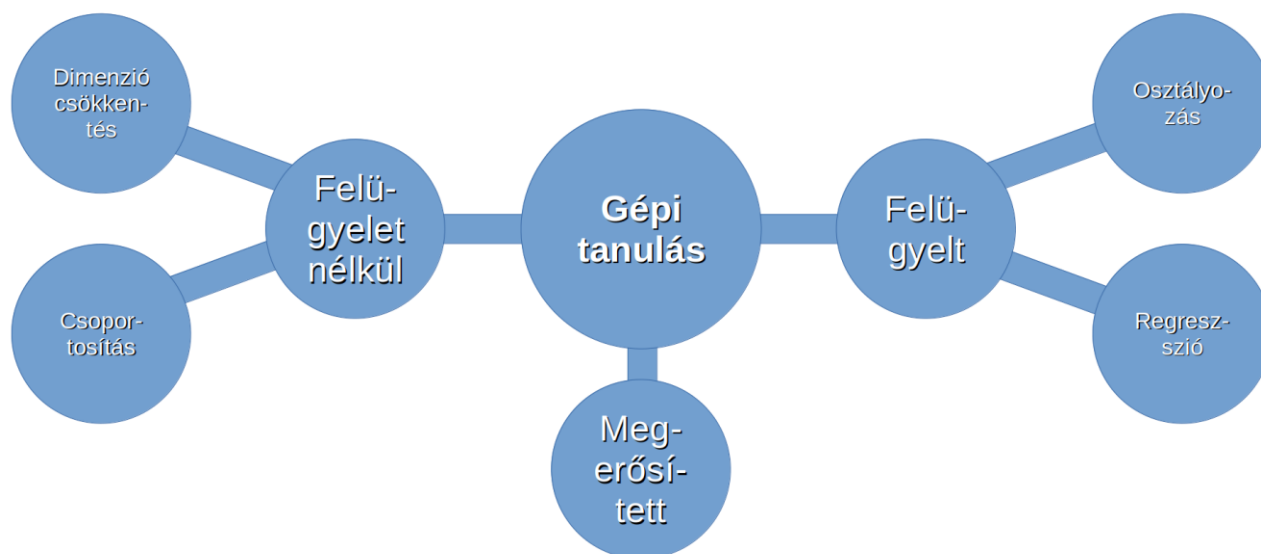
1. táblázat

Hasonlóságok	Eltérések	
	Legkisebb négyzetek (LS)	Gépi tanulás (ML)
<p>Legjobban illeszkedő függvény keresése</p> <p>Az észlelésből származó adatokat használjuk</p>	<p>Lineáris</p> <p>A mérési adatok és az eredmények közötti függvényt ismerni kell</p> <p>Durva hibás mérésekre érzékeny</p> <p>Zárt képletek</p> <p>Determinisztikus</p>	<p>Nem lineáris</p> <p>A mérési adatok és az eredmények közötti függvényt nem kell ismerni</p> <p>Nagy adathalmaz kezelésében hatékony, robusztus</p> <p>Fokozatos közelítés</p> <p>Sztochasztikus</p>

Mind a gépi tanulás, mind a mélytanulás az adatokból próbálja megtanulni az összefüggéseket. A két eljárás között a feldolgozás technológiájában vannak különbségek. A mélytanulás a mesterséges neurális hálózatokat alkalmazza, míg a gépi tanulás egyszerűbb eszközökkel operál. A gépi tanulás esetén a jellemzők azonosítása emberi közreműködéssel történik. (2. táblázat)

A gépi tanulás módszerei között megkülönböztetünk felügyelt, felügyelet nélküli és megerősített módszereket. A felügyelt módszerek esetén a tanuló adatokat „címkéznünk” kell, azaz meg kell adnunk az input adatokhoz tartozó helyes eredményt a tanításhoz. A címke lehet véges számú kategória, ez esetben osztályozásról beszélünk vagy egy folytonos érték, amikor regresszióról beszélünk. A felügyelet nélküli módszereknél nincsenek címkék. Itt az adatokban rejlő összefüggés tárjuk fel. Ilyen alkalmazási terület például csoportosítás (klaszterezés) vagy a dimenzió csökkentés. A megerősített tanulási algoritmusok a jutalmazás, büntetés alapvetően használják. A feldolgozás eredményére adott visszajelzés alapján folyamatosan tanul az eljárás. (2. ábra)

Gépi tanulás	Mélytanulás
Kisebbs tanuló adathalmaz	Nagyobb tanuló adathalmaz
Több emberi közreműködést igényel	Kevesebb emberi közreműködést igényel
Rövidebb tanítási idő	Hosszabb tanítási idő
CPU is megfelelő	GPU szükséges



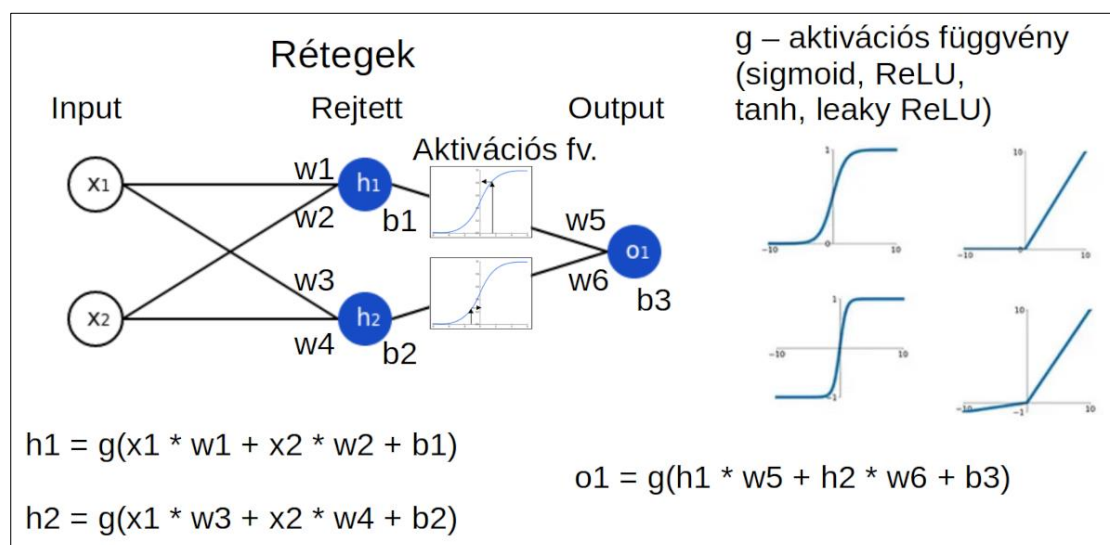
2. ábra Gépi tanulási módszerek

A mesterséges neurális hálózatok az emberi agy általunk eddig megismert működését modellezik. Egy neuron több más neurontól kapott adatot összesítve adja tovább egy másik neuronnak. A neurális hálózatok esetén a tanulás során az összegzésben használt súlyok és az eltolások megtalálása a feladat úgy, hogy az ismert eredményekhez közeli választ kapjunk a modellünkből. A neurális hálózatok egy input és egy output réteg között több rejtett réteget tartalmazhatnak, csak a szomszédos rétegekben található neuronok között van kapcsolat. Általában teljesen összekapcsolt rétegeket használnak, amikor a szomszédos rétegek között minden neuron között kapcsolat van. A neurális hálózatok tanítása során az indulásnál súlyokat és eltolás értékeket rendelnek a neuronokhoz, akár véletlen szám generálással. Ezután a tanító adatokkal a neurális hálózatból kiszámítják az output rétegen megjelenő értékeket, ez az előre terjesztés (forward propagation). Majd megvizsgálják az eltérést a számított és az ismert eredmények között, majd az output rétegtől visszafelé haladva módosítják a súlyokat és az eltolás értékeket (backward propagation), hogy az ismert eredményeket jobban közelítse a neurális hálózat. Egy ilyen előre és vissza terjesztést nevezünk epochának, melyet többször megismételnek. A visszafelé terjesztés során a gradiens irányába lépünk, az egyes rétegek között pedig a lánc szabályt alkalmazzák a deriváltak meghatározására. Az egyes neuronok által továbbított értékeket egy átviteli függvényen is átterjesztik, ez teszi lehetővé, hogy nem lineáris függvények közelítésére is alkalmas legyen. (3. ábra)

A felügyelt gépi tanítási módszereknél a rendelkezésre álló címkézett adatokat jellemzően három részre bontjuk, a tanításra használt, a tanítás közbeni validálásra használt és az elkészített modell tesztelésére használt adatokat. A teszt adatokat nem használjuk fel a tanítás során csak ellenőrzésre. A modellek kialakítása során az alul tanítás és a túl tanítás elkerülése fontos. A túltanítás esetén a tanító adatokat túl jól elsajátítja a modell. Az alul tanítás esetén túlságosan általánosít a modellünk.

A gépi tanulási módszerek alkalmazhatók idősoros adatok előrebecsülésére. Számos speciális neurális hálózatot dolgoztak ki az idősorokhoz (RNN, LSTM).

Az elkészített modellek már egyszerűen használhatók egy-egy feladat megoldására, nincs szükség a tanítás során felhasznált adatokra. Egy neurális hálózat esetén a tanítás során kialakult súlyokat és eltolásokat felhasználva ki kell számolni a saját adatainkkal az előre terjesztés eredményét.



3. ábra Az előre terjesztés folyamata neurális hálózatokban

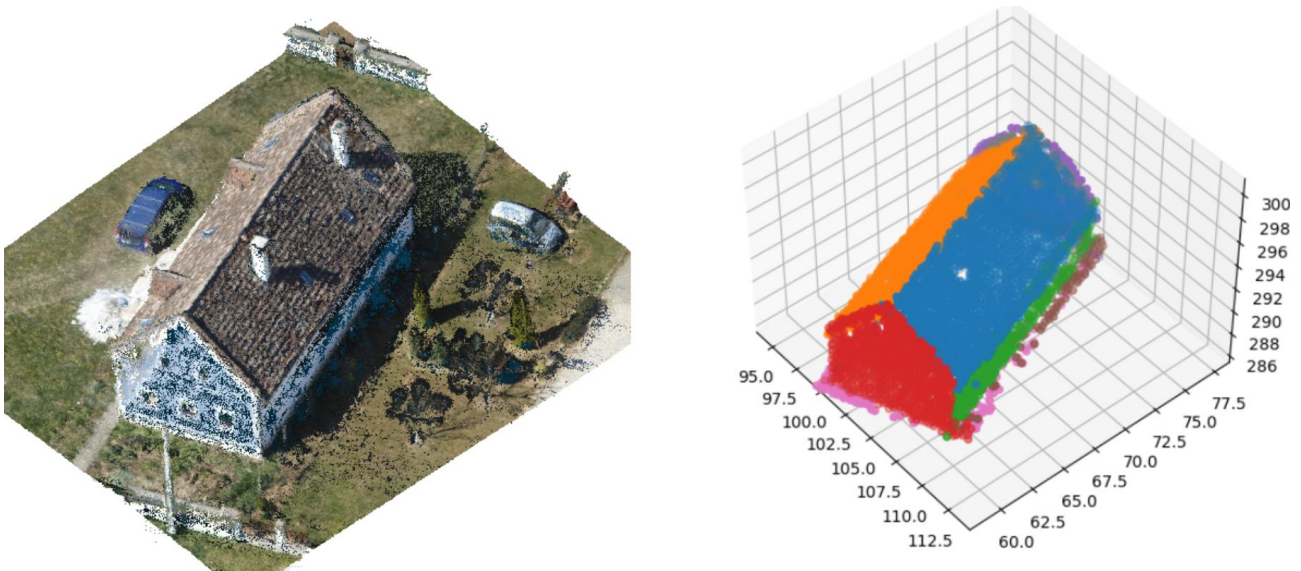
Az egyre nagyobb digitálisan rendelkezésre álló adatnak és az informatika hatékonyságnövekedésének köszönhetően egyre nagyobb modellek, mély neurális hálózatok készülnek. A nagy adathalmazon tanított és többféle területen felhasználható modelleket alapmodelleknek nevezik (Foundation Modell, FM), ezek képezik a generatív mesterséges intelligencia alkalmazások alapjait, melyek képesek szöveget, képet, zenét előállítani. Ilyen például a ChatGPT, a DALL E. Az alap modelleket nagy címkézetlen adathalmazok alapján tanítják be, mely során önmagukat felülvizsgálva javulnak. Az egyes tényleges feladatok megoldásához a finomhangolást kisebb címkézett adathalmazokon végzik el.

### 3. GEODÉZIAI ALKALMAZÁSOK

A földmérés területén a legtöbb feladat megoldása során zárt képletekkel dolgozunk. Ezekben az esetekben a mesterséges intelligencia alkalmazása várhatóan nem jár számottevő eredménnyel. Inkább a gépi látás, képfeldolgozás, pontfelhő feldolgozás, automatizált mérőrendszerek területén kecsegtet nagyobb eredménnyel a gépi tanulási módszerek felhasználása. A teljesség igénye nélkül mutatnék be néhány geoinformatikai alkalmazást a következőkben.

A gépi látás kutatások a humanoid robotok, az önvezetők autók fejlesztése kapcsán nagy lendületet kaptak. A Structure from Motion (SfM) és a Multi-View Stereo (MVS) eljárás is erről területről került át a fotogrammetriai feldolgozás eszköztárába. Egy viszonylag egyszerűbb gépi látási probléma, hogy a képeken automatikusan találjuk meg az egyedi jelleggel bíró illesztőpont jeleket. Ilyen megoldás több szoftverhez is létezik. Az OpenDroneMap (ODM) nyílt forráskódú programjához kidolgoztam az ArUCO jelek automatizált felismerésére egy programot [4] [6]. Ezzel a drón felvételek feldolgozása teljesen automatizálttá vált az ODM-ben.

Egy másik a geodéziában jól használható egyszerűbb eljárás a RANSAC (Random Sample Consensus), mely a felügyelet nélküli ML módszerek közé sorolható. Hatékonyan használható egyszerű geometriai elemekhez (sík, gömb) tartozó pontok kiválasztására a pontfelhőkben [2]. A nadír és ferde irányú drón felvételekből előállított pontfelhőkben az épületek falain is sok pont leképeződik, így nem csak a tetősíkok, hanem a falsíkok is automatizáltan megtalálhatók. A többszörös sík keresés segítségével az épületek egyes falsíkjaira eső pontok elkülöníthetők, ezen síkok alapján az épületek alaprajzát készítettük el egy kutatás projekt keretében [3]. A RANSAC eljárás eredményeként megkapott szűrt ponthalmazra a legkisebb négyzetek módszerével célszerű elvégezni a geometriai alakzat illesztését, a véletlen jellegű hibák hatásának csökkentése érdekében. (4. ábra)

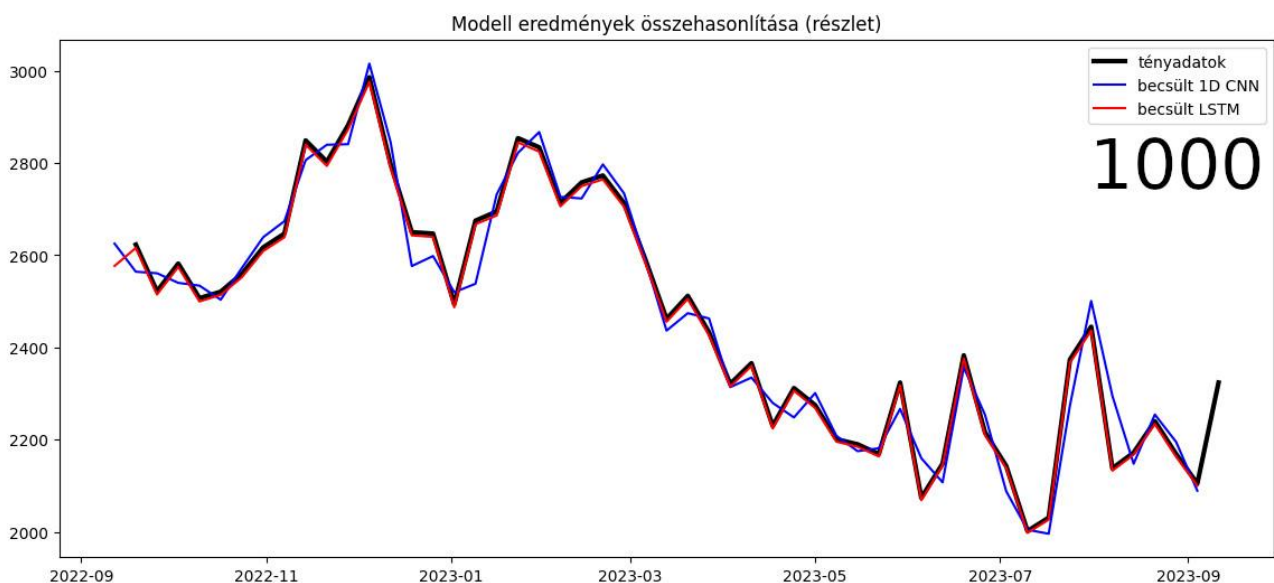


4.ábra Többszörös sík keresés a pontfelhőből

A RANSAC módszer nem biztosítja, hogy az egy síkon lévő pontok térben összefüggőek, például az az egy sorban elhelyezkedő épületeknél könnyen előfordulhat, hogy két vagy több épületen lévő pontok egy síkra esnek. Ilyenkor a térben összefüggő pontokat külön kell választani. Erre a Density-Based Spatial Clustering of Applications with Noise (DBSCAN) módszer alkalmazható, mely szintén egy felügyelet nélküli ML módszer, mely a pontok sűrűségét vizsgálja. A más klaszterező eljárásokkal szemben a DBSCAN előnye, hogy képes a zajt elkülöníteni, azaz anomália detektálásra is alkalmas.

A digitalizálás segítésére is alkalmazzák már a gépi tanulást. Szabálytalan alakzatok félautomatikus digitalizálására egy felügyelt tanítási módszerrel kialakított modellt hozott létre a Bunting Labs [8], melyet egy QGIS modulon keresztül használhatjuk. Szkennelt térképek, ortofotók és műholdképek alapján tanították meg a modellt törtvonalak vagy zárt idomok határának követésére. Jól használható folyók, tavak partvonalának vagy szintvonalak hatékony digitalizálására. Színes rasztereken is használható és szaggatott vonalakat is képes követni.

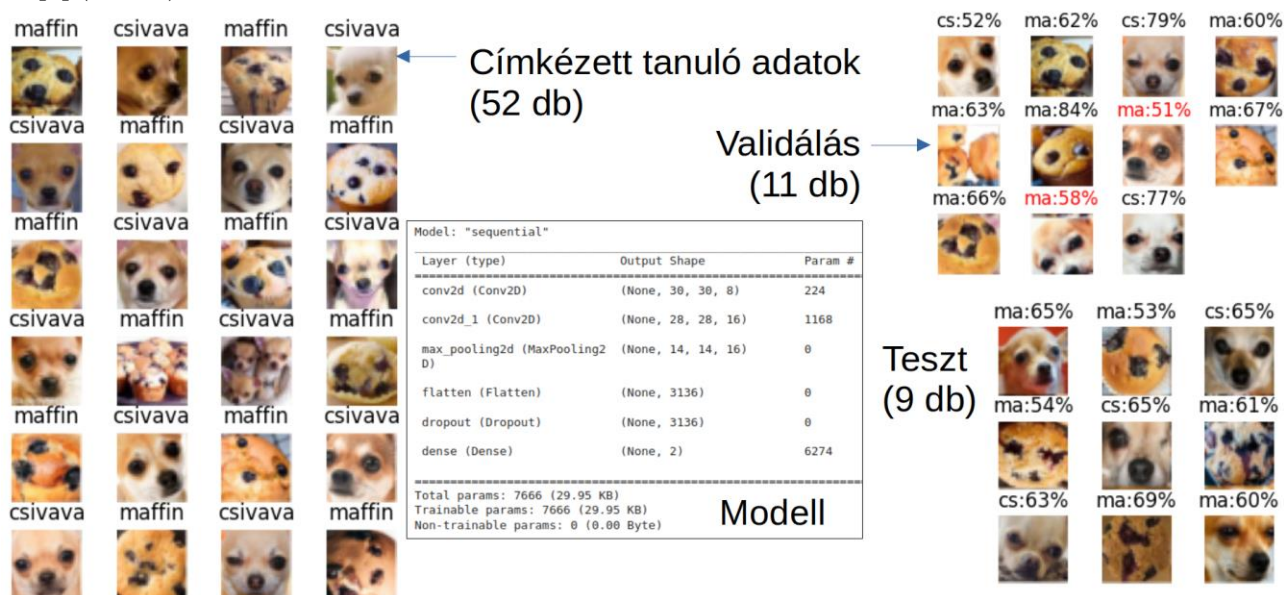
A NASA és az IBM együttműködéséből született egy térinformatikai alapmodell a földmegfigyelési feladatok támogatására [1]. 1TB harmonizált Landsat és Sentinel 2 (HLS) műholdképet is felhasználva tanították be a modellt, melyre épülő alkalmazások Prithvi néven (a Föld szanszkrit nyelven) szabadon elérhetők a Hugging Face-n (<https://huggingface.co/ibm-nasa-geospatial>). Jelenleg előntés térképek, idősorok alapján történő termény szegmentálás, futótűz nyomok szegmentálás alkalmazások állnak rendelkezésre.



5. ábra Idősoros adatok modellezése 1000 epocha után

Az elmúlt évben és idén nehézségeket tapasztalhattunk a GNSS méréseink során, melyet a Nap 11 éves periódusú napfolt tevékenység maximuma okoz. A napfoltok számára az 1700-as évektől állnak rendelkezésre adatok, melyeket a Belga Királyi Observatórium tesz közzé. 1818-tól napi megfigyelési adatok érhetők el. Kétféle módszerrel feldolgoztam 1849-től napjainkig a havi adatokat, 1D-s konvolúciós neurális hálózattal, illetve Long Short Term Memory (LSTM) algoritmussal (5. ábra).

Az utolsó példával a gépi látás témájához térünk vissza egy osztályozási feladat kapcsán. Az osztályozás során arra szeretnénk választ kapni, hogy mit ábrázol a kép. Ennél a feladatnál jellemzően konvolúciós neurális hálózatot alkalmaznak. A példában a szakmánkhoz kevésbé kapcsolódó, de számomra izgalmas kérdésre szeretnénk választ kapni, vajon a kép áfonyás muffint vagy csivavát ábrázol. 26 muffin és 26 csivava képet sikerült összegyűjteni az internetről, melynek 80%-át tanításra, 20%-át pedig validálásra használtunk. A tanító adatokkal 88%-os, a validálás használt képekkel pedig 82%-os eredményt sikerült elérni. Végül a tanítás során kialakult modellel 9, a tanításhoz nem használt képet ellenőriztük a modellt, ahol 100%-os eredményt értünk el. [5] (6. ábra)



6. ábra Csivava vagy muffin modell

## KÖSZÖNETNYILVÁNÍTÁS

Köszönöm a BME Általános és Felsőgeodézia Tanszéknek és munkatársainak a támogatását a cikkhez kapcsolódó kutatómunka elvégzéséhez. Külön köszönet dr. Takács Bence és Hrutka Bence segítségéért.

## IRODALMI HIVATKOZÁSOK

- [1] Albrecht C. M., Elmegreen B., Gunawan O., Hamann H. F., Klein L. J., Lu S., Mariano Siebensschuh F. C., Schumde J: *Next-generation geospatial-temporal information technologies for disaster management*, IBM Journal of Research and Development ( Volume: 64, Issue: 1/2, 01 Jan.-March 2020)
- [2] Hrutka B., Siki Z.: *Többszörös sík keresés*, GitHub, [https://github.com/OSGeoLabBp/tutorials/blob/master/hungarian/ransac/ransac\\_sik.ipynb](https://github.com/OSGeoLabBp/tutorials/blob/master/hungarian/ransac/ransac_sik.ipynb) (utolsó letöltés 2024.08.30)
- [3] Hrutka B.; Siki, Z.; Takács, B.: *AUTOMATED PROCESSING OF POINT CLOUDS TO UPDATE LAND REGISTRY MAPS*, INTERNATIONAL ARCHIVES OF PHOTOGRAMMETRY AND REMOTE SENSING (2002-) XLVI-4/W2-2021 pp. 77-82.
- [4] Siki Z.: *Find-CGP*, OpenDroneMap, <https://opendronemap.org/findgcp/>, (utolsó letöltés: 2024.08.30)
- [5] Siki Z.: *Csivava vagy muffin?*, GitHub, [https://github.com/OSGeoLabBp/tutorials/blob/master/hungarian/machine\\_learning/lessons/czivava.ipynb](https://github.com/OSGeoLabBp/tutorials/blob/master/hungarian/machine_learning/lessons/czivava.ipynb) (utolsó letöltés 2024.08.30)
- [6] Siki Z., Takács B.: *Automatic Recognition of ArUco Codes in Land Surveying Tasks*, BALTIC JOURNAL OF MODERN COMPUTING, 2021, 9 : 1 pp. 115-125.
- [7] Trevillian C.: *The changing role of the surveyor*, GIM International 2023. Issue 6. pp 36-37 (<https://www.gim-international.com/content/article/unwavering-integrity-in-an-increasingly-complex-digital-continuum>)
- [8] *An AI copilot for vectorizing in QGIS*, Bunting Labs, <https://buntinglabs.com/solutions/ai-vectorizer-qgis-plugin>, (utolsó letöltés 2024.08.30)