

Folyami makróműanyag szennyezők detektálása képalapú mesterséges intelligenciával

Tikász Gergely

Konzulens: Dr. Baranya Sándor

Vízépítési és Vízgazdálkodási Tanszék

2023/24 őszi félév



M Ű E G Y E T E M 1 7 8 2



Tartalom

Tartalmi kivonat	3
1. Bevezetés.....	4
1.1. Makróműanyag szennyezők.....	4
1.2. Folyami makróműanyag vizsgálati módszerek	9
1.2.1. Emberi számlálás.....	9
1.2.2. Kép alapú vizsgálat	10
1.2.3. Hálóval történő vizsgálat.....	10
1.2.4. Merülőfallal történő vizsgálat	10
1.2.5. Műanyagok kézi begyűjtése	10
1.3. Mesterséges intelligencia	11
1.3.1. Mesterséges intelligenciák elméleti háttere.....	11
1.3.2. Makróműanyagok detektálása mesterséges intelligenciával.....	13
1.4. A dolgozat célja	14
2. Alkalmazott módszerek.....	15
2.1. Alkalmazott mélytanuló eszköz	15
2.2. Tanításhoz használt képek	18
2.3. Annotálás	18
2.4. Augmentáció.....	20
2.5. Modell tanítása	20
2.6. Validálás	23
3. Eredmények.....	24
3.1. Fejlesztett modellek.....	24
3.2. Modellek bevetése.....	26
4. Diskusszió.....	35
4.1. Eredmények értékelése.....	35

4.2. További fejlesztési feladatok előirányzása	36
5. Konklúzió	37
Köszönetnyilvánítás	37
Ábrajegyzék	38
Irodalom jegyzék.....	39
Internetes hivatkozások	41

Tartalmi kivonat


A felszíni vizekben egyre jelentősebb problémaként jelenik meg az antropogén hulladék, mint szennyező anyag. Az utóbbi évtizedekben a műanyag használati tárgyak és csomagolások száma rohamosan növekedett, ezzel együtt jelent meg és nőtt a műanyag hulladék mennyisége a településeken kívül, a mezőgazdasági és természetvédelmi területeken. Az ártereken összegyűlt hulladékot egy kisebb árhullám is könnyedén öblíti ki, így a természetes uszadékkal együtt vonul le a folyón. Az ártereken eldobott vagy odahordott műanyag túlnyomó részt makróműanyag (>5 mm), amely vegyi és biológiai hatások, valamint hosszú ideig tartó UV sugárzás és mechanikai igénybevétel hatására apróbb darabokra esik szét és mikróműanyag (<5 mm) szennyezővé válik. Hazánk medence jellege és vízrajza miatt különös mértékben kiszolgáltatott a szomszédos országokból érkező folyami makróműanyag szennyezésnek. Az érkező „hulladékáradat” nem csak ökológiai és esztétikai szempontból veszélyes, de az árvízi levonulást és egyes műtárgyak üzemeltetést is akadályozza.

A műanyag szennyezők viselkedéséről keveset tudunk, mivel azok észlelési, mérési és monitoring módszerei még kidolgozatlanok és nem elterjedtek. Jelen dolgozatban felszíni vizekben, elsősorban folyami környezetben megjelenő makróműanyagot detektáló kép alapú módszer fejlesztése és annak eredményei kerülnek bemutatásra. A makróműanyag észleléséhez vízfelületről videófelvételek készültek, amelyek vizsgálatához számos területen alkalmazott objektum felismerő mélytanuló eljárás került bevetésre. A dolgozat célja a felvételeken megjelenő makróműanyagok detektálása és számszerűsítése és a tanított detektor teljesítményének vizsgálata validáció során. Ezzel lehetővé téve az eszköz későbbi bevetését valós idejű makróműanyag detektálásra. A makróműanyagok detektálása lehetőséget adhat monitoring vagy riasztó állomások létrehozására és a makróműanyagok kvantifikálására. Ilyen állomásokkal gyűjtött adatokkal transzport modelleket állíthatunk fel, valamint vizsgálhatjuk a makróműanyagok konzervatívitasát is, így jobban megérthetjük a műanyagszennyezés viselkedését.

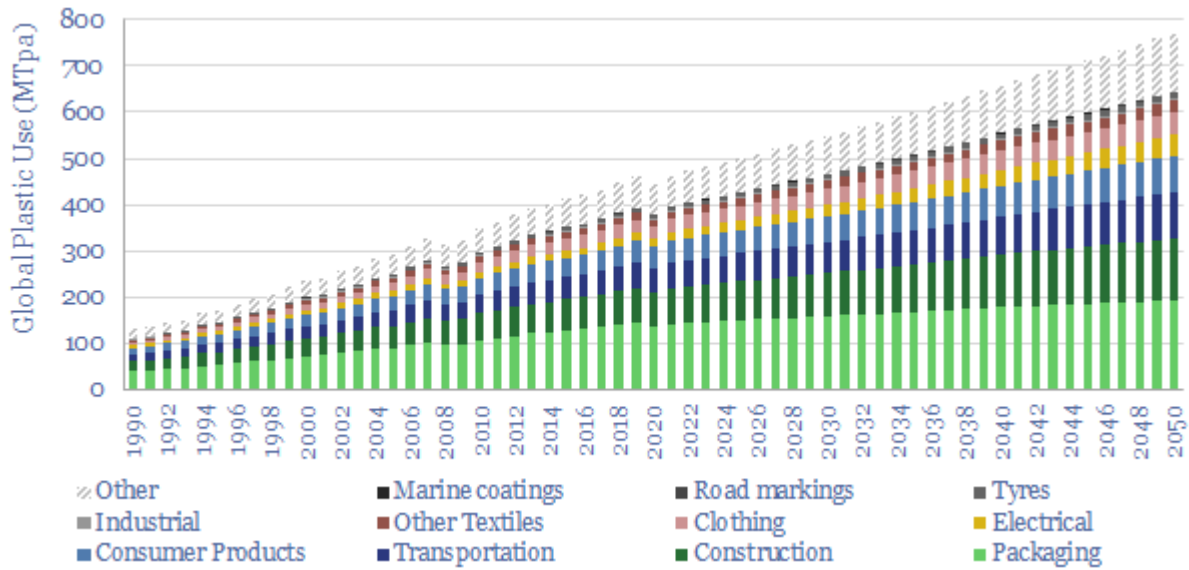
1. Bevezetés

1.1. Makróműanyag szennyezők

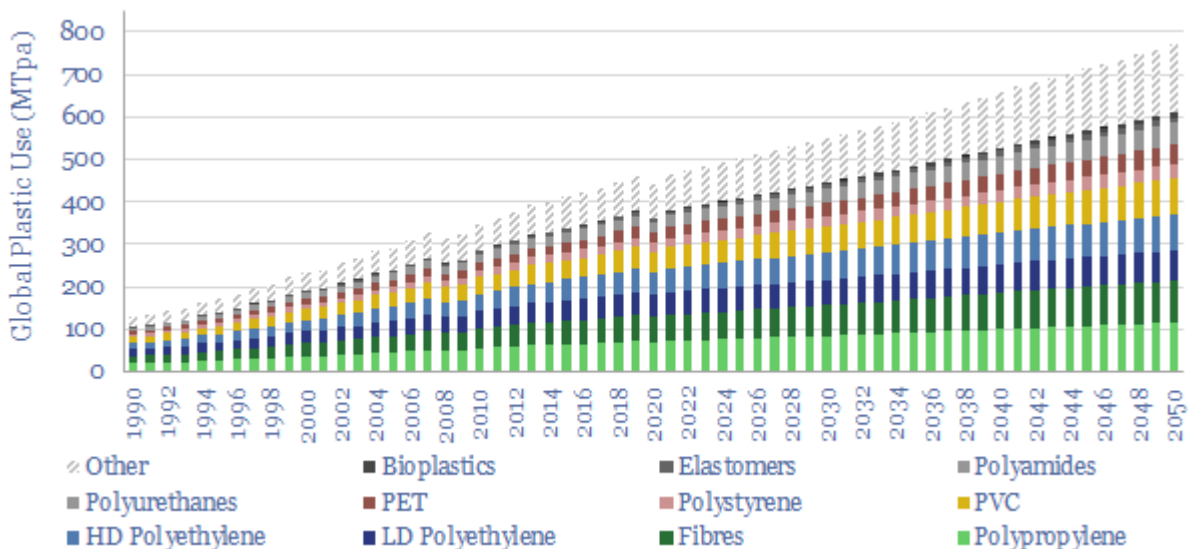
1839-ben Eduard Simon német vegyész felfedezte a polisztirolt (PS) az első szintetikus polimert, amelyet nemsokkal követett számos egyéb polimer típus is, mint a celluloid és a polivinilklorid (PVC). A természetes és szintetikus polimerek kutatása és az újonnan felfedezett anyagok használata igen jelentőssé vált a 20. század első felében, amikor több mint 15 különböző polimer osztályt szintetizáltak és kezdtek el gyártani. (Andrady és Neal, 2009) A különböző műanyag típusok népszerűsége a második világháború után exponenciális ütemben nőtt (1. ábra). Így 2022-re az emberiség éves műanyagfelhasználása elérte a 470 millió tonnát (2. ábra, 3. ábra).



1. ábra: A világ műanyaggyártása 1950-2019 között (Pires da Mata Costa, et al., 2021)



2. ábra: Éves műanyagigény iparágak szerint millió tonna per évben (Tunder Said Energy)



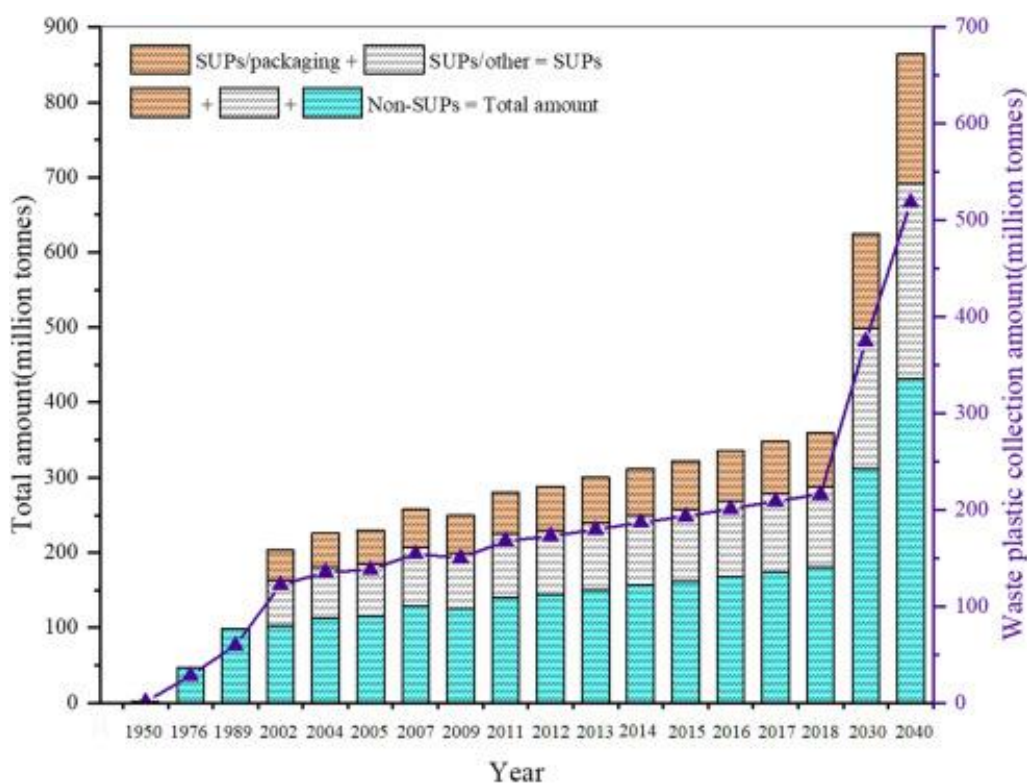
3. ábra: Éves műanyagigény polimertípusok szerint millió tonna per évben (Tunder Said Energy)

A polimerek elterjedésének és töretlen népszerűségének oka, hogy a számos egyedi tulajdonsággal rendelkeznek: nagyon széles hőmérséklet-tartományban használhatók, vegyszer- és UV állók, valamint nagyon erősek és szívósak, de forró olvadékként könnyen megmunkálhatók. Ugyanakkor előállítási költségük viszonylag alacsony. (Geyer, et al., 2017)


A 2000-es évekre a műanyagtermékek között megjelentek az egyszerűhasználatos vagy eldobható termékek, mint a pillepalackok, az egyszerűhasználatos evőeszközök, stb. (4. ábra). Ezen kívül a csomagolóanyagok is jelentős mértékben műanyag alapúak lettek, ez nemcsak a

műanyagok iránti igényt fokozta, de drasztikusan növelte a műanyag hulladék mennyiségét is. (Chen, et al., 2020)

A feleslegessé vált műanyag hulladék egy részét elégetik és egy részét újra hasznosítják, de jelentős mennyiség a mai napig eltemetésre kerül (5. ábra). A legnagyobb problémát ezek az anyagok ott okozzák, ahol nincs szervezett hulladékgyűjtés, így a konzervatív hulladékok vagy háztartásokban kerülnek elégetésre, elásásra vagy egyes esetekben lakott területen kívül történnek elhelyezésre. Ezen kimenetelek mindegyike aggályos, környezetszennyező és akár egészségre is ártalmas, ugyanakkor jelen dolgozatban csak a vízgyűjtőkön felhalmozott hulladékkal foglalkozom.



4. ábra: Globális műanyag- és egyszerhasználatos műanyagtermelés (egyszerhasználatos műanyag - *Single-Use Plastic* [SUP]) (Chen, et al., 2020)



5. ábra: Összesített műanyag hulladék-termelés és ártalmatlanítás (millió tonnában).

A folytonos vonalak az 1950 és 2015 közötti történelmi adatokat mutatják;

a szaggatott vonalak a történelmi tendenciák 2050-ig tartó előrejelzését mutatják

(Geyer, et al., 2017)

Sajnos gyakori jelenség, hogy a folyó árterét hulladéklerakásra használják, amely ilyen szempontból 'praktikusnak' bizonyul, mivel a felgyülemlett hulladékot a következő árhullám kiöblíti, így helyben nem okoz további problémát. A műanyagok többsége a víznél kisebb sűrűségű, így azok a vízfelszínén úszva hatalmas távolságokat tehetnek meg.

Természetbe kerülésükkor a műanyagdarabok szinte kizárólag makróműanyag kategóriába sorolhatóak, vagyis 5 mm-nél nagyobb szemcse méretűek. Útjuk során a hosszantartó UV sugárzás, a hőmérsékletváltozás és mechanikai hatások során aprózódhatnak és mikróműanyaggá (< 5mm) válhatnak. A mikróműanyagok élővilágra és az emberi szervezetre gyakorolt hatásai intenzíven kutatott téma (Ying, et al., 2023, Ivy, et al., 2023, Xiang, et al., 2023), de ismereteink igen korlátosak a témáról,

A mikróműanyagok felhalmozódhatnak élő szervezetekben, elsősorban állatokban, halakban, amelyek életben maradása kérdésessé válik, valamint így élelmiszerként sem használhatóak.

A makróműanyagok is veszélyeztethetnek élőlényeket, ezen felül egy-egy árhullámmal érkező hulladékáradat hasonlóan az abiotikus hordalékhoz felgyülemlhet az ártereken, műtárgyak

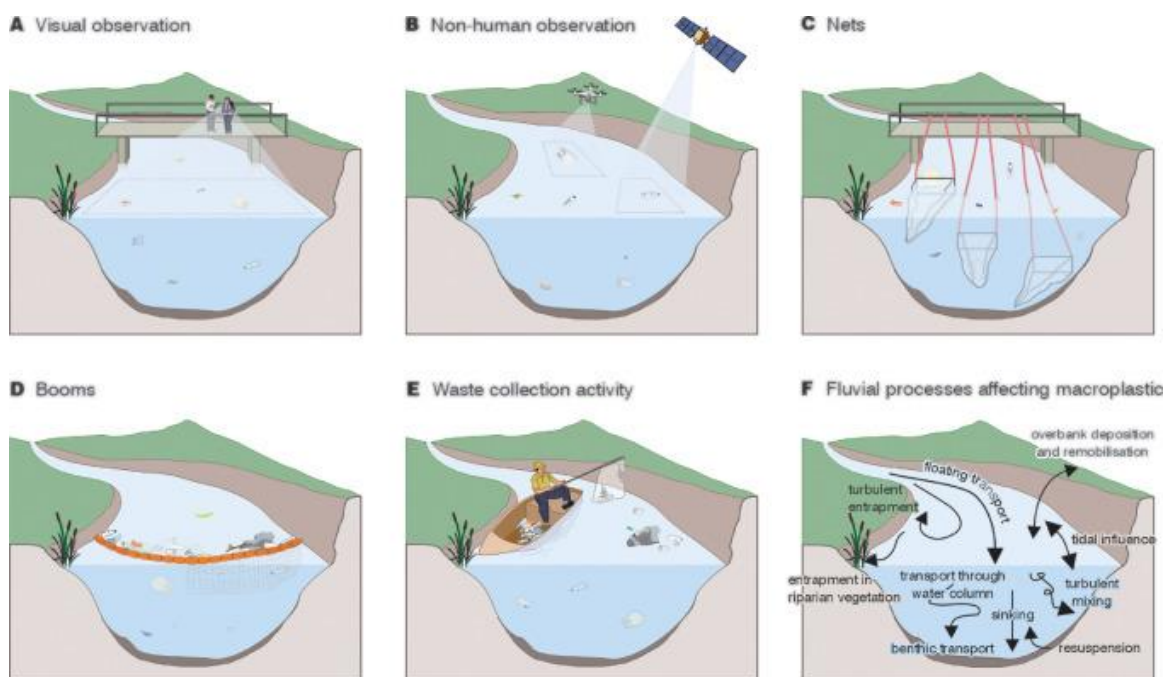
belsejében, és jéghez, uszadékhoz hasonlóan műtárgyak előtt. Emiatt problémát okozhat az árvízi levezetésben, üzemeltetésben (6. ábra). Mindezek miatt a makróműanyagok észlelése növekvő jelentőségű mind riasztáshoz, mind monitoring tevékenységekhez.



6. ábra: Felgyülemlett makróműanyag és uszadék a Kiskörei duzzasztó felvизén

1.2. Folyami makróműanyag vizsgálati módszerek

A detektálási és megfigyelési módszerek alapvetően két csoportba oszthatóak, az egyik a makróműanyagok vizuális észlelésén alapszik, ez történhet emberi megfigyelő által, vagy valamilyen digitális optikai eszköz segítségével. A másik csoport a műanyagok fizikai mintázásán alapszik, ez történhet hálóval, merülőfallyal és a műanyagok kézi begyűjtésével. (Hurley, et al., 2023)



7. ábra: Makróműanyag vizsgálati módszerek (Hurley, et al., 2023)

1.2.1. Emberi számlálás

Egy folyó makróműanyag szennyezettségének fontos jellemzője, a makróműanyag fluxus vagy hozam, amely tömeg per idő vagy darabszám per idő dimenziójú és azt mutatja meg, hogy a vizsgálati állapotban egységnyi idő alatt mennyi makróműanyag áramlik át egy szelvényen. A vizsgálatnak a legegyszerűbb módja a helyszínen megszámolni, hogy adott idő alatt hány makróműanyagot látunk átúszni a vizsgálati szelvényen. Ez a módszer ugyan nem igényel különösebb felszerelést, de folyamatos emberi jelenlétet és figyelmet követel. A vizsgálatot olyan helyről lehet végezni, ahonnan a vizsgálati szelvény belátható, például hidakról, de kisebb folyók, patakok partról is vizsgálhatóak. Nagyobb, szélesebb folyók esetében, ahol egy teljes szelvényt nem lehet egyszerre belátni, kisebb darabokra kell osztani és az egyes darabokon egymás után elvégezni a számolást. Ez csak közel állandó vízjárás mellett végezhető el. (Emmerik, et al., 2018)

1.2.2. Kép alapú vizsgálat

Ahogy számos más területen, a folyami makróműanyagok vizsgálatára is bevethetőek kép alapú eszközök. Erre alkalmazhatunk rögzített kamerát (Xue, et al., 2021, Musić, et al., 2020, Kylili, et al., 2020), drónnal vagy repülőőről készült felvételt (Garcia-Garin, et al., 2021, Papakonstantinou) és akár műholdfelvételeket is. Rögzített kamerával készült felvételeknél az emberi számláláshoz hasonló helyre van szükség, valamint annak végzési szabályai is megegyeznek. Jelentősége, hogy a kamera kis költség mellett is folyamatosan tud üzemelni, valamint több kamera képe össze-szinkronizálható, elkerülve ezzel a dupla detektálásokat.

A videófelvetelek elemzése elvégezhető emberi számlálással is, viszont az egyre pontosabb és gyorsabb képalapú mestereges intelligenciák alkalmazásával automatizálható a folyamat, így csökkentve a vizsgálat munkaidejét és javítva az eredmények konzisztenciáját. Kép alapú mestereges intelligenciát alkalmazó vizsgálatokat az 1.3.2-es fejezet mutat be.

1.2.3. Hálóval történő vizsgálat

A fizikai mintavételezésnek egyik módja, ha egy fix ponthoz vagy mérőcsónakhoz rögzített hálót használunk. Ebben az esetben a hozam meghatározására a háló vízbe merítésének ideje is rögzítendő. Több összekapcsolt hálóval akár a műanyagok vízoszlop menti eloszlása is vizsgálható, ami csak igen szennyezett folyóknál lényeges, ahol a műanyag több rétegben jelenik meg. (Morritt, et al., 2014)

1.2.4. Merülőfallal történő vizsgálat

Ez a módszer hasonló a hálóval történő vizsgálatához, itt az áramlásra merőleges merülőfalakat helyezünk el a folyóban, ami csapdázza a felszínen, avagy annak közelében úszó műanyagokat. Merülőfalakkal elzárhatunk teljes keresztmetszelvényt, vagy csak kisebb szegmenseket is. Ez a módszer inkább kármentesítésre szolgál, mint csupán vizsgálatra, de az elzárás ideje és a kiemelt műanyag tömege vagy darabszáma alapján meghatározható a hozam.

1.2.5. Műanyagok kézi begyűjtése

Egy árhullám után a partok mentén, illetve az ártereken lerakódott műanyagok begyűjtése is szolgáltatott információval, ugyanakkor a műanyag hozam megállapítására nem alkalmas a vizsgálat. Alkalmazása sokkal inkább a kármentesítés területén jellemző.

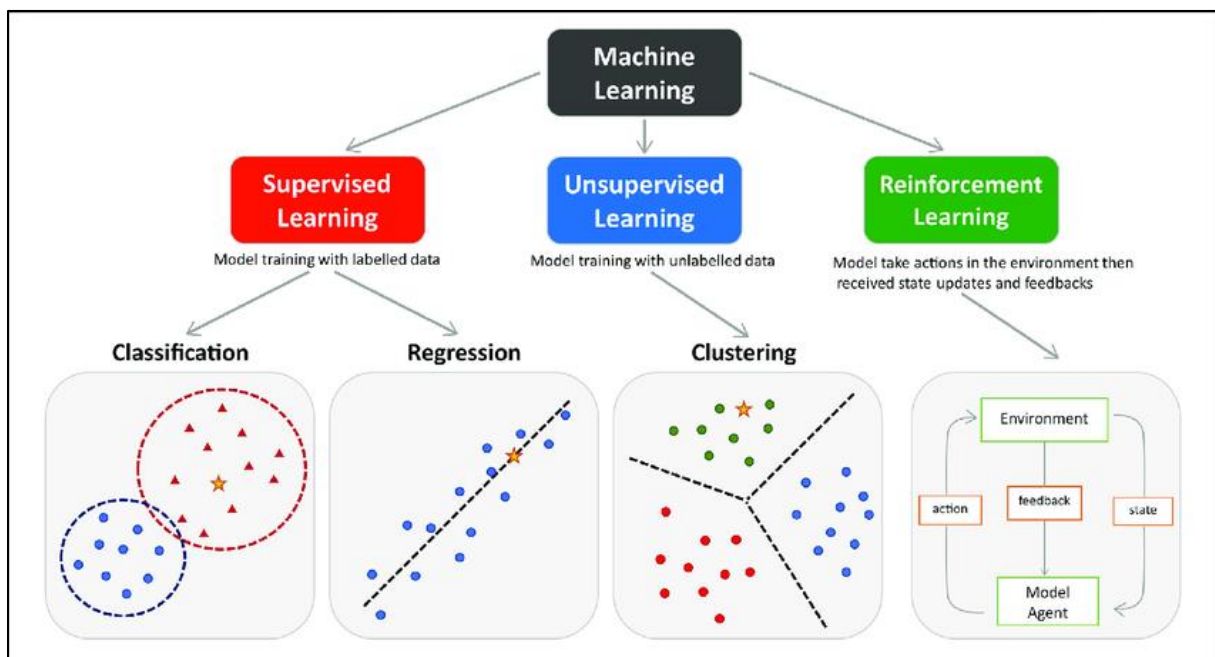
A fizikai mintagyűjtésen alapuló módszerek előnye, hogy a begyűjtött műanyagokon további vizsgálatok végezhetőek el, amelyek információt szolgáltathatnak a műanyag koráról, anyagáról, aprózódási állapotáról és egyéb jellemzőkről. (Liro, et al., 2023)

1.3. Mesterséges intelligencia

1.3.1. Mesterséges intelligenciák elméleti háttére

A mesterséges intelligenciának (*Artificial Intelligence- AI*) nincs szilárd definíciója, a kifejezés egy gyűjtő fogalom olyan számítógépes rendszerekre, amelyek olyan problémák megoldását teszik lehetővé, ami konvencionálisan emberi intelligenciát követelne. (Partridge, 2017) Ez alatt érthetünk komplex problémamegoldást, önálló döntéshozatalt vagy előrejelzést. Ezeknek az eszközöknek az előnye, hogy egyszerűbb korábban csak emberi erőforrással megoldható feladatokat automatizálhatnak, így növelve a kapacitást és csökkentve a munkai igényt. Segítségükkel nagy mennyiségű adat dolgozható fel, akár valós időben, ezért ezek a rendszerek igen elterjedtek folyamatirányításban, robotikában, önvezetésben és számos más technikai területen.

Az AI technológiák fejlődése és a megoldandó problémák számos irányzatot termeltek ki, amelyből az egyik legjelentősebb a gépi tanulási irányzat (*Machine Learning - ML*). Az ML eszközök meglévő adatokból építenek fel modelleket, hogy azokkal hasonló bemeneti adatokhoz gyorsan és önállóan adjanak eredményt.



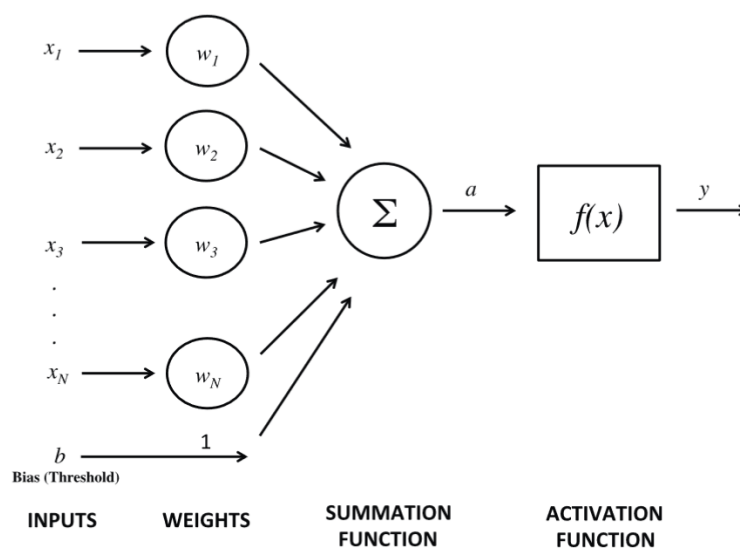
8. ábra: Gépi tanulási ágak (Peng, et al., 2021)

Az ML technológiák közé tartozik a mélytanulás (*Deep Learning - DL*) is, ami a mesterséges neurális hálózatokon (*Artificial Neural Networks – ANN*) alapszik. Az ANN-eket az emberi agy neuron hálózata ihlette. A mesterséges hálózatot a biológiai neuronokhoz hasonló egységek építik fel, amelyek egymáshoz kapcsolódnak és kapcsolódásaik révén hoznak létre egy nemlineáris determinisztikus modellt. Egy mesterséges neuronnak alapvetően két fázisa van, amelyet a 9. ábra szemléltet. Az első, az x_1, \dots, x_N bemeneti jeleket összegyűjti a kapcsolatokon keresztül, és a bemeneti jelek lineáris kombinációját kiszámítja a következőképpen:

$$a = \sum_{i=0}^N x_i w_i + b$$

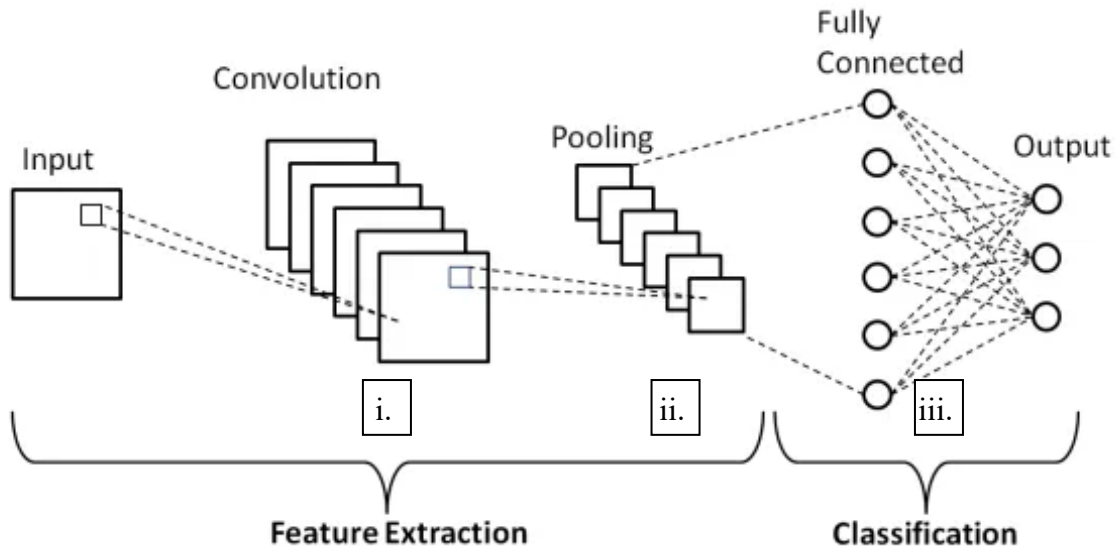
A lineáris kombináció a második fázis bemenete, ahol egy aktiváló függvény egy y kimeneti jelet bocsát ki (Yilmaz, et al., 2023).

$$y = f(a)$$



9. ábra: Mesterséges neuron működése (Yilmaz, et al., 2023)

Képalapú elemzéshez a hagyományos ANN nem alkalmazható, mivel a kép minden pixele egy inputnak számítana, így a modellnek 10^5 - 10^6 nagyságrendű bemeneti adata lenne, ami hatalmas számítási igényt jelentene. Ezért a kép alapú vizsgálatokhoz az ANN-ek egy speciális változatát használják a Konvolúciós neurális hálózatokat (*Convolution Neural Network - CNN*). Egy CNN-ben 3 féle réteg van (10. ábra): (i.) konvolúciós réteg, (ii.) összevonó (pooling) réteg, (iii.) teljesen összekapcsolt réteg. Tehát egy hagyományos ANN-hez képest az i. és a ii. rétegekkel egészül ki.



10. ábra Konvolúciós Neurális Hálózat felépítése: bemenet, konvolúciós réteg (i.), összevonás (ii.), teljesen összekapcsolt réteg (iii.), kimenet (forrás: medium.com)

A CNN-ek a bemenetet (input) különböző szűrőkkel pásztázzák végig a bemenet és a szűrő konvolúciójával, így tulajdonságtérképeket (feature map) állítanak elő. Az összevonó rétegek különböző módszerekkel vonnak össze bizonyos tulajdonságtérképeket, ezzel csökkentve a számítási igényt. A teljesen összekötött rétegben a tulajdonság térképek közötti összefüggések felállítása történik a tanítás során. Az így kapott tulajdonságtérképeket előállító rétegek és a neuronokban felállított kapcsolatok együtt alkotják a kész modellt.

1.3.2. Makróműanyagok detektálása mesterséges intelligenciával

Az 1.2.2 fejezetben bemutatott képalapú módszerek mára szinte kivétel nélkül kiegészülnek a felvételeket elemző különböző CNN alapú mesterséges intelligenciákkal. Az alkalmazások túlnyomó részt tengeri környezetben történnek, ahol a makróműanyag szennyezők hosszútávon gyülemlenek fel.

Egy kiemelkedő pontosságú modellt fejlesztett társaival Teng. Kutatásuk során hajóra rögzített kamerával és drónfelvételekkel dolgoztak, amelyek képeivel (2050 db) egy YOLOv5x modell tanítottak, aminek a pontossága meghaladta a 95 %-ot minden detektált osztályban. (Teng, et al., 2022)

Szintén tengeri környezetben végzett kutatást társaival de Vries, ahol tengerjáró hajókon elhelyezett kamerák képeit dolgozták fel. A képekkel (~ 15000) tanítottak egy YOLOv5s és egy FR-

CNN modellt is, majd az eredményeiket összehasonlították, és arra a következtetésre jutottak, hogy a YOLO modell szignifikánsan jobban teljesített (de Vries, et al., 2020).

Wolf és társai tengerparti és folyami környezetben erősen szennyezett területeken készült drón-felvételeket vizsgáltak, amelyekre két modellt tanítottak. Egy nagyobb képrészletet (csempeket) elemző detektort és egy kisebb képrészletet elemző kvantifikáló modellt. Mindkét modell klasszifikáló CNN volt (Wolf, et al., 2020).

1.4. A dolgozat célja

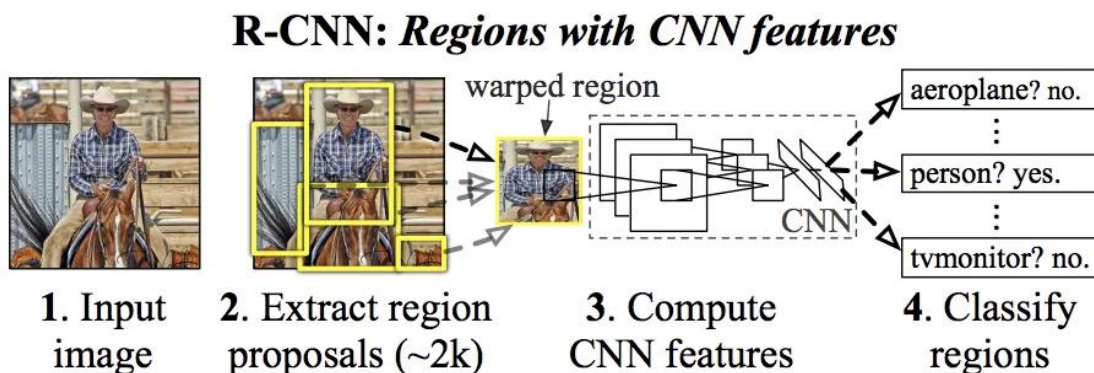
A dolgozat célja, hogy az egyre inkább elterjedő képalapú mélytanuló objektumdetektálásra alkalmas eszközök bevezetését vizsgálja hazai folyami makróműanyag mérésekre. A dolgozat egy alkalmazható, valós idejű makróműanyag detektáló és kvantifikáló rendszer fejlesztésének első lépését a mélytanuló detektor előállítását mutatja be, valamint további fejlesztési feladatokat irányoz előre.

2. Alkalmazott módszerek

2.1. Alkalmazott mélytanuló eszköz

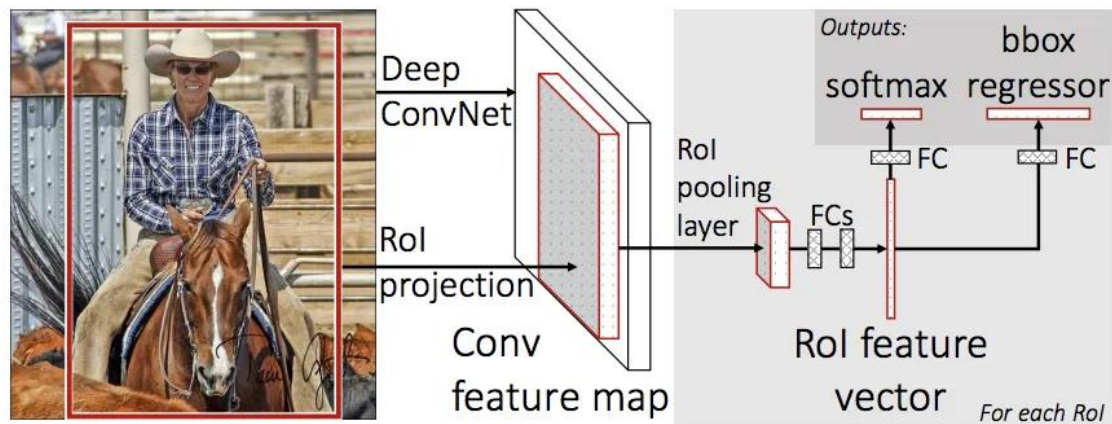
A képalapú detektálásokhoz szinte kivétel nélkül CNN modelleket használnak, ezek a modellek kellően robusztusak fényképfelvételek gyors vizsgálatához, így a 1.4-es fejezetben kitűzött feladat elvégzéséhez is ilyen eszközt kerestem. Mivel a CNN-ök intenzív fejlődési fázisban vannak, így az egyes konkrét eszközök között nincs egyértelmű sorrend. Nem csak a modellek és azok architektúrái, de a modellek működési elvei között sincs általánosan elfogadott legideálisabb megoldás.

Az elterjedt R-CNN módszer (*Region based Convolutional Neural Network*) (Girshick, et al., 2014) ugyan mára elavult, de az egyik legjelentősebb irányzat alapja. Ennek a módszernek az elve, hogy az elemzendő képből kiválaszt 2000 részletet és ezeket elemzi egy CNN architektúrával (11. ábra).



11. ábra: R-CNN működése (Girshick, et al., 2014)

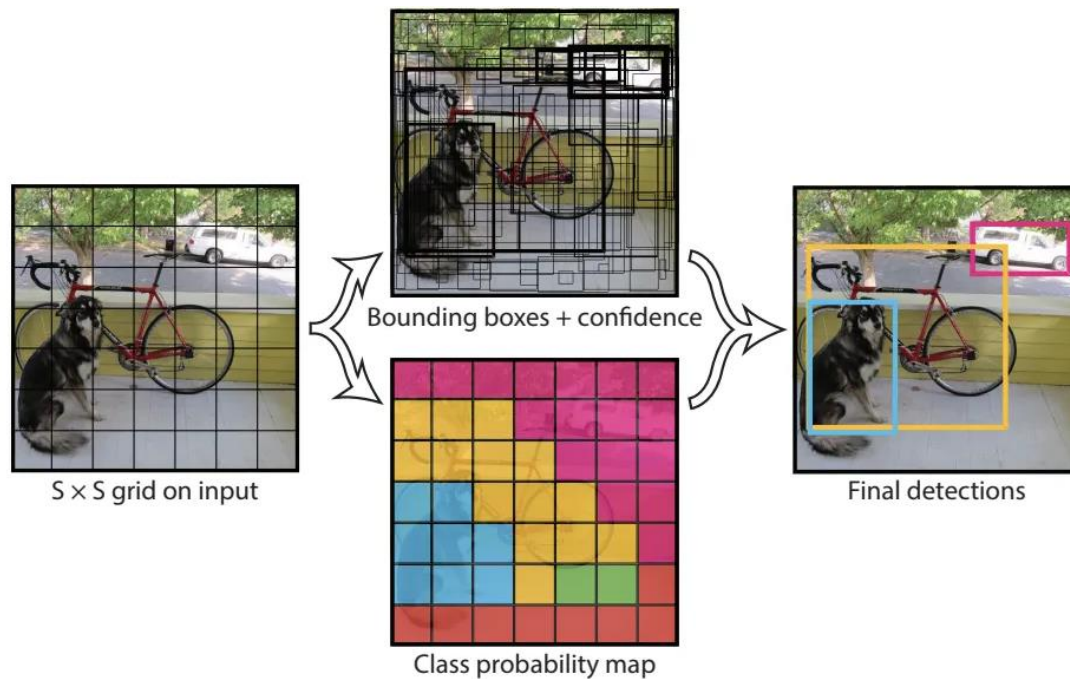
Később a fejlesztők tovább gondolva a módszert előálltak a Fast R-CNN eljárással (Girshick, 2015), amely az eredeti 2000 képrészlet helyett egy konvolúciós tulajdonságtérkép alapján választ ki potenciálisan jelentős képrészleteket, így nagymértékben gyorsítja a folyamatot (12. ábra).



12. ábra: Fast R-CNN működése (Girshick, 2015)

Ennek az elvnek egy máig alkalmazott változata a Faster R-CNN (Ren, et al., 2015) ahol, a tulajdonság térképet már egy külön neurális hálózattal dolgozza fel, így még kevesebb és még lényegesebb területeket választva ki.

A másik igen széleskörben elterjedt módszer a YOLO (*You Only Look Once* – „csak egyszer nézel”) (Redmon, et al., 2016). Ennek a módszernek az alapja, ahogy a beszédes neve is mutatja, az, hogy a képet csak egyszer pásztázza át, ekkor előállít befoglaló dobozokat (*Bounding Box - BB*). Ezekhez a dobozokhoz rendel vizsgált osztályonként valószínűségi értékeket, majd a legmagasabb valószínűségű doboz-osztálypárokat hagyja meg (13. ábra).

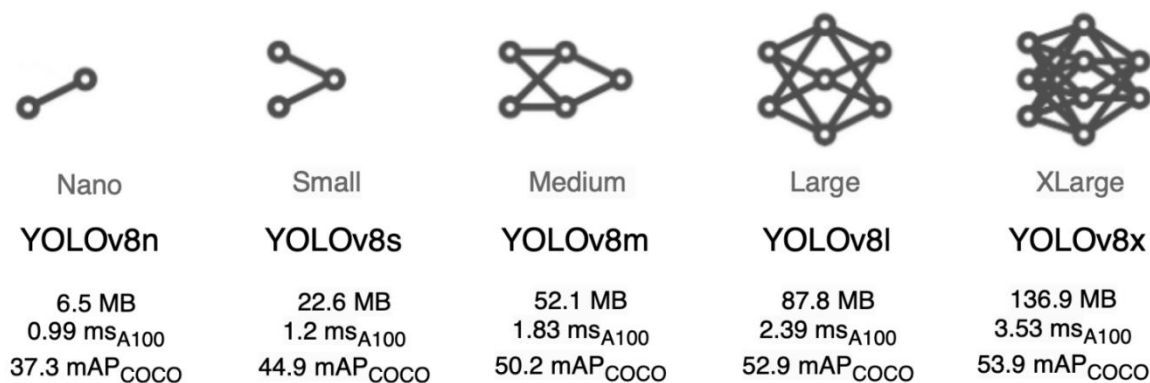


13. ábra: YOLO működése

A YOLO-t 2018-ig Joseph Redmond fejlesztette, ám a 3. generáció (YOLOv3) kiadását követően félve a katonai alkalmazástól és adatvédelmi aggályok miatt felhagyta a fejlesztést. Ezután az Ultralytics csapat vette át a fejlesztést, kiadva a makróműanyag detektálásra is többek által alkalmazott YOLOv5-öt (Teng, et al., 2022, de Vries, et al., 2020).

A makróműanyag detektálás releváns irodalmában talált jobb eredményei és egyszerűbb alkalmazhatósága miatt a YOLO-t választottam, annak a legfrissebb (2023.01.23-án kiadott) YOLOv8 verzióját használtam.

A YOLOv8 5 különböző méretű modellt tartalmaz (14. ábra), ezek: N (Nano - nanó), S (Small - kicsi), M (Medium - közepes), L (Large - nagy) és X (eXtra large – extra nagy).



14. ábra: YOLOv8 modelljei és azok tulajdonságai (memória igény, detektálás sebessége A100-as GPU-n és mAP a COCO 2017-es adatkészleten) (Sharma, 2023)

Mivel a detektálási időtartamok (14. ábra) egy kiemelkedően nagy teljesítményű Grafikai kártyán (Nvidia A100) történő futtatásra igazak, és a hosszabbtávú fejlesztési céloom egy szabadba kitelephető eszköz volt, ahol a modell egy kis kapacitású CPU-n fog futni, ezért jelen dolgozatban csak az S és az M modelleket alkalmaztam.

2.2. Tanításhoz használt képek

A Modell felparaméterezését a mesterséges intelligenciáknál tanításnak nevezzük, ennek egy kritikus eleme a tanítási adathalmaz felépítése. Ahogy minden modell, a mesterséges intelligenciák is, öröklök a kalibrációjukhoz használt adatok hibájából adódó bizonytalanságokat, ezért fontos, hogy a lehető legjobb tanítási adathalmazt állítsuk elő. Az adathalmaz egyik fele a tanítási képekből áll, a másik felét az ezeken tett annotálások adják, utóbbit a 2.3 fejezet részletezi. A tanítási képeknek relevánsnak és a modell későbbi alkalmazásához hasonlóknak kell lennie.

A tanításhoz 1667 felvétel lett összegyűjtve, többségük a Vízépítési és Vízgazdálkodási tanszéken, valamint 223 felvételt kaptam egy a PET Kupától kapott kamera-elemző egység hardver és ahhoz tartozó szoftvercsomag részeként. Ez a rendszer elméletben a 1.4 fejezetben leírt detektáló rendszerként működik egy beágyazott Faster R-CNN modellel. Sajnos gyakorlati alkalmazásra nem alkalmas, mivel nagy mennyiségű téves detektálást végez, ezért fejlesztője felhagyta (Paller és Élő, 2022).

2.3. Annotálás

Annotálás során adjuk hozzá a képekhez azt az információt, amit vissza várunk a modelltől, ez objektum detektálás esetén általánosan a detektálni kívánt objektumokat jelölő határoló

doboz – BB. Az annotálást akkurátusan kell végezni, úgy, hogy egy detektálni kívánt objektumot se hagyjunk ki, valamit ne adjunk meg olyan BB-t, ami nem tartalmaz objektumot. Szintén lényeges, hogy az egyes objektumok megfelelő osztályba kerüljenek.

A kapott képek jelentős része már annotálva volt, de nem a célkitűzéseimnek megfelelően. Mivel kvantifikálás is cél, ezért a műanyag darabokat (többségben palackok) egyesével jelöltembe, és a korábbi különféle forrásból származó osztályokból csak egyet a plastic-ot hagytam meg. Ezen elvek mentén annotáltam a felvételeket a Roboflow online felületet alkalmazva. Egyes képekhez nem BB tartozott, hanem pixel maszk (olyan színes kép, ahol az egyes színek jelölik az egyes osztályokat) (15. ábra). Ezekből egy saját programmal készítettem BB-eket.



15. ábra: pixel maszk

Az annotálás során minden BB-hez 5 adat kerül, a BB osztálya, középpontja vízszintes koordinátája, középpontja függőleges koordinátája, szélessége, magassága. Utóbbi 4 négy normálva

van a kép méretével, tehát pl.: BB szélesség/ képszélesség. Így a képek átméretezése során az annotációk nem változnak.

2.4. Augmentáció

Augmentáció egy eszköz a tanítási adathalmaz kibővítésére, ami végsősoron javíthatja a modell tulajdonságait. Az adathalmaz kibővítése úgy érhető el, hogy valamilyen leányokat gyártunk az eredeti képekből különböző transzformációkkal és szűrőkkel. Jelen esetben minden képből 4 leányt készítettem, alkalmazva függőleges és vízszintes megnyújtást, valamint átméretezést $\pm 10\%$ -kal, elforgatást $\pm 15^\circ$ -kal, mozgási elmosódást, és perspektivikus transzformációt. Ezeket a transzformációkat véletlenszerűen alkalmaztam - vagy épp nem - a megadott határok között véletlenszerű mértékben. Az augmentációt az Imgaug Python függvénykönyvtár felhasználásával saját programban végeztem el, amivel összesen 8321 kép-annotáció párt tudtam előállítani. Az így előállt adathalmazt 3 a YOLO által megkívánt részre osztottam: tanítási- (70%), tesztelési- (10%) és validációs adatkészletekre (20%).

2.5. Modell tanítása

A modellek tanítása lényegében a teljesen összekapcsolt réteg neuronjai súlyainak kalibrálása. A folyamat során a tanításra használt képeket kapja meg a modell és arra ad egy eredményt a hálózat aktuális súlyaival, majd ezt az eredményt a tanító algoritmus összehasonlítja a kézi annotációval, utóbbit alapigazságnak nevezzük (*Ground Thruth*). Azt a lépést amikor előre felé használjuk a hálózatot Forward Propagation-nek (FP) nevezzük, ezt használjuk a tanítás első lépéseként és a modell későbbi felhasználása során is. A tanítás második lépéseként a hálózatot a kimenet felől használjuk, úgy, hogy az alapigazságot adjuk meg bemenő adatként és az egyes neuronok hibáit állítjuk elő, ez az ún. Backward Propagation (BP). Ezek után egy optimalizáló függvény változtatja a súlyokat a hibák csökkentése érdekében. Egy FP, egy BP és egy súly változtatás a tanítás egy ciklusa, amit *epoch*-nak nevezünk. Egy epoch alatt beadjuk a modellnek a teljes tanítási adathalmazt. A feladat párhuzamosíthatósága miatt egyszerre több képet is be tudunk adni a hálózatnak, az egyszerre beadott képek alkotnak egy *batch*-et. A batch mérete meghatározza a tanítás sebességét, minél több képet elemez egyszerre a modell, annál gyorsabban végez. A batch méretét a rendelkezésre álló memória szabja meg, a tanítást a Google Colab-ban elérhető Tesla T4-es GPU-n végeztem, ami 16 GB memóriával rendelkezik.

A korábban említett optimalizáló függvény feladata, hogy megtalálja a hibafüggvény minimumát. Ehhez a hibafüggvény gradiensét használják az adott pontban, és a gradienssel ellentétes

irányába lépnek tovább a tanulási ütemmel. (*Learning Rate*). A modellek tanításához az SGD (*Stochastic Gradient Descent*) módszert használtam, amely a következő képlettel írható le (Aburaed, et al., 2022):

$$\Theta = \Theta - \alpha \cdot \nabla_{\Phi} J(\Theta; x^i; y^i)$$

ahol,

Θ : a modell paraméterei

α : a tanulási ütem


$\nabla_{\Phi} J$: a célfüggvény

x: objektum

y: BB

i: az objektum sorszáma.

A minimum keresést a 16. ábra szemlélteti.

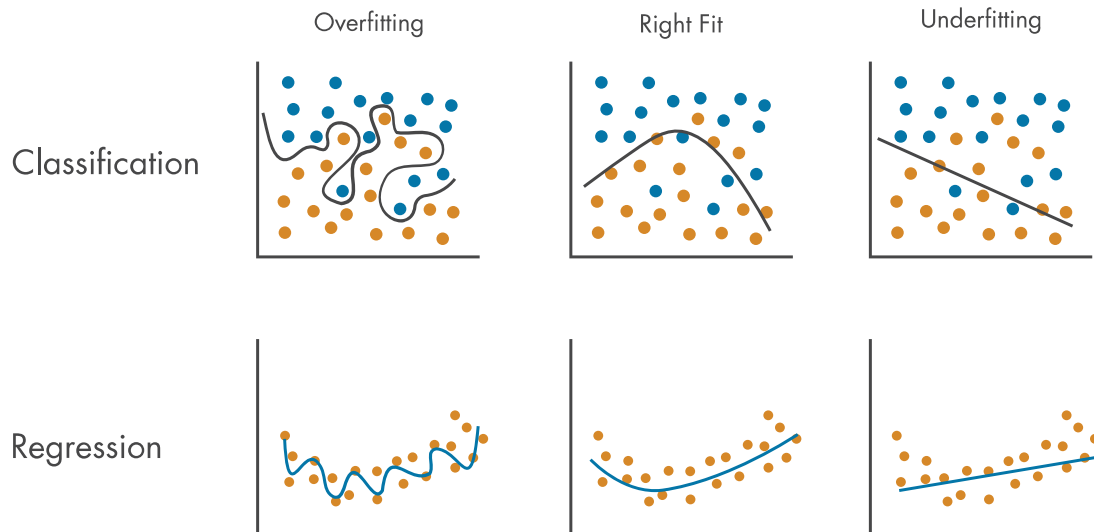


16. ábra: SGD működése (forrás: medium.com)

A tanítás során a YOLOv8 modellnek számos hiperparamétert kell megadni, ezek olyan paraméterek, amelyek a tanítás során nem változnak, a tanító személynek kell megadni őket és a modell eredményességét nagymértékben befolyásolják. Néhány lényeges hiperparamétert már bevezettem, ezek az epoch, bach, learning rate, optimizer (SGD). A dolgozatban bemutatott modelleket képméret és architektúra függvényében eltérő bach mértettel tanítottam SGD optimizer-rel. A képméret a lényeges tulajdonsága a modellnek, jelentése, hogy mekkora képet elemez a modell (eltérő mértű képeket erre alakít), a dolgozatban 640-es és 1280-as képméretre tanított modellek eredményei kerülnek bemutatásra.

A YOLO tanító algoritmus minden epoch után elvéggez egy tesztet, itt a tanítási képektől független teszt adathalmazon végzi el a detektálást, és hasonlítja össze a detektálásokat az

alapigazsággal. Ha a tanítási adathalmazon jelentősen jobb eredményeket kezd elérni a modell, mint a teszten akkor túltanulás (*overfitting*) (17. ábra) jelensége áll fent.



17. ábra: Túltanulás (*overfitting*) forrás: MathWorks

Túltanulás esetén a modell túlságosan specifikus lesz a tanítási adatokra, így a predikciók pontossága jelentősen csökken. A túltanulás elkerülésére augmentáció (2.4 fejezet) alkalmazható.

2.6. Validálás

Validálás során a kész modell-lel elemezzük a validálásra félretett adathalmazt, és az eredményeket hasonlítjuk össze az alapigazságokkal, hasonlóan a tanítás során végzett teszteléshez. Az eredmények alapján a program előállítja a modell összetévesztési mátrixát (*confusion matrix*), ami megmutatja az egyes osztályokat hány alkalommal tévesztette össze a modell. Jelen esetben csak egy osztály van, így csak annyi információval szolgál, hogy az alapigazság hányad részét jelölte meg helyesen.

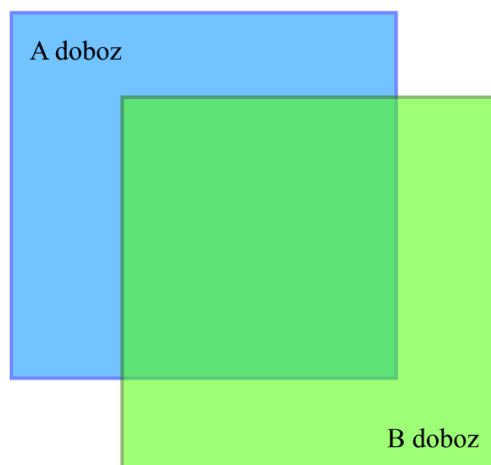
A validáció és a teszt során több mutatóval is mérhetjük a modell eredményességét. Az egyik legegyszerűbb a pontosság (P - *Precision*) (1. képlet), amely a helyesen detektált objektumok és az összes detektálás aránya.

$$P = \frac{TP}{FP+TP} \quad (1.)$$

Egy másik egyszerű mutató az átfedés (R - *Recall*) (2. képlet), ami a helyes detektálások és az alapigazságban megadott összes objektum aránya.

$$R = \frac{TP}{TP+FN} \quad (2.)$$

A fenti mutatók esetében a helyes detektálásokat az IoU (*Intersection over Union* – metszet per unió) módszerrel határozhatjuk meg (18. ábra). Vagyis a detektált BB és az alapigazság BB IoU-át számítjuk ki, és ha ez meghalad egy megadott határértéket, akkor tekintjük helyes detektálásnak (TP - *True Positive*), ha nem, akkor helytelen detektálásnak (FP - *False Positive*). Azokat az objektumokat melyeket a modell egyáltalán nem ismert fel, hamis negatív (FN - *False Negative*) detektálásoknak nevezzük.



18. ábra: IoU (Metszet per Unió)

A leggyakrabban használt mutató a detektálások pontosságára az mAP (*mean Average Precision*) Az mAP az egyes predikciók pontosságának (P) súlyozott átlagaként kerül kiszámításra; a súly az átfedés (R) növekedése az előző predikcióhoz képest képest, ehhez a predikciókat azok magabiztossági értéke (*Confidence*) (0-tól 1-ig a modell által adott érték, a modell magabiztosságát jelöli a predikció valóságát illetően) szerint sorba rendezzük. Másképpen a P-R görbe alatti területként számítható ki. Az mAP50 az 50 %-os IoU határral számított mAP, ez a leggyakrabban használt, viszont szintén alkalmazott az mAP50-95 ami az 50, 55, 60, ..., 90, 95 %-os IoU határral számolt mAP-k átlaga.

A validálás során előállított mutatók segítenek eldönteni, hogy a modell megfelel-e további felhasználásra, illetve segítségükkel egyszerűbb rangsort felállítani a különböző módszerekkel tanított modellek között.

3. Eredmények

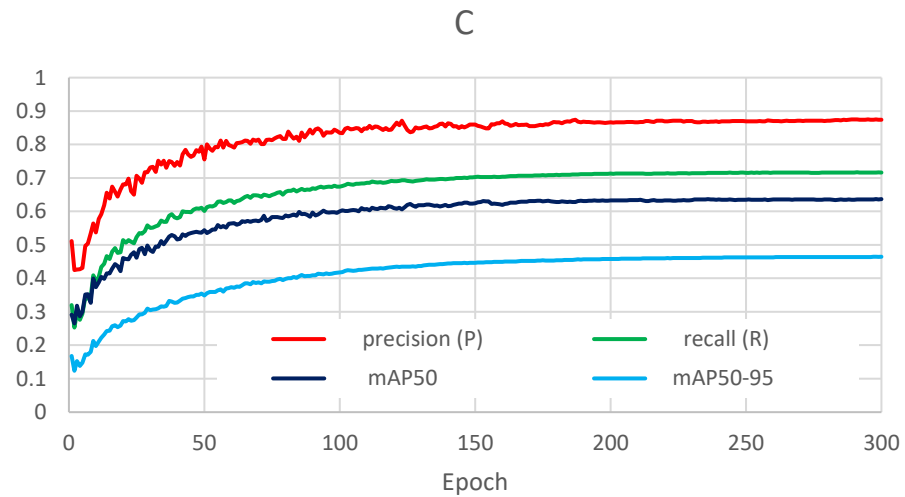
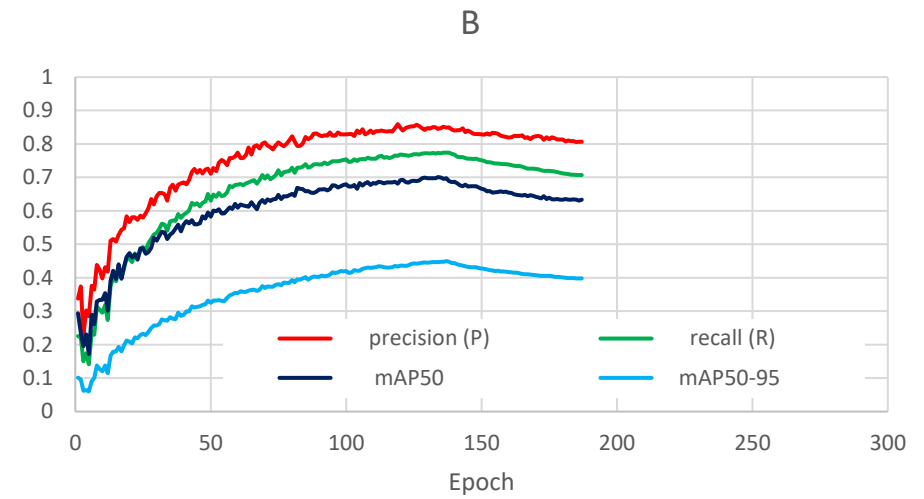

3.1. Fejlesztett modellek

A 2.2-2.4 fejezetekben bemutatott módon előállított adathalmazon számos modellt tanítottam, ezek közül 3 modell kerül bemutatásra (1. táblázat).

Modell	Architektúra	Méret	Bach méret
A	YOLOv8s	640x640	39
B	YOLOv8s	1280x1280	11
C	YOLOv8m	640x640	22

1. táblázat: Modellek tanítási tulajdonságai

A modell mérete az a képméretet pixelben, amelyet bemenő adatként kezel, az ennél nagyobb, vagy kisebb méretű képeket úgy méretezi át, hogy egy ekkora négyzetbe férjenek el (oldal arányt megtartva). A Bach méretet a lehető legnagyobbra vettem fel minden modell esetén, amit a GPU memóriája lehetővé tett. A három modell tanítás közti tesztjeinek eredményeit a 19. ábra tartalmazza. Itt látható, hogy az A és a B modell tanítása nem tartott 300 epoch-ig, mivel az A modell mutatói már kellő mértékben stagnáltak akkor, amikor a tanítás megszakadt a Colab GPU felhasználás időkorlátja miatt, így további epoch-okra nem indítottam el. A B modell teszt-eredményein pedig egyértelmű túltanulás látható 140 epoch-tól. Vagyis a modell minden további epoch-kal veszít az eredményességéből.



19. ábra: Modellek teszt eredményei a tanítás során

Időrend szerint az A modell született elsőnek, a kisebb (távolabbi) objektumok jobb detektálása érdekében tanítottam a nagyobb felbontású képeket vizsgáló B modellt, valamint a teljesítmény általános javulását remélve tanítottam az összetettebb hálózatot használó C modellt. A modellek részletes eredményeit a 2. táblázat tartalmazza.

Modell	Precision	Recall	mAP50	mAP50-95	Validation
A	0,8528	0,6072	0,6872	0,4260	0,64
B	0,8491	0,6977	0,7739	0,4498	0,73
C	0,8744	0,6363	0,7166	0,4641	0,67

2. táblázat: Modellek eredményei

3.2. Modellek bevetése

Az előző fejezetben bemutatott modelleket fényképfelvételeken vettem be, a fényképeket a 2.2 fejezetben említett Paller és Élő által fejlesztett eszköz készítette. A felvételek a Dunán, a Petőfi híd felett a jobbsparton állomásozó MOL zöldszigetről (üzemanyagtöltő állomás) készültek 2023 augusztusában egy kisebb árhullám során (tetőző vízállás: 406 cm – Budapest 08.10.).

A kihelyezett mérőeszközön futó modell (Paller féle) detektáláshoz szükséges minimum magabiztossági érték alacsonyra, 0,1-re lett beállítva, azért, hogy a modell ne limitálja a képek készítését. Az alábbiakban az A modellel készült elemzések láthatóak.



20. ábra: A modell detektálásai kékekkel, magabiztossági értékekkel; nem detektált műanyagok pirossal



21. ábra: A modell detektálási késsel, magabiztossági értékekkel; nem detektált műanyagok pirossal



22. ábra: A modell detektálásai késsel, magabiztossági értékekkel; nem detektált műanyagok pirossal

A 20. ábra22. ábra egy érkező műanyagpalackot tartalmaz, amelyet a modell már csak akkor detektál, amikor az közelebb ér.



23. ábra: A modell detektálásai késsel, magabiztossági értékekkel; nem detektált műanyagok pirossal



24. ábra: A modell detektálásai kékekkel, magabiztossági értékekkel; nem detektált műanyagok pirossal

A 23. ábra és a 24. ábra egy egyszerhasználatos műanyag tál és egy pótkerék elvonulását mutatja. A pótkereket a modell távolabbról is felismerte, viszont a tálat csak közvetlen közelről. Az utolsó képen egyik hulladékot sem detektálta a modell, viszont a képen megjelenő korlátot tévesen műanyagként jelölte meg.



25. ábra: A modell detektálásai késsel, magabiztossági értékekkel; nem detektált műanyagok pirossal


A 25. ábra felül egy hullámfodrozódást alul egy uszadékrönköt detektált műanyagnak a modell. Mindkét detektálás téves, viszont nem jelentősen alacsonyabb a hozzájuk tartozó magabiztossági érték, mint a korábbi műanyag tálhoz tartozó (0,45).



26. ábra: A modell detektálásai késsel, magabiztossági értékekkel; nem detektált műanyagok pirossal

A 26. ábra egy doboz- vagy vödörtető helyes detektálása látható.

A modell bevetésre került a Dunánál jelentősen szennyezettebb Bodrog folyón is. Ehhez a vizsgálathoz szükséges felvételeket a PET Kupától kaptam. Az eredményeket a 27. ábra28. ábra tartalmazza, ahol a detektálások sűrűsége miatt a dobozok osztályát és magabiztossági értékeit nem ábrázoltam., mivel azok kitakarták volna egymást.



27. ábra: Makróműanyag detektálások a Bodrogon



28. ábra: Makróműanyag detektálások a Bodrogon

4. Diszkusszió

4.1. Eredmények értékelése

A 3.1-es fejezetben bemutatott modellek közül a B és C modell csak kismértékben mutatott jobb eredményeket a teszt és validálási fázisokban. A 3.2-fejezetben látható felvételeken mindhárom modell ugyan azon detektálásokat tette, kivéve a 24. ábra felső képét, ahol csak az A és B modell detektált tévesen, ezért lettek csak az A modell eredményei ábrázolva. A felvételek elemzése egy Intel Core i7-8565U processzoron történt, ahol az A modell hozzávetőlegesen 200 ms alatt, a B modell 800 ms alatt és a C modell 400 ms alatt elemzett egy képet. Az eredmények alapján kijelenthető, hogy a magasabb számítási igényű B és C modell nem bizonyult sikereesebbnek, így a magasabb felbontás, illetve az összetettebb modell nem oldja meg az A modell hiányosságait.

Ugyanakkor a Bodrogról származó fényképeken az A modell sikeresen detektálta legtöbb műanyagot kevés hibás detektálás mellett.

Ismeretes, hogy a neurális hálózatok sokszor igen specifikusak, a tanítási környezetükre. Ez a jelen kutatási területen is igaz (29. ábra).



29. ábra: Az A folyóra tanított modell eredményei másik folyókon, tovább tanítás függvényében (Lieshout, et al., 2020)

Ez a jelenség tetten érhető a 3.1-es fejezetben bemutatott modelleken is, hiszen validációs eredményeik elmaradnak a 1.3.2 fejezetben bemutatott nemzetközi eredményektől. Ez egyrésztől betudható a jelentősen kisebb tanítási adathalmaznak és a képei sokrétűségének. A 29. ábra alapján egy modell új környezetben történő bevetése esetén annak eredményei jelentősen javíthatóak az új környezetből származó felvételek felhasználásával történő további tanítással.

4.2. További fejlesztési feladatok előirányzása

A jelenlegi modellek egyike sem bizonyult kellően pontosnak és megbízhatónak, hogy az valós feladatra bevethető legyen. Ugyanakkor a teszt során nagy mennyiségű fényképfelvétel készült (810). Ugyan ezeknek csak egy töredéken van makróműanyag, de az 'üres' képek is igen hasznosak egy adott pozícióra beállított modell tanítására. Segítségükkel a területre jellemző tereptárgyak és a felvételi szögből adódó tükröződések (ld. 25. ábra felső kép) detektálása küszöbölhető ki, mivel a modell nem csak azt tanulja meg hogy mi műanyag, hanem azt is mi nem az. Feltételezhetően az új képekkel tovább tanított modellek már megbízhatóbb detektálásra lesznek képesek.

Ha a modellel nem vagyunk elégedettek annak saját detektálásait, mint annotációkat megjavíthatjuk és az így kapott adatokkal taníthatjuk tovább, így az annotációs munka csökkenthető.

Jelen dolgozatban bemutatott eredmények a modell detektáló üzemmódjával készültek, ugyanakkor a YOLOv8 beépített objektum követő (*tracking*) móddal rendelkeznek, így a kvantifikálás egyszerűbbé válik, elkerülve egy objektum többszöri számítását.

Mivel a modell architektúráját nem kívánom lecserélni, ezért a jelenlegi modelleket már el lehet kezdeni beágyazni egy kameraképet valós időben elemző programba. A programnak folyamatosan elemeznie kell a felvételt (ha szükséges csökkentett képkocka sebességgel), majd a detektálásokat és az azokat tartalmazó felvételeket mentenie kell. Ezen felül időbélyeggel számolnia kell a detektálásokat, mivel így kaphatunk hasznos idősorokat, amelyeket más forrásból származó idősorokkal össze lehet vetni (pl.: vízállás idősorok). Mindez azért tehető meg, mert a modell architektúrája a tanítások során változatlan marad, így az input és output is. Tehát egy modell verzió csere során csak a súlyokat tartalmazó fájlt kell cserélni.

Előreláthatóan a detektálást és a számlálást végző program egy a kamera mellett működő számítógépen fut majd. Az így előálló mérőeszköz kielégíti a jelen kutatás hosszútávú céljait, tehát képes (legalább nappal) valós idejű makróműanyag detektálást végezni, így az eredményei alapján operatív feladatok és kutatási tevékenységek is folytathatóak.

5. Konklúzió

A világ egyre növekvő műanyag és kiemelten az egyszerűhasználatos műanyag fogyasztása jelentősen megnövelte a természetbe kerülő makróműanyagok mennyiségét. Ezért a folyóinkon megjelenő makróműanyag terhelés egyre nagyobb figyelmet követel. A dolgozatban bemutatott makróműanyag detektálásra alkalmas képalapú technológia lehetőséget nyújt folyami környezetben a makróműanyag szennyezők számának vizsgálatára, illetve beavatkozás szükségének megállapítására. A bemutatott modellek még nem alkalmasak üzemszerű bevetésre, viszont megfelelő alapot adnak a kutatás későbbi fázisainak.

Köszönetnyilvánítás

Szeretnék köszönetet mondani konzulensemnek dr. Baranya Sándorbnak az értékes tanácsaiért és iránymutatásáért, amiket a kutatásom és a dolgozatom készítése során kaptam. Ezenkívül köszönettel tartozom Ermilov Alexander Anatolnak a kutatás előkészítésében végzett munkájáért. Kiemelném a PET kupa támogatását is, amely eszközökkel, információkkal és média anyagokkal segítette kutatásomat. Jelen kutatás az MTA Fenntartható Fejlődés és Technológiák Nemzeti Programja keretében valósult meg.

Ábrajegyzék

1. ábra: A világ műanyaggyártása 1950-2019 között (Pires da Mata Costa, et al., 2021).....	4
2. ábra: Éves műanyagigény iparágak szerint millió tonna per évben (Tunder Said Energy) ...	5
3. ábra: Éves műanyagigény polimertípusok szerint millió tonna per évben (Tunder Said Energy)	5
4. ábra: Globális műanyag- és egyszerhasználatos műanyagtermelés (egyszerhasználatos műanyag - <i>Single-Use Plastic</i> [SUP]) (Chen, et al., 2020)	6
5. ábra: Összesített műanyag hulladék-termelés és ártalmatlanítás (millió tonnában). A folytonos vonalak az 1950 és 2015 közötti történelmi adatokat mutatják; a szaggatott vonalak a történelmi tendenciák 2050-ig tartó előrejelzését mutatják (Geyer, et al., 2017).....	7
6. ábra: Felgyülemlett makróműanyag és uszadék a Kiskörei duzzasztó felvizen	8
7. ábra: Makróműanyag vizsgálati módszerek (Hurley, et al., 2023).....	9
8. ábra: Gépi tanulási ágak (Peng, et al., 2021).....	11
9. ábra: Mesterséges neuron működése (Yilmaz, et al., 2023).....	12
10. ábra Konvolúciós Neurális Hálózat felépítése: bemenet, konvolúciós réteg (i.), összevonás (ii.), teljesen összekapcsolt réteg (iii.), kimenet (forrás: medium.com).....	13
11. ábra: R-CNN működése (Girshick, et al., 2014)	15
12. ábra: Fast R-CNN működése (Girshick, 2015)	16
13. ábra: YOLO működése.....	17
14. ábra: YOLOv8 modelljei és azok tulajdonságai (memória igény, detektálás sebessége A100-as GPU-n és mAP a COCO 2017-es adatkészleten) (Sharma, 2023).....	18
15. ábra: pixel maszk.....	19
16. ábra: SGD működése (forrás: medium.com).....	21
17. ábra: Túltanulás (overfitting) forrás: MathWorks	22
18. ábra: IoU (Metszet per Unió)	23
19. ábra: Modellek teszt eredményei a tanítás során.....	25
20. ábra: A modell detektálásai késsel, magabiztossági értékekkel; nem detektált műanyagok pirossal	26
21. ábra: A modell detektálásai késsel, magabiztossági értékekkel; nem detektált műanyagok pirossal	27
22. ábra: A modell detektálásai késsel, magabiztossági értékekkel; nem detektált műanyagok pirossal	28

23. ábra: A modell detektálásai késsel, magabiztossági értékekkel; nem detektált műanyagok pirossal	29
24. ábra: A modell detektálásai késsel, magabiztossági értékekkel; nem detektált műanyagok pirossal	30
25. ábra: A modell detektálásai késsel, magabiztossági értékekkel; nem detektált műanyagok pirossal	31
26. ábra: A modell detektálásai késsel, magabiztossági értékekkel; nem detektált műanyagok pirossal	32
27. ábra: Makróműanyag detektálások a Bodrogon.....	33
28. ábra: Makróműanyag detektálások a Bodrogon.....	34
29. ábra: Az A folyóra tanított modell eredményei másik folyókon, tovább tanítás függvényében (Lieshout, et al., 2020)	35

Irodalom jegyzék

Aburaed, N., Alsaad, M., Mansoori A., S., Al-Ahmad, H., (2022). A Study on the Autonomous Detection of Impact Craters. *Artificial Neural Networks in Pattern Recognition* pp. 181-194

Andrady, A. L., Neal, M. A., (2009). Applications and societal benefits of plastics. *Philosophical Transactions of the Royal Society B: Biological Sciences*, Vol. 364, pp. 1977–1984.

Armitage, S., Awty-Carroll, K., Clewley D., Martinez-Vicente V., (2022) Detection and Classification of Floating Plastic Litter Using a Vessel-Mounted Video Camera and Deep Learning Remote Sensing, Vol. 14

Garcia-Garin O., Monleón-Getino T., López-Brosa P., Borrell A., Aguilar A., Borja-Robalino R., Cardona L., Vighi M., (2021) Automatic detection and quantification of floating marine macro-litter in aerial images: Introducing a novel deep learning approach connected to a web application in R, *Environmental Pollution*, Volume 273,

Geyer, R., Jambeck, J. R., Law, K. L. (2017). Production, use, and fate of all plastics ever made. *Science Advances*, 3(7),

Girshick, R. (2015). Fast r-cnn. In *Proceedings of the IEEE international conference on computer vision* (pp. 1440-1448).

Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 580-587).

Gonçalves G., Andriolo U., Pinto L., Duarte D., (2020) Mapping marine litter with Unmanned Aerial Systems: A showcase comparison among manual image screening and machine learning techniques, *Marine Pollution Bulletin*, Volume 155,

Hurley R., Fredrik H., Braaten V., Nizzetto L., Steindal E. H., Lin Y., Clayer F., van Emmerik T., Buenaventura N. T., Eidsvoll D. P., Økelsrud A., Norling M., Hans N. A., Olsen M., (2023), Measuring riverine macroplastic: Methods, harmonisation, and quality control, *Water Research*, Volume 235,

Ivy N., Bhattacharya S., Dey S., Gupta K., Dey A., Sharma P., (2023) Effects of microplastics and arsenic on plants: Interactions, toxicity and environmental implications, *Chemosphere*, Volume 338,

J. Musić, S. Kružić, I. Stančić, F. Alexandrou (2020) Detecting underwater sea litter using deep neural networks: an initial study 2020 5th International Conference on Smart and Sustainable Technologies (SpliTech). pp. 1-6,

Konan Jean-Claude, K., (2022) A COMPREHENSIVE OVERVIEW OF ARTIFICIAL INTELLIGENCE, *Proceedings of the CS & IT Conference - CSCP*, Vol. 12, No. 23, pp. 173-194

Kylili K., Hadjistassou C., Artusi A., (2020) An intelligent way for discerning plastics at the shorelines and the seas *Environ, Sci. Pollut. Res.*, 27 , pp. 42631-42643,

Liro M., Zielonka A, van Emmerik T., (2023) Macroplastic fragmentation in rivers, *Environment International*, Volume 180

Morritt D., Stefanoudis P. V., Pearce D., Crimmen O. A., Clark P. F., (2014) Plastic in the Thames: A river runs through it, *Marine Pollution Bulletin*, Volume 78, Issues 1–2,

Paller, G., Élő, G., (2022). Towards a Floating Plastic Waste Early Warning System.

Papakonstantinou, A., Batsaris, M., Spondylidis, S., Topouzelis, K. A., (2021) Citizen Science Unmanned Aerial System Data Acquisition Protocol and Deep Learning Techniques for the Automatic Detection and Mapping of Marine Litter Concentrations in the Coastal Zone. *Drones*, No. 5-6.

Partridge D., (2017), *Reference Module in Neuroscience and Biobehavioral Psychology*, Artificial Intelligence Elsevier,

Peng, J. Jury, E. Dönnies, P., Ciurtin, C., (2021). Machine Learning Techniques for Personalised Medicine Approaches in Immune-Mediated Chronic Inflammatory Diseases: Applications and Challenges. *Frontiers in Pharmacology*. Vol. 12.

Pires da Mata Costa, L., Miranda, D., Oliveira, A., Falcon, L., Pimenta, M., Bessa, I., Wouters, S., Andrade, M., Pinto, J., (2021). Capture and Reuse of Carbon Dioxide (CO₂) for a Plastics Circular Economy: A Review. *Processes*. Vol. 9.

Redmon, J., Divvala, S., Girshick, R., Farhadi, A., (2016). You only look once: Unified, real-time object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 779-788).

Ren, S., He, K., Girshick, R., Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. *Advances in neural information processing systems*, Vol. 28.

Teng C., Kylili K., Hadjistassou C., (2022) Deploying deep learning to estimate the abundance of marine debris from video footage, *Marine Pollution Bulletin*, Volume 183,

van Emmerik T., Kieu-Le T. C., Loozen M., van Oeveren K., Strady E., Bui X. T., Egger M., Gasperi J., Lebreton L., Nguyen P. D., Schwarz A., Slat B., Tassin B., (2018) A Methodology to Characterize Riverine Macroplastic Emission Into the Ocean, *Frontiers in Marine Science*, Volume 5

van Lieshout, C., van Oeveren, K., van Emmerik, T., & Postma, E. (2020). Automated river plastic monitoring using deep learning and cameras. *Earth and Space Science*, 7,

Wolf, M, van Den B., Katelijn, G., Shungudzemwoyo P., Gnann, N., Sattler, K., Stahl, F., Zielinski, O., (2020) Machine learning for aquatic plastic litter detection, classification and quantification (APLATIC-Q), *Environmental Research Letters*, vol. 15

Xue B., Huang B., Wei W., Chen G., Li H., Zhao N., Zhang H., (2021) An efficient deep-sea debris detection method using deep neural networks *IEEE J. Sel. Top. Appl. Earth Observations Remote Sensing*, Vol. 14, pp. 12348-12360,

Yangzhou X., Peñuelas J., Sardans J., Liu Y., Yao B., Yuan L., (2023) Effects of microplastics exposure on soil inorganic nitrogen: A comprehensive synthesis, *Journal of Hazardous Materials*, Volume 460,

Yılmaz, M.; Bostancı, B. (2023) Investigation of Real Estate Tax Leakage Loss Rates with ANNs. *Buildings*, Vol. 13,

Ying L., Mochen W., Huijuan L., Hailin X., Jianguo T., Mengyang L., Fenglin W., Yanming L., Jie W., Si L., (2023) Current advances in microplastic contamination in aquatic sediment: Analytical methods, global occurrence, and effects on elemental cycling, *TrAC Trends in Analytical Chemistry*, Volume 168,

Yuan C., Abhishek K. A., Fan W., Quanyin T., Jinhui L., (2021) Single-use plastics: Production, usage, disposal, and adverse impacts, *Science of The Total Environment*, Volume 752,

Internetes hivatkozások

CNN felépítése – medium.com

<https://medium.com/techiepedia/binary-image-classifier-cnn-using-tensorflow-a3f5d6746697>

[Megtekintve: 2023.05.28.]

Global plastic demand: breakdown by product, region and use?

<https://thundersaidenergy.com/downloads/global-plastics-an-overview/>

[megtekintve: 2023.10.09.]

SDG működése – medium.com

<https://medium.com/@jasraj.singh/what-is-stochastic-in-stochastic-gradient-descent-sgd-20d462aec672>

[Megtekintve: 2023.05.28.]

Sharma, A. (2023) Training the YOLOv8 Object Detector for OAK-D,

<https://pyimg.co/9qcei>

[Megtekintve: 2023.10.26.]

Túltanulás (overfitting) – MathWorks.com

<https://www.mathworks.com/discovery/overfitting.html>

[Megtekintve: 2023.10.28.]