XX. TISZÁNTÚLI AGRÁRTUDOMÁNYI NAPOK az „Intelligens megoldások a mezőgazdaságban” - 2024.10.03.

Gyomdetektálás és osztályozás számítógépes látással egy minimális számú képi adathalmaz segítségével

Moldvai László[1,2], Mesterházi Péter Ákos[2], Teschner Gergely[1], Nyéki Anikó[1]

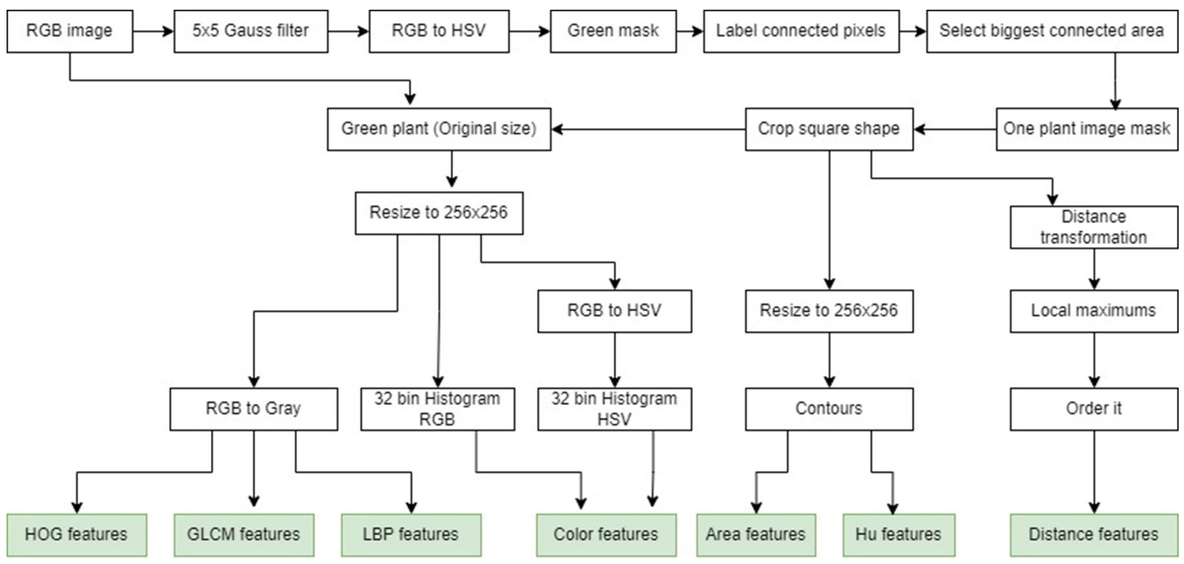
[1] Széchenyi István Egyetem, Albert Kázmér Mosonmagyaróvári Kar Biológiai Rendszerek és Precíziós Technológiai Tanszék, Mosonmagyaróvár
[2] AXIÁL Kft., Baja

I. Bevezetés

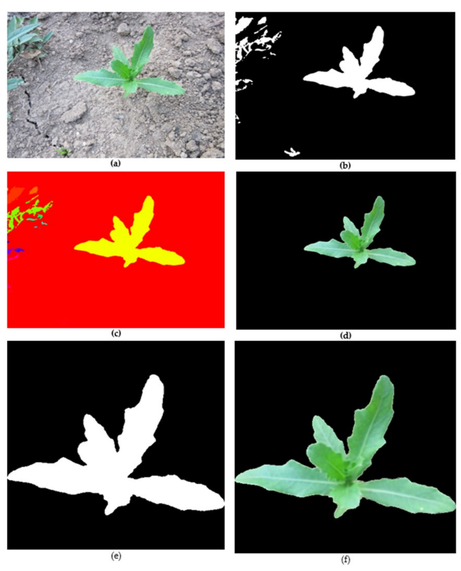
A számítógépes látás területén két kiemelkedő módszertan érdemel különös figyelmet: a hagyományos jellemzőalapú megközelítések és a mélytanulásos módszerek. Az előbbi magában foglalja a képekből származó értelmezhető jellemzők kinyerését, amelyek alapján elvégzik az osztályozási feladatokat. Ez a módszer a képen belüli jellegzetes tulajdonságok, mint például formák, textúrák vagy színminták azonosításán alapul, amelyeket aztán növények osztályozására használnak. Az utóbbi Deep Learning alapú rendszereknek növényfajonként több ezer betanító képre van szüksége, ami gyakran nem áll rendelkezésre.

II. Anyag és módszer

A tanulmány 6 féle növény (Bluegrass, White goosefoot, Lettuce, Sedge, Corn, Cirsium setosum) osztályozását elemezte. Minden fajról 500 kép állt rendelkezésre. Training és teszt képek két csoportját hoztuk létre. Train mintának: 5, 10, 20, 40, 80 és 160 képet választottunk fajonként. Összehasonlításképpen a neurális hálózat betanításához néhány ezer képre van szükség. Az elemzés célja az volt, hogy kevés tanító képpel is lehetséges-e jó osztályozót készíteni, hagyományos képfeldolgozás és gépi tanulás útján. A folyamat során a képekből kiemeltük az egyedülálló növényeket, majd létrehoztuk a szín hisztogramokat, háromféle textúra jellemzőt és háromféle alaktényezőt. Az adatokat és azok kombinációit hatféle osztályozási algoritmussal teszteltük: SVM (Support Vector Machine), RF (Random Forest), KNN (k-Nearest Neighbors), ANN (Artificial Neural Network), NB (Naïve Bayes), és GBM (Gradient Boosting Machine). Az osztályozás jóságát a Precision és a Recall paraméterek kiszámításával, illetve az igazságmátrixok (confusion matrix) elemzésével végeztük.



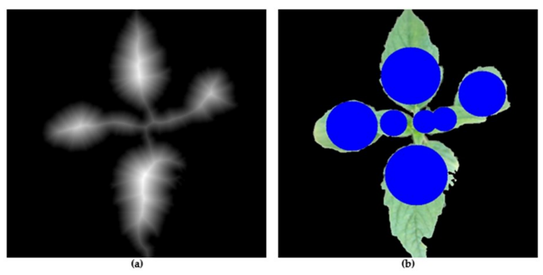
1. ábra: Képfeldolgozás folyamata



2. ábra: Növény kiemelése



3. ábra: Kontúr és alaktényezők



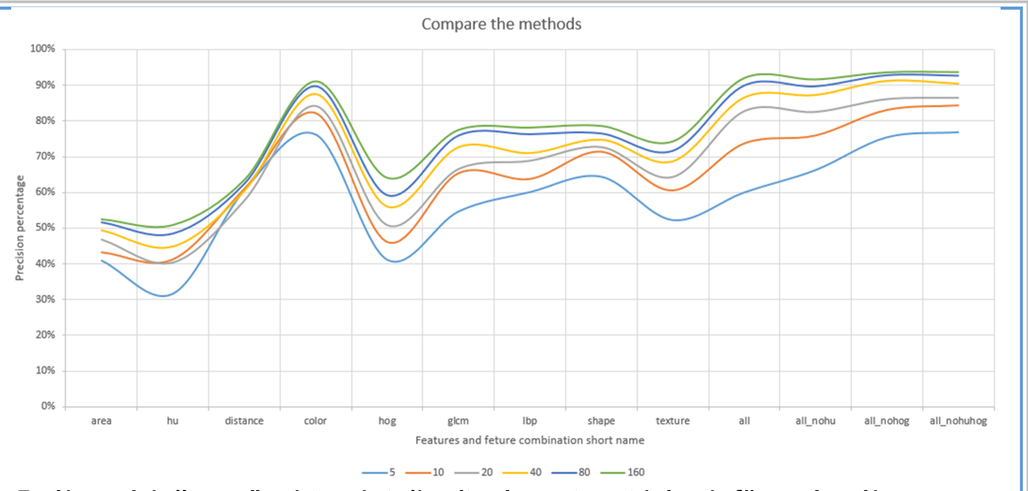
4. ábra: Távolság transzformáció

III. Eredmények

Kevesebb mint 40 kép esetén az RF osztályozó bizonyult a legjobb választásnak. Azonban ahogy a képek száma növekedett, a GBM osztályozó általában jobb eredményeket hozott. **GBM osztályozót használva 94,56%-os recall értéket értünk el** 160 kép alapján gyom típusonként. A jellemző vektorokat tekintve, ha csak egy-egy típust használtunk, az eredmények nem voltak kielégítőek (40%-70%), azonban a jellemzők kombinációit alkalmazva nagyon jó, 90% feletti pontosságot értünk el. Figyelemre méltó, hogy a HOG jellemzők és a Hu-momentumok beépítése általában rontja az osztályozás teljesítményét. A tanulmány kimutatta, hogy már mindössze 10 betanító képpel is kifejleszthető egy 84%-os pontosságú osztályozó. Körülbelül **40 betanító képpel pedig elérhető a 91%-os pontosság**.

Train image number		5	10	20	40	80	160
Test image number		495	490	480	460	420	340
SVM	precision	41.86	59.21	66.56	71.66	73.96	78.99
	recall	41.31	56.09	64.62	70.62	72.90	77.94
RF	precision	76.86	84.33	86.53	90.45	92.72	93.77
	recall	76.46	83.98	86.53	90.43	92.70	93.73
KNN	precision	33.63	44.38	46.40	52.02	54.37	58.60
	recall	36.26	43.06	43.26	50.43	53.53	57.79
ANN	precision	35.08	47.79	22.86	56.79	48.53	65.19
	recall	28.86	44.52	23.16	49.67	44.76	59.41
NB	precision	58.32	59.60	61.14	61.73	63.24	63.22
	recall	56.57	57.35	59.79	62.25	63.69	63.68
GBM	precision	66.57	74.58	81.99	90.30	92.75	94.35
	recall	67.00	72.99	81.28	90.04	92.62	94.26

1. táblázat: A 6 osztályozó precision és recall teljesítménye adatkészlet szám függvényében



5. ábra: A jellemzővektorok teljesítménye teszt képek függvényében

Training Set							
TARGET / OUTPUT	Bluegrass	White goosefoot	Sedge	Lettuce	Corn	Cirsium setosum	SUM
Bluegrass	324 15.88%	2 0.10%	9 0.44%	0 0.00%	4 0.20%	1 0.05%	340 95.29% 4.71%
White goosefoot	1 0.05%	325 15.93%	3 0.15%	3 0.15%	5 0.25%	3 0.15%	340 95.59% 4.41%
Sedge	3 0.15%	5 0.25%	318 15.59%	0 0.00%	14 0.69%	0 0.00%	340 93.53% 6.47%
Lettuce	7 0.34%	0 0.00%	13 0.64%	314 15.39%	0 0.00%	6 0.29%	340 92.35% 7.65%
Corn	0 0.00%	2 0.10%	11 0.54%	0 0.00%	318 15.59%	9 0.44%	340 93.53% 6.47%
Cirsium setosum	0 0.00%	7 0.34%	0 0.00%	0 0.00%	5 0.25%	328 16.08%	340 96.47% 3.53%
SUM	335 96.72% 3.28%	341 95.31% 4.69%	354 89.83% 10.17%	317 99.05% 0.95%	346 91.91% 8.09%	347 94.52% 5.48%	1927 / 2040 94.46% 5.54%

6. ábra: Az igazságmátrix (confusion matrix)

IV. Következtetések

A kutatás adatai alapján látható, hogy hagyományos képfeldolgozás és gépi tanulás segítségével akár már 20-40 kép is elegendő egy-egy növény felismerésének elfogadható betanításához, de 100 kép esetén már a felismerési ráta 90-94%-os pontosságával a mélytanulási eljárások pontosságát is sikerül megközelíteni. Ezért érdemes mindkét megközelítési módot használni az adataink mennyiségének függvényében.

Köszönetnyilvánítás:

- A kutatómunkát a „Precíziós Bio-Műszaki Kutatócsoport" végezte, amelyet a "Széchenyi István Egyetemért Alapítvány Kuratóriuma" támogatott.
- A kutatómunka a Kooperatív Doktori Program Doktori Hallgatói Ösztöndíj keretében készült, amelyet a Kulturális és Innovációs Minisztérium és a Nemzeti Kutatási, Fejlesztési és Innovációs Alap támogatott.

Nemzeti Kutatási, Fejlesztési és Innovációs Hivatal

Kulturális és Innovációs Minisztérium