Klasifikacija biljaka prema karakteristikama lista

Andlar, Domagoj

Undergraduate thesis / Završni rad

2018

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Organization and Informatics / Sveučilište u Zagrebu, Fakultet organizacije i informatike**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:211:931278

Rights / Prava: Attribution-NonCommercial-NoDerivs 3.0 Unported/Imenovanje-Nekomercijalno-Bez prerada 3.0

Download date / Datum preuzimanja: **2024-03-29**

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
VARAŽDIN

Repository / Repozitorij:

Faculty of Organization and Informatics - Digital Repository

zir.nsk.hr

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
V A R A Ž D I N

Domagoj Andlar

Klasifikacija biljaka prema karakteristikama lista

SEMINARSKI RAD

Varaždin, 2018.

SVEUČILIŠTE U ZAGREBU

FAKULTET ORGANIZACIJE I INFORMATIKE

V A R A Ž D I N

Domagoj Andlar

Matični broj: 42821/14–R

Studij: Informacijski sustavi

Klasifikacija biljaka prema karakteristikama lista

SEMINARSKI RAD

Mentor:

Doc.dr.sc. Petra Grd

Varaždin, rujan 2018.

Sadržaj

1. Uvod 1
2. Građa lista i razlike među listovima 2
2.1. Baza lista 2
2.2. Palistići 2
2.3. Peteljka 3
2.4. Plojka 3
2.5. Obilježja listova 4
2.5.1. Trajnost 4
2.5.2. Raspored, poredak, listored ili filotaksija 4
2.5.2.1. Razdijeljenost (rasčlanjenost) lista 6
2.5.2.2. Oblik plojke 9
2.5.2.3. Rub plojke 11
2.5.2.4. Vrh plojke 12
2.5.2.5. Osnova plojke 13
2.5.2.6. Oblik peteljke 14
2.5.3. Nervatura 15
3. Znanstveni radovi 17
4. Digitalna obrada slike 19
4.1. Slika 19
4.2. Konverzija u nijanse sive (grayscale) 20
4.3. Pretvorba u crno-bijelu sliku 20
4.4. Detekcija ruba 21
4.4.1. Prewitt detektor 21
4.5. Pronalaženje kutova 22
5. Neuronska mreža 23
5.1. Biološki neuron 23
5.2. Umjetni neuron 23
5.3. Umjetna neuronska mreža 25
5.4. Učenje 26
5.5. Algoritam širenjem unazad (backpropagation) 26
6. Implementacija aplikacije 28
6.1. Rad aplikacije 28
6.2. Procesiranje slike 32
6.3. Neuronska mreža 33

6.3.1. Transfer funkcije 33
6.3.2. Backpropagation Network 33
6.4. NetworkTrainer 33
6.4.1. DataPoint 33
6.4.2. DataSet 33
6.4.3. Permutator 33
6.4.4. NetworkTrainer 34
7. Zaključak 35
8. Popis slika 36
9. Literatura 37

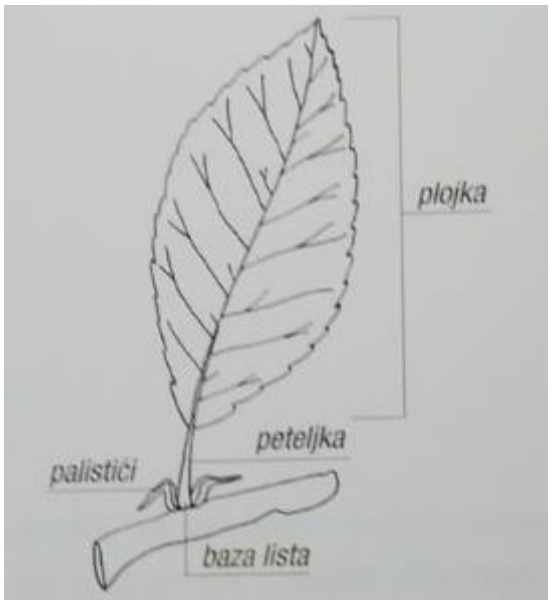
1. Uvod

Svaka biljka ima jedinstvene karakteristike lista, te je na temelju tih karakteristika moguće odrediti o kojoj vrsti biljke je riječ. Jedna takva karakteristika je i oblik lista, tj. obrub. Obrub lista može biti gladak, nazubljen, dvostruko nazubljen, vrh lista može biti zaobljen ili šiljast. Ta karakteristiku da svaka biljka ima jedinstven obrub lista bit će iskorištena za izradu ovog rada.

Ovaj rad se sastoji od dva dijela: teorijskog i praktičnog. Aplikacija se sastoji od dva osnovna dijela, to su digitalna obrada slike koja služi da se prvo dobije obrub lista, a onda i tokeni koji će biti proslijeđeni drugom dijelu aplikacije koji je neuronska mreža koja ima zadaću na osnovu tih tokena odrediti o kojoj je vrsti riječ. Zbog toga će u teorijskom dijelu biti objašnjeno što je to digitalna obrade slike i bit će spomenute neke osnovne operacije kao što su point operacije i filteri, te će također biti objašnjeno i što je to neuronska mreža, vrste neuronskih mreža, te kako se mreža uči, a posebno će biti objašnjen algoritam širenjem unatrag (backpropagation algoritam) koji će biti korišten u aplikaciji. Bit će dan i pregled znanstvenih radova koji imaju istu temu da bi se prikazali i drugi načini klasifikacije listova. U praktičnom dijelu će biti objašnjeno kako radi aplikacija, te čemu služi koja klasa i što rade njezine metode. Za razvoj aplikacije bit će korišten C# programski jezik, Aforge.NET programski dodatak te neka gotova programska rješenja koja su dostupna na GitHub-u.

2. Građa lista i razlike među listovima

U ovom dijelu će biti opisani dijelovi listova i razlike među listovima. Listovi su najčešće građeni od baze lista, peteljke i plojke. Uz bazu lista mogu biti i palistići koji su specifičnog oblika za pojedine vrste i uglavnom su manji od lista.[19]



Slika 1 Građa lista, [19]

2.1. Baza lista

Još se naziva lisno dno ili podina. Baza lista je najdonji dio lista kojim list prijanja za stabljiku, većinom je je zadebljana, no može biti tako zadebljana da obavija stabljiku. Kod mnogih se listova ne može razlikovati jer potpuno prelazi u peteljku. Nasuprotni listovi mogu imati srasle baze. [19]

2.2. Palistići

Palistići su postrane, većinom sitne, izrasline pri dnu baze. Mogu biti različitog oblika, građe, boje i konzistencije. Mnoge vrste imaju neupadljive palistiće ili oni potpuno nedostaju. Prema građi lista se razlikuju dvije vrste palistića. Prvi su postrani koji se uvijek javljaju u paru, lijevo i desno od baze lista, drugi su pazušni koji su uvijek pojedinačni, te često izgledaju poput kukuljice. Palistići mogu biti preobraženi u trnove , u ljuske pupova, ili rjeđe u vitice. Palističi mogu trajati koliko i list ili otpasti ubrzo nakon razvoja lista, pri čemu na izbojku ostave ožiljak. Trajni palistići ostaju na izbojku i nakon otpadanja lista. [19]

2.3. Peteljka

Peteljka je dio s kojim je plojka pričvršćena na stabljiku. Obično ima istu građu kao i stabljika. Peteljka se nastavlja na lisnu bazu i više ili manje je oštro odvojena o plojke. Može biti različitog oblika i veličine te različito položena prema stabljici. S obzirom na položaj prema stabljici peteljka može biti:

a. Priljubljena: skoro prilegnuta uz stabljiku
b. Uspravna: pod kutom manjim od 45° prema stabljici
c. Odmaknuta: na stabljici stoji pod kutom od 45°
d. Ispružena: za stabljiku pričvršćena pod kutom od 90°

Prema ravnini osi, bez obzira kako je položena prema stabljici, peteljka može biti:

a. Ravna: ravna u odnosu na os
b. Savijena: u odnosu na svoju os nije ravna
c. Zavojita: više puta ovijena

Prema atomskoj građi peteljka može biti jednostrana i dvostrana. Peteljka kod nekih vrsta može nedostajati. Takvi listovi se nazivaju sjedeći. Neke vrste mogu imati list s proširenom i plosnatom peteljkom koja je preuzela funkciju plojke, a plojka nedostajati. Takvi listovi se nazivaju flodij. Peteljke mogu biti preobražene u vitice, s kojih krajem vegetacijskog razdoblja otpadaju samo liske, a vitice ostaju na stabljici. [19]

2.4. Plojka

Plojka je gornji, u većini slučajeva glavni i najveći dio lista pa u svakodnevnom govoru često pod listom se misli na plojku. Plojka je različite veličine, oblika ruba, konzistencije, boje nervature, rasporeda puči… može biti građena on jednog dijela ili više odvojenih dijelova, odnosno liski. Listovi uglavnom imaju plojke s različitom gornjom i donjom stranom. Pri tome je gornja strana tamnije zelena, a s donje strane se nalaze puči. Listovi goji imaju jednaku gornju i donju stranu plojke su uglavnom uspravni, odnosno postavljeni tako da su jednako osvjetljeni s obje strane. [19]

2.5. Obilježja listova

Listovi se mogu razvrstati na mnoge načine, odnosno prema različitim kriterijima, kao što su trajnost, raspored duž izbojaka, pričvršćivanje za izbojak, veličina, oblik, konzistencija, boja, pokrov, nervatura i sl. Navedena obilježja detaljnije su objašnjena u nastavku. [19]

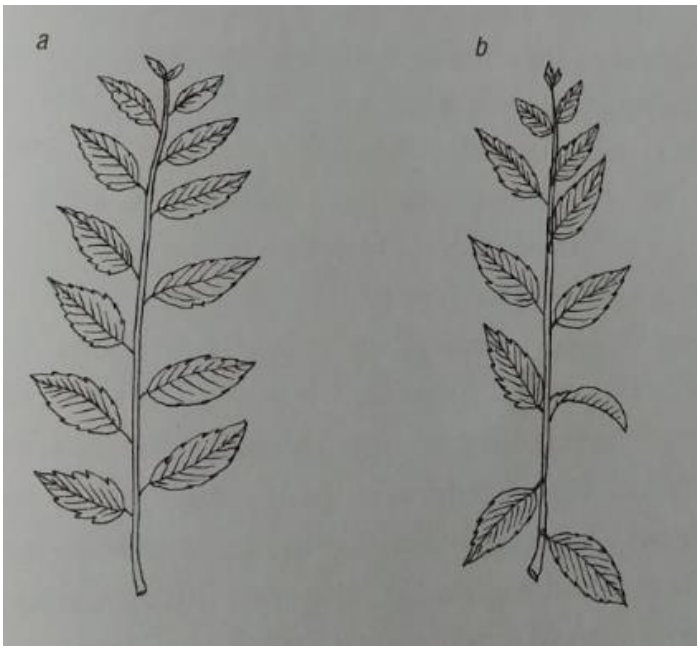
2.5.1. Trajnost

Listovi, u pravilu, imaju ograničeni životni vijek i vrlo rijetko kod višegodišnjih, drvenastih biljaka isti listovi ostaju za vrijeme cijelog života biljke. S obzirom na trajanje listovi mogu biti[19]:

a. Vazdazeleni: otpadaju nakon više, najmanje dva, vegetacijska razdoblja, nikad svi odjednom, već tijekom cijele godine otpadaju najstariji listovi
b. Zimzeleni: otpadaju početkom drugog vegetacijskog razdoblja, za vrijeme razvoja novih listova
c. Listopadni: otpadaju nakon završetka prvog vegetacijskog razdoblja, odnosno u jesen svake godine, do početka sljedećeg vegetacijskog razdoblja izbojci su bez listova
d. Otpadajući: listovi traju manje od jednog vegetacijskog razdoblja, odnosno otpadaju vrlo rano, još tijekom ljeta

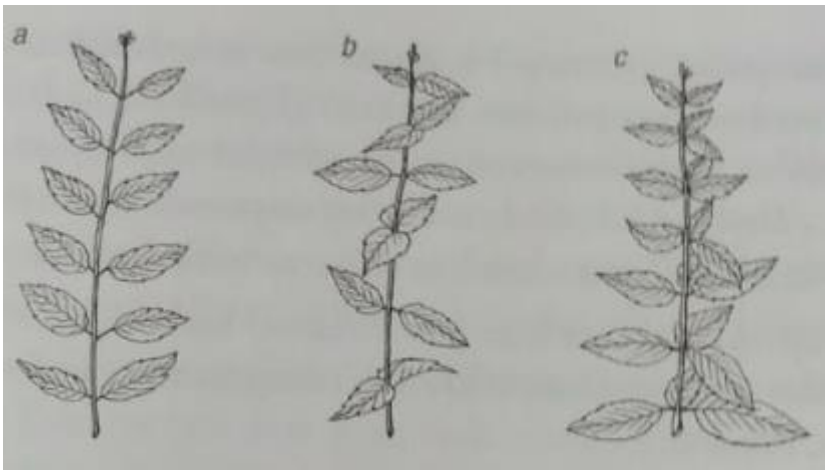
2.5.2. Raspored, poredak, listored ili filotaksija

Listovi su na stabljici poredani točno u određenom redu, te uje taj poredak specifičan za svaku vrstu. U svakom koljencu može biti jedan ili više listova pa prema tome postoje dva rasporeda: naizmjenični ili izmjenični i pršljenasti. Raspored je naizmjenični ako je u svakom koljencu smješten jedan list. Kod naizmjeničnih listova razlikuju se dvoredni i zavojiti raspored.



Slika 2 Naizmjenični raspored listova: a dvoredni, b zavojiti, [19]

Raspored je pršljenast nalazi više listova. Najčešći je dvostruki pršljen, odnosno nasuprotni raspored kod kojega se u jedno koljencu nalazi dva lista jedan nasuprot drugome. Nasuprotni listovi mogu biti raspoređeni dvoredno, odnosno u dva niza koji su međusobno usporedni, na suprotnim stranama izbojka. Često je nasuprotni raspored unakrsno nasuprotan, kod kojega je jedan par listova pomaknut 90% u odnosu na susjedni gornji i donji par. Rjeđe su u jednom koljencu smještena tri ili više listova. [19]

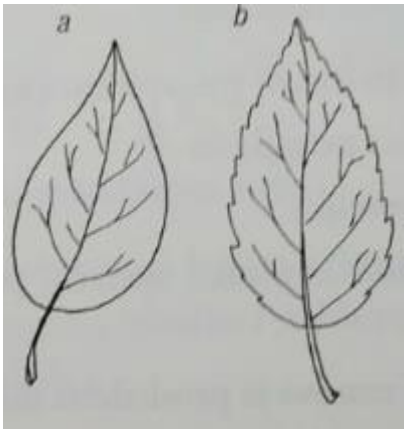


Slika 3 Pršljenasti raspored listova: a nasuprotni, b unakrsno nasuprotni, c tri lista u pršljenu, [19]

2.5.2.1. Razdijeljenost (rasčlanjenost) lista

Prema razdijeljenosti razlikuju se jednostavni i sastavljeni listovi. List je jednostavan ako peteljka nosi samo jednu plojku, a ako peteljke nema, list je sjedeći i sastoji se samo od jedne plojke. Jednostavni listovi mogu biti:

a. Cjeloviti: plojka nije urezana, a ako urezi postoje oni su plitki i ne sežu u plojku dublje od četvrtine



Slika 4 Cjeloviti jednostavni listovi: a cijelog ruba, b napiljenog ruba, [19]

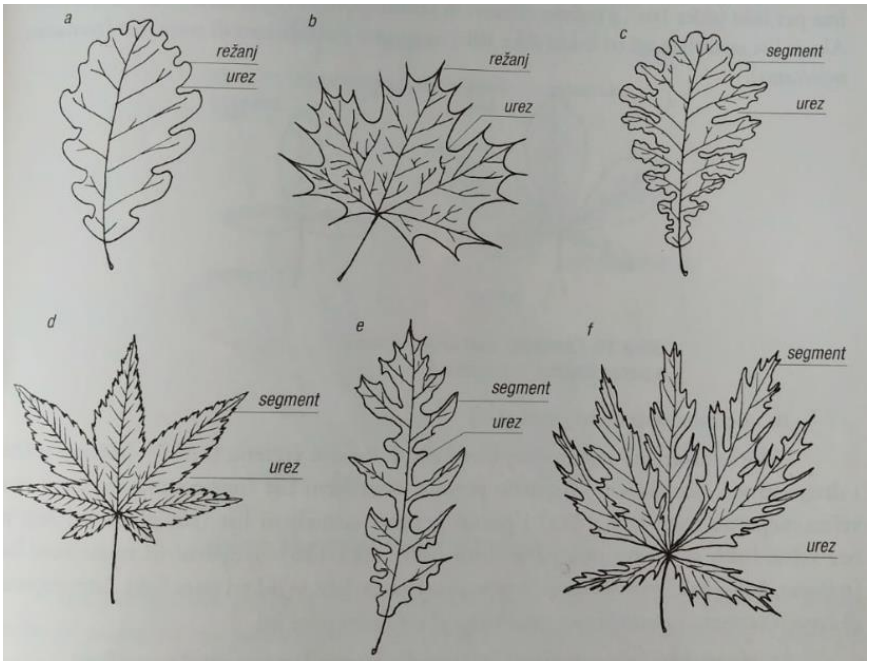
b. Urezani: plojka je urezana

Prema dubini ureza listovi mogu biti:

a. Režnjasti ili krpasti
b. Razdijeljeni
c. Rascijepani

Postoje dva tipa režnjastih listova: perasto režnjaste listove i dlanasto režnjaste listove. Perasto režanjski listovi imaju ureze najviše do polovice poluploke. Plojka je urezana tako da su režnjevi, dio lista između dvaju ureza, perasto poredani, duž cijelog ruba i usmjereni prema srednjoj žili, i nervatura je perasta. Dlanasto režanjski listovi imaju ureze do polovice plojke, te su urezi dlanasto poredani, nervatura je dlanasta, žile teku u vrhove režnjeva, urez se nalazi između dvaju žila. Razlikuju se dva tipa razdijeljenih listova: perasto razdijeljeni listovi i dlanasto razdijeljeni listovi. Kod razdijeljenih listova plojka je urezana dublje od polovice, ali kod perasto razdijeljenih listova urezi ne dopiru do srednje žile, odnosno kod dlanasto razdijeljenih listova ne dopiru do osnove plojke. Dio između dvaju ureza naziva se segment. Kod perasto razdijeljenih listova plojka je urezana tako da su segmenti perasto poredani, usmjereni prema srednjoj žili i nervatura je perasta. Kod dlanasto razdijeljenih listova plojka je urezana tako da su segmenti dlanasto poredani , a urezi usmjereni prema osnovi plojke. Kod rascijepanih listova urezi dopiru do srednje žile (kod perasto rascijepanih), odnosno gotovo do

osnove plojke (kod dlanasto rascijepanih listova), oštri su i linearni. Segmenti su nježni i tanki. Kod perasto rascijepanih listova plojka je poprečno rascijepana tako da su segmenti perasto poredani. Kod dlanasto rascijepanih listova plojka je rascijepana tako da su segmenti dlanasto poredani.



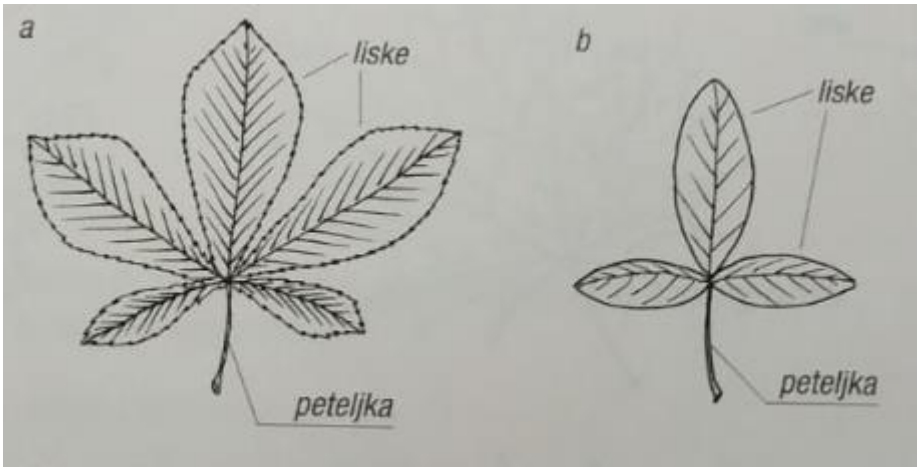
Slika 5 Urezani jednostavni listovi: a perasto režnjasti, b dlanasto režnjasti, c perasto razdijeljeni, d dlanasto razdijeljni, e perasto rascijepani, d dlanasto rascijepani, [19]

Režnjasti, razdijeljeni i rascijepani nadalje mogu biti podijeljeni u prema broju režnjeva ili segmenata. Dvorežanjski, dvodijelni i dvocjpni listovi imaju dva režnja, odnosno segmenta, koji se oblikuju prema dubini ureza. Trorežnjasti, trodijelni i trocjepni listovi imaju tri režnja, odnosno segmenta koji se razlikuju po dubini ureza.

List je sastavljen ako se više plojki nalazi na zajedničkom vretenu ili lisnoj osi. Jedna plojka sastavljenog lista naziva se liska. Svaka liska je je sjedeća ili je peteljčicom prirasla za lisnu os. Sastavljeni listovi mogu biti:

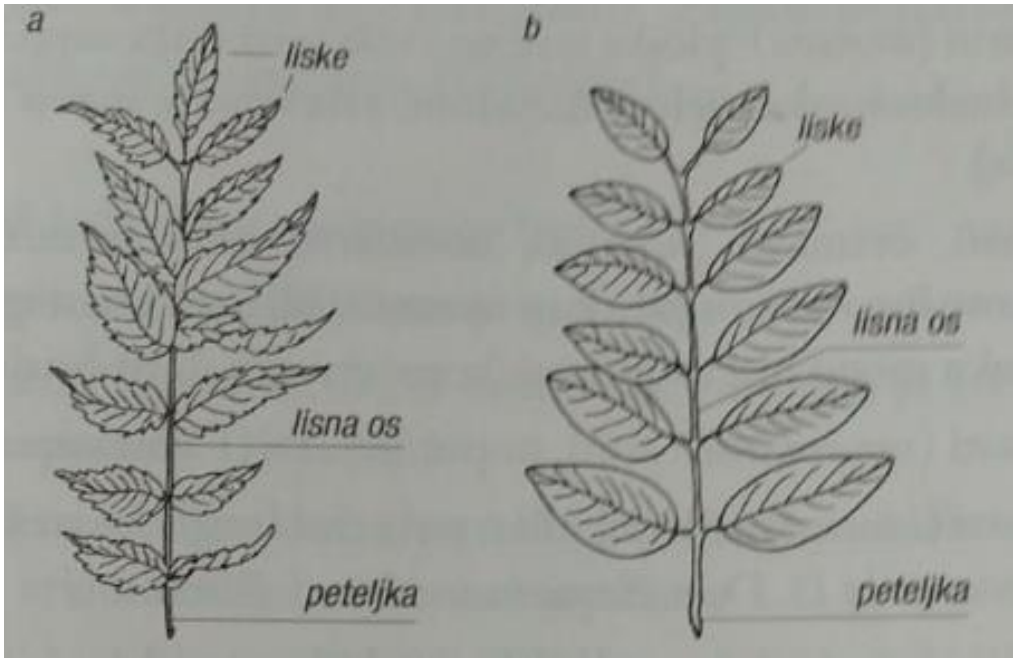
a. Dlanasto ili prstato sastavljeni
b. Perasto sastavljeni
c. Dvostruko ili višestruko sastavljeni

Kod dlanasto ili prstato sastavljenih listova liske polaze iz jedne točke, odnosno zrakasto se šire od vrha zajedničke peteljke. Dlanasto sastavljen list može imati pet liski pa se naziva peterolikavi ili peterobrojni sastavljeni lis, može imati sedam liski pa se naziva sedmeroliskavi ili sedmerobrojni sastavljeni list i može imati tri liske pa se naziva troliskavi ili trojni list.

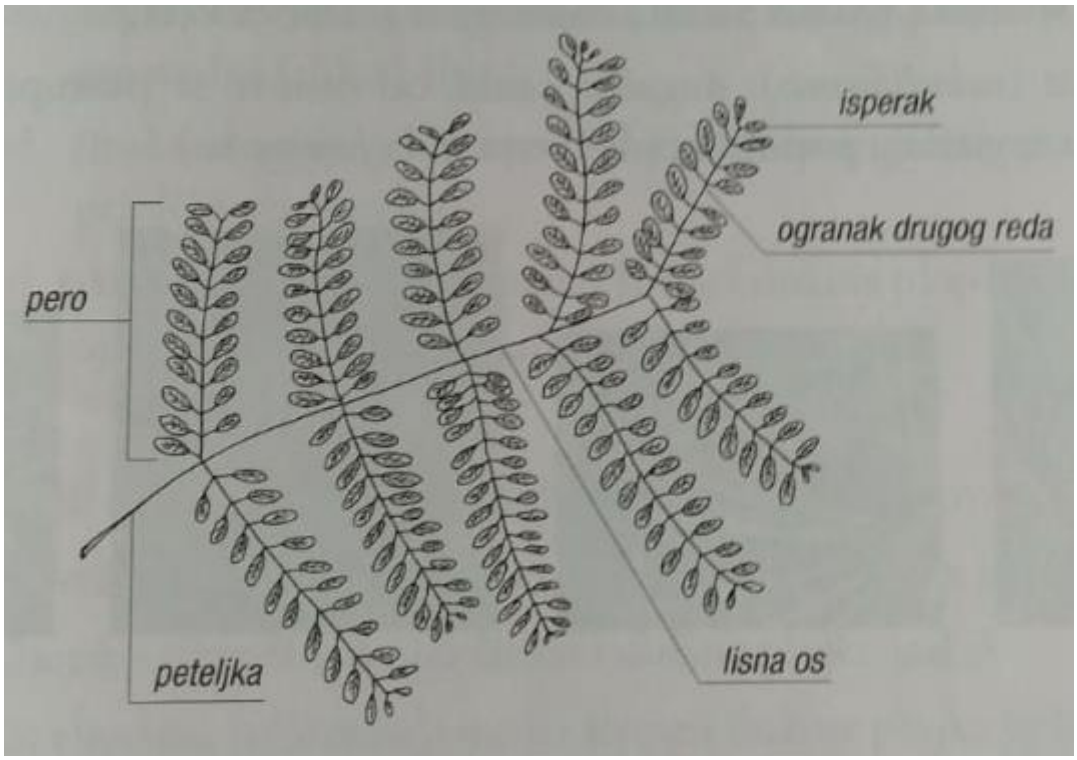


Slika 6 Dlanasto sastavljeni listovi: a peteroliskavi, b troliskavi, [19]

Kod perasto sastavljenih listova liske se nalaze na zajedničkoj lisnoj osi ili lisnom vretenu, bočno s jedne i druge strane. Razlikuju se neparno perasto sastavljeni list koji ima vršnu, neparnu lisku, i parno perasto sastavljeni list koji nema vršnu lisku. Kod dvostruko ili višestruko sastavljenih listova svaka liska naziva se isperak, a cijeli ogranak s ispercima naziva se pero. [19]



Slika 7 Perasto sastavljeni listovi: a neparno, b parno, [19]



Slika 8 Dvostruko perasto sastavljeni list, [19]

2.5.2.2. Oblik plojke

Po obliku plojke bitnu su različiti listovi golosjemenjača i kritosjemenjača. Listovi golosjemenjača mogu biti[19]:

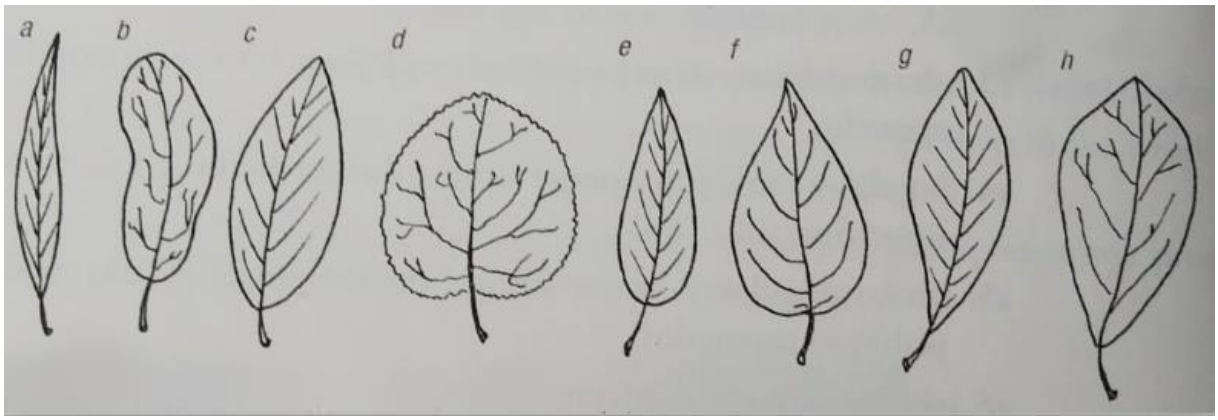
a. Linearni: plojka deset ili više puta duža nego široka, uglavnom je jednako široka cijelom dužinom, a na vrhu se sužuje
b. Igličasti, četinasti: općeniti pojam za linearne listove četinjača koji su tanki, šiljasti i slični iglicama
c. Ljuskasti: sitni, poput ljuske
d. Suličasti: nekoliko puta duži nego široki, završavaju šiljasto
e. Dvorežnjasti, dvokrpasti: plojka razrezana na dva režnja
f. Duguljasti: plojka je dva do tri puta duža nego što je široka, a najšira je na sredini
g. Šilasti: dugački, tanki, od osnove se potpuno suzuju prema vrhu, izgledaju poput šila

Posebni oblici golosjemenjača[19]:

a. Dvostruka iglica: dvije iglice srasle duž jednog ruba
b. Filokladij: listoliki, često rombični kratki izbojci koji su smješteni u pazušcu sitnih ljuskastih listova
c. Tuljčast: poput tuljca

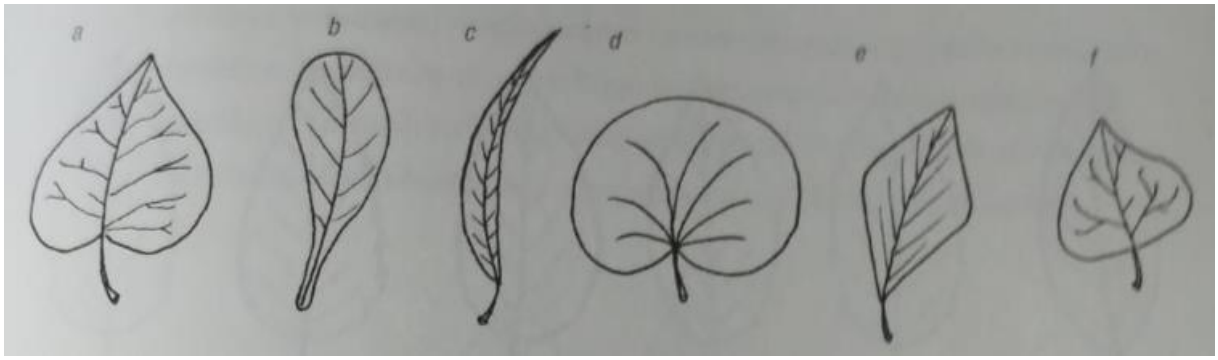
Listovi drvenastih kritosjemenjača mogu biti[19]:

a. Duguljasti: rubovi teku više ili manje usporedno, vrh i osnova su zaobljeni
    1. Linearni: omjer širine i duljine plojke je 1:12 ili više, rubovi su usporedni
    2. Remenasti ili trakasti: omjer širine i duljine je 1:6 do 1:8, vrh je zaobljen, osnova nije sužena
    3. Usko duguljasti: omjer širine i duljine plojke je 1:3, rubovi su približno usporedni
    4. Duguljasti: omjer širine i duljine plojke je 1:2, rubovi su usporedni
    5. Široko duguljasti: omjer širine i duljine plojke je 2:3, rubovi su približno usporedni
    6. Jako široko duguljasti: omjer širine i duljine plojke je 5:6, u sredini su najširi, vrh i osnova su zaobljeni
b. Eliptični ili ovalni: najširi su u sredini dužine, vrh i osnova su šiljasti
    1. Vrlo usko eliptični: omjer širine i duljine plojke je 1:6
    2. Usko eliptični: omjer širine i duljine plojke je 1:3
    3. Eliptični: omjer širine i duljine plojke je 1:2
    4. Široko eliptični, ovalni: omjer širine i duljine plojke je 2:3
    5. Okruglasti: omjer širine i duljine plojke je 5:6
    6. Okrugli: omjer širine i duljine plojke je 1:1
    7. Sferoidni: omjer širine i duljine plojke je 4:3
c. Jajasti: najširi su u donjoj polovici, osnova je zaobljena, vrh većinom šiljast
    1. Usko suličasti: omjer širine i duljine plojke je 1:6
    2. Usko suličasti: omjer širine i dužine plojke je 1:3
    3. Usko jajasti: omjer širine i duljine plojke je 1:2
    4. Jajasti: omjer širine i duljine plojke je 2:3
    5. Široko jajasti: omjer širine i duljine plojke je 5:6
    6. Jako široko jajasti: omjer širine i duljine plojke je 1:1
d. Obrnuto jajasti: najširi su u gornjoj polovici, vrh je zaobljen, osnova je sužena
    1. Usko obrnuti suličasti: omjer širine i duljine plojke je 1:6
    2. Obrnuto suličasti: omjer širine i duljine plojke je 1:3
    3. Usko obrnuti jajasti: omjer širine i duljine plojke je 1:2
    4. Obrnuto jajasti: omjer širine i duljine plojke je 2:3
    5. Široko obrnuto jajasti: omjer širine i duljine plojke je 5:6
    6. Jako široko obrnuto jajasti: omjer širine i duljine plojke je 1:1



Slika 9 Oblik listova kritosjemenjača: a linearni, b duguljasti, c eliptični, d okrugli, e suličasti, f jajasti, g obrnuto suličasti, h obrnuto jajasti, [19]

e. Posebni oblici listova:
    1. Srcasti: plojka prema vrhu postupnu sužena i šiljasta, na osnovi zaobljena, sa srcastim urezom
    2. Lopatasti: plojka je duža od svoje širine, vrh je široko zaobljen, osnova sužena
    3. Srpasti: plojka je srpasto zakrivljena, peteljka je na jednom od vrhova
    4. Bubrežasti: plojka je šira od svoje dužine, na osnovi je urezana
    5. Rombični, kosočetvorni: ovalni, malo uglasti u najširem dijelu
    6. Deltasti: plojka ima oblik grčkog slova delta



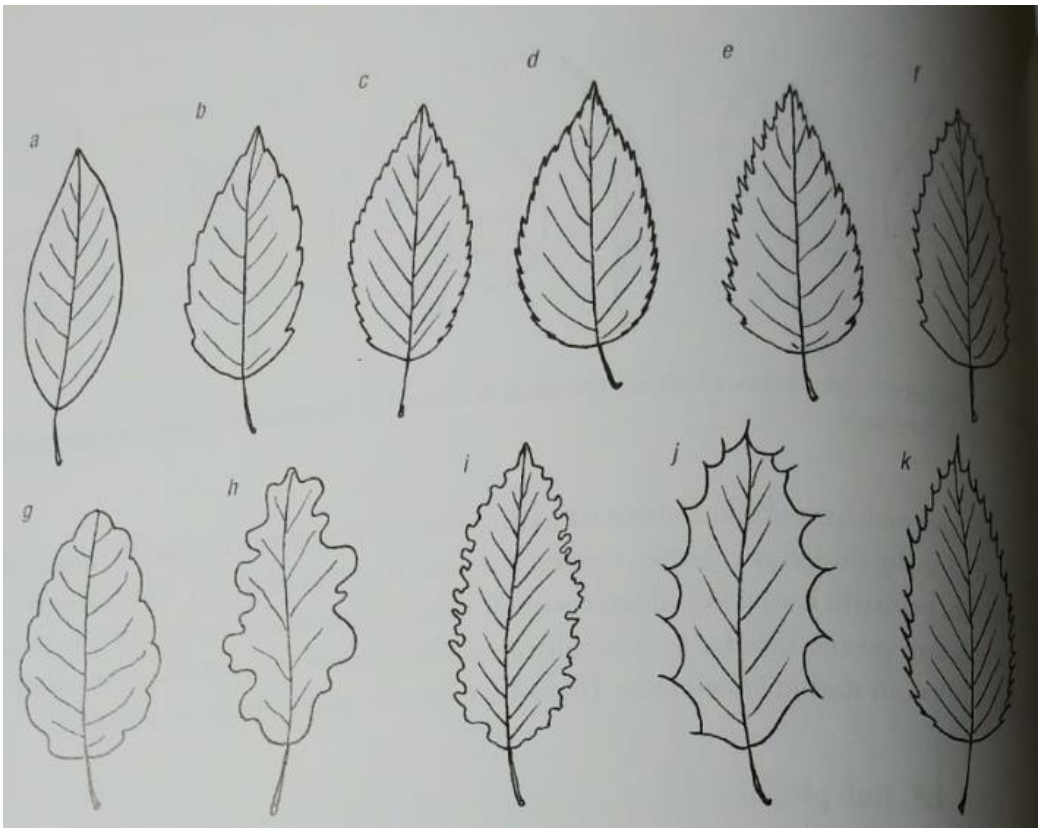
Slika 10 Posebni oblici kritosjemenjača: a srcasti, b lopatasti, c srpasti, d bubrežasti, e rombični, f deltasti, [19]

2.5.2.3. Rub plojke

Rub plojke može biti cijeli ili plitko urezan. Prema urezima i zupcima rub može biti[19]:

a. Napiljen, pilast: zupci i urezi su šiljasti, zupci su savijeni i prema vrhu lista usmjereni
b. Fino napiljen, piličast: zupci i urezi su šiljasti, zupci su vrlo sitni i brojni
c. Urezano napiljen: zupci su dugački, oštri, urezi su barem tri puta duži od širine osnove zupca

d. Dvostruko napiljen: rub je krupno napiljen, zupci imaju još jedan, dva ili više manjih zubaca
e. Nazubljen, zupčav: zupci stoje ravno, okomito na lisnu plojku, šiljasti su, osnova ureza je zaobljena
f. Narovašen: zupci su zaobljeni, urezi su šiljasti
g. Izverugan: pravilno se izmjenjuju veća udubljena sa zaobljenim ili zupčastim ispupčenjima
h. Valovit, verugast: plitka, zaobljena izbočenja i udubljenja čine valovitu liniju
i. Trnovit: zupci imaju čvrste bodljikave vrhove, ako su vrhovi pri tome posebno dugački rub je osjav



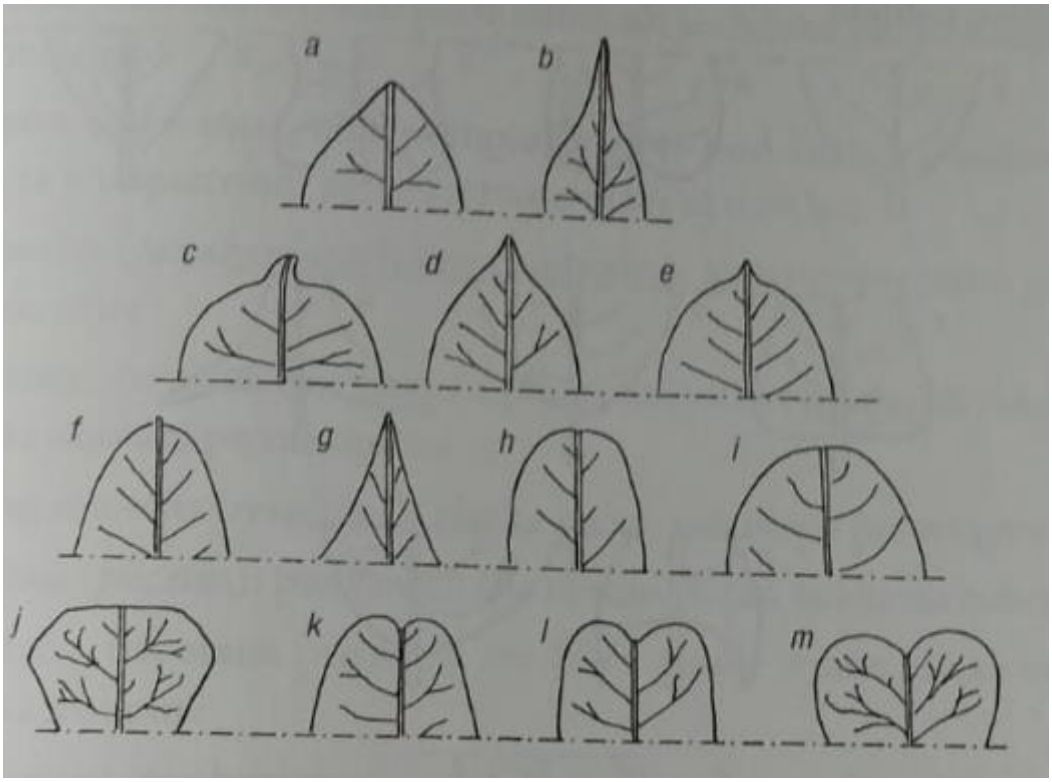
Slika 11 Rub plojke: a cijeli, b napiljen, c fino napiljen d urezano napiljen, e dvostruko napiljen, f nazubljen, g narovašen, h izverugan, i valovit j trnovit, k osjav, [19]

2.5.2.4. Vrh plojke

Vrh plojke može biti[19]:

a. Šiljast: općenito kao suprotan pojam tupom vrhu, rubovi se spajaju pod kutom manjim od 90°, vrh nije izdužen
b. Ušiljen: vrh naglo prelazi u više ili manje produženo suženje koje s obje strane konkavno

c. Šiljkav: s kratkim, finim, oštrim šiljkom na vrhu koji nije završetak srednje žile
d. Dugošiljat, dugošiljav: vrh je dugačko šiljast, završava čvrstim oštrim šiljkom koji je tvrđi od plojke
e. Šiljat, šiljav: naglo šiljast, s malim, kratkim, čvrstim šiljkom koji je nastavak srednje žile i uz koji teku uski dijelovi plojke.
f. Šiljčićav: kao šiljat, ali s manjim, finijim šiljkom
g. Bodljikav: postupno sužen u čvrsti, oštri, bodljikavi vrh
h. Tup. Više ili manje zaobljenog vrha, rubovi se spajaju pod kutom većim od 90°
i. Zaobljen: zaobljeno zatupljen
j. Odrezan: naglo i ravno završava kao da je poprečno odrezan
k. Izrubljen: vrh je blago urezan, urez zatvara kut manji od 90°
l. Uzubljen: na vrhu plitko udubljen ili krnjeg vrha, inače zaobljen
m. Obrnuto srcast: naopako srcast, duboko urezanog vrha



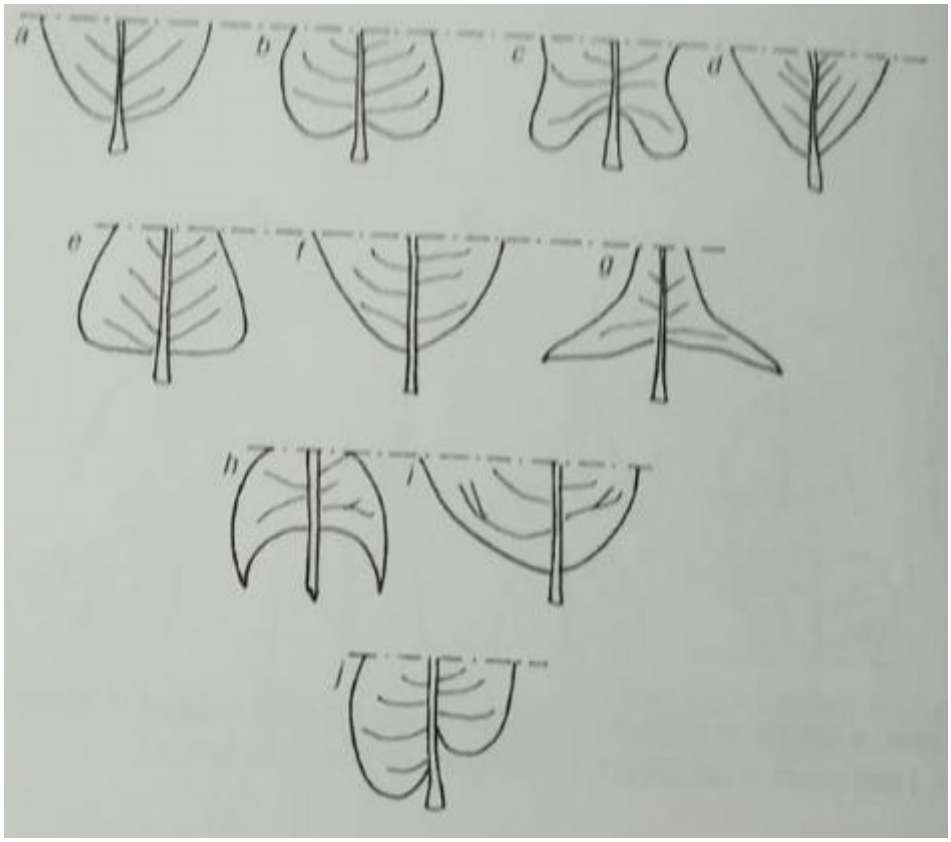
Slika 12 Vrh plojke: a šiljast, b ušiljen, c šiljkav, d dugošiljat, e šiljat, f šiljčav, g bodlikav, h tup, i zaobljen, j odrezan, k izrubljen, l uzubljen, m obrnuto srcast, [19]

2.5.2.5. Osnova plojke

Opis osnove plojke definira kakva je plojka u donjem dijelu gdje prelazi u peteljku ili je kao kod sjedećih listova, pričvršćena za stabljiku. Osnova plojke može biti[19]:

a. Okruglasta: obje polovice plojke su polukružne

b. Srcasta: polukružna, sa srcastim urezom na dnu kojega je peteljka
c. Uškava: kao srcasta, ali su obje polovice plojke dugačko izvučene i postrano otklonjene, poput uški
d. Klinasta: rubovi poluplojki su ravni, sužavaju se od sredine do osnove
e. Odrezana: donji dio je ravan kao poprečno odrezan
f. Tupa: rubovi obiju poluplojki sastaju se pod tupim ili pravim kutom, rubovi su savijeni
g. Kopljasta: osnova je trokutasto udubljena, dva izbočena šiljasta režnja su prema van, više ili manje pod pravim kutom od peteljke otklonjena
h. Streličasta: kao srcasta ali su obje polovice plojke dugačko izvučene, šiljaste i prema dolje usmjerene
i. Asimetrična: poluplojke su nejednako velike, ne preklapaju se
j. Kosa: jedna poluplojka na osnovi niže pada od druge, a inače su gotovo jednake



Slika 13 Osnova plojke: a okruglasta, b srcasta, c uškava, d klinasta, e odrezana, f tupa, g kopljasta, h streličasta, i asimetrična, j kosa, [19]

2.5.2.6. Oblik peteljke

Prema obliku peteljka može biti[19]:

a. Oblovaljkasta: na poprečnom prerezu okrugla

b. Valjkasta: na poprečnom prerezu okruglasta
c. Plosnata: plosnata u trbušno-leđnom smjeru
d. Spljoštena: plosnata u bočnom smjeru
e. Bridasta: na poprečnom prerezu trobidasta do višebridasta
f. Žljebasta: s gornje strane ulegnuta poput žljeba
g. Krilata, okriljena: bočne strane obrubljlene lisnim staničjem

Prema duljini peteljka može biti[19]:

a. Kratka: duljina ne prelazi 2/3 duljinu plojke
b. Srednja: jednako duga kao i plojka
c. Duga: duža od plojke
d. Izdužena: višestruko duža od plojke

Prema debljini peteljka može biti[19]:

a. Tanka: promjer je najmanje deset puta manji od njezine duljine
b. Debela: promjer je veći od desetine njezine dužine

2.5.3. Nervatura

Nervatura je skup žila koje teku kroz list, odnosno žilni sustav. Osim provodne funkcije žile daju listu i čvrstoću. Debele žile nazivaju se i rebra, na donjoj strani su plojke se vide kao izbočenja, a na gornjoj kao udubljenja. Prema načinu razgranjena postoje tri osnovna tipa nervature[19]:

a. Viličasta: žile se pravilno granaju, nema glavne žile, a ogranci slobodno završavaju , odnosno nisu povezani
b. Paralelna: žile teku usporedno cijelom dužinom lista, od osnove do vrha, međusobno su povezane vrlo sitnim poprečnim žilama
c. Mrežasta: žile se granju od jedne ili više glavnih žila na sve finije žilice, a cijelo razgranjenje izgleda kao mreža
    1. Perasto mrežasta: list ima jednu glavnu žilu od koje granaju druge žile
    2. Dlanasto mrežasta: od osnove plojke razdvaja se više glavnih žila koje se zrakasto šire prema rubu lista, a ostale žile se granaju od njih

Prema tome kako teku postrane žile nervatura može biti[19]:

a. Rubohodna, kraspedodromna: žile drugog reda teku do ruba plojke
b. Kamptodromna: žile drugog reda teku lučno, ali ne dopiru do ruba plojke

c. Akrodromna: žile drugog reda ne dopiru do ruba plojke, već se lučno svijaju prema vrhu, gdje se skupljaju
d. Brohidodromna: žile drugog reda do ruba lista teku više ili manje ravno ili lučno, ali prije samog ruba tvore petlju, tako što se donja žila u luku savija prema gornjoj i sa njom spaja
e. Diktiodromna: žile drugog reda ne dopiru do ruba plojke već se više puta granaju i međusobno spajaju

3. Znanstveni radovi

U ovom dijelu je dan osvrt na neke znanstvene radove s temom klasifikacije biljaka na temelju karakteristike lista. Prvi rad je „A Leaf Recognition Algorithm for Plant Classification Using Probabilistic Neural Network“ iz 2007. Ideja projekta je bila ideja da naprave bazu podataka biljaka zbog toga što su mnoge korisne i ljekovite biljke u opasnosti od izumiranja. Sustav bi trebao automatski prepoznavati biljke na temelju 12 svojstava lista izvedenih iz 5 svojstava, te su ta svojstva proslijeđena probalističkoj neuronskoj mreži. Rezolucija svi slika je 800x600 piksela. Prva faza sustava je digitalna obrada slike. Slika u boji je prvo pretvorena u sliku u nijansama sive (grayscale slika) po formuli

$$siva = 0.2989 * R + 0.5870 * G + 0.1140 * B$$

Zatim je slika pretvorena u crno-bijelu sliku, a prag je određen na temelju histograma slike. Slika je zatim izglađena, te je pronađen rub lista. Nakon što je slika obrađena prvo su izvađena 5 osnovnih svojstava, te je na temelju njih određeno 12 novih pomoću koji je vršena klasifikacija. Za klasifikaciju je korištena probalistička neuronska mreža. Probalistička neuronska mreža je istrenirana sa 1800 listova za klasifikaciju 32 vrste biljaka, te su postigli točnost od 90.312% u prosijeku.[8]

Drugi rad je „Leaf Classification Using Shape, Color, and Texture Features“ iz 2011. U radu su uzete boje, vene i teksturalna svojstva za klasifikaciju lista. Dva tipa svojstava su korištena u radu, a to su geometrijska svojstva i Polar Fourier transformacije. Geometrijska svojstva su tankoća i zaokruženost. Deskriptori izvedeni od Polar Fluerier su invarijante pod akcijama transformacija, skaliranja i rotacije. Za klasifikaciju je odabrana probalistička neuronska mreža. Mreža kao izlaz daje indeks biljke u bazi. Ova metoda dala je eksperimentalne rezultate točnosti u prosijeku od 93.75% na Flavia skupu podataka sa 32 veste biljka. [9]

Treći rad je „Leaf Shape Identification Based Plant Biometrics“ iz 2010. Ovaj sustav nije u potpunosti autonoman jer korisnik prije digitalne obrade slike mora na listu ručno označiti bazičnu točku lista i nekoliko referentnih točaka na rubu lista. Nakon toga aplikacija može digitalno obraditi sliku i izvaditi svojstva kao što su ekscentričnost, glavna os, sporedna os, promjer te konveksno područje. Vrijednost tih svojstava su zatim proslijeđena probalističkoj neuronskoj mreži za klasifikaciju. Slike u ovom sustavu mogu biti bilo kojeg formata i rezolucije, no u radu su sve slike bile u JPEG formatu i rezolucije 1600x1200 piksela. Mreža je

istrenirana sa 1200 uzoraka od 30 različitih biljaka. Eksperimentalni rezultati su pokazali točnost od 91.41%. [10]

Zadnji rad koji sam obradio je „Classification of Leaf Images“ iz 2006. U radu su korištena svojstva bazirana na regiji zato što su robusnija u odnosu na svojstva bazirana na koturi. Svojstva koja su koristili su omjer lista, kompaktnost, središte te horizontalna i vertikalna projekcija. Listovi su ručno trgati s biljaka , stavljani na bijelu pozadinu, te poslikani digitalnom kamerom. Za klasifikaciju su uzeli algoritam 1-NN pravila i dobili točnost aplikacije od 82.33%. Metoda funkcionira na principu da se prvo odstrane beznačajne biljke. Za to je korištena formula za računanje različitosti između slike koja se ispituje i slika u bazi. Formula za računanje različitosti koristi omjer lista, kompaktnost i središte. Pomoću te formule je odstranjeno 2/3 biljaka iz baze. Zatim je uz pomoć vertikalne i horizontalne projekcije određena pripadnost lista biljci.[11]

4. Digitalna obrada slike

Pojam „digitalna obrada slike“ se na razvoj programskih rješenja koja manipuliraju slikom. Postoje tri tipa procesiranja slike: slika u sliku, slika u informaciju i informacija u sliku. Kod transformacije slika u sliku ulaz je slika, a izlaz je obrađena slika. Koristi se za poboljšanje kvalitete slike, restauraciju slike te promjenu geometrije slike. Kod slika u informaciju ulaz je slika, a izlaz informacija. Koristi se kod statistike slike (histogrami), kompresije slike te analize slike (prepoznavanje uzoraka, ekstrakcija karakterističnih točaka...). Kod informacija u sliku ulaz je informacija, a izlaz slika. Koristi se kod dekompresije slika, računalne grafike, virtualne stvarnosti, animacije te rekonstrukcije dijelova slika iz CT i MRI podataka. Postoje dva područja primjene digitalne obrade slike, prvo poboljšanje slike za ljudsku interpretaciju i drugo procesiranje podataka slike za računalnu percepciju. Danas se digitalna obrada slike koristi u medicini, geografiji, arheologiji, fizici... [1] U ovom radu su korištena dva tipa, prvi je slika u sliku. Taj tip je korišten kod konverzije slike lista prvo u sliku u nijansama sive (grayscale), zatim u binarnu sliku (crno-bijelu), te na kraju da dobivanje samo ruba. Drugi tip je slika u informaciju koji je korišten kod pronalaženja kutova, te sinusa kutova.

4.1. Slika

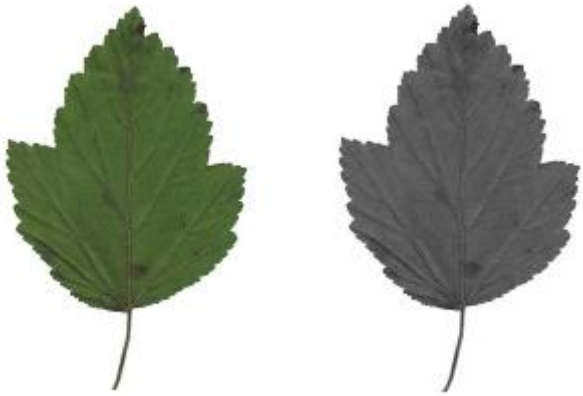
Slika je dvodimenzionalna funkcija inteziteta svijetla f(x,y). Digitalna slika se može promatrati i kao matrica čije kolone i redovi identificiraju točku na slici, piksel. Slika može biti crno-bijela, u nijansama sive (grayscale) ili u boji. Tipična slika u nijansama sive (grayscale) koristi 8-bitova po pikselu što pikselu daje raspon vrijednosti inteziteta od [0, 255], gdje 0 predstavlja minimalnu svjetlinu (crna), a 255 maksimalnu svjetlinu (bijela). Kod binarnih slika (crno – bijelih) piksel je jedan bit (0 ili 1). Slike u boji najčešće koriste RGB kodiranje (red, green, blue). Kod RGB slika piksel sadrži 3 boje te svaki piksel zauzima 3x8=24 bita, te se može prikazati 16,7 milijuna boja. Za ispis se najčešće koristi CMYK model (cyan, magenta, yellow, key). Formati slika se dijele u dvije grupe: rasterske i vektorske. Rasterske slike su slike s pikselima u matrici i koristi diskretne koordinate. Vektorske slike prikazuju geometrijske objekte korištenjem kontinuiranih koordinata, koje se rasteriziraju kada ih je potrebno prikazati na fizičkom uređaju.[1][2][16]

4.2. Konverzija u nijanse sive (grayscale)

Konverzija RGB slike u sliku u nijansama sive (grayscale) najjednostavnije se računa kao srednja vrijednost komponenti boja: $Y = (R + G + B)/3$. Pošto crvenu i zelenu smatramo svjetlijom bojom od plave dobivena slika će biti pretamna u području zelene i crvene, a presvijetla u području plave. Rješenje za to je izračunavanje težinske sume komponenti boja:

$$Y = Lum(R, G, B) = w_R * R + w_G * G + w_B * B$$

Preporučene vrijednosti težina su: $w_R = 0.2125$, $w_G = 0.7154$, $w_B = 0.072$. [2]



Slika 14 Konverzija u nijanse sive (grayscale)

4.3. Pretvorba u crno-bijelu sliku

Nakon što je dobiven list u sivoj nijansi boje na bijeloj pozadini ili nekoj drugoj pozadini sa dovoljno velikim kontrastom u odnosu na boju lista slika se može pretvoriti u crno-bijelu. Prag pretvorbe se obično određuje pomoću histograma na način da se napravi histogram slike u nijansama sive. Takav histogram ima dva veća vrha, jedan je za boju lista, a drugi za boju pozadine. Između ta dva vrha se pronađe točka sa najmanjom vrijednošću, te se ta točka uzme kao prag. Zatim se na slici u nijansama sive svi pikseli sa vrijednošću manjom od praga pretvore u crnu boju, a pikseli sa većom vrijednosti od praga pretvore u bijelu boju. [8]



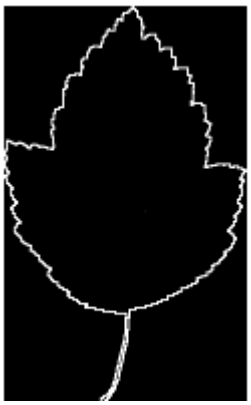
Slika 15 Crno-bijela slika lista

4.4. Detekcija ruba

Rubovi su lokacije na slici gdje postoji nagla varijacija u intezitetu ili boji susjednih piksela. U slici sa smetnjama tehnike za detekciju ruba ne bi smjele detektirati smetnje na slici. Najčešće postoje tri koraka za detekciju ruba :

- Redukcija smetnji – pokušava maknuti što više smetnji bez izglađivanja rubova
- Poboljšanje ruba – primjena filtera koji je snažan na rubovima, a slab na ostalim dijelovima slike, tako da se rubovi mogu identificirati kao lokalni maksimum na izlazu filtera
- Lokalizacija ruba - odlučuje se koji lokalni maksimum izlaza filtera je značajan rub, a koji je uzrokovan smetnjama

Najjednostavniji detektori rade minimalno izglađivanje smetni te jednostavnu lokalizaciju, te se primjenjuju na slikama u nijansama sive[3].



Slika 16 Rub lista

4.4.1. Prewitt detektor

Prewitt detektor je jedan od najpopularnijih 3x3 detektora ruba. Radi na principu da izračunava gradijent kao par konvolucijskih operacija [3]:

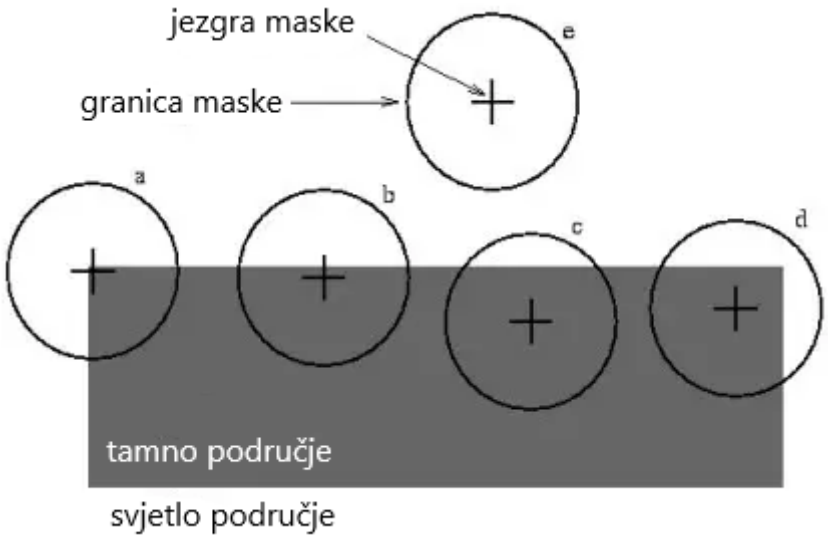
$$G_x(x,y) = h_x * f(x,y)$$
$$G_y(x,y) = h_y * f(x,y)$$

gdje su h_x i h_y jednaki[3]:

$$h_x = \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix}$$
$$h_y = \begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix}$$

4.5. Pronalaženje kutova

Da bi bilo moguće izračunati sinuse kutova, prvo treba pronaći kutove. U ovom radu detekcija kutova je obavljena pomoću SUSAN (Smallest Univalue Segment Assimilating Nucleus) principa za detekciju kutova. SESAN detektor je realiziran pomoću krušne maske. Ako se svjetlina svakog piksela u maski usporedi sa jezgrom te maske, tada se može definirati područje maske koje ima istu ili sličnu svjetlinu kao jezgra [18].

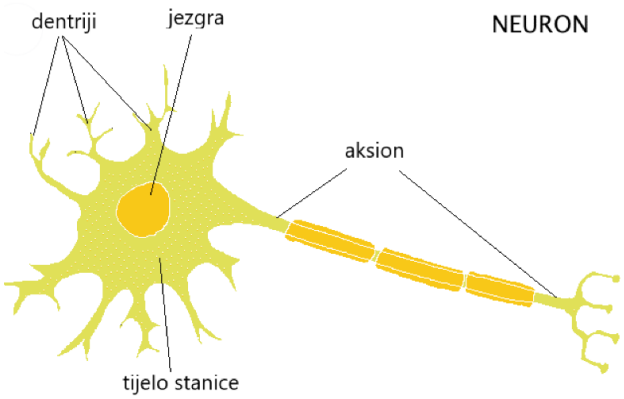


Slika 17 SUSAN detektor, [18]

5. Neuronska mreža

5.1. Biološki neuron

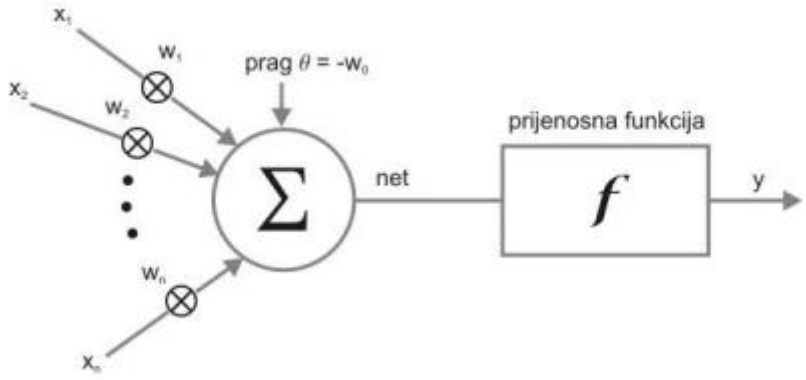
Neuron je osnovni element neuronske mreže. Sastoji se od dentrita, tijela stanice (soma) i aksona. Tijelo stanice sadrži jezgru koja sadrži genetski materijal u obliku hromozona. Dentriji su kraći produžeci koji primaju kemijske signale od drugih neurona. Akson je duži produžetak koji služi za prijenos elektro-kemijskog signala drugim neuronima. Između dvaju neurona je sinapsa, praznine preko koje se prenosi signal.[12]



Slika 18 Biološki neuron, [12]

5.2. Umjetni neuron

Umjetni neuron je matematička funkcija osmišljena kao model biološkog neurona. On je osnovna jedinica umjetnih neuronskih mreža. Umjetni neuron prima jedan ili više signala s neurona iz prethodnog sloja i njihovu sumu šalje na neuronima u sljedećem sloju. Vrijednost neurona iz prethodnog sloja se množi s težinom veze između njega te neurona u trenutnom sloju, sve ulazne vrijednosti se pomnože te se suma pusti kroz funkciju transformacije i pošalje na izlaz.



Slika 19 Umjetni neuron, [4]

Izlaz neurona najčešće je između 0 i 1 ili -1 i 1. Funkcija transformacije je obično sigmoidna funkcija, ali može biti i neka druga ne linearna funkcija. Tri najčešće funkcije transformacije su [7]:

- Sigmoidna funkcija – primjer sigmoidne funkcije je tangens hiperpolni, funkcija obično poprima vrijednosti između 0 i 1, a ponekad i između -1 i 1

$$\varphi(v) = \tanh\left(\frac{v}{2}\right) = \frac{1 - \exp(-v)}{1 + \exp(-v)}$$

- Funkcija praga – funkcija ima određen prag aktivacije, te ukoliko je suma veća ili jednaka od tog praga, vrijednost se prosljeđuje dalje, ukoliko je manja ne događa se ništa

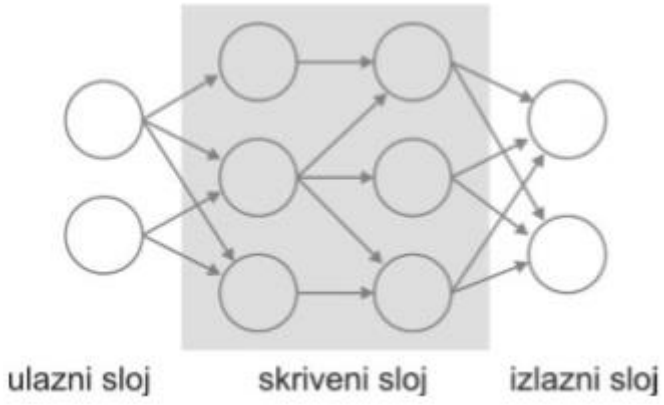
$$\varphi(v) = \begin{cases} 1\ ako\ je\ v \geq 0 \\ 0\ ako\ je\ v < 0 \end{cases}$$

- Funkcija linearnih segmenata – funkcija je slična funkciji praga samo što umjesto dva stanja izlaza imamo više stanja: 0, 1 i v

$$\varphi(v) = \begin{cases} 1\ ako\ je\ v\ \geq \frac{1}{2} \\ v\ ako\ je - \frac{1}{0} < v < \frac{1}{2} \\ 0\ ako\ je\ v \leq -\frac{1}{2} \end{cases}$$

5.3. Umjetna neuronska mreža

Umjetna neuronska mreža je skup umjetnih neurona koji su međusobno povezani i interaktivni kroz obradu signala. Mreža ima sloj ulaza i sloj izlaza, te može imati jedan ili više skrivenih slojeva koji se nalaze između ulaznog i izlaznog sloja.



Slika 20 Umjetna neuronska mreža, [4]

Ovisno o kriterijima neuronske mreže možemo podijeliti na sljedeće vrste [7]:

- Prema primjeni:
  - Predviđanje
  - Klasifikacija
  - Klasteriranje
  - Aproksimacija funkcije
- Prema tipu veze:
  - Statičke
  - Dinamičke
- Prema topologiji:
  - Jednoslojne
  - Višeslojne
  - Samo-organizirajuće
- Prema metodama učenja:
  - Nadgledano učenje
  - Nenadgledano učenje

Glavne primjene neuronskih mreža su u sljedećim područjima[7]:

- Klasteriranje

- Koristi se u kompresiji podataka i rudarenju podataka. Algoritam pronalazi sličnosti između uzoraka i smješta ih u slične razrede.

- Klasifikacija i prepoznavanje uzoraka
  - Koristi se za prepoznavanje specifičnih uzoraka kao primjerice prepoznavanje simbola.
- Aproksimacija funkcije
  - Koristi se za procjenu nepoznate funkcije $f()$.
- Predviđanje
  - Prognozira karakteristične vrijednosti podataka dobivenih u vremenu. Takvi sustavi imaju veliki utjecaj na sustave za donošenje odluka.

5.4. Učenje

Jedno od najvažnijih svojstva neuronskih mreža je sposobnost učenja. Postoje tri osnovne paradigme učenja neuronskih mreža[5]:

- Učenje pod nadzorom
  - Glavna karakteristika je prisutnost vanjskog učitelja, učitelj ima znanje o okolini u obliku parova ulaz – izlaz, učenje se vrši sve dok mreža ne nauči imitirati učitelja
- Učenje podrškom
  - Učenje podrškom je on-line karaktera, kroz proces pokušaja i pogreške uči se ulazno-izlazno preslikavanje, učitelj samo određuje koliko je određeni korak dobar
- Učenje bez nadzora
  - Nema učitelja koji upravlja procesom učenja

5.5. Algoritam širenjem unazad (backpropagation)

Učenje algoritmom sa širenjem pogreške unazad (backpropagation algoritam) koristi metodu gradijentnog spusta da bi minimizirao nastalu pogrešku na izlazu mreže nad skupom primjera za učenje. Za dane podatke za učenje t_k i izlaza izlaznog sloja O_k pogreška se izračunava kao:

$$E = \frac{1}{2}\sum_{k \in K}(O_k - t_k)^2$$

Učenje se svodi na pretraživanje minimuma u n-dimenzionalnom prostoru hipoteza gdje je n ukupan broj težina. Površina pogreške E nije parabolična kao kod jednog procesnog elementa, već ima brojne lokalne minimume.[12]

Notacija [12]:

- I je ulazni sloj, J je skriveni sloj, K je izlazni sloj
- x_j^l: ulaz u čvor j sloja l
- W_{ij}^l: težina iz sloja $l-1$ čvor i u sloj l čvor j
- $\sigma(x) = \frac{1}{1+e^{-x}}$: sigmoidna transfer funkcija
- θ_j^l: prag čvora j sloja l
- O_j^l: izlaz čvora j u sloju l
- t_j: ciljana vrijednost čvora j izlaznog sloja

Algoritam širenjem unatrag (backpropagation)[17]:

1. Pokrenemo mrežu prvo sa svojim ulaznim podacima da dobijemo izlazne podatke
2. Za svaki izlazni sloj izračunamo $\delta_k = O_k(1-O_k)(O_k - t_k)$
3. Za svaki skriveni sloj izračunavamo

$$\delta_j = O_j(1-O_j)\sum_{k\in K}\delta_k W_{jk}$$

4. Ažuriramo težine i pragove

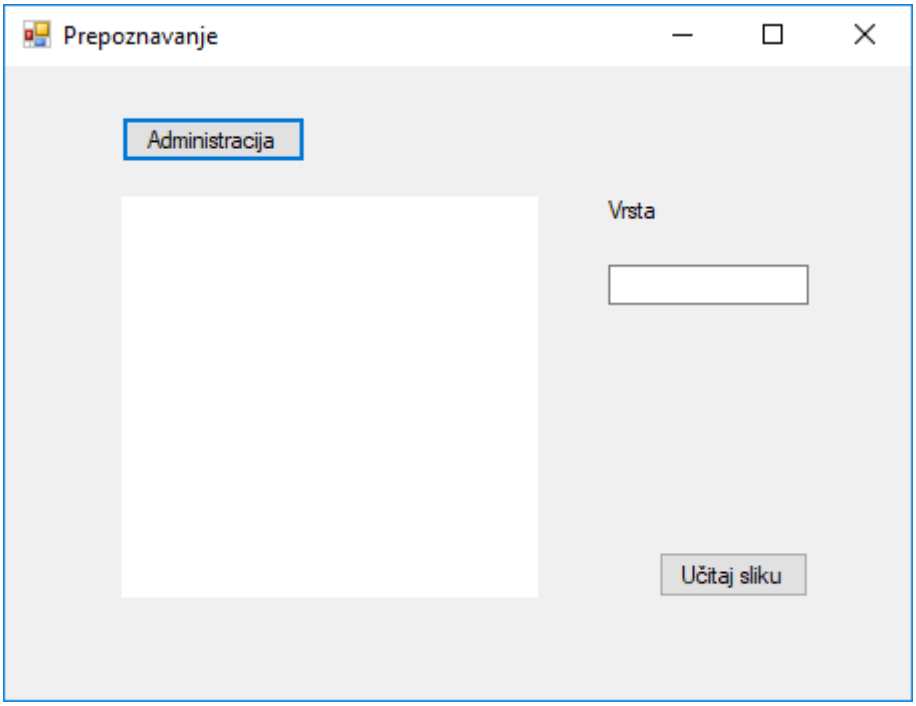
$$\Delta W = -\eta\delta_l O_{l-1}$$
$$\Delta\theta = -\eta\delta_l$$
$$W + \Delta W \rightarrow W$$
$$\theta + \Delta\theta \rightarrow \theta$$

6. Implementacija aplikacije

Aplikacija ima dva važna dijela. Prvi dio je digitalna obrada slike, a drugi je neuronska mreža, koja ima klasu za treniranje i klasu za klasifikaciju. Mreža koristi algoritam širenjem unatrag (backpropagation). Aplikacija radi na principu da se nađu kutovi na obrubu lista te se izračunaju sinusi kutova koji predstavljaju tokene koji se prosljeđuju mreži. Mreža će imati tri sloja, veličina ulaznog sloja će ovisiti o broju tokena (broj tokena od lista koji ih ima najviše, dok će se ostalima dodati nule do tog broja), a veličina izlaza o broju vrsta koje imamo u bazi. Svaki izlazni čvor predstavlja jednu vrstu, te ako se unese list te vrste izlaz tog čvora bi trebao biti 1, a ostalih 0.

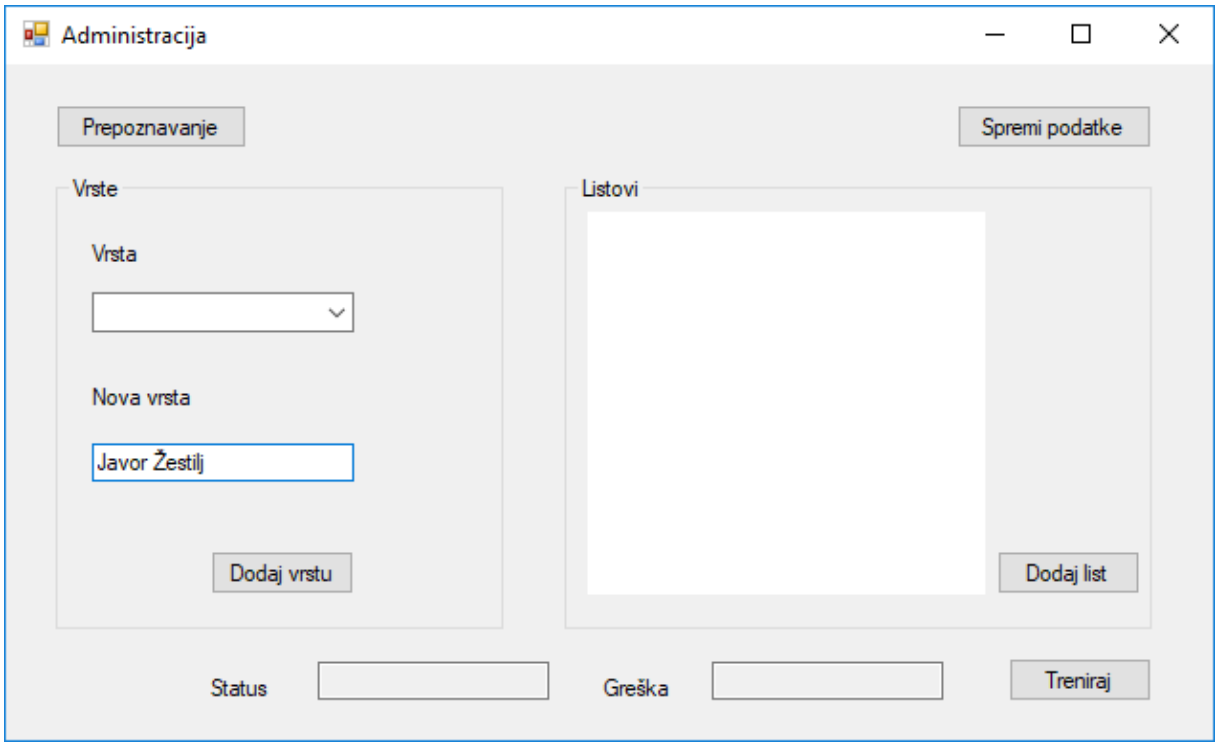
6.1. Rad aplikacije

Kada se aplikacija pokrene prvo se otvori prozor za prepoznavanje vrsta, no ako aplikacija nije istrenirana, treba se istrenirati. Aplikacija se trenira tako da se na početnoj formi klikne na gumb „Administracija“.



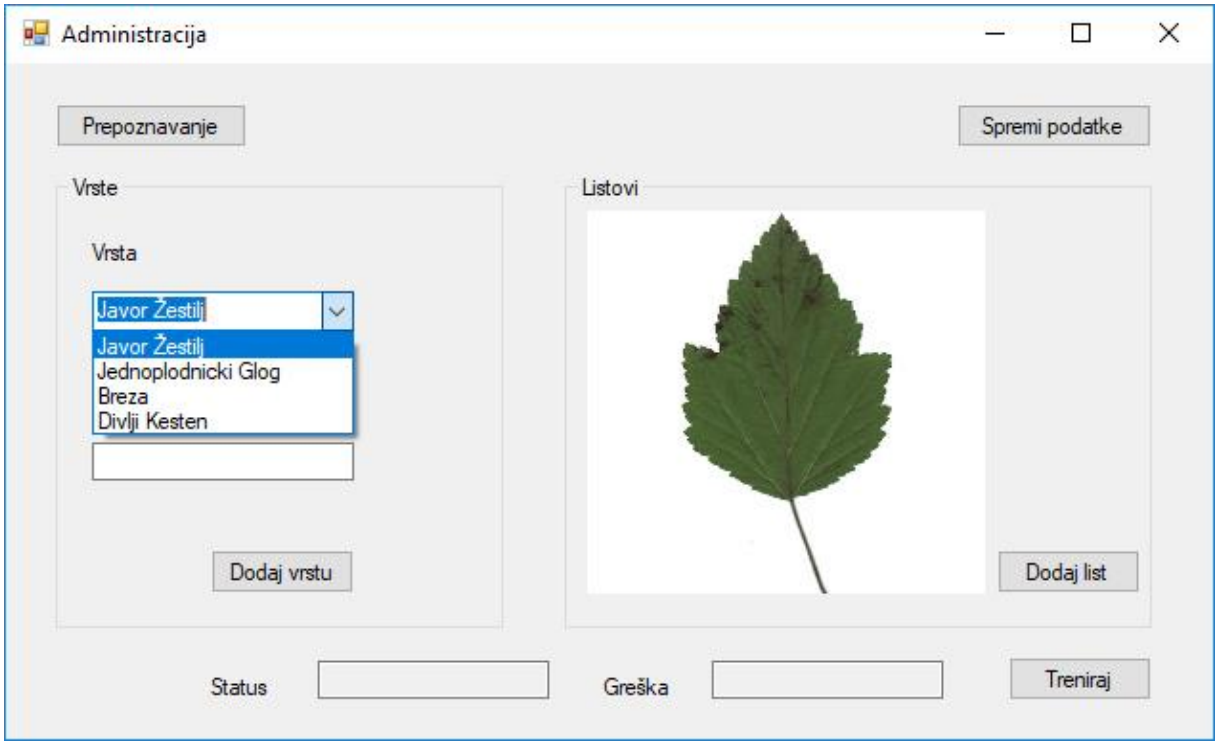
Slika 21 Prikaz početne forme

Kada je otvoren prozor administracije, prvo treba dodati vrste biljaka. To se radi na način da se u dijelu za vrste u tekstualni okvir napiše ime vrste i klikne na gumb „Dodaj vrstu“.



Slika 22 Dodavanje nove vrste

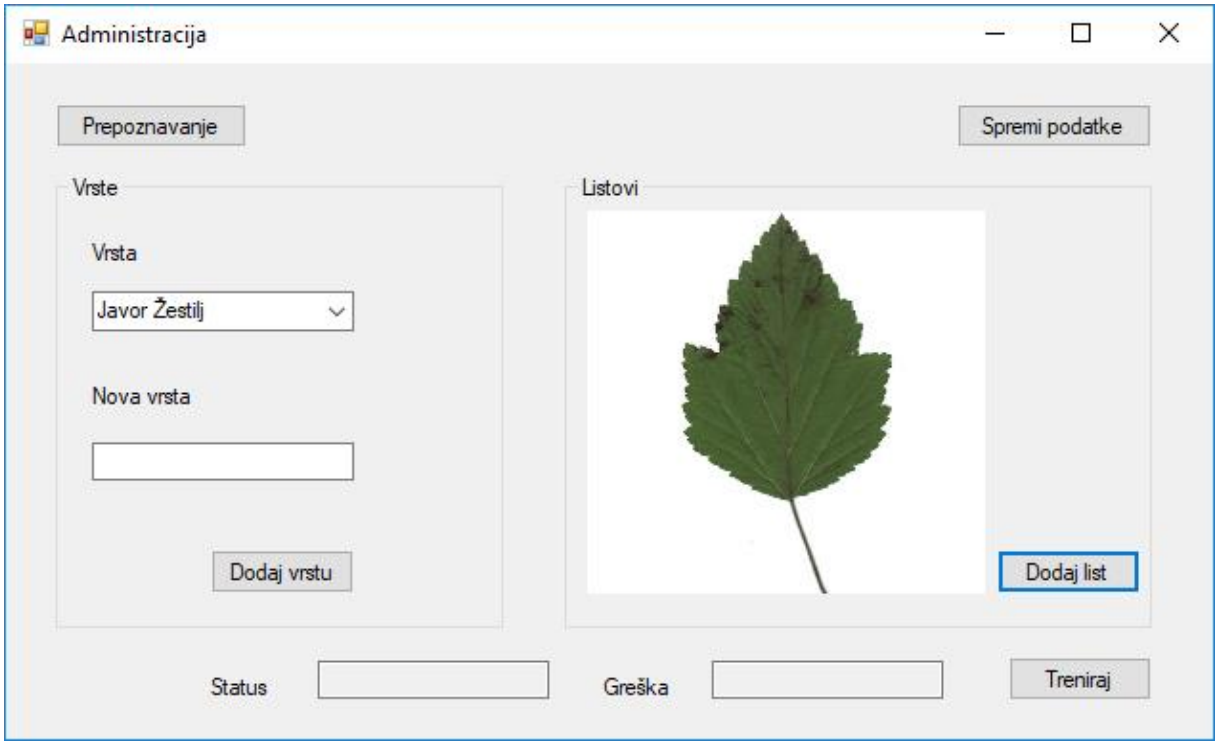
Nakon dodavanja vrste, vrsta će se automatski dodati u padajući izbornik sa vrstama. Taj postupak je potrebno ponoviti za sve vrste. Moguće je i naknadno dodavanje novih vrsta.



Slika 23 Prikaz dodanih vrsta

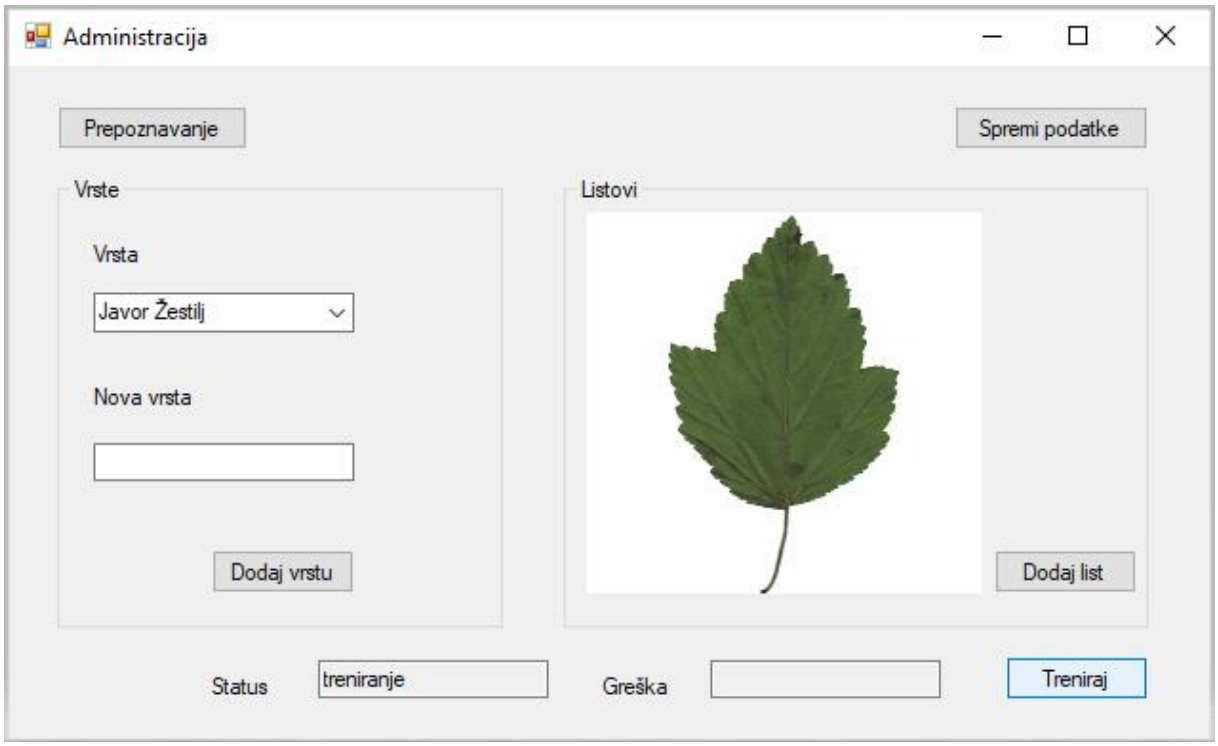
Kada su dodane željene vrste, za svaku vrstu treba dodati primjere lista. To se radi na način da se u padajućem izborniku odabere vrsta kojoj se dodaje list, zatim se klikne na gumb „Dodaj

list“ na što će se otvoriti dijalog za odabir slika, odabere se slika i klikne na gumb „Otvori“. Na to aplikacija automatski obrađuje sliku i vadi podatke za klasifikaciju. Kad se izvade potrebni podaci, u prostoru za sliku prikazati će se slika lista, te se može dodati novi list.



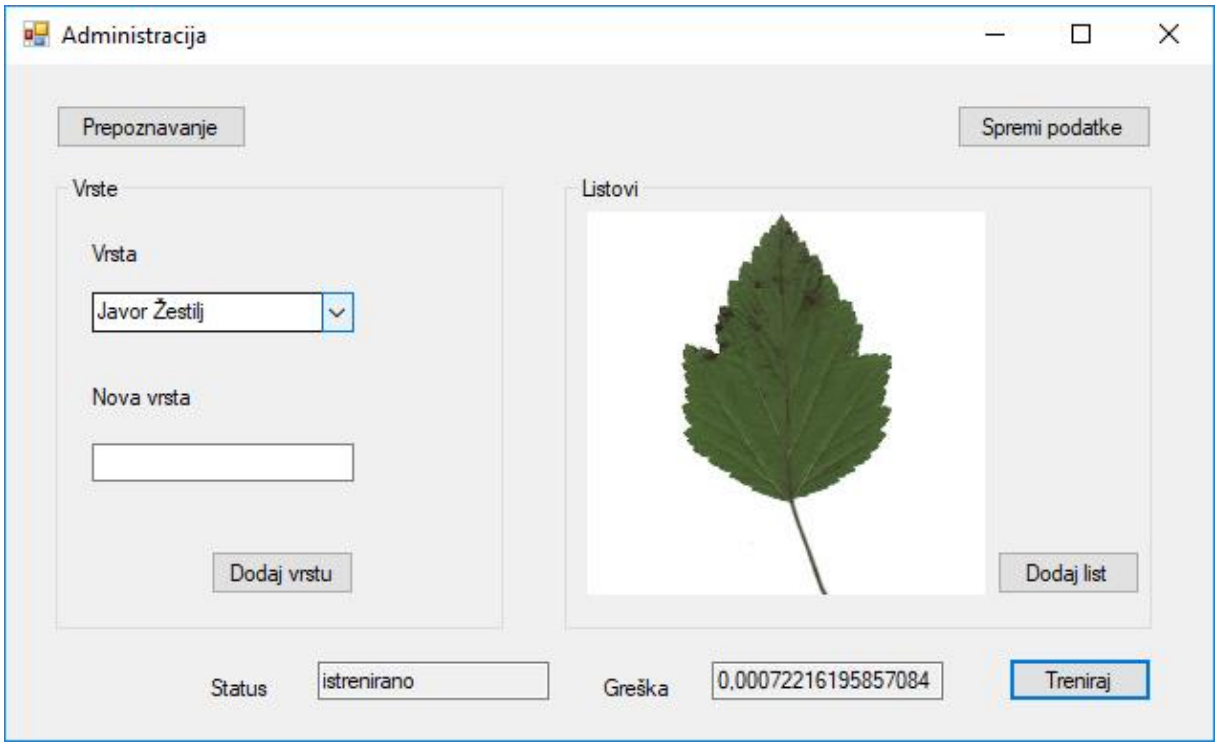
Slika 24 Dodavanje lista

Kada su svi listovi za sve vrste dodani treba spremiti ulazne podatke u paru s izlaznim podacima. To se radi da se klikne na gumb „Spremi podatke“. Aplikacija zatim podatke spremi u xml datoteku. Nakon toga se mreža može trenirati. Potrebno je samo kliknuti na gumb „Treniraj“. Kada se pokrene treniranje, u tekstualnom okviru za status pisat će „treniranje“.



Slika 25 Treniranje mreže

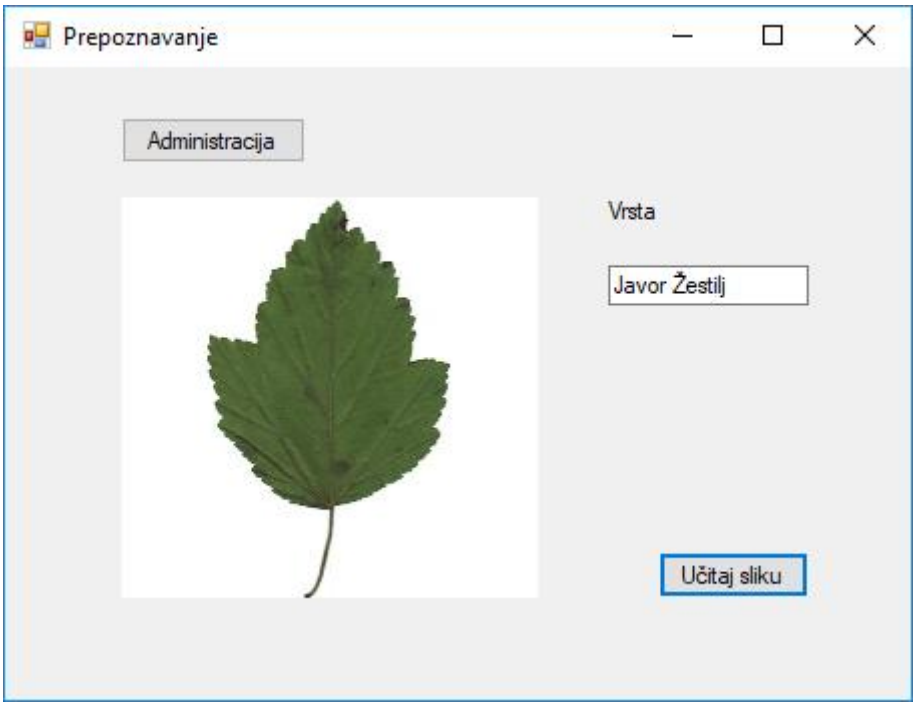
Kada je mreža istrenirana, status se izmjeni u „istrenirano“ i prikaže se vrijednost greške.



Slika 26 Mreža je istrenirana

Zatim je potrebno vratiti na prozor za prepoznavanje, to se može klikom na gumb „Prepoznavanje“ ili klikom na X u gornjem desnom kutu. Sada se može ispitivati listove. Za

ispitivanje vrste lista potrebno je samo kliknuti na gumb „Učitaj sliku“ i odabrati sliku lista. Aplikacija zatim obradi sliku i prikaže ime vrste u tekstualnom okviru za prikaz rezultata.



Slika 27 Prepoznavanje vrste

6.2. Procesiranje slike

Klasa ProcesiranjeSlike sadrži metode za obradu slike i dobivanje tokena koji se prosljeđuju mreži. Tokeni koji se prosljeđuju mreži su sinusi kutova na obrubu lista.

Metode:

- `public Bitmap OdrediRub(Bitmap slika)` – metoda poziva prewitt metodu za određivanje ruba
- `public Bitmap UGrayscale(Bitmap slika)` – pretvara sliku u boji u sliku u nijansama sive
- `public Bitmap UCrnoBijelo(Bitmap slika)` – pretvara sliku u binarnu sliku
- `public List<IntPoint> OdrediKuteve(Bitmap slika)` – određuju se kutovi pomoću Susan Corner detektora
- `private void SortirajKuteve()` – pošto algoritam za određivanje kutova ne prati rub nego ide po redovima odozgo prema dolje, treba sortirat kutove tako da slijede rub lista
- `public double[] OdrediSinuse(Bitmap slika)` – izračunava sinuse kutova koji služe kao tokeni koji se prosljeđuju mreži

6.3. Neuronska mreža

6.3.1. Transfer funkcije

Prva klasa je klasa tipa enum i ona sadrži naziva transfer funkcija. Druga klasa sadrži definicije transfernih funkcija te njihove derivacije. Metodama se proslijedi odabrana funkcija iz enum klase te se pomoću prekidnog operatora ostvaruje da se izračunava samo ta funkcija.

6.3.2. Backpropagation Network

Ova klasa sadrži metode za upravljanje mrežom. Metoda Run pokreće mrežu, metoda Train služi za treniranje mreže, dok se metoda Nudge poziva dok nekoliko iteracija nema prevelikih pomaka u treniranju mreže. Njoj je zadaća da poremeti vrijednosti težina i pragova kako bi se mreža brže istrenirala. Još važnije metode u klasi su Load i Save koje služe za učitavanje i spremanje mreže.

6.4. NetworkTrainer

6.4.1. DataPoint

Klasa DataPoint sadrži jedan par ulaznih i izlaznih podataka, tj. sadrži ulazne podatke jednog slučaja (u ovom slučaju tokeni jednog lista), te za taj ulaz ciljane izlazne vrijednosti. Klasa sadrži dvije metode. Prva metoda Load služi za učitavanje podataka, dok druga metoda ToXml služi za kreiranje xml elementa.

6.4.2. DataSet

Klasa DataSet sadrži skup DataPoint objekata. Ima dvije metode ToXml za kreiranje xml dokumenta, tj. za spremanje podataka, te metoda Load za učitavanje DataPoint objekata.

6.4.3. Permutator

Klasa Permutator ima za zadatak u svakoj iteraciji treninga izmijeniti redoslijed DataPoint objekata u DataSetu kako se mreža ne bi stalno trenirala s istim redoslijedom podataka. Klasa ima jednu metodu Premute koja ustvari ne izmjenjuje redoslijed DataPoint objekata, nego generira polje sa izmiješati indeksima te se polje prosljeđuje treneru mreže te se na taj način postiže slučajan redoslijed DataPoint objekata u procesu treninga.

6.4.4. NetworkTrainer

Klasa NetworkTrainer služi za treniranje mreže. Uzima DataSet set podataka te i prosljeđuje metodi za treniranje u klasi BackPropagationNewtwork. Klasa sadrži podatke o tome kolika bi trebala biti maksimalna pogreška, koliko puta će se maksimalno izvršiti iteracija treniranja u slučaju da se pogreška ne može spustiti ispod zadane maksimalne pogreške jer bi mogla nastat beskonačna petlja te drugi podaci koji su potrebni za treniranje mreže. U klasi su tri metode. Prva metoda TrainDataSet služi za treniranje mreže, CheckNudge provjerava je li potrebno poremetiti vrijednosti težina, te zadnja, GetErrorHistory vraća listu u kojoj su pogreške svake iteracije.

7. Zaključak

Dok je za ljude prepoznavanje uzoraka jednostavna operacija, za računalo je potrebno dosta snage za takvu operaciju. Neuronske mreže, unatoč značajnom napretku, još su daleko slabije od ljudskog mozga, no pojavom jačih računala sve se više koriste u praksi, a dolaskom kvantnih računala približit će se ostvarenju svog punog potencijala.

Prilikom izrade ovog rada prikazan je postupak za prepoznavanje objekata. Objašnjeno je što je digitalna obrada slike i neke operacije nad slikom, te što je i kako se implementira umjetna neuronska mreža. Na temelju tih tehnika implementirana je jednostavna aplikacija za klasifikaciju biljaka na temelju karakteristike obruba lista. Aplikacija je implementirana u programskom jeziku C#, a za implementaciju je još korišten programski dodatak aforge, te programska rješenja s GitHub-a.

8. Popis slika

Slika 1 Građa lista, [19] 2
Slika 2 Naizmjenični raspored listova: a dvoredni, b zavojiti, [19] 5
Slika 3 Pršljenasti raspored listova: a nasuprotni, b unakrsno nasuprotni, c tri lista u pršljenu, [19] 5
Slika 4 Cjeloviti jednostavni listovi: a cijelog ruba, b napiljenog ruba, [19] 6
Slika 5 Urezani jednostavni listovi: a perasto režnjasti, b dlanasto režnjasti, c perasto razdijeljeni, d dlanasto razdijeljni, e perasto rascijepani, d dlanasto rascijepani, [19] 7
Slika 6 Dlanasto sastavljeni listovi: a peteroliskavi, b troliskavi, [19] 8
Slika 7 Perasto sastavljeni listovi: a neparno, b parno, [19] 8
Slika 8 Dvostruko perasto sastavljeni list, [19] 9
Slika 9 Oblik listova kritosjemenjača: a linearni, b duguljasti, c eliptični, d okrugli, e suličasti, f jajasti, g obrnuto suličasti, h obrnuto jajasti, [19] 11
Slika 10 Posebni oblici kritosjemenjača: a srcasti, b lopatasti, c srpasti, d bubrežasti, e rombični, f deltasti, [19] 11
Slika 11 Rub plojke: a cijeli, b napiljen, c fino napiljen d urezano napiljen, e dvostruko napiljen, f nazubljen, g narovašen, h izverugan, i valovit j trnovit, k osjav, [19] 12
Slika 12 Vrh plojke: a šiljast, b ušiljen, c šiljkav, d dugošiljat, e šiljat, f šiljčav, g bodlikav, h tup, i zaobljen, j odrezan, k izrubljen, l uzubljen, m obrnuto srcast, [19] 13
Slika 13 Osnova plojke: a okruglasta, b srcasta, c uškava, d klinasta, e odrezana, f tupa, g kopljasta, h streličasta, i asimetrična, j kosa, [19] 14
Slika 14 Konverzija u nijanse sive (grayscale) 20
Slika 15 Crno-bijela slika lista 21
Slika 16 Rub lista 21
Slika 17 SUSAN detektor, [18] 22
Slika 18 Biološki neuron, [12] 23
Slika 19 Umjetni neuron, [4] 24
Slika 20 Umjetna neuronska mreža, [4] 25
Slika 21 Prikaz početne forme 28
Slika 22 Dodavanje nove vrste 29
Slika 23 Prikaz dodanih vrsta 29
Slika 24 Dodavanje lista 30
Slika 25 Treniranje mreže 31
Slika 26 Mreža je istrenirana 31
Slika 27 Prepoznavanje vrste 32

9. Literatura

[1] Bača M, Grd P. Digitalna obrada slike https://elfarchive1617.foi.hr/pluginfile.php/82072/mod_resource/content/1/FOI_PDS_OTB_SEM_1.pdf

[2] Bača M, Grd P. Histogrami, point operacije i filteri https://elfarchive1617.foi.hr/pluginfile.php/83483/mod_resource/content/1/FOI_PDS_OTB_SEM_4.pdf

[3] Bača M, Grd P. Slike u boji https://elfarchive1617.foi.hr/pluginfile.php/83482/mod_resource/content/1/FOI_PDS_OTB_SEM_2.pdf

[4] Dalbelo Bašić B, Čupić M, Šnajder J (2011) Umjetne neuronske mreže https://www.fer.unizg.hr/_download/repository/UI_12_UmjetneNeuronskeMreze.pdf

[5] Lončarić S. Neuronske mreže: Proces učenja https://www.fer.unizg.hr/_download/repository/02-ProcesUcenja.pdf

[6] Mačkić K (2009) Primjena neuronskih mreža u fizici i informatici http://www.phy.pmf.unizg.hr/~planinic/diplomski/Kenan_Mackic.pdf

[7] Švogor I (2008) Primjena neuronskih mreža u raspoznavanju uzoraka

[8] Stephen Gang Wu, Forrest Sheng Bao, Eric You Xu, Yu-Xuan Wang, Yi-Fan Chang, Qiao-Liang Xiang (2007) A Leaf Recognition Algorithm for Plant Classification Using Probabilistic Neural Network

[9] Abdul Kadir, Lukito Edi Nugroho, Adhi Susanto, Paulus Insap Santosa (2011) Leaf Classification Using Shape, Color, and Texture Features

[10] Javed Hossain, M. Ashraful Amin (2010) Leaf Shape Identification Based Plant Biometrics

[11] Chia-Ling Lee i Shu-Yuan Chen (2006) Classification of Leaf Images

[12] Boeree G. The Neuron http://webspace.ship.edu/cgboer/theneuron.html

[13] http://www.aforgenet.com/

[14] https://github.com/jens-maus/lrecog

[15] https://github.com/TheFellow/Neural-Network-Tutorial-CSharp

[16] https://www.tutorialspoint.com/dip/index.htm

[17] https://www.youtube.com/watch?v=aVId8KMsdUU&list=PL29C61214F2146796

[18] https://www.quora.com/What-is-the-difference-between-Harris-Corner-Detection-and-SUSAN-Corner-Detection

[19] Idžojtić M. (2009) Dendrologija-list