Procjena procesa dozrijevanja banane pomoću multispektralne slike

Presečki, Tea

Master's thesis / Diplomski rad

2016

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Agriculture / Sveučilište u Zagrebu, Agronomski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:204:119819

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

Repository Faculty of Agriculture University of Zagreb

zir.nsk.hr

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U ZAGREBU

AGRONOMSKI FAKULTET

Tea Presečki

PROCJENA PROCESA DOZRIJEVANJA BANANE POMOĆU MULTISPEKTRALNE SLIKE

DIPLOMSKI RAD

Zagreb, rujan 2016.

Sveučilište u Zagrebu

Agronomski fakultet

Studij: Hortikultura

Tea Presečki

PROCJENA PROCESA DOZRIJEVANJA BANANE POMOĆU MULTISPEKTRALNE SLIKE

DIPLOMSKI RAD

Mentor: Prof. dr. Sc. Tomislav Jemrić

Zagreb, rujan 2016.

Ovaj diplomski rad je ocijenjen i obranjen dana _____ s ocjenom _____ pred stručnim povjerenstvom u sastavu:

1. Prof. dr. sc. Tomislav Jemrić _____
2. Prof. dr. sc. Đani Benčić _____
3. Prof. dr. sc. Stjepan Sito _____

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilišta u Zagrebu

Agronomski fakultet **Diplomski rad**

Procjena procesa dozrijevanja banane pomoću multispektralne slike

Tea Presečki

SAŽETAK

Diplomski rad analizom multispektralnih slika i usporedbom rezultata sa standardnom metodom procjene zrelosti pomoću sheme COPLAC® determinira različite faze zrelosti ploda banane.

Predmet istraživanja je plod Cavendish banane (*Musa* AAA) s Kanarskih Otoka podijeljen u sedam kategorija definiranih prema boji kore. Rađene su tri serije analiza od kojih se jedna sastoji od sedam plodova, a druge dvije od 14 plodova. Plodovi su čuvani ukupno 16 dana na 12°C, a 24 ploda su izložena djelovanju etilena u trajanju od četiri dana. Istraživanje je popraćeno multispektralnim slikama uzoraka, koje su kasnije analizirane u programu MATLAB.

Istraživanje je pokazalo kako infracrveni kanal jako dobro odvaja plod od pozadine te pokazuje vrlo dobro oblik ploda, ali ne pokazuje razliku u stupnju zrelosti. Razlike u zrelosti plodova bolje se razlikuju crvenim kanalom.

Etilen je ključan hormon pri dozrijevanju plodova, a plodovi koji nisu bili izloženi određenoj koncentraciji etilena nisu postigli jednaku zrelost.

Tijekom istraživanja upotrijebljene su dvije komore. U jednoj komori se etilen raspršuje od stražnje strane komore prema naprijed, a u drugoj se s vrha komore etilen raspršuje u dozama prema dolje. Premda su plodovi banane raspoređeni u sve djelove obiju komora kako bi se istražilo eventualni utjecaj načina aplikacije etilena, pokazalo se kako položaj ploda u komori nije utjecao na njegovo dozrijevanje.

Zaključak istraživanja je prijedlog kako bi se sortiranje plodova banane olakšalo upotrebom multispektralnih kamera zbog ograničenja ljudskog faktora, točnije ljudskog oka, pošto ono nije u mogućnosti determinirati procese u pulpi ploda banane.

Ključne riječi: *Musa acuminata* AAA, banana, multispektralne slike, MATLAB, dozrijevanje

Diplomski rad je pohranjen u Centralnoj knjižnici Agronomskog fakulteta u Zagebu, Svetošimunska cesta 25.

Voditelj: Prof. dr.sc. Tomislav Jemrić

Članovi povjerenstva: Prof. dr. sc. Đani Benčić

Prof. dr. sc. Stjepan Sito

BASIC DOCUMENTATION CARD

University of Zagreb
Faculty of Agriculture **Thesis**

Non-destructive estimation of ripening process of banana by means of multispectral imaging

Tea Presečki

SUMMARY

Thesis analysis of multispectral images and comparing the results with the standard assessment method by COPLACA® organization determines different maturity stages of the banana fruit.

The subject of research is the fruit of a banana (Musa AAA), Cavendish type, grown in Canary Islands divided into seven categories defined by the color of the crust. They are divided according to a series of seven fruits and in two series of 14 fruits. The fruits were stored a total of 16 days at 12 ° C and 24 fruits were exposed to ethylene for a period of four days. The study is accompanied by multispectral images of samples, which were later analyzed in the program MATLAB.

Research has shown that infrared channel successfully separated the fruit from the background and showed very precise fruit shape, but doesn`t show the different level of maturity. The level of maturity is better distinguished with the red channel.

Ethylene is a key hormone in fruit ripening. Categories that had not been exposed to a certain concentration of ethylene have not reached the same maturity.

For the research we used two chambers. In one chamber ethylene was sprayed from the rear to the front side of the chamber and in the second chamber ethylene was sprayed in doses from the top down. The banana fruits were evenly distributed in all parts of both chambers to examine possible differences of the impact of ethylene. It was shown that the position of the fruits in the chamber did not affect its maturation.

The conclusion of the research is the proposal to use multispectral cameras while sorting banana fruits to exclude the limitations of the human factor, particularly the human eye which is unable to determine the processes in the pulp of the banana fruits.

Keywords: *Musa acuminata* AAA, banana, multispectral image, MATLAB, ripening

Thesis is deposited in the Central library of the Faculty of Agriculture, Zagreb, Svetošimunska cesta 25.

Mentor: Prof. dr.sc. Tomislav Jemrić
Reviewers: Prof. dr. sc. Đani Benčić
Prof. dr. sc. Stjepan Sito

SADRŽAJ

1. UVOD.....9
2. **CILJ ISTRAŽIVANJA**.....10
3. **PREGLED LITERATURE**.....11
3.1. Nedestruktivne metode.....11
3.1.1. Tehnika spektralnih slika.....12
3.1.2. Tehnika multispektralnih slika.....13
3.2. Banana (*Musa spp.)*.....14
3.2.1. Taksonomija i klasifikacija.....14
3.2.2. Morfologija.....15
3.2.3. Berba i nakon berbe.....17
3.2.4. Distribucija i značaj.....19
4. MATERIJALI I METODE.....22
4.1. Proces čuvanja na 12 °c,.....22
4.1.1. Serija 1.....23
4.1.2. Serija 2.....23
4.1.3. Serija 3.....23
4.2. Analiza čuvanja u kontroliranoj atmosferi.....24
4.3. Sustav multispektralnih slika.....25
4.4. Ne-nadzirana (ward) metoda.....26
5. REZULTATI I DISKUSIJA.....27
5.1. Analiza slika i histograma procesa čuvanja na 12 °c.....27
5.2. Analiza slika i histograma u analizi čuvanja u kontroliranoj atmosferi.....33
6. ZAKLJUČAK.....41
7. POPIS LITERATURE.....42

Pogreška! Izvor reference nije pronađen.. **UVOD**

Banana je po potrošnji najvažniji plod na svijetu. Za europsko tržište najviše se proizvodi na Kanarskim Otocima (Španjolska), gdje je glavna sorta Musa acuminata AAA (podgrupa Cavendish) (Diezma i sur., 2016). Banane nose 33% agrikulturne proizvodnje na otoku, a godišnje se proizvodi oko 400 milijuna kila plodova banana.

Određivanje stadija zrelosti ploda banane potrebno je za optimalno upravljanje i distribuciju, izvoz te postavljanje na tržište. U komercijalnoj praksi, stadiji zrelosti se uglavnom određuju usporedbom plodova sa shemom u boji (Diezma i sur., 2016). Standardna shema koja se koristi za vizualno uspoređivanje je COPLAC (Cooperativas Plataneras de Canarias). Ta je metoda subjektivna i nedovoljno pouzdana pa je potrebno pronaći bržu i sigurniju metodu za određivanje stupnja zrelosti

Multispektralna analiza slike je nedestruktivna metoda za utvrđivanje zrelosti ploda kojom je moguće objektivnije procijeniti stupanj zrelosti ploda, ali je još uvijek u fazi eksperimentalnog razvoja.

U ovom radu istražuje se determiniranje različitih faza zrelosti ploda banane analizom multispektralnih slika i uspoređuju rezultati sa standardnom metodom procjene zrelosti pomoću sheme COPLACA®.

Istraživanje je provedeno na bananama (Musa AAA) vrste Cavendish s Kanarskih Otoka. Uzorci su podijeljeni u sedam kategorija definiranih prema boji kore. Uzima se jedna serija po sedam plodova i dvije serije od četrnaest plodova. Plodovi se čuvaju 16 dana na 12°C, a zatim se uzimaju 24 ploda koji se izlažu djelovanju etilena u trajanju od četiri dana. Prije čuvanja i nakon dozrijevanja snimaju se multispektralne slike uzoraka i analiziraju u programu MATLAB.

2. CILJ ISTRAŽIVANJA

Banana je klimakterijski plod koji za komercijalne svrhe dozrijeva u posebnim komorama s obnovljivim zrakom, u kontroliranoj temperaturi i vlažnosti zraka, kontroliranim dozama etilena te opremljenim sofisticiranim instrumentima za praćenje CO2, temperature i relativne vlažnosti.

Nakon dozrijevanja u komorama, potrebno je pravilno sortirati plodove prema zrelosti kako bi se optimalno upravljalo njima, distribuiralo te postavilo na tržište.

Do sada se u komercijalnoj praksi stadij zrelosti uglavnom određivao usporedbom plodova sa shemom COPLACA®. Ova metoda je subjektivna i nedovoljno pouzdana te je cilj prvog dijela ovog istraživanja bio utvrditi da li je moguće multispektralnim kamerama determinirati stadije zrelosti plodova.

Povodom zaključka da je etilen ključan hormon u dozrijevanju plodova banane, cilj drugog dijela istraživanja bio je dokazati da banane, ubrane sa stabla u zelenoj fazi, ne mogu dozrijeti bez tretmana etilenom.

3. PREGLED LITERATURE

3.1. Nedestruktivne metode

U prehrambenim tehnologijama, u procesima nakon berbe već godinama se koriste tradicionalne ili destruktivne metode, kao što su: penetrometar za mjerenje čvrstoće, refraktometar za analizu topljive suhe tvari, senzorske analize teksture i okusa te druge kemijske metode. Prilikom uporabe destruktivnih metoda javlja se problem kako dobiti reprezentativne uzorke za cijelu količinu plodova, potrebno je više vremena za analizu te se uništava puno uzoraka. To dovodi do ekonomskog gubitka.

Ovaj problem prevladan je uporabom ne-destruktivnih metoda koje se mogu rabiti u selekciji i procjeni plodova te se time prevladavaju moguća odstupanja kakvoće između skupina uzoraka, bez uništavanja nužne količine plodova (Zerbini, 2006.).

Tijekom posljednjih nekoliko desetljeća opsežna istraživanja provedena su na razvoju ne-destruktivnih metoda za procjenu kvalitete kakvoće voća i povrća (Hertog, 2005.; Pup i Matsuoka, 2000.; Pup i Garg, 2010.).

Ne-destruktivne metode su široka skupina tehničkih analiza koje se koriste u znanosti i industriji za procjenu svojstava, sastava ili sustava materijala bez oštećenja. U poljoprivredi se koristi uglavnom za analize plodova poslije berbe.

Mogu se klasificirati prema načelu koji se rabi za otkrivanje svojstva ploda: mehanička, zvučna, optička i druga. Abbott i sur. (1997.) si grupirali ove tehnike u pet glavnih kategorija: 1.) udarni senzori; 2.) mjerenje brzine ili prigušivanje vibracije; 3.) mjerenje rezonantne vibracijske frekvencije takvog vala; 4.) mjerenje apsorpcije svjetlosti; 5.) mjerenje raspršenja svjetlosti kroz voće.

Ying Yibin i sur. (2003.) analizirali su tri različite vrste mjernih metoda, kao što su: regularna refleksija, transmisija i difuzna refleksija te su razradili primjenu tih tehnologija za mjerenje sadržaja šećera, kiselosti i određivanje čvrstoće plodova. Liu yande i sur. (2003.) proučavali su tehnologije izmjere vlakana, osmislili sustav detekcije za kvalitetu ploda i istražili tehniku izmjere vlakana senzornom refleksijom, difuznom refleksijom i transmisijom.

Rezultati su pokazali da je difuzna refleksija bila najbolja metoda za detekciju unutarnjih svojstava plodova. Također su uspostavili ne-destruktivnu metodu pomoću infracrvene spektroskopije difuzne refleksije za određivanje sadržaja šećera u jabuci i breskvi te su postigli dobre rezultate. Istovremeno, Fu Xiaping i sur. (2004.) proveli su srodne eksperimente te dobili slične rezultate (citirao Gao., i sur., 2009.).

He Dongjian i sur. (2001.) navode kako su znanstvenici u Japanu razvili senzor za detekciju zrelosti kruške i jabuke pomoću spektroskopije vidljivog i infracrvenog spektra svijetlosti. Zatim su razvili uređaj za sortiranje voća, koji odabire plodove prema zrelosti i boji te su primjenili ovu tehnologiju za automatski odabir voća na sortirnoj liniji. Povezali su zrelost, senzor boja, automatsko rangiranje, liniju proizvodnje paketa te ostvarili visoko automatizirano ne-destruktivno ocjenjivanje voća (citirao Gao.,i sur., 2009.).

Među optičkim tehnikama, neposredna infracrvena refleksija spektroskopije (NIRS) dobiva sve veću popularnost za procjenu kvalitete voća, budući da u posljednja dva desetljeća ova tehnika daje ohrabrujuće rezultate za procjenu parametara kvalitete voća (Zerbini, 2006.).

S drugačijim pristupom, Lu (2004.a) je predložio uporabu raspršene svjetlosti s multispektralnim slikama. Oštar, usmjeren širokopojasni svjetlosni snop osvijetli dio ploda, stvarajući povratno rasipanje slike na površini ploda. Spektralne slike su dobivene od četiri različite valne duljine u rasponu 680-940 nm (citirano prema Zerbini, 2006.).

3.1.1. Tehnika spektralnih slika

Tehnika spektralnih slika kombinira konvencionalne slike i spektralnu tehniku te je u mogućnosti dobiti prostorne i spektralne podatke proizvoda, što je vrlo korisno za procjenu pojedinih prehrambenih artikala. Ova tehnika privukla je velik interes u akademskim i industrijskim krugovima te se brzo razvila tijekom proteklog desetljeća (Gowen i sur, 2007.; Lorente i sur, 2012.).

Spektralne slike su trodimenzionalne (3-D) u prirodi, s dvije prostorne dimenzije i jednom spektralnom dimenzijom. Postoje tri glavne klase u području tehnike spektralnih slika, multispektralne, hiperspektralne i ultraspektralne slike, gdje se uglavnom koriste multispektralne i hiperspektralne slike. Glavna razlika između multi i hiperspektralnih slika je u rasponu valnih duljina ili frekvencija. Hiperspektralna tehnika dobiva slike s brojnim rasponom (10-100) kontinuiranih valnih duljina, dok multispektralna tehnika dobiva slike s nekoliko (manje od 10) zasebnih valnih duljina.

3.1.2. Tehnika multispektralnih slika

Tehnologija multispektralnih slika stvorena je kombinacijom sustava koji su osjetljivi na različite dijelove spektra. Ima za cilj stjecanje prostornih i spektralnih podataka koji su neposredno korisni za aplikaciju u datom tenutku na određenom području (na primjer: pakirnice voća i postrojenja za preradu hrane). Može uhvatiti djelove svjetlosnog spektra izvan vidljivog područja, kao što je infracrvena svjetlost, čime ekstrahira dodatne informacije koje ljudsko oko ne uspijeva uhvatiti (Lleó, i sur. 2009.).

U proizvodnim pogonima još uvijek radnici sortiraju plodove na linijama za sortiranje, što je slučaj kod banana. Problem je što ljudsko oko često ne može primijetiti neki nedostatak kod ploda. Za razliku od ljudskog oka, vid stroja nije limitiran vidljivom regijom elektromagnetnog spektra. Osjetljivost CCD (charged coupled device) kamera je u rangu od 400- 1000 nm pa su spektralne kamere postale dio širokog istraživanja i korištenja (Blasco i sur. 2007.).

Proces dozrijevanja popraćen je promjenom koncentracije raznih pigmenata. Za multispektralne slike su važna dva vidljiva područja: 680 nm koji se odnose na sadržaj klorofila i 450 nm koji se odnose na sadržaj karotenoida. Klorofil je fotosintetski pigment koji ima apsorpcijsku točku u crvenom svjetlu, a karotenoid je pigment koji ima apsorpcijsku točku u plavom svjetlu. Još jedno važno područje je 800 nm koji se odnosi na infracrveno svjetlo koje je važna referentna razina.

Za multispektralne slike može se primijeniti oboje: metoda linijskog i prostornog skeniranja. Metoda prostornog skeniranja može istodobno prikupiti slike jedne valne duljine i više odabranih valnih duljina. Svjetlo iz prostornog prizora je obično podijeljeno u nekoliko dijelova uz pomoć optičkih uređaja za odvajanje (npr. uređaj za razdvajanje snopa). Spektralno podijeljen prizor će proći odvojeno kroz unaprijed separirani filter. Slike uskog valnog spektra će se zatim formirati na nekoliko kamera ili na jednoj kameri s velikim CCD senzorom. U postupku linijskog skeniranja postoji određivanje položaja svih korisnih snopova duž spektralna dimenzije detektora CCD. Prikupljaju se samo podaci iz odabranih snopova, što smanjuje količinu podataka za svaku liniju skenirane slike (y, k). Propusnost odabranih snopova može se podesiti grupiranjem piksela duž spektralne dimenzije.

3.2. Banana (Musa spp.)

Banane su porijeklom iz Jugoistočne Azije te regije Zapadnog Pacifika. Najraniji zapisi o uzgoju banana su iz Indije, prije otprilike 2500 godina. Moguće je da su prenesene iz Indonezije preko Indijskog oceana na Madagaskar, a nakon toga u Istočnu Afriku, Zair i Zapadnu Afriku. Na afričkim obalama banane su poznate 14-15 stoljeća od kada su se doselili Portugalci. Oni su donijeli banane iz Zapadne Afrike na Kanarske otoke, a zatim su u 16. stoljeću banane s Kanarskih otoka prenesene do Santa Dominga (Dominikanska Republika) (Robinson i Saúco, 2010).

Banana (engleski) ima različite nazive: bananier (francuski), pisang (malajski, indonezijski), kluai (Tajland), chuoi (Vijetnam), Xiang Jiao (kineski) (Paull i Duarte, 2011).

3.2.1. Taksonomija i klasifikacija

Carstvo: *Plantae*
Podcarstvo: *Tracheobionta*
Nadodjeljak : *Spermatophyta*
Odjeljak: *Magnoliophyta*
Razred: *Liliopsida*
Podrazred: *Zingiberidae*
Red: *Zingiberales*
Porodica: *Musaceae*
Rod: *Musa L.*

Generički naziv Musa potječe od arapske riječi '*mouz*'. Banane su bile poznate ranim Arapima i pojavljuju se u Kuranu kao "rajsko drvo'. Rod Musa ima više od 50 vrsta, a neke od tih vrsta imaju brojne podvrste. Najraniju "znanstvenu" klasifikaciju banana izradio je Linnaeus u 1783. godini i dao ime *Musa sapientium* svim desertnim bananama koje su bile slatke kada dozriju i konzumiraju se svježe (Robinson i Saúco, 2010).

Modernu metodu klasificiranja jestivih banana izradili su Simmonds i Shepherd (1955.). Njihova klasifikacija temelji se ponajprije na relativnom doprinosu *M. acuminata* i *M. balbisiana* na sastav sorte, a zatim na broj stanica ili kromosomu kultivara.

Većina modernih jestivih banana izvorno su dobivene iz dvije divlje, cjepljene vrste, *M. acuminata* Colla (A genom) i *M. balbisiana* Colla (B genom), koji su porijeklom iz jugoistočne Azije. Tu su i *Musa schizocarpa* (S genom) i *Musa textilis* (T genom), ali one nisu toliko bitne (Robinson i Saúco, 2010.).

Svi znanstvenici koji su pokušali taksonomski odrediti banane slažu se da se ne mogu sve jestive banane staviti pod isti znanstveni naziv. Naziv *M. acuminata* bi se mogao primijeniti na čiste, bez sjemenske sorte diploidnih (AA) i triploidnih (AAA) oblika desertnih banana kao što su 'Pisang Mas' i 'Grand Nain'. Slično tome, naziv *M. balbisiana* se može primijeniti na čiste, bez sjemenske sorte diploidnih (BB) i triploidnih (BBB) oblika banana za kuhanje kao što su 'Abuhon' i " Saba. Mnogi hibridi ne mogu nositi određeni naziv zbog miješanog sastava i razlika u broju kromosoma. Dakle, međunarodno je prihvaćeno da su svi kultivari banana roda *Musa*, koju slijedi šifra koja označava genetsku skupinu i broj stanica ili kromosoma, nakon čega slijedi naziv podgrupe (ako ih ima), zatim popularni naziv sorte. Na primjer: *Musa AAA* (Cavendish podskupina) Grand Nain '; *Musa AAB* (Plantain podskupina) 'Sirena'; *Musa BBB* 'Saba'; *Musa AB* 'Ney Poovan'etc (Robinson i Saúco, 2010.).

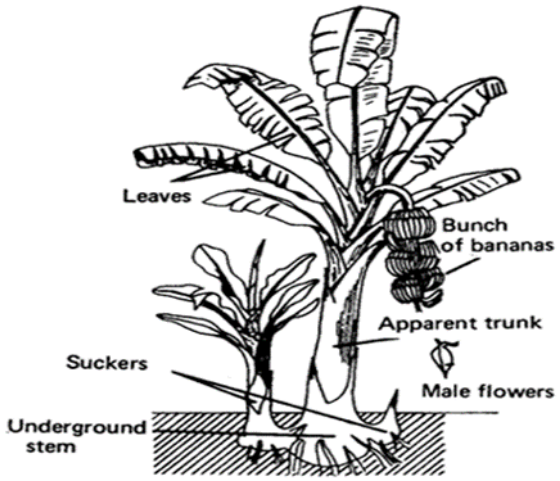
Cavendish podgrupa (AAA) izuzetno je važna za svjetsku trgovinu, za izvoz u tropima, a za lokalne trgovine u subtropima. Postoji velika razlika između kultivara u ovoj podskupini. Neki od najvažnijih su Dwarf Cavendish tip, gdje je glavna sorta ' Dwarf Cavendish'; Giant Cavendish tip gdje su glavni klonovi "Mons Mari ',' Williams ',' Grand Nain 'i ' Giant Guverner'; Robusta tip u kojoj su glavni klonovi 'Tall Mons Mari', 'Poyo', 'Valery' i 'Americani' i Lacatan tip sa sinonimima 'Pisang Masak Hijau', 'Monte Cristo' i 'Giant Fig' (Robinson i Saúco, 2010.).

3.2.2. Morfologija

Banana je monokotilna zeljasta biljka, jer nakon berbe zračni dijelovi odumiru i ne postoje drvenaste komponente. Zimzelena trajnica je zbog toga što novi odjeljci rastu iz baze matične biljke te zamijenjuju dijelove koji su odumrli. Osnovni dijelovi biljke banane prikazani su na slici 1.

Korijenski sustav čini adventivni, mesnati korijen bez glavnog korijena. Primarni korijeni potječu obično u skupinama od dva do četiri, obično tri, od površine središnjeg

cilindra unutar gomolja. Sekundarni korijeni potječu iz ksilema blizu vrha korijena i nastavljaju se kao primarni korijen koji se proteže kroz tlo. Isto vrijedi i za tercijarni korijen koji proizlazi iz sekundarnog (Robinson i Saúco, 2010).



Slika 1. Skica biljke banane
(http://www.fao.org/docrep/006/t0308e/T0308E03.htm)

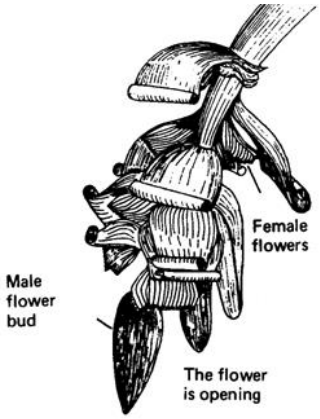
Prava stabljika banane je djelomično ili potpuno pod zemljom, a poznata je kao gomoljasti rizom. Botanički opis banane po Cobleyu (1963), Haareru (1964) i Stover Simmondsu (1987) kako navode Robinson i Saúco (2010) ukazuje da stabljiku banane treba smatrati kratkim gomoljem. Gomolj je važan organ za pohranu, održavanje i rast mladih izbojaka. Prije cvatnje gomolj sadrži oko 45% ukupne suhe tvari u biljci, što opada na oko 30% u fazi dozrijevanja ploda jer se zalihe koriste za rast ploda.

Prvi listovi rastu iz središnjeg meristema mladih izbojaka, izlazeći kao uski, kasnije se postupno šire. Nakon otprilike šest mjeseci naraste u potpunu veličinu. Najveći listovi su oni koji rastu prije cvatnje. Kora lista je u početku kružnog oblika, potpuno zatvara meristem, a kasnije rastom lista se u središtu odvajaju.

Dvije su vidljive faze razvoja biljke banana, jedan je vegetativna faza, naznačena pojavom lišća te produktivna faza, lako prepoznatljiva po nastanku izdanaka.

U određenom stadiju razvoja biljke započinje razvoj cvata. Pokretanje ove transformacije se ne vidi izvana, niti postoje bilo koji drugi karakteristični znakovi inicijacije cvijeta. Priroda poticanja cvatnje je nepoznata i daljnji predmet znatnih nagađanja. Nedavna istraživanja (Hernández i sur., 2008. citirano prema Robinson i Saúco, 2010.) ukazuju na akumulaciju giberelinske kiseline (GA3) u gomolju (AAB cv. 'Hartón'). To može ukazivati na

ulogu GA3 u procesima meristemske promjene i rasta stanice, ali ova teorija još nije istražena i potvrđena.



Slika 2. Cvijet banane

(http://www.fao.org/docrep/006/t0308e/T0308E03.htm)

Prijelazna faza počinje kad se apikalni meristem počne dizati i pokazivati intenzivnu miotsku aktivnost. Umjesto listova pojavljuju se cvijetne brakteje, prvo ženske pa muške. Cvat je kompleksni šiljak koji se sastoji od čvrste peteljke na kojoj su cvjetići raspoređeni u čvor klastera, svaki čvor sastoji se obično od dva reda cvijetova postavljenih na poprečnim jastucima te pokrova koji štiti mlade cvjetiće (slika 2). Cvjetni klasteri sa braktejama rastu spiralno, ali ne zaokružuju u potpunosti peteljku. Bazalni čvorovi nose ženske cvjetove, sadrži od pet do 18 tih čvorova. Jestive banane sadrže niz grozdova banana razvijenih iz ženskih cvjetova koji su odvojeno povezani sa debelim peteljkama. Eventualnu postignutu količinu plodova koji će izrasti određuju uvjeti nakon početka cvatnje, a to su: temperatura, broj listova i lisno područje tijekom razvoja, plodnost tla i voda te stadij zrelosti u vrijeme berbe.

Plod banane, unatoč tome što je podrijetlom iz inferiornog ovarija, botanički je okarakterizirano kao bobica s perikarpom. Jestive banane su vegetativno partenokarpne i razvijaju jestivu pulpu bez oprašivanja, za razliku od divljih vrsta kojima je potrebno oprašivanje. Većina sorti AAA Cavendish podskupine su sterilne i ne mogu stvarati sjeme, dok sorta AAA 'Gros Michel' daje jednu ili do dvije sjemenke po skupini plodova, ako se oprašuju s diploidima.

Razvoj ženskog ploda dijeli se u dvije faze, prije nastanka ploda i nakon. Fazom prije nastanka ploda dominira rast kore, a pulpa se počinje razvijati u drugoj fazi. Tijekom prvog mjeseca kora predstavlja 80% ukupne svježe mase voća. Nakon toga pulpa rapidno raste te se

omjer pulpa/ kora povećava od 0,17 do 1,82 u 80 dana. Omjer 1,0 postiže oko 70 dana nakon nastanka (Robinson i Saúco, 2010).

3.2.3. Berba i nakon berbe

Utvrđivanje i održavanje optimalnog roka berbe grozdova banana te rukovanje plodovima tijekom prijevoza i pakiranja od vitalne su važnosti za postizanje visoke kakvoće ploda i vrhunske cijene na tržištu. Neispravna berba, transport, pakiranje i tehnike čuvanja mogu dovesti do fizičkog ili fiziološkog oštećenja ploda, što dovodi do smanjenja kakvoće i cijene. Čimbenici prije berbe također imaju važnu ulogu u performaciji tijekom berbe i poslije berbe. Namjera je uvijek proizvesti velike plodove, bez mana, s pravilnom dužinom plodova. Neki od čimbenika prije berbe koji utječu na kakvoću ploda su prvenstveno: sorta, klimatski uvjeti, uvjeti tla, stručnost upravljanja, rok berbe i funkcionalno područje lista na biljci tijekom razvoja izdanaka.

Za marketing na mjestu ili prijevoz na kratke udaljenosti plod može biti na 90% pune zrelosti, za srednje udaljenosti se koristi plod 75% pune zrelosti te za duge udaljenosti manje od 75% od pune zrelosti.

Banane se pakiraju u kartonske kutije kao cijeli komadi (grozdovi), klasteri ili pojedinačno, a masa pakiranja u kartonu može varirati od 12 do 18 kg, ovisno o zemljama i tržištima. Da bi se osigurala zaštita plodova, između redova se rabe većinom 'jastučići' od kraft papira ili plastike. Polietilenske film obloge se obično rabe u izvozu voćnih kartona kako bi se smanjio gubitak vode tijekom prijevoza i pružila određena zaštita od štete nastale trenjem. Zrak se također može usisati iz košuljice za uklanjanje kisika. Nakon pakiranja kutije banana se prevoze na paletama kako bi se smanjila šteta nastala prilikom rukovanja. Za lokalno tržište palete kartonskih kutija se utovaruju na kamione za prijevoz do komora za dozrijevanje. Prijevoz u hladnjačama je neophodan kako bi se spriječio proces dozrijevanja prije dolaska na odredište. Temperatura od 12 do 14°C je potrebna za Cavendish banane kako bi se spriječilo dozrijevanje bez uzrokovanja štete na plodu. Kako bi se izbjeglo nakupljanje etilena potrebna je dobra ventilacija zraka tijekom transporta. Po dolasku na odredište, palete se brzo prenose do komora za dozrijevanje, a zatim u veleprodajnu distribuciju.

Robinson i Saúco (2010) navode kako ubrana banana prolazi kroz četiri fiziološke faze razvoja, i to pre-klimakterijsku ili fazu "zeleni život", klimakterijsku fazu, fazu zrenja, fazu dozrelih plodova i fazu starenja.

Faza 'zeleni život' predstavlja razdoblje od berbe do vidljive faze klimakterija. To je razdoblje niske metaboličke aktivnosti i komercijalni cilj je produžiti to razdoblje što je duže moguće.

Klimakterijska faza je kada plod počne proizvoditi etilen. U klimakterijskom voću poput banana postoji brzi i masivni porast proizvodnje etilena koji prethodi dišnom klimakteriju. Nakon što je izazvalo početni porast disanja, proizvodnja etilena se ponovno smanjuje. Dva enzima koji reguliraju sintezu etilena u plodovima su ACC sintaza koja stvara ACC i enzim formiranja etilena (EFE) koji generira etilen iz ACC.

Tijekom zrenja postoji nekoliko vidljivih promjena. Započinje omekšavanje tkiva tijekom koje se škrob degradira na šećere te se snaga stanične stijenke sve više pogoršava. Koncentracija otopljenih polisaharida i uronske kiseline te njihove enzimske aktivnosti se povećavaju. Kora postaje svijetlo-zelena, a zatim žuta kako opada koncentracija klorofila. Tijekom promjene boje, pulpa postaje mekša i slađa kako se omjer šećera /škroba povećava te se proizvodi karakterističan miris.

U proizvodnji se koristi shema boja za dozrijevanje banana koja ima sedam faza, od zelene boje, do žute te žute sa smeđim mrljama.

Ako plod banane ostavimo da dozrijeva prirodno na kraju će omekšati, ali će kora postati bez sjaja, blijedo žuta i neprivlačna. Kako bi bili sigurni u čvrstu teksturu i dobar okus, svijetlo- žutu boju kore i ujednačeno dozrijevanje, zeleni plodovi moraju dospjeti umjetno pomoću etilena.

Banane komercijalno dozrijevaju u zatvorenim komorama s obnovljivim zrakom, u kontroliranoj temperaturi i vlažnosti zraka, s dozama etilena, opremljenim sofisticiranim instrumentima za praćenje CO2, temperature i relativne vlažnosti. Postoje tri faze u procesu dozrijevanja: porast temperature, distribucija etilena i ventilacija za vrijeme smanjenja temperature.

3.2.4. Distribucija i značaj

Banane su glavno voće u međunarodnoj trgovini i najpopularnije na svijetu. Po obimu one su prvo voće koje se izvozi, dok su drugi u rangu nakon agruma u smislu vrijednosti (FAO, 2009., citirao Jaiswal i sur.,2012.).

Većina banana koje su proizvedene u tropskim zemljama se izvoze u dva najvažnija svjetska tržišta, a to su Europa i Sjeverna Amerika (SAD i Kanada). Druga važna tržišta su Japan i Rusija.

Indija je sa svojom velikom bio-raznolikošću banana najveći proizvođač i potrošač s procjenjenom proizvodnjom od 16 milijuna tona godišnje kako navodi Jaiswal i sur. (2012.)

Kanarski otoci (Španjolska) imaju vrlo intenzivan uzgoj banana i glavni su proizvođač za Europu. Oni imaju proizvodnu površinu od oko 9000 ha, sa 400 000 godišnje, a izvoze oko 90% do kopna Španjolskoj. Važno je naglasiti da je više od 95% desertnih banana koje se izvoze su iz AAA Cavendish podskupine.

Prema FAOSTATu iz 2010 godine, najveći svjetski proizvođač banana 2006. godine, kao što je i prikazano na tablici 1., bila je Indija sa daleko većom prednošću pred svima. Slijede je Kina, Brazil, Filipini, Ekvador te ostali.

Najvažniji svjetski uvoznici i izvoznici u 2006. godini prema FAOSTAT-u mogu se vidjeti u tablici 2. Ekvador, Filipini, Costa Rica i Brazil najveće zemlje izvoznice banana, dok je USA daleko najveći uvoznik, a slijede Njemačka, Belgija, Japan te ostale zemlje.

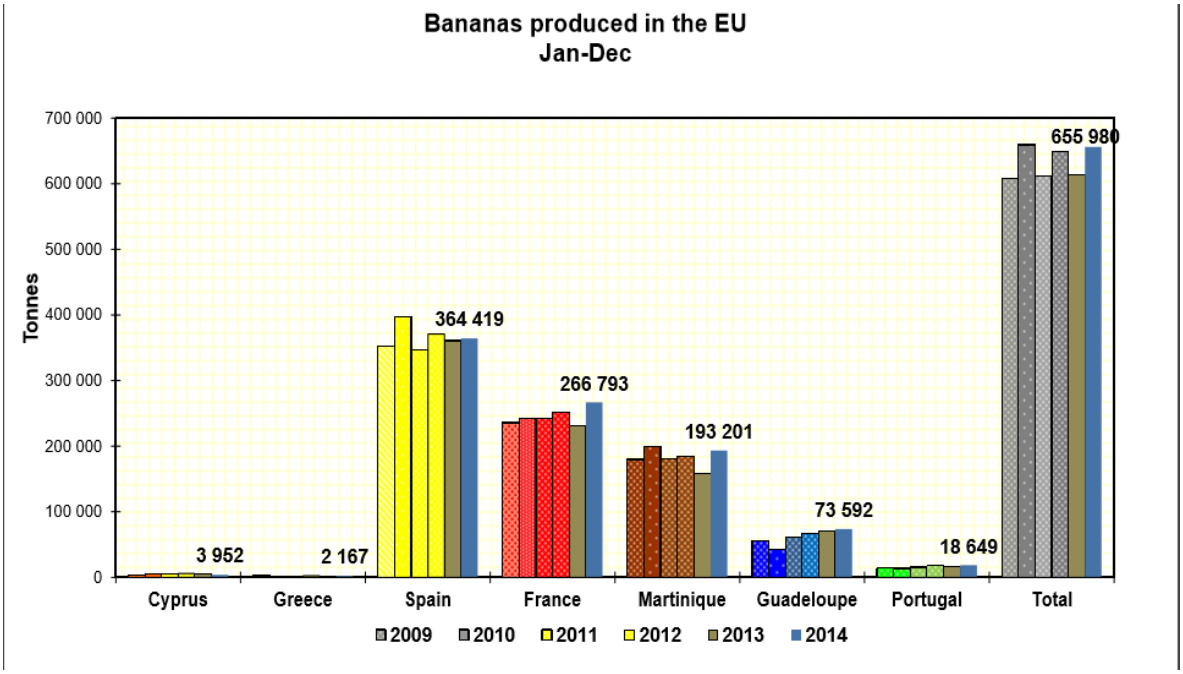
Prema podacima za Europsku komisiju koje je radila tvrtka iz koje su plodovi za analizu ovog istaživanja, u Europi se 2014. godine proizvodilo 655 980 tona banana. Na prvom mjestu je bila Španjolska sa proizvodnjom od 364 419 tona (Grafikon 1.).

Tablica 1. Svjetska proizvodnja banana 2006. godine (FAOSTAT, 2010.)

Country	Production (x 1000 t)	Country	Production (x 1000 t)
Asia		Central America and Caribbean	
India	20,858	Costa Rica	2,220
China	7,115	Mexico	2,196
The Philippines	6,795	Guatemala	1,001
Indonesia	5,037	Honduras	890
Thailand	2,000	Dominican Republic	548
Vietnam	1,350	Panama	440
Bangladesh	909	Others	1,464
Malaysia	530	Total	8,759
Others	1,051		
Total	45,645	Africa	
		Burundi	1,600
South America		Egypt	885
Brazil	6,956	Cameroon	860
Ecuador	6,127	Uganda	615
Colombia	1,750	Kenya	600
Venezuela	509	South Africa	344
Others	481	Others	3,235
Total	15,823	Total	8,139
Oceania			
Papua New Guinea	870	Europe	
Australia	181	Spain	362
Others	163	Others	38
Total	1,214	Total	400
		Total (world)	79,980

Tablica 2. Najvažniji svjetski uvoznici i izvoznici banana 2006. godine (FAOSTAT, 2010.)

Major importing countries	Volume (x 1000 t)	Major exporting countries[a]	Volume (x 1000 t)
USA	3,839	Ecuador	4,908
Germany	1,292	The Philippines	2,312
Belgium	1,180	Costa Rica	2,183
Japan	1,044	Brazil	1,943
UK	925	Colombia	1,568
Russian Federation	894	Guatemala	1,055
Italy	646	Honduras	515
China/Hong Kong	459	Panama	431
Canada	458	Ivory Coast	286
France	408	Cameroon	256
Argentina	295	Dominican Republic	187
Iran	294	Bolivia	81
South Korea	280	Belize	73
The Netherlands	279	Mexico	67
Ukraine	272	Yemen	60
Saudi Arabia	235	Surinam	45
Sweden	188	Nicaragua	38
Chile	166	Saint Lucia	35
Algeria	147	Sri Lanka	35
Portugal	142	Lebanon	34
Spain	133	Jamaica	32
Austria	130	Malaysia	24
Czechoslovakia	122	St Vincent and the Grenadines	24
Others	2,023	Others	597
World imports (total)	15,851	World exports (total)	16,789



Grafikon 1. Proizvodnja banana u Europi 2014. godine

(iz statistike Eurobane za Europsku komisiju)

4. MATERIJALI I METODE

Uzorci banana (Musa AAA) sorte Cavendish preuzeti su iz tvrtke za čuvanje i distribuciju s Kanarskih Otoka. Prije početka analize banane su bile minimalno obrađene i grupirane u 7 kategorija dozrijevanja prema navodima u shemi COPLAC® (Cooperativas Plataneras de Canarias). Multispektralne su slike snimljene prije i tijekom procesa dozrijevanja. Slike su snimljene samo s jedne strane ploda. Analiza slika i podataka provedena je pomoću Matlab programa (verzija 7.0, Math Works, Inc., USA).



Slika 3. Shema 7 različitih kategorija banana iz COPLAC®

Dva su dijela eksperimenta: prvi je proces čuvanja na temperaturi od 12°C, a drugi analiza čuvanja u kontroliranoj atmosferi.

4.1. Proces čuvanja na 12 °C

U ovom eksperimentu materijal se sastoji od tri niza podataka, pod nazivom serija 1, serija 2 i serija 3.

4.1.1. Serija 1

Serija 1 sastoji se od sedam uzoraka od kojih svaki odgovara jednoj kategoriji banane. Podaci su uzeti tijekom pet različitih dana. Analiza počinje 16. travnja, kada su uzorci uzeti iz skladišta tvrtke, razvrstani u kategorije te su snimljene prve multispektralne slike. Nakon toga, multispektralne slike snimljene su i 21. travnja, 22. travnja, 24. travnja i 27. travnja. Uzimanje podataka ovih uzoraka trajalo je 12 dana, a uzorci su u međuvremenu bili pohranjeni u hladnjak na 12 ° C.

4.1.2. Serija 2

Serija 2 sastoji se od 14 uzoraka, za svaku kategoriju uzeta su dva uzorka banana. Podaci su uzeti šest različitih dana. Analiza počinje 21. travnja, kada su uzorci uzeti iz skladišta tvrtke, razvrstani u kategorije i snimljene prve multispektralne slike. Nakon toga, multispektralne slike napravljene su 22. travnja, 24. travnja, 27. travnja, 29. travnja i 6. svibnja. Uzimanje podataka ovih uzoraka trajao je 16 dana, a uzorci su u međuvremenu uskladišteni u hladnjaku na 12 ° C.

Zadnji dan analize uzeti su uzorci samo od prve četiri kategorije (8 banana), jer kategorije 5, 6 i 7 nisu više bile za uporabu.

Na dan klasifikacije (ponedjeljak 20. travnja) uzeta su po dva uzorka banana koji odgovaraju svakoj boji kategorije prema shemi COPLACA®. Smješteni su u hladnjak na 12ºC, pri čemu je došlo do promjene temperature te su neki od uzoraka brže dospijevali. Idućeg dana napravljena je nova klasifikacija u kojoj je kategorija 3 uzoraka prešla u kategoriju 4 te se u ovom eksperimentu izgubila kategorija 3.

4.1.3. Serija 3

Serija 3 sastoji se od 14 banana, za svaku kategoriju uzeta su 2 uzorka. Podaci su uzeti pet različitih dana. Analiza počinje 8. svibnja kada su uzorci uzeti iz skladišta tvrtke, razvrstani u kategorije i snimljene prve multispektralne slike. Nakon toga, multispektralne

slike napravljene su 11. svibnja 14. svibnja, 18. svibnja i 21. svibnja. Uzimanje podataka ovih uzoraka trajalo je 14 dana, uzorcima su u međuvremenu uskladišteni u hladnjak na 12 ° C.

4.2. Analiza čuvanja u kontroliranoj atmosferi

Uzeto je 12 kutija s uzorcima koje su stavljene u dvije različite komore za dospijevanje. Jedna komora radnog naziva *nova komora*, raspodjeljuje etilen s generatorom koji je postavljen na stropu. Druga, radnog naziva *stara komora*, injektira etilen sa stražnjeg dijela komore. U svakoj komori je stavljeno 6 kutija, iz svake kutije oduzeta su dva uzorka zelenih banana, što ukupno čini 12 uzoraka iz svake komore. Uzorci su postavljeni na tri pozicije u svakoj komori, četiri uzorka straga, četiri u sredini i četiri sprijeda. Multispektralne slike snimane su u laboratoriju, dana 25. svibnja, nakon čega su banane ponovo prebačene u komore za dospijevanje.

Nakon što su uzorci dozrijevali četiri dana u komorama, 29. svibnja uzeti su natrag u laboratorij na analizu. Iz iste kutije su također uzeti 24 nova uzorka. Novi uzorci uzeti su radi utvrđivanja hoće će biti razlike između uzoraka koji su bili cijelo vrijeme u komorama s onima koji su doživjeli stres prijenosom u laboratorij.

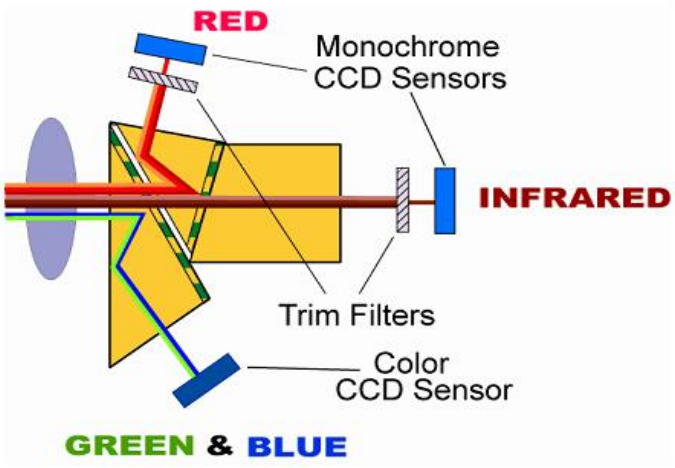
Za vrijeme eksperimenta u kontroliranim uvjetima, plodovi su skladišteni pod programiranim klimatskim uvijetima prikazanim u tablici 4.

Tablica 4. Program koji je vodio dozrijevanje banana

Dan	**1**	**2**	**3**	**4**	**5**	**Jedinica**
Trajanje	36	24	12	12	12	Hor
SP. Temp	18	17	16	15	14	°C
T.Max	20	20	20	20	20	°C
T.Min	12	12	12	12	12	°C
SP. Hum	95	90	75	70	70	%
H. Max	100	100	100	100	100	%
H. Min	50	50	50	50	50	%
Vent.OFF	30	30	30	30	30	Min
Vent. ON	24	24	24	24	24	Hor

4.3. Sustav multispektralnih slika

Sustav slika sastoji se od uređaja za sakupljanje slika, National Instruments, i tri CCD (fotosenzibilni senzor) prilagođenih kamera, DuncanTech / Redlake MS-3100 (Redlake Inc., USA). Optički obložen filter i CCD niz slika nalaze se na svakoj od tri izlaza prizme. Slike uzete iz svakog niza nastale su valnim duljinama svjetla koje su prošli kroz svaki optički put u prizmi. U ovim kamerama sklop prizme je dizajniran posebno za stjecanje crvene, zelene i plave boje vidljive duljine. Pojasni filteri su centrirani na 800 nm infracrveno (IR), 675 nm crveno (R) i 450 nm plavo (B), uz propusnost od 20 nm. Ove duljine su određene kao vrlo korisne u procjenjivanju karakteristike biljaka i organskih materijala.



Slika 4. RGB / CIR Spektralna konfiguracija

DuncanTech kamere su dostupne u tri standardizirane spektralne konfiguracije. RGB (crvena/red, zelena/green, plava/blue) konfiguracija osigurava visoku kvalitetu slika u boji. Infracrveno oslikavanje u boji (CIR- Color-infrared) temelji se na zelenim, crvenim i infracrvenim duljinama. Konačno, konfiguracija RGB / CIR daje crvene, zelene, plave i infracrvene valne duljine, ali rezolucija u zelenim i plavim valnim duljinama je donekle umanjena. RGB / CIR konfiguracija koristi prvi tanki (dikroični) filter da bi reflektirao zelene i plave valne duljine na prvom izlazu iz prizme. Drugi dikroični filter se koristi za izoliranje crvenog svjetla na drugom izlazu iz prizme. Monokromni CCD senzor ostvaruje crveno polje

u punoj rezoluciji. Konačno, treći monokromni CCD senzor koristi se za infracrveno svijetlo koje izlazi kroz stražnji dio prizme (slika 4).
Izvor svjetla daje šest halogenih žarulja od 100 W.

4.4. Ne-nadzorana (ward) metoda

Ne-nadzirom (Ward) klasifikacija voća provodi se pomoću histograma. Ne-nadzirana analiza prema Ward metodi (Ward, 1963) provedena je s ciljem definiranja referentne klase na temelju omjera slika (R680 / R800) histograma određenog skupa podataka. Razmotren je i višedimenzionalni prostor, gdje svaka dimenzija korespondira razini intenziteta histograma. Svaki histogram je predstavljen kao pojedina točku na višedimenzionalnom prostoru. Ward klasifikacijska metoda se primjenjuje za računanje matrica Euklidske udaljenosti između svakog para pojedinaca (histograma), grupiranje najbližih pojedinacai hijerarhijskim spajanjem grupa (ili pojedinaca) čiji kombinacije daju najmanju Ward povezanu daljinu (Ward Linkage Distance), to jest: minimalni porast u zbroj kvadrata novouspostavljene grupe (Lunadei, L., 2011).

Unutar skupine zbroj kvadrata u klasteru izračunava se kao zbroj kvadrata udaljenosti između svih objekata u klasteru i centralnog klastera.

Ward Linkage Distance (Dward) između dvije skupine A i B matematički je opisan kao:

Eq (1) $Dward(a,b) = SSab - [SSa + SSb]$

Tada je SS zbroj kvadrata unutar grupe a (SS_a), grupe b (SS_b) ili obje grupe spojene (SSab).

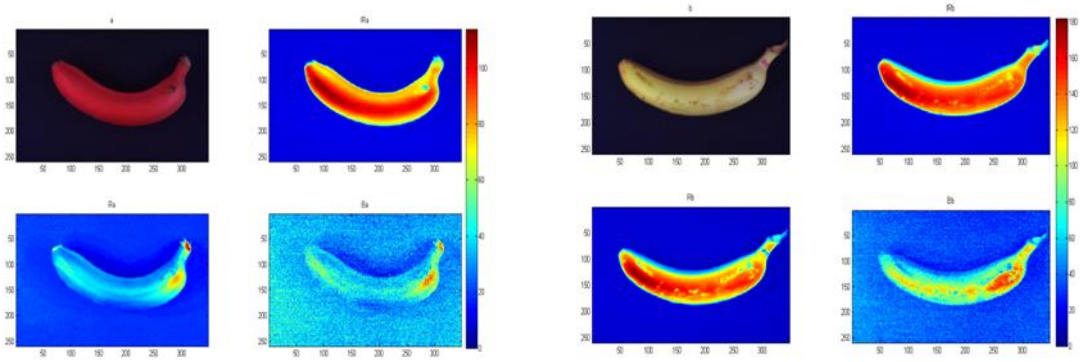
Kao prednost pred ostalim metodama određivanja klastera, Ward metoda uzima u obzir sve histograme uz određen broj podataka postavljenih na svakoj razini grupiranja, stvarajući tako vrlo dobro strukturirane i homogene grupe (Lunadei, L., 2011). Razvijen je u MatLab® 7,0 program kako bi se automatski generirale grupe prema maksimalnom Ward Linkage Distance. Prosječni histogram se izračuna za svaku ne-nadziranu grupu i definira kao referentna klasa.

5. REZULTATI I DISKUSIJA

5.1. Analiza slika i histograma procesa čuvanja na 12 °C

U kompjutorskom programu MATLAB analizirane su slike u tri valne duljine-kanala: crveni (R), infracrveni (IR), plavi (B), također crveni / infracrveni (R/IR) te njihovi histogrami. Za analizu faza dozrijevanja ploda najvažnije su crvene (R) i infracrvene (IR) duljine, jer se od tih slika u crvenoj duljini i omjerom R / IR izračunava svaki uzorak. Izračunati su i histogrami za regije određenih banana za obje vrste slika koji se koriste u daljnjoj analizi.

Slika 5. prikazuje primjer dviju banana koje pripadaju kategoriji 1 (lijevo) i kategoriji 7 (desno). Svaka slika sastoji se od četiri slike koje odgovaraju svakom kanalu te kombinaciji sva tri kanala. Infracrveni kanal jako dobro odvaja plod od pozadine te pokazuje vrlo dobro oblik ploda, ali ne i razliku razine zrelosti. Razina zrelosti bolje se razlikuje crvenim kanalom. Kako plodovi dozrijevaju u crvenom kanalu može se vidjeti porast reflekcije zbog degradacije kloroplasta. Banana iz kategorije 1 ima mali intenzitet boja te je jače vizualno pomiješana s pozadinom. To pokazuje da je ovaj plod vrlo nezrelo. S druge strane, banana iz kategorije 7 ima intenzivnu razinu boje, uglavnom najviše razine. To pokazuje da je ovaj plod vrlo zreo. Plavi kanal ne daje toliko informacija.

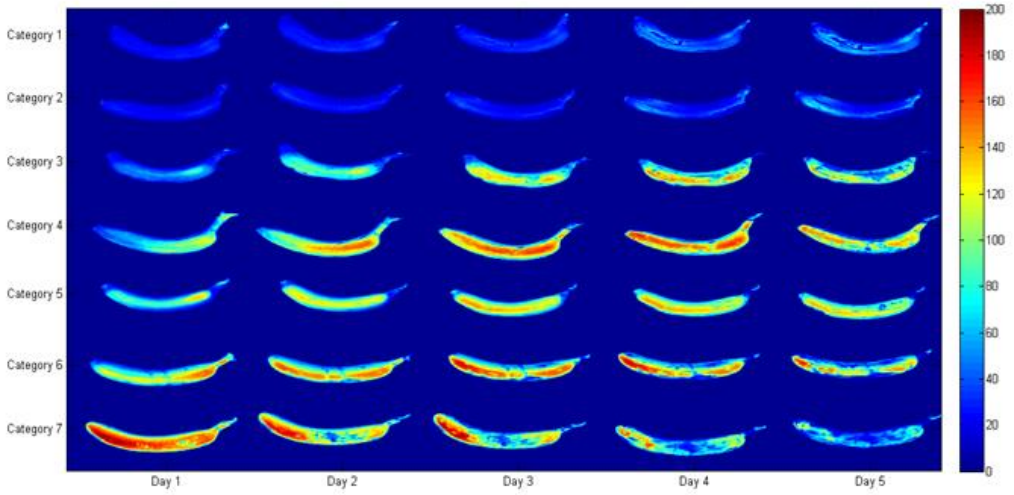


Slika 5. Banana iz kategorije 1 (lijevo), i banana iz kategorije 7 (desno). Obje slike su snimljene prvi dan analize. Svaka slika odvojena je u tri kanala, crveni kanal (Ra, Rb), infracrveni kanal (IRa, IRb) i plavi kanal (Ba, Bb). X i Y osi predstavljaju broj piksela slika. Vertikalna traka boja predstavlja razinu intenziteta slika.

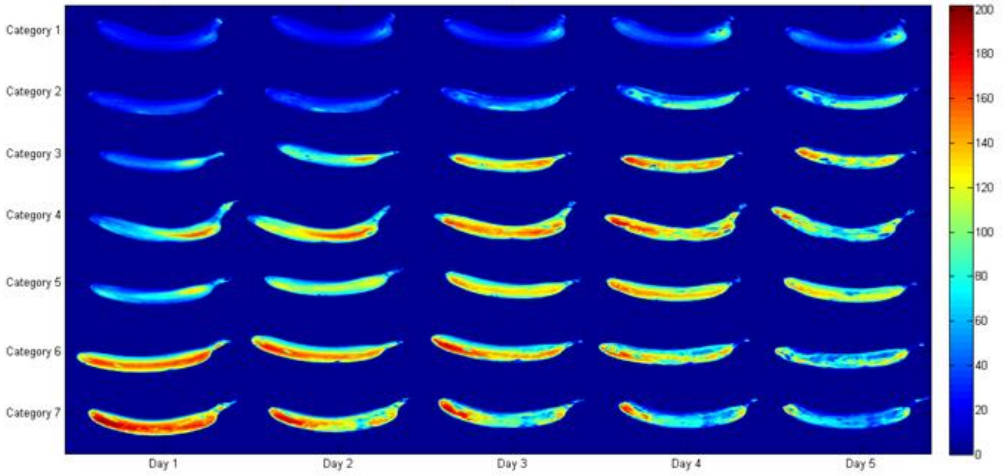
Slika 6 (a) prikazuje sedam banana (prva banana iz svake kategorije), slika 6(b) prikazuje drugih sedam banana (druga banana iz svake kategorije). Slike odgovaraju crvenom kanalu, ali su plodovi prethodno segmentirani od pozadine uporabom manualne granice aplicirane na infracrvene slike. Na slikama crvenog kanala, vrijednosti iznad intenziteta 23 snimljene kamerom odgovaraju plodu, dok razina intenziteta ispod 23 odgovara pozadini.

Prve dvije kategorije (1 i 2) predstavljaju banane koje su upravo stigle u skladište na tretman etilenom. Te banane su nezrele i zelene boje. Tijekom analize primjećeno je da ove dvije kategorije dozrijevaju vrlo polako, gotovo ništa, ostajući na 1. ili 2. kategoriji tijekom pet dana procesa dozrijevanja. Na slici 6 (b) može se uočiti da je banana 2 iz kategorije 2 počela dozrijevati 4. i 5.dana analize, ali jako teško bez tretmana etilenom. Prije dolaska na tržište banane se tretiraju četiri ili pet dana dozom etilena, kako bi mogle početi dozrijevati. Nakon toga prelaze u kategorije 3 i 4 koje su u savršenom stanju za odlazak na tržište. Na slici se može vidjeti da kategorije 3, 4 i 5 dozrijevaju normalno, postepeno te se posljednjih dana analize počinju raspadati. Nakon 13 dana bile su previše zrele za konzumaciju i tržište, žuto-smeđe kore u prirodnoj boji. Posljednje dvije kategorije se već drugi dan analize počinju raspadati jer su u laboratorij došle već prezrele. Zadnjih dana analize su potpuno smeđe boje, neupotrebljive. Na slikama se može vidjeti da s dozrijevanjem intenzitet svjetlosti koju reflektira banana povećan, a nakon što se plod počne raspadati intenzitet boje opet opada.

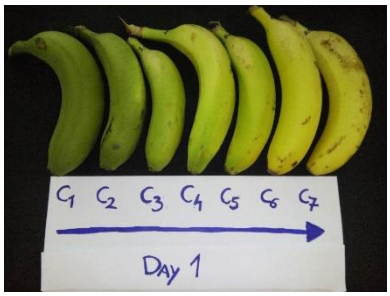
Moglo bi se zaključiti da se promatrano ponašanje događa zbog etilena: banana iz kategorije 3 je više primila određenu dozu etilena prije dolaska u laboratorij i one su pokazale određenu evoluciju.

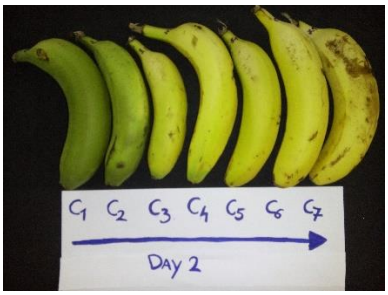


Slika 6.(a) Dozrijevanje sedam kategorija banana, prva banana iz svake kategorije, iz serije 3 tijekom pet dana. Prikazano je u crvenom kanalu, a plodovi su prethodno segmentirani od pozadine.



Slika 6. (b) Dozrijevanje sedam kategorija banana, druga banana iz svake kaegorije, iz serije 3 tijekom pet dana. Prikazani su crvenim kanalom, a plodovi su prethodno segmentirani od pozadine.





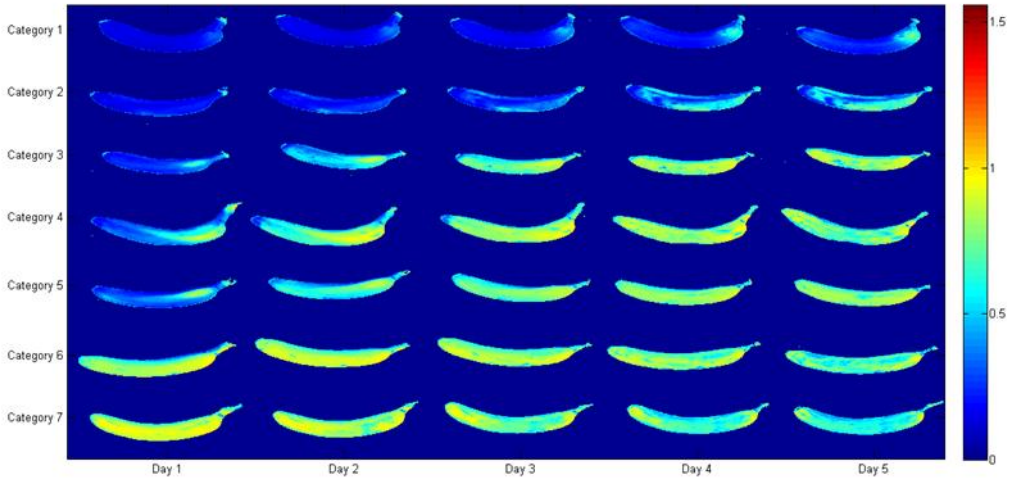




Slika 7. Plodovi banana snimljeni digitalnom kamerom. Sedam plodova, svaki iz jedne kategorije snimljeni su svakog dana analize, od 1. do 5.

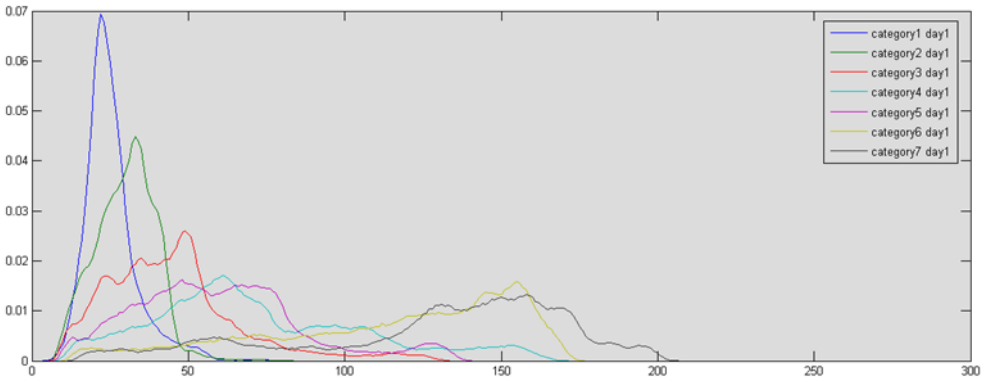
Usporedimo li sliku 6 (b) i sliku 7 koje prikazuju iste plodove kroz pet dana analize, možemo primijetiti da plodovi slikani digitalnom kamerom izgledaju zrelije nego što zapravo jesu. Kako digitalnom kamerom, tako i vizualno samim ljudskim okom možemo vidjeti samo površinsku koru ploda te ne možemo s pouzdanjem zaključiti koliko je taj plod zaista zreo. Na primjer banana kategorije 2 po shemi COPLACA® petog dana izgleda zrelo približno kao i kategorija 5 ili čak možda 6 prvog dana analize, dok se po multispektralnim slikama svrstava u 3. kategoriju. Takav doživljaj imamo samo zato što je kora već požutjela i počela dobivati smeđe mrlje, a taj plod je iznutra zapravo još relativno nezreo. Isto možemo primijeniti i na ostale plodove.

Prema Delwiche i sur., (1987.) navode Lleo i sur. (2009.), omjer R / IR pokazao se dobrim indeksom zrelosti za sortiranje žute Clingstone breskve. Slika 8. predstavlja R / IR sliku. Za granicu R / IR slike, regija slike koja odgovara plodu je identificirana sa IR razinom intenziteta višom od 23. Glavna prednost je naknadna kompenzacija promjenom svijetla i efekta oblika, no ne postoji tako velik učinak na konveksnost.

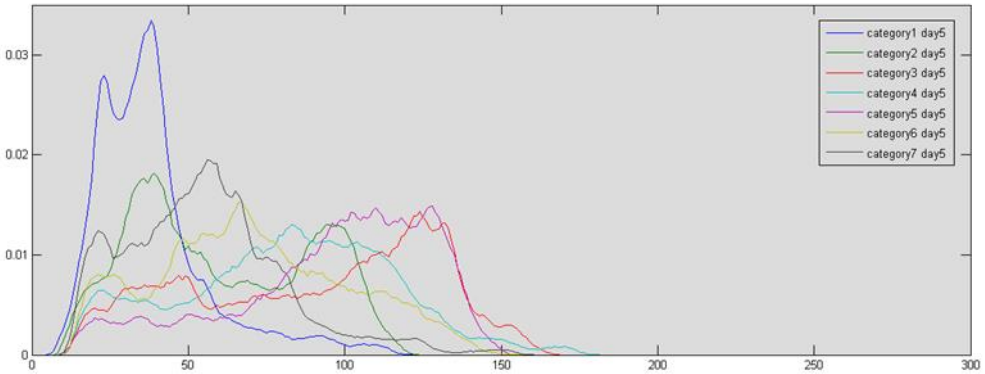


Slika 8. Sedam kategorija banana tijekom pet dana u omjeru refleksije R / IR.

Grafikon 2 (a, b) predstavlja histogram sedam banana, jedan iz svake kategorije, prvog i posljednjeg dana analize s obzirom na crveni kanal. X os predstavlja razinu intenziteta slike (od 0 do 255) i Y osi frekvenciju piksela za svaku razinu intenziteta. Na histogramu se vidi kako uzorci dozrijevaju od prvog do zadnjeg dana. Banane prvog dana su nezrele i njihovi odgovarajući histogrami su viših piksela na nižim razinama intenziteta, dok su histogrami banana posljednjeg dana s manje piksela na višim razinama intenziteta. To također može biti povezano sa sadržajem klorofila. Banane koje su nezrele imaju veći sadržaj klorofila koji se može vidjeti na grafikonu kao veći vrh, za razliku od zrelih banana koje imaju manji vrh i kod kojih je krivulja ujednačenija.

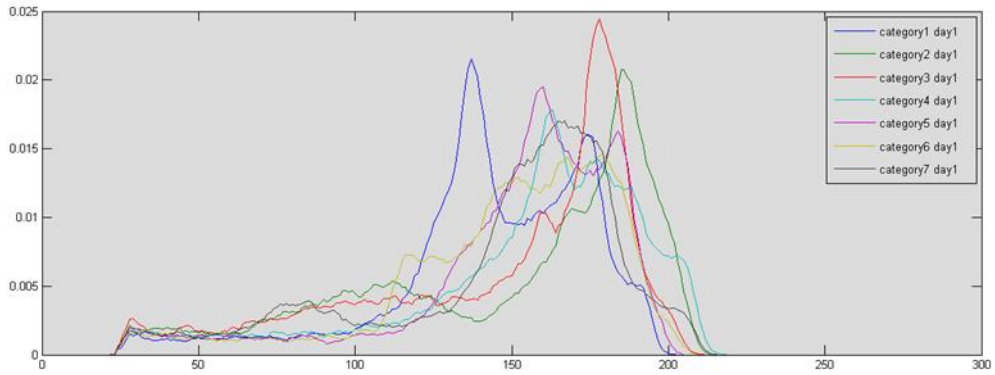


Grafikon 2(a) Histogram od sedam banana, prvog dana analize, svaki odgovara drugoj kategoriji (od 1-7) s obzirom na crveni kanal. X os predstavlja razinu intenziteta slike (od 0 do 255) i Y osi frekvencije piksela za svaku razinu intenziteta.

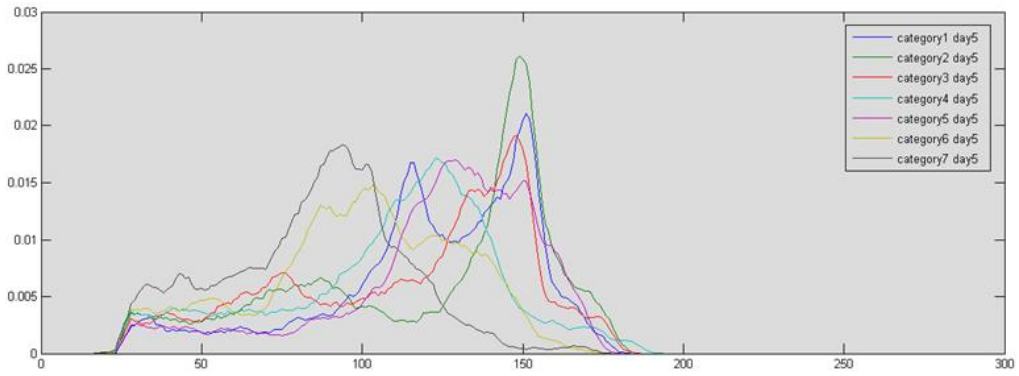


Grafikon 2(b) Histogram od sedam banana petog dana analize, svaki odgovara drugoj kategoriji, s obzirom na crveni kanal. X os predstavlja razinu intenziteta slike (od 0 do 255) i Y osi frekvencije piksela za svaku razinu intenziteta.

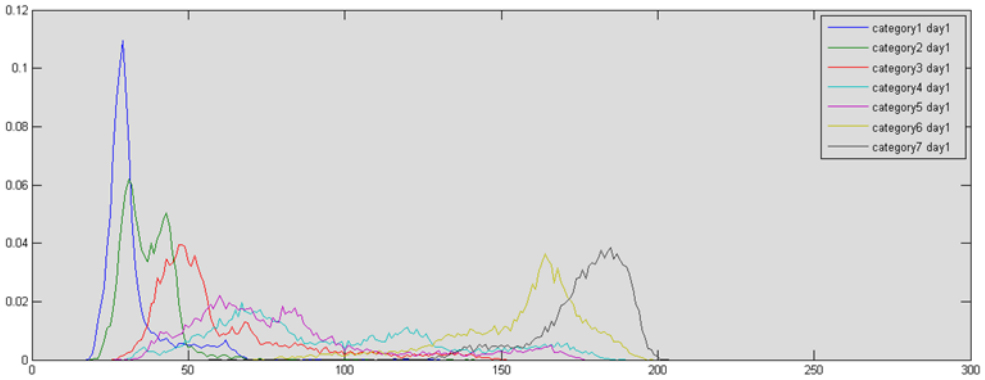
Na grafikonu 3 (a,b) može se vidjeti histogram od sedam banana, svaka odgovara drugoj kategoriji. Grafikon 3(a) predstavlja banane prvog dana analize, grafikon 3(b) predstavlja banane petog dana analize, s obzirom na infracrveni kanal. Iz histograma se može zaključiti da infracrveni kanal nije dobar za analiziranje zrenja plodova. Za razliku od tog grafikon 4(a,b) prikazuje iste plodove u R/IR omjeru, gdje se može vidjeti pravilno dozrijevanje plodova. Primjetna je veća razlika između plodova prvog i petog dana analize. Također na grafikonu 4(b) primjećuje se kako banana iz kategorije 1 ne dozrijeva te su njezini pikseli i dalje veći na nižim razinama intenziteta, što pokazuje da još uvijek ima jako puno klorofila u sebi te da je nezrela.



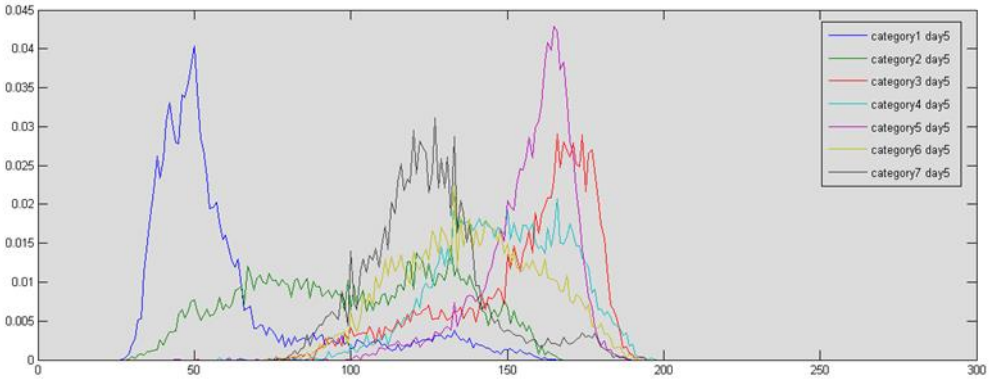
Grafikon 3(a) Histogram sedam plodova banana prvog dana analize, gdje svaki plod odgovara drugoj kategoriji (od 1-7) s obzirom na infracrveni kanal. X os predstavlja razinu intenziteta slike (od 0 do 255) i Y osi frekvencije piksela za svaku razinu intenziteta.



Grafikon 3(b) Histogram sedam banana petog dana analize, gdje svaki plod odgovara drugoj kategoriji (od 1-7) s obzirom na infracrveni kanal. X os predstavlja razinu intenziteta slike (od 0 do 255) i Y osi frekvencije piksela za svaku razinu intenziteta.



Grafikon 4(a) Histogram sedam plodova banana prvog dana analize, gdje svaki plod odgovara drugoj kategoriji s obzirom na omjer refleksije R / IR. X os predstavlja razinu intenziteta slike (od 0 do 255) i Y osi frekvencije piksela za svaku razinu intenziteta



Grafikon 4(b) Histogram sedam banana petog dana analize, gdje svaki plod odgovara drugoj kategoriji s obzirom na omjer refleksije R / IR. X os predstavlja razinu intenziteta slike (od 0 do 255) i Y osi frekvencije piksela za svaku razinu intenziteta.

3.2. Analiza slika i histograma u analizi čuvanja u kontroliranoj atmosferi

S obzirom da je nakon prvog eksperimenta zaključeno da prve dvije kategorije ne dozrijevaju, želi se prikazati kako te dvije kategorije dozrijevaju uz prisutstvo određene koncentracije etilena. Slike 9 (a,b) i 10 (a,b) predstavljaju banane iz drugog eksperimenta koje su bile skladištene u kontroliranoj atmosferi, u dvije različite komore, kako bi vidjeli postoji li razlika u učinkovitosti između te dvije komore. Slika 9 (a,b) segmentirana je crvenim

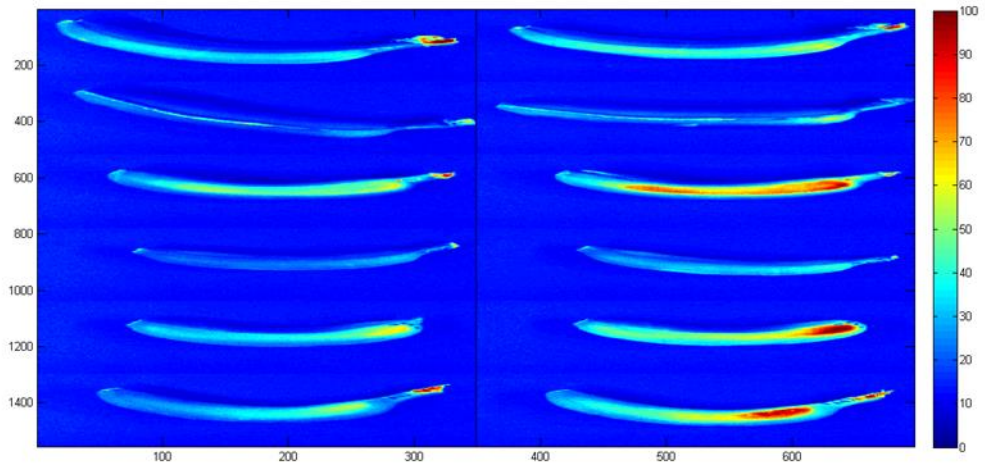
kanalom, dok je slika 10 (a,b) segmentirana R/IR kanalom, gdje možemo primijetiti da je u analizi bolje koristiti crveni kanal jer se puno lakše raspoznaju stadiji zrelosti.

Slika 9 (a) prikazuje banane iz stare komore koja injektira etilen u dozama sa stražnje strane komore. Na lijevoj strani slike su uzorci prije tretmana etilenom, a na desnoj strani nalaze se uzorci koji su četiri dana tretirani u komori s etilenom. Može se vidjeti da su svi uzorci zreliji nakon tretmana te spadaju u kategoriju 3. Također se može primijetiti da plodovi nisu podjednako zreli. Banana u drugom i četvrtom redu još uvijek pripada kategoriji 2 po svojoj zrelosti, ali su oni također bili manje zreli prvog dana eksperimenta. Njima bi trebao još jedan dan tretmana etilenom kako bi postigle nivo zrelosti za tržište. To pokazuje da je kategorizacija plodova prije nego što se stave u komoru važna, što je kod banana ključan problem, jer dolaze u grozdovima, u kojem će se to uvijek događati pošto je jedan zreliji od drugog.

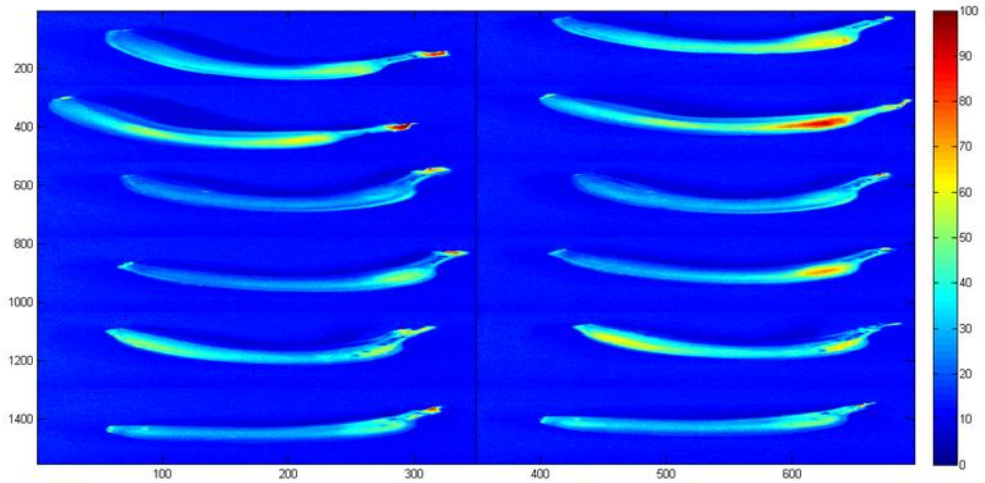
Slika 9 (b) prikazuje banane iz nove komore koja čini raspodjelu etilena s generatorom koji je postavljen na stropu. Na lijevoj strani slike su uzorci prije distribucije etilena, dok su na desnoj strani uzorci nakon tretiranja četiri dana u komori s etilenom. Može se primijetiti da uzorci dozrijevaju sporije nego u starijoj komori.

Može se reći da je starija komora bolja, jer plodovi dozrijevaju brže, ali također treba analizirati i druge činjenice. Može biti slučaj da nova komora treba različitu dozu etilena, jer je distribucija drugačiji nego kod stare te bi za jedan dan više u komori bile iste kao u staroj. Isto tako možemo vidjeti da su uzorci iz komore 2 podjednako zreli, što može biti slučaj podjednake prvotne kategorizacije ili bolje raspodjele etilena, što u konačnici može biti prednost.

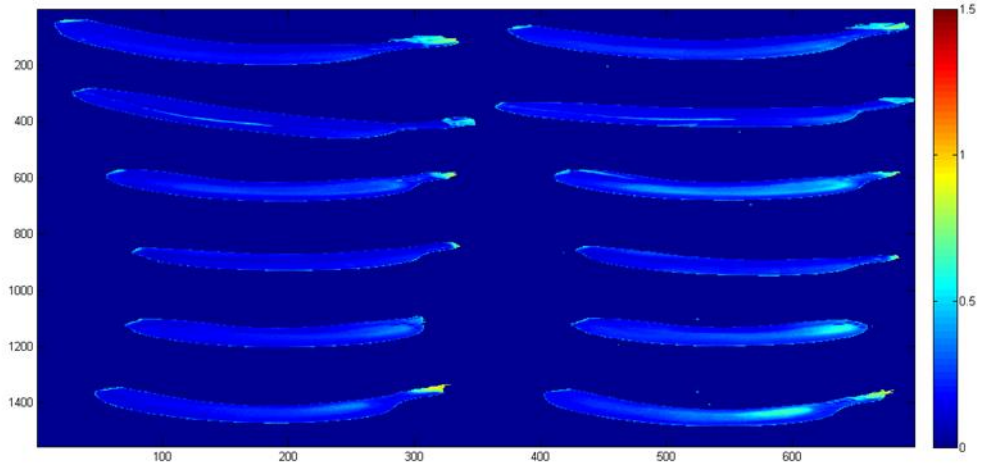
Na obje slike, prva dva reda pripadaju uzorcima koji su bili smješteni u stražnjem dijelu komore, trećeg i četvrtog reda uzorcima smještenim u sredini, a zadnja dva smještena naprijed. Može se vidjeti da ne postoji znatna razlika između ta tri mjesta. Uzorci koji su bili zreliji prvi dan, prije etilena, također su zreliji nakon tretmana etilenom. To pokazuje da pozicija u komori nije važna za dozrijevanje plodova, jer etilen dolazi podjednako do svih plodova.



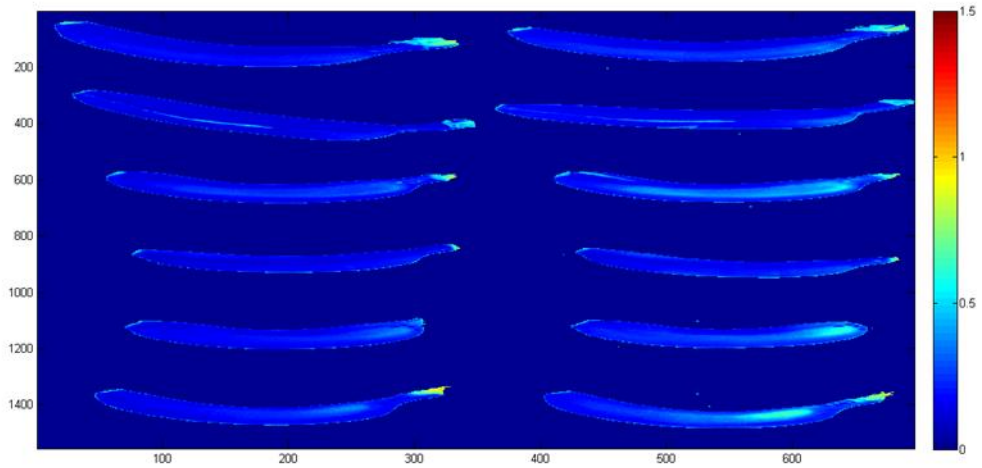
Slika 9(a) Plodovi banane iz drugog eksperimenta, snimljeni u crvenom kanalu. Prikaz banana iz stare komore, s lijeve strane nalaze se uzorci prije injekcije etilena, s desne strane uzorci nakon četiri dana tretmana u komori s etilenom. Prva dva reda pripadaju uzorcima koji su bili smješteni u stražnjem dijelu komore, treći i četvrti red uzorcima u sredini komore te zadnja dva reda uzorcima s prednje strane komore.



Slika 9(b) Plodovi banane iz drugog eksperimenta, snimljeni u crvenom kanalu. Prikaz banana iz nove komore, s lijeve strane nalaze se uzorci prije distribucije etilena, a na desnoj strani su uzorci nakon četiri dana tretmana u komori s etilenom. Prva dva reda pripadaju uzorcima koji su bili smješteni u stražnjem dijelu komore, treći i četvrti red uzorcima u sredini komore te zadnja dva reda uzorcima s prednje strane komore.



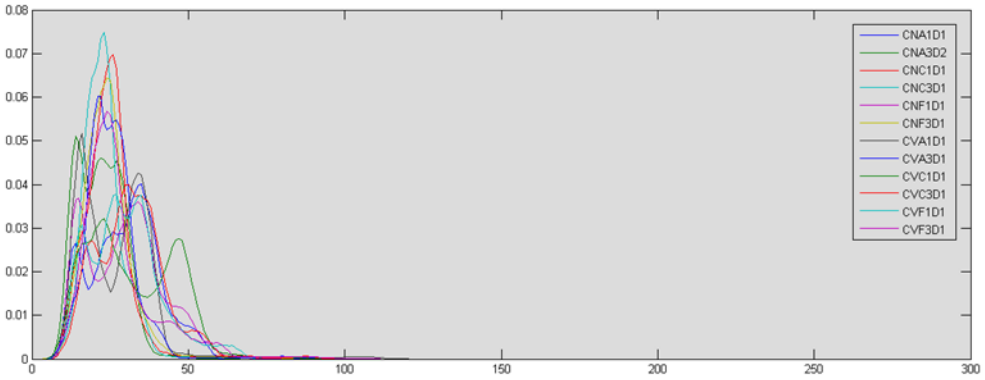
Slika 10 (a) Prikazuje iste uzorke banana kao na slici 9(a), u odnos refleksiju R / IR.



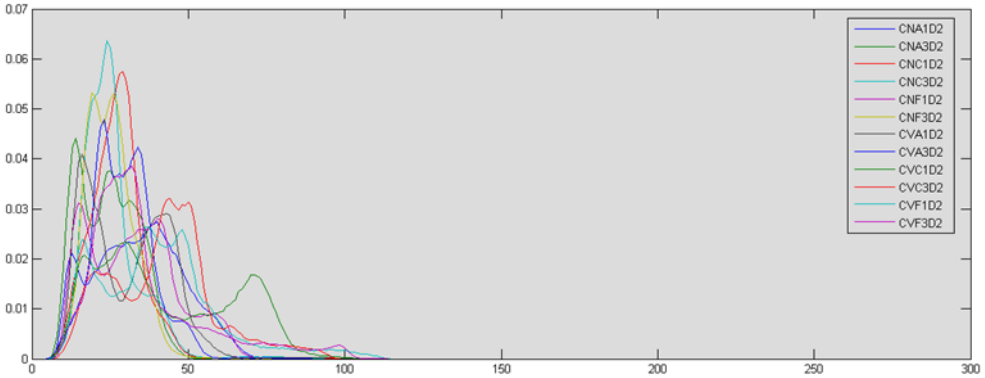
Slika 10(b) Prikazuje iste uzorke banana kao na slici 9 (b), u odnos refleksiju R / IR.

Grafikon 5(a,b) predstavlja histograme uzoraka banana iz drugog eksperimenta u crvenom kanalu. Grafikon 5(a) prikazuje uzorke prvog dana analize, uzeta su po dva uzorka iz svakog položaja u komori, odnosno šest uzoraka iz svake komore, sve zajedno 12 uzoraka banana. Grafikon 5(b) prikazuje uzorke iz drugog (posljednji) dan analize, uzeta su po dva uzorka iz svakog položaja u komori, odnosno šest uzoraka iz svake komore, sve zajedno 12 uzoraka banana.

Može se vidjeti da histogrami banana od prvog dana analize pokazuje više piksela na nižim razinama intenziteta. Nije velika razlika u odnosu na histogram banana od zadnjeg dana analize, iako histogram posljednjeg dana analize pokazuje nešto manje piksela na nižim razinama intenziteta, a više na višim razinama intenziteta. Možemo zaključiti da su uzorci zreliji nakon tretiranja etilenom u trajanju od četiri dana.



Grafikon 5(a,b) Histogrami uzoraka plodova banana iz drugog eksperimenta u crvenom kanalu. Prikazuje uzorke prvog dana analize, dva uzorka sa svakog položaja u komori, odnosno šest uzoraka iz svake komore, sve zajedno 12 uzoraka banana. X os predstavlja razinu intenziteta slike (od 0 do 255) i Y osi frekvencije piksela za svaku razinu intenziteta.



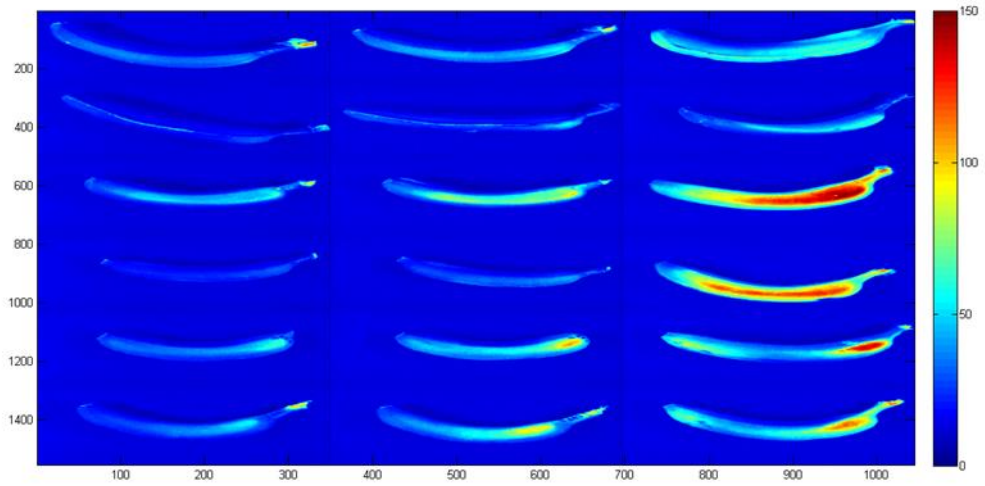
Grafikon 5(b) Histogrami uzoraka plodova banana iz drugog eksperimenta u crvenom kanalu. Prikazuje uzorke iz drugog (posljednjeg) dan analize, dva uzorka svakog položaja u komori, odnosno šest uzoraka iz svake komore, sve zajedno 12 uzoraka banana. X os predstavlja razinu intenziteta slike (od 0 do 255) i Y osi frekvencije piksela za svaku razinu intenziteta.

Slika 11(a,b) prikazuje usporedbu banana prije tretmana etilenom i nakon tretmana u crvenom kanalu, dok slika 12(a,b) prikazuje iste plodove samo u R/IR kanalu. U prvom stupcu prikazane su banane prvog dan analize, prije tretmana etilenom. Drugi stupac prikazuje banane nakon tretmana etilenom. Ovi uzorci su isti od prvog dana analize. Posljednji stupac prikazuje banane koje su od prvog dana u komorama, one nisu pretrpjele stres transportiranjem u laboratorij.

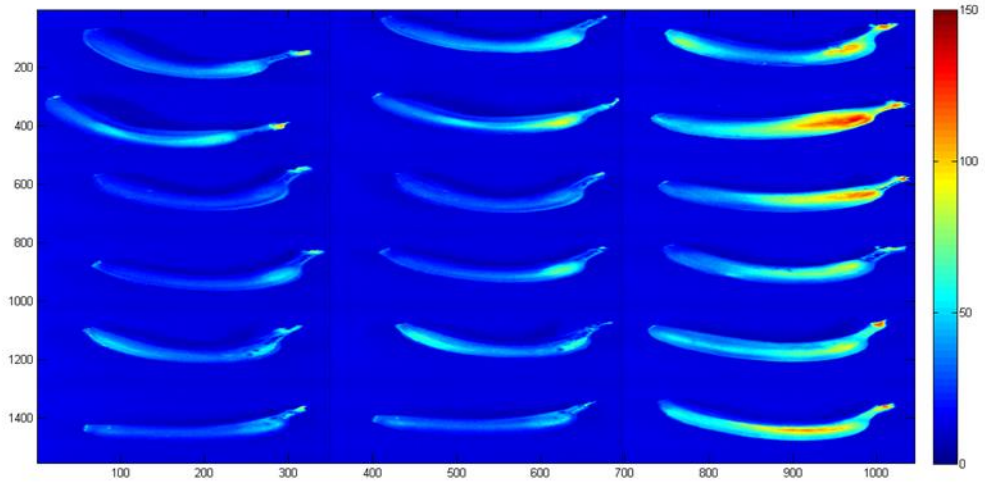
Na obje slike, prva dva reda pripadaju uzorcima koji su bili smješteni u stražnjem dijelu komore, treći i četvrti red uzorcima u sredini komore te zadnja dva uzorcima s prednje strane komore.

Slika 11(a) predstavlja uzorke iz stare komore, dok slika 11(b) predstavlja uzorke iz nove komore.

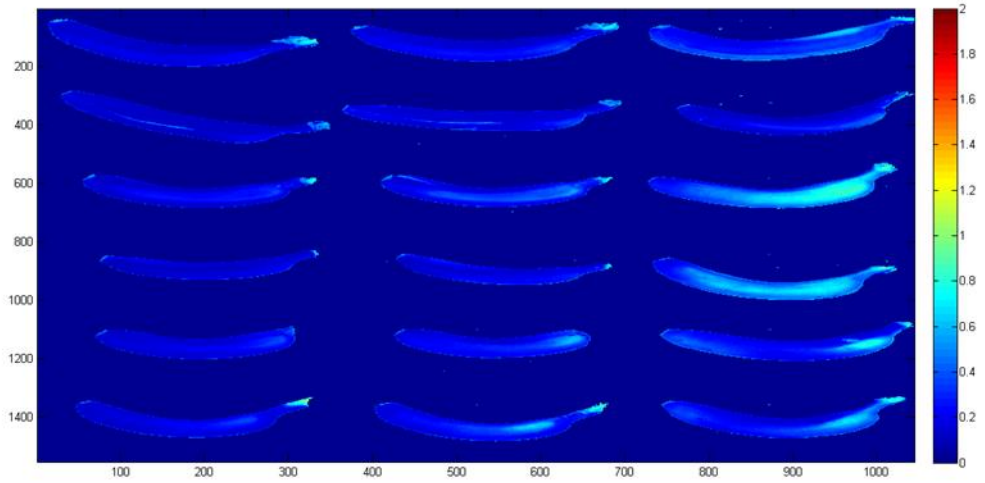
Banane iz trećeg stupca su od prvog dana analize u komorama sa kontroliranim uvjetima. Može se primijetiti da su zrelije od ostalih uzorka te zaključujemo da bi i ostali uzorci u istim uvijetima bili podjednako zreli. Dokazano je da banane dozrijevaju, tj. prelaze iz prve dvije kategirije jedino uz prisutstvo etilena.



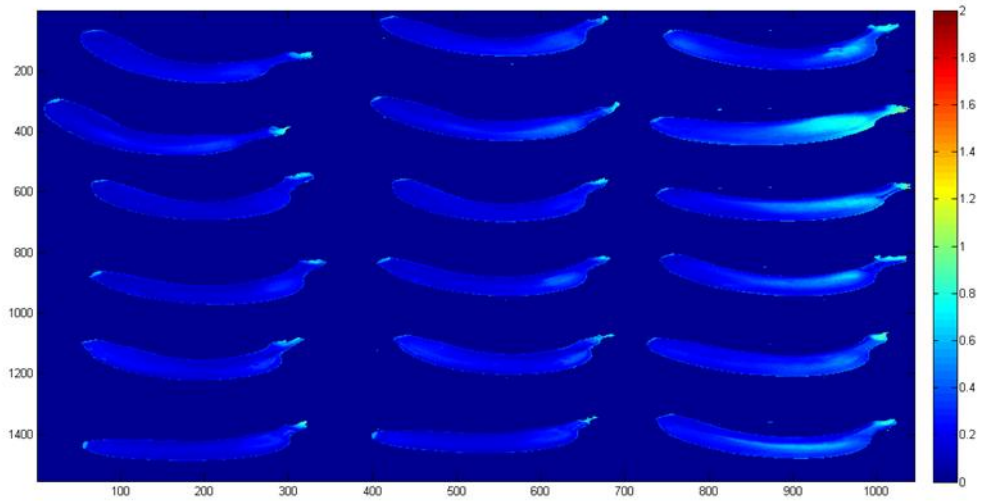
Slika 11(a) Usporedba uzoraka iz stare komore prije tretmana etilenom i nakon tretmana etilenom u crvenom kanalu.



Slika 11(b) Usporedba uzoraka iz nove komore prije tretmana etilenom i nakon tretmana u crvenom kanalu

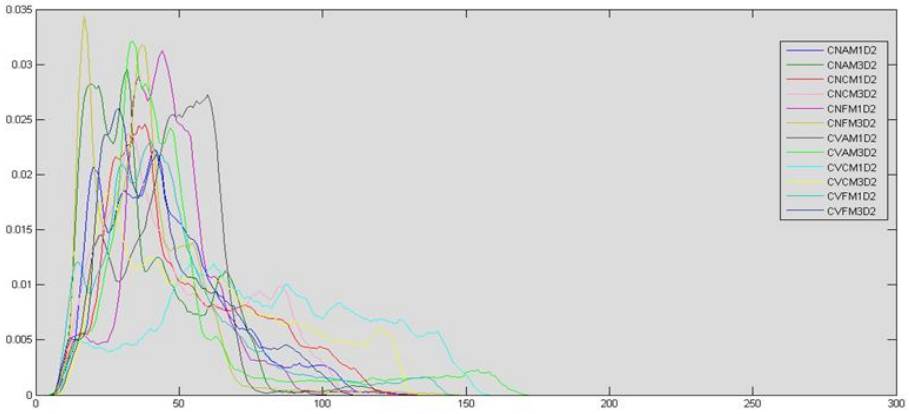


Slika 12 (a) Usporedba uzoraka iz stare komore prije tretmana i nakon tretmana u odnosu refleksije R / IR.

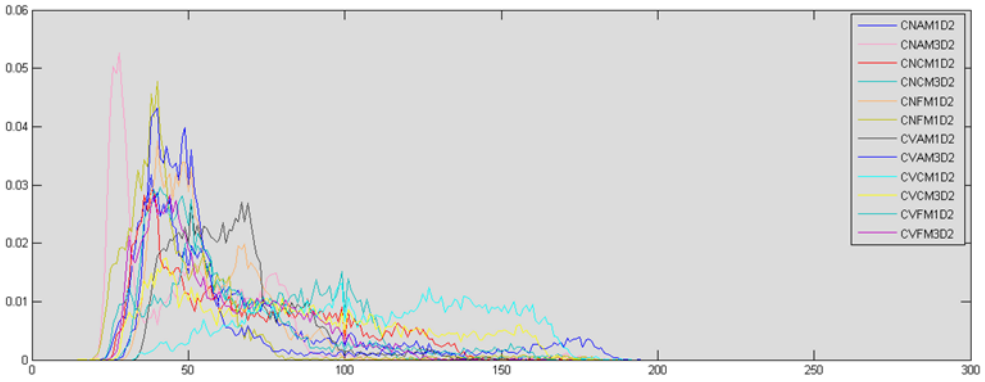


Slika 12 (b) Usporedba uzoraka iz nove komore prije tretmana i nakon tretmana u odnosu refleksije R / IR.

Grafikon 6 predstavlja histogram u crvenom kanalu banana koje su normalno dozrijevale u komorama s etilenom. Prikazuje banane iz stare i nove komore, po dva uzorka iz svakog položaja u komori. Grafikon 7 prikazuje iste plodove samo u omjeru R/IR.



Grafikon 6. Histogram plodova banana u crvenom kanalu koje su dozrijevale normalno u komorama s etilenom. X os predstavlja razinu intenziteta slike (od 0 do 255) i Y osi frekvencije piksela za svaku razinu intenziteta. Prikazuje banane iz stare i nove komore, po dva uzorka iz svakog položaja u komori.



Grafikon 7. Histogram u R / IR omjeru plodova banana koje su normalno dozrijevale u komorama s etilenom. X os predstavlja razinu intenziteta slike (od 0 do 255) i Y osi frekvencije piksela za svaku razinu intenziteta. Prikazuje banane iz stare i nove komore, po dva uzorka iz svakog položaja u komori.

6. ZAKLJUČAK

Cilj diplomskog rada je istraživanje i determiniranje različitih faza zrelosti ploda banane analizom multispektralnih slika i usporedba rezultata sa standardnom metodom procjene zrelosti pomoću sheme COPLACA®.

Istraživanje je provedeno na bananama (*Musa* AAA) vrste Cavendish s Kanarskih Otoka kroz podjelu prema sedam kategorija definiranih prema boji kore u serijama po sedam plodova i u dvije serije od 14 plodova. Plodovi su se čuvali 16 dana na 12°C, a zatim su se uzimala 24 ploda koja su izložena djelovanju etilena u trajanju od 4 dana tijekom kojih su se snimale multi spektralne slike uzoraka, koje su kasnije analizirane u programu MATLAB.

Prije izvedbe istraživanja uzeto je u obzir kako su u multispektralnim slikama važna dva vidljiva područja: 680 nm koji se odnose na sadržaj klorofila i 450 nm koji se odnose na sadržaj karotenoida. Prema visokom udjelu klorofila u plodu banane utvrđuje se nezrelost ploda.

Istraživanje je pokazalo kako infracrveni kanal jako dobro odvaja plod od pozadine te pokazuje vrlo dobro oblik ploda, ali ne pokazuje razliku razine zrelosti. Razina zrelosti bolje se razlikuje crvenim kanalom. Kako plodovi dozrijevaju u crvenom kanalu može se vidjeti porast refleksije zbog degradacije kloroplasta.

Pokazalo se kako je etilen ključan pri dozrijevanju plodova te kako kategorije koje nisu bile izložene određenoj koncentraciji etilena nisu postigle jednaku zrelost. Dodatno je taj zaključak potkrijepljen drugim dijelom istraživanja u komorama s kontroliranom atmosferom, gdje su banane četiri dana bile izložene tretiranju etilenom.

Tijekom istraživanja upotrijebljene su dvije komore. U jednoj komori se etilen raspršuje od stražnje strane komore prema naprijed, a u drugoj se s vrha komore etilen raspršuje u dozama prema dolje. Plodovi banane su raspoređeni u sve dijelove obiju komora kako bi se ispitala eventualna razlika u utjecaju etilena. Pokazalo se kako položaj ploda u komori nije utjecao na njegovo sazrijevanje. Komora u kojoj je etilen raspršivan sa stražnje strane pokazala se kao bolje rješenje pošto plodovi dozrijevaju brže, ali također u sljedećim istraživanjima treba analizirati i druge činjenice.

Konačno se može zaključiti kako bi bilo uputno u strojeve za sortiranje uvrstiti multi spektralne kamere zbog ograničenja ljudskog oka, koje nije u mogućnosti determinirati procese u pulpi ploda banane.

7. POPIS LITERATURE

- Blasco, J., Aleixos, N., Gómez, J., & Moltó, E. (2007). Citrus sorting by identification of the most common defects using multispectral computer vision. Journal of Food Engineering, 83(3), 384-393.
- Diezma, B., Lleó, L., Franco, S., Presečki, T., Ruiz-Altisent, M., & Roger, J. M., (2016). Multispectral and hyperspectral imaging for monitoring banana ripeness. CIGR-AgEng conference, Jun. 26-29.2016 Aarhus, Denmark.
- Diezma, B., Lleó, L., Roger, J. M., Herrero-Langreo, A., Lunadei, L., & Ruiz-Altisent, M. (2013). Examination of the quality of spinach leaves using hyperspectral imaging. Postharvest Biology and Technology, 85, 8-17.
- Gao, H., Zhu, F., & Cai, J. (2009). A review of non-destructive detection for fruit quality. In International Conference on Computer and Computing Technologies in Agriculture (pp. 133-140). Springer Berlin Heidelberg.
- Gowen, A. A., O'Donnell, C., Cullen, P. J., Downey, G., & Frias, J. M. (2007). Hyperspectral imaging–an emerging process analytical tool for food quality and safety control. Trends in Food Science & Technology, 18(12), 590-598.
- Jaiswal, P., Jha, S. N., & Bharadwaj, R. (2012). Non-destructive prediction of quality of intact banana using spectroscopy. Scientia Horticulturae, 135, 14-22.
- Jaiswal, P., Jha, S. N., & Bharadwaj, R. (2012). Non-destructive prediction of quality of intact banana using spectroscopy. Scientia Horticulturae, 135, 14-22.
- Lleó, L., Barreiro, P., Ruiz-Altisent, M., & Herrero, A. (2009). Multispectral images of peach related to firmness and maturity at harvest. Journal of Food Engineering, 93(2), 229-235.
- Lleó, L., Roger, J. M., Herrero-Langreo, A., Diezma-Iglesias, B., & Barreiro, P. (2011). Comparison of multispectral indexes extracted from hyperspectral images for the assessment of fruit ripening. Journal of Food Engineering, 104(4), 612-620.
- Lorente, D., Aleixos, N., Gómez-Sanchis, J., Cubero, S., García-Navarrete, O. L., & Blasco, J. (2012). Recent advances and applications of hyperspectral imaging for fruit and vegetable quality assessment. Food and Bioprocess Technology, 5(4), 1121-1142.

- Lunadei, L., Galleguillos, P., Diezma, B., Lleó, L., & Ruiz-Garcia, L. (2011). A multispectral vision system to evaluate enzymatic browning in fresh-cut apple slices. Postharvest Biology and Technology, 60(3), 225-234.
- Merzlyak, M. N., Solovchenko, A. E., & Gitelson, A. A. (2003). Reflectance spectral features and non-destructive estimation of chlorophyll, carotenoid and anthocyanin content in apple fruit. Postharvest Biology and Technology, 27(2), 197-211.
- Paull, R. E., & Duarte, O. (2011). Tropical fruits (Vol. 1). CABI.
- Qin, J., Chao, K., Kim, M. S., Lu, R., & Burks, T. F. (2013). Hyperspectral and multispectral imaging for evaluating food safety and quality. Journal of Food Engineering, 118(2), 157-171.
- Robinson, J. C., & Saúco, V. G. (2010). Bananas and plantains (Vol. 19). Cabi.
- Ward Jr, J. H. (1963). Hierarchical grouping to optimize an objective function. Journal of the American statistical association, 58(301), 236-244.
- Wu, D., & Sun, D. W. (2013). Advanced applications of hyperspectral imaging technology for food quality and safety analysis and assessment: A review—Part I: Fundamentals. Innovative Food Science & Emerging Technologies, 19, 1-14.
- Wu, D., & Sun, D. W. (2013). Advanced applications of hyperspectral imaging technology for food quality and safety analysis and assessment: a review—part II: applications. Innovative Food Science & Emerging Technologies, 19, 15-28.
- Zerbini, P. E. (2006). Emerging technologies for non-destructive quality carotenoid and anthocyanin content in apple fruit. Postharvest Biology and Technology, 27(2), 197-211.
- Zerbini, P. E. (2006). Emerging technologies for non-destructive quality evaluation of fruit. Journal of fruit and ornamental plant research, 14, 13.

Internet izvori:

http://www.fao.org/docrep/006/t0308e/T0308E03.htm -pristupila 28.8.2016.

http://www.freshplaza.com/article/93136/Canary-Islands-banana-opening-new-markets-in-Europe -pristupila 18.9.2016