

# Pregled metoda za detekciju neispravnosti na različitim proizvodima

---

**Tomašić, Branimir**

**Undergraduate thesis / Završni rad**

**2018**

*Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj:* **Josip Juraj Strossmayer University of Osijek, Faculty of Electrical Engineering, Computer Science and Information Technology Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek**

*Permanent link / Trajna poveznica:* <https://um.nsk.hr/um:nbn:hr:200:403519>

*Rights / Prava:* [In copyright](#)/[Zaštićeno autorskim pravom.](#)

*Download date / Datum preuzimanja:* **2025-01-27**

*Repository / Repozitorij:*

[Faculty of Electrical Engineering, Computer Science and Information Technology Osijek](#)



**SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU  
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I  
INFORMACIJSKIH TEHNOLOGIJA**

**Preddiplomski studij računarstva**

**PREGLED METODA ZA DETEKCIJU NEISPRAVNOSTI  
NA RAZLIČITIM PROIZVODIMA**

**Završni rad**

**Branimir Tomašić**

**Osijek, 2018.**

# SADRŽAJ

1. UVOD.....	1
1.1. Zadatak završnog rada.....	1
2. TEKSTILNA INDUSTRIJA .....	2
2.1. Strukturni pristup .....	3
2.2. Statistički pristup .....	3
2.2.1. Matrica prostornih ovisnosti intenziteta piksela .....	4
2.2.2. Autokorelacije .....	4
2.2.3. Matematičko-morfološki pristup .....	5
2.3. Spektralni pristup.....	6
2.3.1. Fourierova transformacija .....	6
2.3.2. Gaborova transformacija .....	7
2.4. Pristup temeljen na modelu .....	8
2.4.1. Autoregresivni model.....	8
2.4.2. Gauss Markov model nasumičnog polja .....	9
2.5. Pristup strojnog učenja.....	9
2.6. Hibridni pristup.....	10
2.7. Baze slika .....	10
2.7.1. TILDA Textile Texture Database .....	10
2.7.2. i-bug: The Fabric Dataset .....	10
2.7.3. AITEX: Fabric Image Database .....	11
3. KERAMIČKA INDUSTRIJA .....	12
3.1. Metode filtriranja .....	13
3.1.1. Waveletova transformacija.....	13
3.1.2. Countorletova transformacija .....	13
3.1.3. Genetički algoritam.....	14
3.1.4. ICA algoritam.....	14
3.1.5. Neuronske mreže .....	15
3.1.6. Gaborovi filteri .....	15
3.2. Algoritmi strukture.....	15
3.2.1. Morfološki algoritam .....	16
3.2.2. Detekcija ruba.....	16

3.3.	Pristup temeljen na modelu .....	17
3.3.1.	Skriveni Markov model.....	18
3.3.2.	Autoregresivni model.....	18
3.4.	Statističke metode .....	18
3.4.1.	Histogram krivulja .....	18
3.4.2.	Weibullova raspodjela.....	19
3.5.	Baza slika .....	19
3.5.1.	VxC TSG Image Database for Surface .....	20
3.5.2.	VisTex database.....	20
4.	DRVNA INDUSTRIJA .....	21
4.1.	Algoritmi izvlačenja dijela .....	22
4.2.	Algoritmi otkrivanja ruba.....	22
4.2.1.	Gradijent smjera.....	23
4.2.2.	Shiozakijeva entropija.....	23
4.3.	Pragni algoritam.....	24
4.3.1.	Otsuova metoda .....	25
4.3.2.	Kapurova entropija.....	25
4.3.3.	Matrica prijelaza .....	25
4.4.	Baza slika .....	25
4.4.1.	Lumber Grading.....	25
4.4.2.	The Wood Database .....	26
5.	ZAKLJUČAK .....	27
	LITERATURA .....	28
	SAŽETAK.....	33
	ABSTRACT .....	34
	ŽIVOTOPIS.....	35
	DODATNI PRILOZI .....	36

## **1. UVOD**

U današnjici proizvodnja tekstila, keramičkih pločica i drvenih proizvoda automatiziran je proces. Traže se dodatni načini kako bi se što više povećala efikasnost proizvodnje i smanjila neispravnost proizvoda. Cilj ovog završnog rada je dati analizu za neke od metoda kojima se provjerava neispravnost pojedinih proizvoda, temeljene na obradi slike u stvarnom vremenu. Uz to potrebno je istražiti postojeće baze slika navedenih proizvoda i objasniti karakteristike pojedine baze.

U drugom poglavlju navedene su i pojašnjene svrhe i razlike metoda koje se koriste za provjeru neispravnosti u tekstilnoj industriji. Uz to navedene su i baze slika koje su se koristile u testiranju navedenih metoda. Treće poglavlje govori o metodama u keramičkoj industriji, kao i o bazama slika za te metode. U četvrtom poglavlju predstavljene su metode u drvenoj industriji. Također su navedene i odgovarajuće baze slika korištene pri testiranju tih metoda. Zadnje poglavlje zaključuje rad.

### **1.1. Zadatak završnog rada**


Zadatak završnog rada je napisati pregled metoda temeljene na obradi slike za detekciju neispravnosti na proizvodima kao što su: tekstil, keramičke pločice, drveni proizvodi i sl. Također je potrebno istražiti postojeće baze slika navedenih proizvoda te objasniti karakteristike pojedine baze.

## 2. TEKSTILNA INDUSTRIJA

Proizvodnja tekstila uobičajeno se vrši na strojevima za tkanje i pletenje. Tkanina se pravi od niti tekstila, koje su najčešće prirodnog podrijetla, kao pamuk. Uz pamuk, često se koristi i vuna kao prirodna sirovina. Od sirovina ostalog podrijetla najčešće se koriste sintetička vlakna. Kako su strojevi za tkanje automatizirani oni imaju zadane dimenzije i brzinu proizvodnje. Tipične dimenzije kreću se od jednog do tri metra širine s brzinom proizvodnje od 20 do 200 m/min. Iz tog razloga postoje i različita vremena rada (engl. *real-time*) koja se koriste za detekciju pogreške. Vremena se razlikuju, a prosječno vrijeme koje se koristi za pregled jednog metra tkanine, širine 1 m, iznosi 250 mm/s [1].

U tekstilnoj industriji, definirano je više od 70 različitih pogrešaka u tkanju [2]. One se mogu podijeliti na dvije kategorije: promjene boje na površini i nepravilnost lokalne teksture [3]. Neke od najučestalijih pogrešaka u tkanju su prikazane na slici 2.1., a one su:

- puknuće igle tijekom tkanja (slika 2.1. a),
- zakretanje tkanja (slika 2.1. b), koje nastaje zbog zakrenute niti,
- zadebljanje niti tkanine (slika 2.1. c), nastaje zbog nepravilnosti same niti,
- rupa u tkanini (slika 2.1. d), čiji je najčešći uzrok neispravn stroj,
- neželjeno šivanje (slika 2.1. e), nastaje neželjenim kretanjama mehanizma i
- mrlje hrđe (slika 2.1. f), koje nastaju zbog istjecanja maziva ili hrđe.



Sl. 2.1. Primjeri pogrešaka u tkanju: a) puknuće igle tijekom tkanja, b) zakretanje tkanja, c) zadebljanje niti tkanine, d) rupa u tkanini, e) neželjeno šivanje, f) mrlje hrđe.

Kako bi se što više pogrešaka detektiralo u procesu proizvodnje razrađene su različite metode. Metode temeljene na slici u boji (sivoj slici) uočavaju pogrešku nastalu pri tkanju te zaustavljaju proizvodnju kako bi se tkanina s detektiranom greškom odstranila iz procesa proizvodnje. Pošto do sada nije pronađena jedinstvena metoda koja bi uočila svaku pogrešku na svakoj vrsti tkanine, prema [4], metode su kategorizirane u šest razreda prema pristupima:


- strukturni (engl. *structural approaches*),
- statistički (engl. *statistical approaches*),
- spektralni (engl. *spectral approaches*),

- temeljen na modelu (engl. *model-based approaches*),
- strojnog učenja (engl. *learning approaches*),
- hibridni (engl. *hybrid approaches*).

Koji su u sljedećim potpoglavljima objašnjeni. Uz njih, u potpoglavljima će biti navedene prednosti i nedostaci navedenih metoda, kao i njihova učinkovitost.

## 2.1. Strukturni pristup

Strukturni pristup zasniva se na pretpostavci da su teksture tkanina kompozicija osnovnih tekstura. Teksturalna analiza obavlja se pribavljanjem svojstava tekstura i zaključivanjem njihovih pravila zamjene [3]. Prema ovom pristupu ukupna se tekstura uzorka tkanine može postići kompozicijom jednostavnih teksturnih elemenata [4]. Strukturna analiza tekstura sastoji se od dvije sekvencijalne faze: otkrivanje osnovne teksture tkanine i modeliranje ukupnog uzorka teksture tkanine [5]. Ovaj pristup je pouzdan jedino u slučaju kada se radi o tkaninama čije su teksture vrlo ujednačene i pravilne [6].




Sl. 2.2. Prikaz nekih jednostavnih struktura tkanja: a) pletenje (engl. *weaving*), b) omotno pletivo (engl. *wrap knitting*), c) pletenje pletiva (engl. *weft knitting*).

## 2.2. Statistički pristup

Statistički pristup se koristi statističkim postupcima kako bi izlučio osnovne značajke teksture. Većina metoda korištenih u ovom pristupu uključuju: matricu pojavljivanja, funkciju autokorelacije i matematičko-morfološki pristup. Zbog njihove važnosti, navedene metode biti će pobliže pojašnjene. Također postoje još i mnoge druge metode koje se koriste u ovom pristupu kao: otkrivanje ruba, histograma, statistički moment, neuronske mreže i sl [4].

### 2.2.1. Matrica prostornih ovisnosti intenziteta piksela

Ova metoda omogućuje karakterizaciju svojstava tekstura mjerenjem ovisnosti između intenziteta boja. Metoda izražava raspodjelu gradijenta orijentacije u određenom dijelu tkanine [7]. Upravo se ta kombinacija gradijenta orijentacije koristi kako bi se prikazala tekstura određene tkanine. Matrica prostornih ovisnosti intenziteta piksela je kvadratna matrica. Njeni elementi odgovaraju relativnoj frekvenciji pojavljivanja parova sivih piksela odvojenih zadanom duljinom [8]. Prema slici 2.3., vidljivo je dobivanje matrice. Na gornjem lijevom dijelu slike prikazana je slika različitih nijansi sive boje. Na donjem lijevom dijelu vidljive su vrijednosti za svaku nijansu sive boje. Dok je na desnoj strani prikazana matrica prostorne ovisnosti intenziteta piksela dobivena iz slike. Na slici je prikazan i primjer dobivanja vrijednosti, u matrici, za vrijednosti intenziteta piksela sedam i osam. Pomoću četrnaest različitih statističkih izračuna koji ulaze u klasifikator, klasifikator izražava prostornu vezu piksela. Zbog toga ova metoda ima visoku stopu pronalaska pogreške, ali je računalno vrlo zahtjevna za uporabu u stvarnom vremenu. Također je osjetljiva na rotaciju i skaliranje te je teško za odrediti optimalni vektor pomaka [4].




Sl. 2.3. Primjer dobivanja matrice prostornih ovisnosti intenziteta piksela. a) slika različitih nijansi sive boje, b) vrijednosti sivih nijansi sa slike a), c) matrica prostornih ovisnosti intenziteta piksela dobivena sa slike b).

### 2.2.2. Autokorelacije

U ovoj metodi ispituje se ponavljanje strukture tkanine na slici. Ako na slici ne postoji nepravilnost, odnosno vidljiva je uobičajena struktura, kao rezultat autokorelacije dolaze sedla



ili doline [9], kao što je vidljivo na slici 2.4. Funkcija daje rezultate za osi x i y te ih iscrtava na graf kao krivulju. Ako nema nepravilnosti krivulje su periodične s odgovarajućim periodima ( $T_x$  i  $T_y$ ), dok su u suprotnome neperiodične.




Sl. 2.4. Rezultati autokorelacije na zadanu tkaninu [10]. a) slika tkanine bez pogreške, b) rezultat autokorelacije za os x, c) rezultat autokorelacije za os y.

Prednosti ove metode su vrlo dobra otpornost na šum i promijene razine svjetlosti na tkaninama. Također razina točnosti klasifikacije na određenim vrstama tkanina je vrlo visoka. Nedostatak koji značajno utječe na odabir ove metode je brzina njezinog izvođenja [11].

### 2.2.3. Matematičko-morfološki pristup

Matematičko-morfološka metoda izvlači svojstva tkanine temeljenih na početnim informacijama o sastavu tkanine [12]. Sastavljena je od dvije vrste operacija: morfološke i matematičke. Morfološke operacije su definirane kao manipulacija binarne slika korištenjem malih grupa elemenata, zvanih konfiguracijski elementi. Osnovne matematičke operacije su: erozija (Slika 2.5.b), proširenost (Slika 2.5.c), otvaranje (Slika 2.5.d) i zatvaranje (Slika 2.5.e). Uz djelovanje jedinične matrice dimenzija 3x3 na originalnu sliku (Slika 2.5.a).



Sl. 2.5. Primjeri djelovanja matematičkih operatora na originalnu sliku. a) originalna slika, b) erozija, c) proširenosti, d) otvaranje, b) zatvaranje.


Morfološki operatori su implementirani samo za neperiodičke tkanine. Stoga se ova metoda često koristi uz metode koje se upotrebljavaju za otklanjanje pogrešaka na periodičkim tkaninama. Ovaj nedostatak nadoknađen je računalnom jednostavnošću i dobrim pronalaženjem grešaka na prirodnim i nasumičnim teksturama [4].

### 2.3. Spektralni pristup

Veliki broj studija proveden je na spektralnom pristupu otklanjanja nepravilnosti na tkaninama. Primarna namjera spektralnog pristupa je otkloniti osnovnu teksturu sa slika i tada promatrati teksture preko prostorne i frekvencijske domene. Prostorna domena koristi se za otklanjanje pogreške, dok se frekvencijska domena koristi za identifikaciju pogreške [4]. Najkorištenije transformacije su: Fourierova i Gaborova transformacija te Waveletova transformacija.

#### 2.3.1. Fourierova transformacija


Fourierova transformacija je tehnika analize koja omogućuje analizu prenesenog signala iz vremenske domene u frekvencijsku [4]. Ova tehnika, kod obrade slika, može se okarakterizirati kao učestalost pojavljivanja komponenata, odnosno frekvencija njihovog pojavljivanja. Prema slici 2.6., vidljivo je kako Fourierova transformacija prikazuje teksturu tkanine (lijevi dio slike) pomoću signala (desni dio slike) tako da sažme sve frekvencije pojavljivanja uzoraka u točke te ih prikaže kao rezultat. Ako na tkanini nema pogreške biti će izražena frekvencija koja odgovara teksturi tkanine.



Sl. 2.6. Fourierova transformacija tkanine bez pogreške [13]. Na lijevoj je strani prikazana slika tkanine, a na desnoj odgovarajući rezultat Fourierova transformacije.

Prema slici 2.7., vidljiva je tkanina koja na sebi ima neispravnost (lijevi dio slike) i rezultat Fourierove transformacije na kojemu je vidljiva ta nepravilnost (desni dio slike). Na njemu je

također naznačen i smjer glavnih frekvencija kojima je tkanina označena i oni su:  $\Theta_1$  i  $\Theta_2$ , koji iznose  $3.58^\circ$  i  $45^\circ$ .




Sl. 2.7. Fourierova transformacija tkanine s pogreškom [13]. Na lijevoj je strani prikazana slika tkanine, a na desnoj odgovarajući rezultat Fourierova transformacije uz smjerove frekvencija.

Fourierova transformacija često je korištena jer spektar prostorne frekvencije nije promjenjiv s obzirom na pomicanje. Prigodan je za globalne i lokalne neispravnosti te ima brzo vrijeme obrade. Ova transformacija ima i neke nedostatke: nije moguća detekcija pogrešaka na tkaninama s nasumičnom teksturom i nije u mogućnosti lokalizirati pogreške te je osjetljiva na rotiranje i skaliranje[4].

### 2.3.2. Gaborova transformacija

Gaborova transformacija koristi se kako bi se analiza tekstura mogla vršiti i u prostornoj i u frekvencijskoj domeni. Transformacija može biti prilagođena s različitim mjerilima i kutovima prema strukturi tekstura, kako bi broj pronađenih pogrešaka bio što bolji. Zato ova transformacija daje optimalnu detekciju neispravnosti u obje domene. Uz to ima i vrlo zadovoljavajuću detekciju pogreške kada se radi o rupama ili rubovima tkanina. Kako postoje različita mjerila i kutovi često je teško pronaći optimalne parametre. Iz tog razloga transformacija je osjetljiva na rotaciju te je računalno zahtjevna metoda [4].




Sl. 2.8. Primjer Gaborove funkcije. Prvi stupac prikazuje originalne slike tkanina, a drugi odgovarajuće rezultate Gaborove funkcije.

## 2.4. Pristup temeljen na modelu

Ovaj pristup najpogodniji je za slike tkanina koje na svojoj površini imaju neispravnosti kao što su puknuće niti tkanine ili puknuće igle. Pristup temeljen na modelu stvara modele iz slika tkanina koje obrađuje. Uz pomoć stvorenih modela određuje slike tkanina te definira što je na slici tekstura tkanine, a što nepravilnost. Kako bi model bio što točniji vrlo je važno postaviti dobre radne parametre kojima će se metoda koristiti [14]. Najkorišteniji modeli su autoregresivni model i Gauss Markov model nasumičnog polja.

### 2.4.1. Autoregresivni model


Autoregresivni model (AR) koristi se kako bi se izrazio stupanj linearne ovisnosti između različitih piksela preko slika tkanina. Razlog učestalog korištenja ove metode je u njegovoj brzini obrade. Metoda zahtijeva samo rješenje linearnog sustava, što ju čini bržom od mnogih drugih metoda koje su usmjerene na nelinearne sustave [15]. Uz to, metoda je pogodna za rad na tkaninama s vrlo nasumičnim uzorkom te nije osjetljiva na rotaciju. S druge strane osjetljiva je na promjene osvjetljenja i na šumove te ima nisku stopu detekcije pogrešaka na velikim slikama s velikim brojem nepravilnosti [4].



Sl. 2.9. Umjetni uzorak tkanine s pogreškom i rezultat dobiven AR modelom

#### 2.4.2. Gauss Markov model nasumičnog polja

Gauss Markov model nasumičnog polja (GMRF) je osjetljiv model koji koristi ovisnost piksela na slikama tkanina. Veze između piksela i isprekidanost se mjere računanjem gustoće svakog piksela u obližnjem području. Ova metoda koristi se u mnogim područjima kao npr. segmentacija, klasifikacija i izvlačenje svojstava [16]. Također je pogodna za korištenje uz statističke i spektralne metode. Jedini nedostaci ovog modela su osjetljivost na rotaciju i skaliranje te nemogućnost prepoznavanja malih neispravnosti [4].



Sl. 2.10. Primjeri tkanina bez pogreške (lijevo) i njihovi GMRF modeli (desno).

#### 2.5. Pristup strojnog učenja

Pristup strojnog učenja kao jednom od svojih metoda koristi se umjetnim neuronskim mrežama te je podijeljen u dva dijela. U prvom dijelu, fazi učenja, neuronska mreža se trenira na setu testnih primjera. Oni su najčešće sastavljeni od različitih tipova tkanina bez neispravnosti. Na njima neuronska mreža stvara podatke o originalnim teksturama tkanine, kao što su orijentacija niti i udaljenost niti tkanine. Nadalje iz njih u drugoj fazi, faza provjere, na novim primjerima tkanina, koji sada sadržavaju i tkanine s pogreškama, određuje da li je tkanina ispravna ili ne. Ti

novi primjeri se prvo razlažu na blokove istih dimenzija kao oni iz testnih primjera, te se zatim njih označava kao ispravne ili neispravne [17]. Važno je za napomenuti kako je u fazi učenja moguće implementirati razne metode koje mogu pronaći različite vrste pogrešaka. Time se postiže nadopunjavanje metoda. Također učinak ove metode u stvarnom vremenu vrlo je poželjan za industrijsku upotrebu [4].

## **2.6. Hibridni pristup**

Kako bi se što efikasnije pronašla svaka pogreška na tkaninama mnogi koriste kombinaciju dvaju ili više metoda. Na taj se način postiže veću efikasnost rada. Glavni objekt ove metode je umanjivanje računalne složenosti metoda i povećavanje stope pronalaska pogrešaka. Tijekom vremena mnogi su koristili hibridni pristup i kombinirali razne metode. Od njih su neke bile zadovoljavajuće dok druge ne. Jedan od primjera kombinacije metoda koje su zadovoljile je kombinacija Waveletove transformacije i matrice prostornih ovisnosti intenziteta piksela. Dok je Waveletova transformacija brza, matrica prostornih ovisnosti intenziteta piksela je temeljita [4].

## **2.7. Baze slika**

U mnogima radovima pravljene su različite baze slika tekstila. Iz tog razloga postoji i mnogo različitih baza slika. Neke baze su napravljene samostalno, samo za testiranje metoda toga rada, dok su za druge baze metodički skupljane slike, sa različitih izvora, kako bi stvorili što raznovrsniju bazu. Neke od većih baza su: TILDA Textile Texture Database, i·bug: The Fabrics Dataset i AITEX: Fabric Image Database.

### **2.7.1. TILDA Textile Texture Database**

TILDA Textile Texture Database je baza tekstura tekstila. U njoj se nalazi osam različitih vrsta tekstila sa sedam različitih vrsta pogreški. Za svaku pojedinu vrstu tekstila postoji 50 različitih osmo bitnih sivih TIF slika, dimenzija 768x512 piksela, što znači da se baza sastoji od 3200 TIF slika koje zauzimaju ukupno 1,2 Gbita prostora [18]. Baza je vrlo raznovrsna i ima zadovoljavajuću kvalitetu slika, ali jedini problem je što su sve slike sive boje.

### **2.7.2. i·bug: The Fabric Dataset**

i·bug: The Fabric Dataset baza je slika tekstila. Nju sačinjava oko 2000 uzoraka tkanina. Sve slike nabavljene su „na terenu“ (u trgovinama), što znači da prevladavaju tkanine napravljene od pamuka i poliestera, ali postoje i razne druge. Slike su u boji te su različitih dimenzija. Zbog

lakšeg preuzimanja slike su podijeljene u četiri dijela. Sva četiri dijela zajedno zauzimaju oko 2,1 Gbita. Jedini nedostatak ove baze slika je nepostojanje slika s pogreškama [19].


### **2.7.3. AITEX: Fabric Image Database**

AITEX: Fabric Image Database sadrži slike sedam različitih tkanina. Baza se sastoji od 245 slika. Od toga 140 ih je bez pogreške, 20 za svaku vrstu tkanine, a 105 sa pogreškom. Slike su dimenzija 4096x256 piksela, a baza slika ukupno zauzima oko 1 Gbita prostora. Svaka slika ima svoju oznaku koja označuje da li je slika bez pogreške ili sa te koja je to pogreška. Jedini problem ove baza je što je nova baza te još nije dostupna [20].

### 3. KERAMIČKA INDUSTRIJA

Proizvodnja u keramičkoj industriji počinje sa sirovinama. One se miješaju kako bi se dobila odgovarajuća smjesa od koje se prave sirove pločice. Sljedeća faza proizvodnje je priprema smjese za prešu. U njoj se već napravljenoj smjesi dodaju razni dodaci koji se nakon obrade odlažu u silosima. Zatim se novonastala smjesa preša pod točno određenim pritiskom, te se onda pločice šalju na sušenje. Nakon određenog vremena u peći za sušenje pločice idu na završnu obradu. Pločice dobivaju završni premaz te se njihova površina ukrašava.

Keramički proizvodi kao što su pločice, prolaze kroz mnogobrojne faze tijekom proizvodnje. Pa tako mogu nastati i razne neispravnosti na proizvodu. Stoga se površne neispravnosti mogu podijeliti u šest kategorija (Slika 3.1.). Engl. *Pinhole* (Slika 3.1.a) je mala rupa, ne veća od jednog milimetra, na površini proizvoda, koja se uobičajeno pojavljuje tijekom pečenja. Zadebljanje glazure (Slika 3.1.b) nastaje skupljanjem glazure, uobičajeno unutar par milimetara, na rubu ili dijelu pločice, a najčešće se pojavljuje tijekom glaziranja. Ogrobotina (Slika 3.1.c) je neispravnost koja se često događa tijekom transporta proizvoda od glaziranja do peći za sušenje. Pukotina (Slika 3.1.d) je najučestalija pogreška koja se pojavljuje zbog brzog pečenja, nagle promjene temperature kojoj je proizvod podvrgnut. Grumen (Slika 3.1.e) je nepravilnost na površini koja izgleda kao kapljica vode, a može nastati zbog prevelike vlage ili sporog dolaska do peći za sušenje. Posljednja je pogreška na rubu (Slika 3.1.f) koja se najčešće događa u peći za sušenje [21].



Sl. 3.1. Vrste površinskih neispravnosti na pločicama. a) engl. *pinhole*, b) zadebljanje glazure, c) ogrobotina, d) pukotina, e) grumen i f) pogreška na rubu.



Kako bi se pogreška otklonila mora se provjeriti cijela površina proizvoda. Uz to slika bi trebala biti visoke rezolucije, a proizvod dobro osvijetljen. Tek tada se može koristiti neka od metoda, koje se mogu podijeliti u četiri skupine [24]:


- metode filtriranja (engl. *Filtering methods*),
- algoritmi strukture (engl. *Structural algorithms*),
- metode bazirane na modelu (engl. *Model based techniques*),
- statističke metode (engl. *Statistical methods*).

### 3.1. Metode filtriranja

Kod metode filtriranja koriste se matematičke transformacije, koje mogu biti linearne i nelinearne te filteri [24]. Najvažniji algoritmi koji se koriste u ovoj metodi su: Waveletova i Countorletova transformacija, genetički i ICA algoritam, Gaborovi filteri te neuronske mreže.

#### 3.1.1. Waveletova transformacija


Waveletova transformacija koristi se za predobradu slika keramičkih pločica i izvlačenje svojstava tekstura sa slike [22]. Ona mjeri razlike u razini sive boje po različitim mjerilima. Rubovi su prikazani kao oštra promjena na slabo promjenljivoj podlozi. To omogućava da Waveletova transformacija zumira te nepravilnosti sa slika [23]. No, za bolji opis skrivenih struktura na slikama prema [24], preporučuje se korištenje prilagodljivih Waveletovih okvira prije onih standardnih.



Sl. 3.2. Rezultati Waveletove transformacije za ogrebotinu (lijevo) te pukotinu i grumen (desno).

#### 3.1.2. Countorletova transformacija

Ova transformacija izvorno je bazirana na ciljevima Waveletove transformacije da savlada slabosti odabranog Waveletovog tipa. Iz toga razloga ima isti princip rada kao i Waveletova funkcija, koristi multi-rezoluciju i krivulju prostorne frekvencije. Originalna slika se pretvara u osam podslika, prema slici 3.3., koje je onda lakše uvećati i na njima otkloniti šumove [25].



Sl. 3.3. Shema osam podslika Countorletove transformacije


Iako je ova metoda poboljšanje u odnosu na Waveletovu transformaciju, jer lakše uočava smjerove tekstura na slikama, ima i svoj nedostatak. Naime, potrebna je dodatna informacija o smjeru teksture kako bi se mogla ispravno izvesti [26].

### 3.1.3. Genetički algoritam

U detekciji pogrešaka na površini Genetički algoritam prvo razmatra statističku vezu, kojom određuje da li određeni piksel odgovara nekoj od površinskih pogrešaka. Zatim se srodni parametri promatraju kao geni te ih algoritam optimizira. Tada ti parametri mogu biti promatrani kao točka zadržavanja ili kao parametri morfološke metode. Iako je ova metoda vrlo jednostavna, njezina faza treniranja ostaje vrlo problematična [27].

### 3.1.4. ICA algoritam

Algoritam analize neovisnih dijelova (engl. Independent component analysis), u digitalnoj obradi slike, pretpostavlja da je slika sastavljena od dvije ili više neovisnih slika. ICA algoritam pokušava pronaći te dijelove na slici. To bi značilo da algoritam prepoznaje pogrešku, u prvom planu, pomiješanu s pozadinskim uzorkom i onda ih odvaja. Jedini nedostatak algoritma je smanjenje učinkovitosti pronalaska pogreške u okolini u kojoj postoji određeni šum [28].




Sl. 3.4. Slika pukotine na pločici i rezultat ICA algoritma

### 3.1.5. Neuronske mreže

Neuronske se mreže, kada je riječ o obradi slika i sustavima detekcije pogrešaka, koriste kao klasifikatori. Zbog toga je potrebno izlučiti vektor značajki keramičkih pločica prije nego se slike daju na obradu neuronskim mrežama. Za vektor značajki mogu se koristiti značajke matrice prostornih ovisnosti intenziteta piksela, waveletove transformacije i sl. Tada neuronska mreža dijeli vektore svojstava u dvije skupine: uzorke bez pogreške i uzorke s pogreškom [29].

### 3.1.6. Gaborovi filteri

Najčešća uporaba Gaborovih filtera je u predobradi slika jer se uz njihovu pomoć mogu razlikovati tipovi pogreške. Imaju veliku učinkovitost u izvlačenju svojstava sa slike. Oni uključuju i različite smjerove i frekvencije. Ako su filteri definirani u prostornoj domeni, tada oni sa sobom povezuju originalnu sliku i tako stvaraju djelomične slike. No, ako su definirani u frekvencijskoj domeni, tada se prvo primjenjuje Fourierova transformacija na sliku. Time se ona pretvara iz prostorne u frekvencijsku domenu i tek se onda primjenjuju Gaborovi filteri. Na kraju pretvorbom dobivenog rezultata nazad, iz frekvencijske domene u prostornu, dobivaju se djelomične slike [30].




Sl. 3.5. Slika pločice s pogreškom (lijevo) i rezultat Gaborovih filtera (desno)

## 3.2. Algoritmi strukture

U algoritmima strukture traže se osnovne i hijerarhijske teksture, koje se koriste za pronalazak pogrešaka. To dovodi do jednostavnog postupka i razumljivog izračuna. Neke od metoda koje se koriste kao algoritmi strukture su: morfološki algoritam i algoritam detekcije ruba [24].

### 3.2.1. Morfološki algoritam

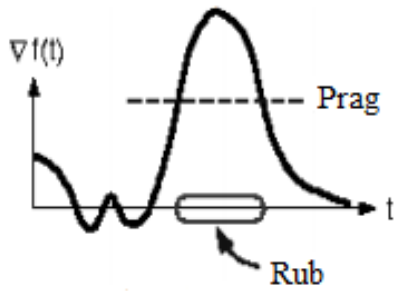
Morfološki algoritam ima mogućnost obraditi binarne slike i slike sivih razina, usmjerenih na morfologiju. Izlazna vrijednost svakoga piksela sa slike je određena vrijednošću vlastitog ulaza kao i vrijednošću susjednih piksela. Tijekom cijele obrade u morfološkim algoritmima koriste se osnovni strukturni elementi. Iz toga razloga važno je odabrati odgovarajući element koji će se koristiti za daljnju obradu [31]. Uobičajeno morfološki operatori se koriste za poboljšavanje, ugađivanje i smanjenje šuma na slikama koje se obrađuju. Uz njihovu pomoću također se izvodi analiza ruba pločica. Nepravilnosti su izvučene s pozadine i svrstane prema svojem obliku i veličini. Neke od nepravilnosti prikazane su na slici 3.6., na lijevoj strani prikazane su slike pločica s pogreškama, a na desnoj strani odgovarajući rezultati postignuti odgovarajućim morfološkim operatorom. Nepravilnosti su svrstane u odgovarajuće skupine i to: ogrebotina (Slika 3.6.b), pukotina (Slika 3.6.d), grumen (Slika 3.6.f) i engl. *pinhole* (Slika 3.6.h) [32].



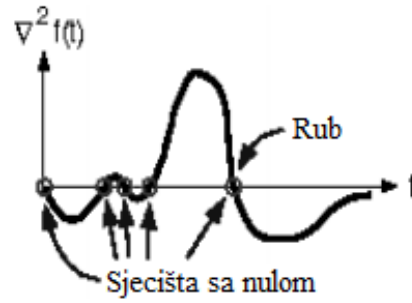
Sl. 3.6. Slika pločica s pogreškom (gore) i rezultati morfoloških operatora (dolje). a) i b) ogrebotina, c) i d) pukotina, e) i f) grumen i g) i h) engl. *pinhole*.

### 3.2.2. Detekcija ruba

Postoje mnoge metode za detekciju pogrešaka na rubovima pločica. Jedna od jednostavnijih je metoda gradijenta slike u koje spadaju: Robertsov, Sobelov i Prewittov operator, koji promatraju maksimume i minimume prve derivacije slike (Slika 3.7.). Postoji i Laplacianova metoda koja promatra kada druga derivacija sječe vremensku os, kako bi pronašla rub (Slika 3.8.) [33].




Sl. 3.7. Princip rada metoda gradijenta.



Sl. 3.8. Princip rada Laplacianove metode.

Također postoje i metode MASD i CMASD koje gledaju kutni pomak piksela. Uvjeti da bi metode ispravno radile su da ulazna slika mora biti binarna te rub mora biti širok jedan piksel i neprekidan. MASD metoda koristi prosječni pomični filter kako bi izgladila vrijednosti rubova zadanog obrisa. CMASD metoda je prilagođena metoda MASD. Ona se bazira na pronalasku pogrešaka na kutovima pločica. Prema slici 3.9., metode gledaju razliku u pomaku trenutnog piksela i idućeg piksela. Tako utvrđuju postoji li odstupanje na tom dijelu ruba koje nije u zadovoljavajućim granicama. Ispravnost ovih metoda ovisi o veličini pomičnog filtera. Ako je filter prevelik metoda će predvidjeti male pogreške. Ako je filter premali metoda će pronalaziti pogreške tamo gdje ih nema [34].



Sl. 3.9. Postupak pronalaska ruba metodama MASD i CMASD.

### 3.3. Pristup temeljen na modelu

U obradi slika ovim pristupom, odabire se model za analizu slika čiji su parametri nepoznati. Zatim metode stvaraju parametre po slikama na kojima su metode trenirane. Kasnije po njima definiraju da li pločica ima nepravilnosti na sebi ili nema [24]. Neke od metoda koje spadaju u pristup temeljen na modelu su: skriveni Markov model i autoregresivni model.

### 3.3.1. Skriveni Markov model

Ovdje, u skrivenom Markovom modelu, svakome pronađenome svojstvu biti će dodijeljeno jedinstveno stanje. Kako bi se ovaj model trenirao pomoću slika koriste se algoritmi: širenje-unatrag, širenje-unaprijed, širenje naprijed-nazad i Viterbijev algoritam [35]. Ukoliko se ova metoda koristi za pronalazak pogrešaka potrebno je definirati: tri varijable stanja, vektor  $\pi$  (vjerojatnost pojavljivanja varijable stanja u nekom dijelu slike) i matricu prelaska stanja. U njoj, matrici prelaska stanja, nalaze se vjerojatnosti prelaska stanja iz ispravnog u neispravno i obrnuto. Jedan od glavnih problem ove metode je složenost njezinih statističkih izračuna [24].

### 3.3.2. Autoregresivni model


Autoregresivni model smatra se jednim od jednostavnijih metoda modelnog pristupa. Nakon određivanja parametara ove metode za željene teksture, ukoliko metoda naiđe na određene dijelove koji nisu u skladu s parametrima koje metoda ima, taj dio se smatra kao dio s pogreškom. Neki od nedostataka ove metode su neodređenost i statistički rezultati [24].

## 3.4. Statističke metode

Statističke metode koriste se statističkim postupcima kako bi izlučile osnovne značajke tekstura. Često se koriste u problemima klasifikacije, ali mogu biti korištene i za detekciju pogrešaka. Neki od postupaka korištenih u ovoj metodi su: histogram krivulja, Weibullova raspodjela matrica prostornih ovisnosti intenziteta piksela i funkcija autokorelacije [24].

### 3.4.1. Histogram krivulja


Histogram mjeri broj različitih nijansi sivih piksela raspodijeljenih na slici. Histogram se sastoji od dvije varijable: varijable  $x$ , koja opisuje nijansu sivih piksela i varijable  $y$  koja govori o broju pojedine sive nijanse sa slike. Na slici 3.10. vidljiv je rezultat histograma (3.10.b) za dio slike koji nema pogrešku (3.10.a) te rezultat na slici 3.10.d, kada dio slike ima pogrešku (3.10.c). Iz oblika histograma se može zaključiti da li pločica ima pogrešku ili nema [36].



Sl. 3.10. Slike dijelova pločice (lijevo) i njihovi histogrami (desno).

### 3.4.2. Weibulova raspodjela

Za detekciju pogrešaka korištenjem Weibulove raspodjele prvo se slika mora podijeliti u identične dijelove. Sljedeći korak je izračunavanje gradijenta amplitude se za svaki pojedinačni dio. Zatim se određuje histogram slike te se na kraju spaja Weibulova raspodjela s histogramom slike. Tada s dobivenim distribucijskim parametrima i s obzirom na njih, kao polja svojstvenog vektora, pogreške se mogu pronaći uz pomoć mjerila udaljenosti [37].



Sl. 3.11. Izgled Weibulove raspodjele za dio bez pogreške (a) i s pogreškom (b)

### 3.5. Baza slika

U keramičkoj industriji ne postoji jedinstvena baza slika, nego je za svaku metodu stvarana osobna baza. Tako da postoji veliki broj bazi slika pločica, no rijetke su dostupne. Jedna od baze je: VxC TSG Image Database for Surface. Uz baze pločica moguće je koristiti i baze općih tekstura: VisTex.

### **3.5.1. VxC TSG Image Database for Surface**

VxC TSG baza je slika keramičkih pločica nastala u VxC laboratoriju. Baza se sastoji od 14 različitih modela pločica, s ukupno 960 slika. No, trenutno nije moguće pristupiti toj bazi [38].

### **3.5.2. VisTex database**


VisTex je baza slika tekstura čiji je cilj pružiti slike tekstura koje predstavljaju stvarne uvijete. Baza se sastoji od četiri dijela, od kojih su samo dva trenutno dostupna. Slike su spremite kao ppm datoteke, a njihove dimenzije su standardno 512x512 i 128x128 [39].



## 4. DRVNA INDUSTRIJA

Prilikom proizvodnje drvenih proizvoda mnogi postupci ovise o kvaliteti samog drveta. Iz toga razloga vrlo je važan pregled drveta tijekom njegove prerade. Prerada drveta počinje njegovim pristizanjem u tvornicu. Kada je drvo dostavljeno u tvornicu njegova kora se uklanja te se klada reže na određenu duljinu. Nakon toga, prema promjeru klade, iz klade se režu definirani oblici. Zatim se izrezani dijelovi šalju na daljnju obradu i sušenje. Ukoliko određeni dio drveta sadrži neispravnosti njegova kvaliteta i stabilnost postaju upitni. Stoga je razvijena kategorizacija prije završne obrade. Ako drvo ima preveliki broj neispravnosti ono se koristi kao gorivo za tvornicu, dok se kvalitetni dijelovi šalju na daljnju obradu i uređivanje.

Neke od najučestalijih nepravilnosti drvnih proizvoda, koji zahvaćaju veći dio površine, su trulež i plava mrlja. Nepravilnosti koje zahvaćaju male dijelove površine su: čvor, pukotina i napadi kukaca [40]. Sve navedene nepravilnosti vidljive su na slici 4.1.



Sl. 4.1. Najučestalije nepravilnosti na drvenim proizvodima [41]. a) trulež, b) plava mrlja, c) čvor, d) pukotina i e) napadi kukaca.

Neispravnosti kao trulež i plava mrlja nastaju zbog gljivica koje se nastanjuju i razmnožavaju u samom drvetu. Iako plava mrlja ne utječe na strukturu i čvrstoću drveta, ona stvara idealno okruženje za stvaranje truleži. Najveći problem u detekciji ovih neispravnosti stvaraju vodena mrlja i godovi koji izgledaju identično plavoj mrlji, odnosno truležu. No, postoje načini da se neispravnosti točno pronađu. Vodena mrlja se na drvetu, ukoliko postoji, najčešće nalazi samo na jednom dijelu površine, a linija podijele najčešće je jasno vidljiva, slika 4.2.



Sl. 4.2. Izgled vodene mrlje na drvetu.

Godovi su, najčešće koncentrične kružnice, kao na slici 4.3. Oni mogu biti uočeni po svojem prepoznatljivom obliku i obrascu [40].



Sl. 4.3. Izgled godova drveta.

Postoji veliki broj metoda i algoritama koje se mogu primijeniti za detekciju nepravilnosti kod drvenih proizvoda. A najučestalije metode mogu se podijeliti u ove tri skupine:


- izvlačenje dijela (engl. *Region extraction*),
- otkrivanje ruba (engl. *Edge detection algorithms*),
- pragni algoritam (engl. *Thresholding algorithms*) [42].

#### **4.1. Algoritmi izvlačenja dijela**


Algoritmi izvlačenja dijela upotrebljavaju različite mjere prema svojstvima slika i metodama odvajanja. To znači da su algoritmi izvlačenja dijela puno fleksibilniji od ostalih algoritama u smislu ciljeva primjene. Jedna od najvećih prednosti ovih algoritama je neosjetljivost na šum. Također je korištenje slika u boji puno jednostavnije nego u drugim metodama. No, problemi nastaju kod odabiranja početnih dijelova. Te zato što, djelomičnom obradom slike nema dovoljan broj čistih, dominantnih dijelova na slici. Dijelova na slici iz kojih se mogu izvući svojstva. Umjesto toga postoji mnogo malih, ne spojenih, dijelova koji zahtijevaju da ih postupak otkloni [42].

#### **4.2. Algoritmi otkrivanja ruba**

Algoritmi otkrivanja ruba mogu se podijeliti u dvije skupine: sekvencijalne i paralelne. U sekvencijalnom otkrivanju ruba već prije potvrđeni pikseli ruba utječu na položaj sljedećeg mogućeg piksela ruba i na rezultat njegovog prihvatanja kao piksela ruba. Nasuprot tome, u paralelnom otkrivanju ruba takve zakonitosti ne postoje. Neki od algoritama su gradijent smjera i Shiozakijeva entropija [42].



Sl. 4.4. Primjeri izgleda rezultata za Shiozakijevu entropiju



Sl. 4.5. Primjeri izgleda rezultata za gradijent smjera

#### 4.2.1. Gradijent smjera

Gradijent smjera koristi kuteve koji su definirani u osam jednako udaljenih smjerova. Gradijent koji daje najveću vrijednost na određenom pikselu odlučuje o smjeru ruba. Tada se stvara binarna karta uz pomoć lokalnih spojeva, koji poboljšavaju stopu pronalaska pogreške ove metode, u karti smjerova kuteva i uz pomoć karte točkaka zadržavanja koja koristi lokalno prilagodljiv prag za svaku točku slike. Uobičajeni problem operatora gradijenta je ovisnost o predodređenim točkama zadržavanja iz kojih se dobiva rub [43].



Sl. 4.6. Primjer rezultata gradijenta smjera.

#### 4.2.2. Shiozakijeva entropija

Shiozakijeva entropija uz pomoć entropije intenziteta na područjima slika izražava rub. Entropija intenziteta je mjera vjerojatnosti koja računa jačinu promjene u zadanom dijelu. Pošto je entropija mala kada je promjena jačine velika, a velika kada je promjena jačine mala, rubovi se mogu izlučiti iz područja gdje je entropija mala. Entropija koja se može definirati i pronaći na sličan način. Detekcija ruba ne ovisi samo o stopi promjene već ovisi i o prosječnoj vrijednosti lokalnih područja. Ova metoda jako je osjetljiva na rubove u tamnim područjima, koristeći se stopom promjene i prosječnom vrijednosti lokalnog područja. To je prošireno na slike u boji i vrlo je jednostavno za implementaciju. Metodi je također dodan faktor otežanja kako bi se


povećala stopa pronalaska neispravnosti i srednji filter boje kako bi se otklonili mali ili slabi rubovi za različite vrste drveta [44].



Sl. 4.7. Primjer rezultata Shiozakijeve entropije.

### 4.3. Pragni algoritam

Prednost pragnog algoritma su davanje zatvorenih granica, jednostavnost za izračunavanje i implementaciju te neosjetljivost na šumove. Najveći problem s mnogim tehnikama ovog algoritma je da su one temeljene na pretpostavci da različiti razredi sa slike imaju različite modove u raspodjeli odabranog svojstva. U mnogim slučajevima s drvetom ta pretpostavka nije točna, kao na slici 4.8., gdje su grafovi uniformni, što znači da slika nema nepravilnosti, dok je na slici prikazana standardna pogreška, čvor [42]. Zato su razvijena sljedeća tri algoritma: Otsuova metoda, Kapurova entropija i matrica prijelaza, koja će biti pojašnjena u sljedećim poglavljima.



Sl. 4.8. Primjer neispravnog pragnog algoritma.

### **4.3.1. Otsuova metoda**

Ova metoda pretpostavlja da je slika sačinjena od dvije vrste klasa. Klasa pozadinskih piksela, što predstavlja teksturu bez pogreške i klasu prednjih piksela, koji predstavljaju nepravilnosti. Bazirana je na razlikovnoj analizi klasa i najmanjoj srednjoj kvadratnoj pogrešci između originalne slike i rezultatne binarne slike. Pragni algoritam je određen s povećanjem između-klasne varijance sivih tonova koja je uz srednju vrijednost sivih vrijednosti korištena kao svojstvo. Ukoliko navedena svojstva ne zadovoljavaju normalnu razdiobu tada se radi o drvetu sa pogreškom. Neke od prednosti Otsuove metode su: jednostavna obrada zbog korištenja samo nultog i prvog reda histograma, metoda ne mora imati prijašnja znanja o oblicima histograma i jednostavno proširenje na više algoritama, koje omogućuje prikaz različitih boja [45].

### **4.3.2. Kapurova entropija**

U ovoj metodi, vjerojatnost raspodjele nepravilnosti i pozadine izvedena je iz originalne raspodjele sivih tonova slike. Zatim je definirana optimalna prag kao siva razina koja dovodi zbroj objekata i pozadine do najviše točke. Po najvišoj točki se zatim određuje ispravnost drveta. Prednosti Kapurove entropije su: dobro definirani modeli teorije informacija i statistički kriteriji te ne zahtijevanje čistih modova histograma [46].

### **4.3.3. Matrica prijelaza**

Matrica prijelaza slična je matrici pojavljivanja, ali ima smanjenu računalnu složenost. U  $(i, j)$  element matrice prijelaza spremljeno je koliko često  $i$ -ta siva razina slijedi  $j$ -tu sivu razinu u određenom prostornom smještaju. Time se stvaraju četiri dijela matrice prijelaza koja se koriste za izračunavanje dvije mjere: procjena spojeva i uvjetna vjerojatnost učestalosti prijelaza između razreda. Zato što ove mjere govore o nepovezanosti obrađenih dijelova, točka zadržavanja odgovara lokalnom minimumu dviju mjera. Prednosti ove metode su: laka razumljivost, kriteriji za odabir točke zadržavanja su dobro definirani i lako nadograđivanje na više točaka zadržavanja [47].

## **4.4. Baza slika**

### **4.4.1. Lumber Grading**

Baza slika za drvnu industriju naziva se Lumber Grading. U njoj se nalazi 838 različitih slika drveta u osam bitnoj verziji u boji. Slike su dimenzija 488x512 piksela u PPM formatu. A zauzimaju 630 Mbita u nesažetoj verziji, a 360 Mbita u sažetoj verziji [48].

#### **4.4.2. The Wood Database**

The Wood Database je baza slika drveta. U njoj se nalaze slike 478 različitih vrsta drveta iz svih dijelova svijeta. Slike su u boji a njihove dimenzije su od 200x200 piksela do 600x600. Jedini nedostatak ove baze je što postoji samo jedna slika za svaku vrstu drveta [49].

## 5. ZAKLJUČAK

U ovom završnom radu cilj je bio napraviti pregled metoda detekcije pogrešaka putem obrade slike. Kako ne postoji nijedna jedinstvena metoda za detekciju svake pogreške na jednom proizvodu predstavljeno je više različitih metoda, algoritama i transformacija. Svaki predstavljeni pristup ima neke svoje prednosti, ali i neke nedostatke. U tekstilnoj industriji metode detekcije podijeljene su u sedam različitih pristupa, od kojih je u svakom pristupu pojašnjeno par metoda najvažnijih za taj pristup. Najbolji pristup u literaturi, od navedenih sedam, je hibridni pristup koji spaja dva ili više pristupa, koji su dobri za različite pogreške kako bi stvorio najefikasniji pristup po broju detektiranih pogrešaka. Keramička industrija ima sličnu podjelu, podijeljena je na četiri pristupa te su u njima objašnjene najznačajnije metode za tu industriju. Najopširnije je pojašnjena metoda filtriranja, čiji se algoritmi stavljaju u prvi plan kada je riječ o detekciji pogrešaka na keramičkim proizvodima, ali postoje i drugi pristupi koji postižu jednake rezultate, kao što su statistički pristup i metode detekcije ruba. U industriji drva, u najkorištenije metode spadaju pragni algoritam, koje se ističu svojom brzinom i lakoćom za razumjeti. Zadatak završnoga rada je bio i proći baze slika koji su se koristili pri testiranju metoda. Predstavljene su baza slika TILDA, i-bug i AITEX za tekstilnu industriju te Lumber Grading i The Wood Database, baza slika drvne industrije uz njih i baza slika za keramičku industriju, VxC TSG, kojoj je nemoguće pristupiti.

## LITERATURA

- [1] C. S. Cho, B. M. Chung, M. J. Park, Development of Real-Time Vision-Based Fabric Inspection System, IEEE transactions on industrial electronics, br. 4, sv. 52, str 1073-1079, Kolovoz 2005.
- [2] Textile Handbook 2000, Hong Kong Productivity Council, The Hong Kong Cotton Spinners Association, 2000.
- [3] P. M. Mahajan, S. R. Kolhe, P. M. Pati, A review of automatic fabric defect detection techniques, Advances in Computational Research, br. 2, sv. 1, str.18–29, 2009.
- [4] K. Hanbaya, M. F. Talub, Ö. F. Özgüvenc, Fabric defect detection systems and methods—A systematic literature review, Optik 127, str.11960-11973, 2016.
- [5] C. Anagnostopoulos, D. Vergados, E. Kayafas, V. Loumos, G. Stassinopoulos, A computer vision approach for textile quality control, The Journal of Visualization and Computer Animation, br.1, sv. 12, str.31–44, Svibanj 2001.
- [6] C. Duchesne, J. J. Liu, J. F. MacGregor, Multivariate image analysis in the process industries: a review, Chemometrics and Intelligent Laboratory Systems, br.117, str.116–128, Kolovoz 2012.
- [7] R. M. Haralick, K. Shanmugam, I. H. Dinstein textural features for image classification, IEEE Transactions on Systems, Man and Cybernetics, br.6, sv. SMC-3, str.610–621, Studeni 1973.
- [8] A. Latif-Amet, A. Ertüzün, A. Ercil, An efficient method for texture defect detection: sub-band domain co-occurrence matrices, Image and Vision Computing br.6-7, sv. 18, str.543-553, Svibanj 2000.
- [9] E. J. Wood, Applying fourier and associated transforms to pattern characterization in textiles textile Research Journal, sv. 60, str.212–220, Travanj 1990.
- [10] E. Hoseini, F. Farhadi, F. Tajeripour, Fabric Defect Detection Using Auto-Correlation Function, International Journal of Computer Theory and Engineering, br.1, sv. 5, Veljača 2013



- [11] Y. F. Zhang, R. R. Bresee, Fabric defect detection and classification using image analysis textile Research Journal, sv. 65, str.1-9, Siječanj 1995.
- [12] C. Solomon, T. Breckon, Fundamentals of Digital Image Processing, Wiley-Blackwell, 2011.
- [13] G. Hu, Q. Wang, G. Zhang, Unsupervised defect detection in textiles based on Fourier analysis and wavelet shrinkage, Applied Optics, br.10, vol.54, Ožujak 2015.
- [14] K. Hanbay, M. F. Talu Kumas,, Hatalarinin online/offline tespit sistemleri ve yöntemleri, Sakarya Üniversitesi Fen Bilimleri Enstitüsü Dergisi [S.l.], br.1, sv. 18, str.49–69, 2014.
- [15] S. H. Hajimowlana, R. Muscedere, G. A. Jullien, J. W. Roberts, 1D autoregressive modeling for defect detection in web inspection systems, Midwest Symposium on Circuits and Systems, str.318–321, Kolovoz 1998.
- [16] J. P. Monaco, A. Madabhushi, Class-specific weighting for Markov random field estimation: application to medical image segmentation, Medical Image Analysis, br.8, sv. 16, str.1477–1489, Prosinac 2012.
- [17] D. Yapi, M. Mejri, M. S. Allili, N. Baaziz, A Learning-Based Approach for Automatic Defect Detection in Textile Images, IFAC-PapersOnLine, br.3, sv. 48, str.2423–2428, Kolovoz 2015.
- [18] Tilda, Vision, UNI Freiburg, Freiburg, 2011, <https://lmb.informatik.uni-freiburg.de/resources/datasets/tilda.en.html>, [22 lipanj]
- [19] C. Kampouris, S. Zafeiriou, A. Ghosh, S. Malassiotis, Fine-grained material classification using micro-geometry and reflectance, 14th Europea Conference on Computer Vision, Amsterdam, 2016, <https://ibug.doc.ic.ac.uk/resources/fibrics/>, [22 lipanj]
- [20] J. Silvestre-Blanes, J. Moreno, I. Miralles, T. Alberro-Alberro, R. Perez-Llorens, AFID: a public fabric image databasse for defect detection, <https://www.aitex.es/afid/>, [22 lipanj]

- [21] M. H. Karimi, D. Asemani, Surface defect detection in tiling Industries using digital image processing methods: Analysis and evaluation, ISA Transactions br.3, sv. 53, str.834-844, Veljača 2014.
- [22] M. Ghazvini, S. A. Monadjemi, N. Movahhedini, K. Jamshidi, Defect detection of tiles using 2D-wavelet transform and statistical features, International Journal of Electrical and Computer Engineering, br.1, sv. 3, str.904-910, Studeni 2009.
- [23] Ž. Hocenski, S. Rimac-Drlje, T. Keser, Visual diagnostics based on image wavelet transform, Proceedings of 9th European conference on power electronics and applications, str.627-31, 2001
- [24] X. Yang, J. Gao, G. Pang, N. Yung textile defect classification using discriminative wavelet frames, Proceedings of the IEEE international conference on information acquisition, str.54-8, 2005.
- [25] R. Eslami, H. Radha, Wavelet based contourlet transform and its application to image coding, Proceedings of the international conference on imageprocessing, str.3-6, 2004.
- [26] Y. Ai, K. Xu, Feature extraction based on contourlet transform and its application to surface inspection of metals, Optical Engineering, br.11, sv. 51, Studeni 2012.
- [27] J. P. Yun, S. Choi, B. Seo, C. H. Park, S. W. Kim, Defects detection of billet surface using optimized gabor filters, Proceedings of the 17th world congress international federation of automatic control Seoul, Korea, str.77-82, Travanj 2008.
- [28] D. M. Tsai, Y. H. Tseng, S. M. Chao, C. H. Yen, Independent component analysis based filter design for defect detection in low-contrast textured images, Proceedings of the 18th international conference on pattern recognition (ICPR), str.218-231, Kolovoz 2006.
- [29] A. Branca, W. Delaney, F. P. Lovergine, A. Distanto, Surface defect detection by texture analysis with a neural network, International Conference in Robotics and Automation (ICRA), 1497-1502, Svibanj 1995.

- [30] M. Sadeghi, M. Shafiee, M. Memarzadeh, Using image processing in grading tile with Gabor wavelet, International Conference on Computer Science and Network Technology, Prosinac 2012.
- [31] S. Lu, B. M. Chen, C. C. Ko, Perspective rectification of document images using fuzzy set and morphological operations, Image and Vision Computing, br.5, sv. 23, str.541-553 Svibanj 2005.
- [32] H. Elbehiery, A. Hefnawy, M. Elewa, Surface defects detection for ceramic tiles using image processing and morphological techniques, International Journal of Computer, Electrical, Automation, Control and Information Engineering, br.5, sv. 1, 2007.
- [33] G. T. Shrivakshan, C. Chandrasekar, A Comparison of various Edge Detection Techniques used in Image Processing, IJCSI International Journal of Computer Science Issues, br.1, sv. 9, Rujan 2012
- [34] T. Matić, I. Vidović, Ž. Hocenski, Real Time Contour based ceramic tile edge and corner defects detection, Tehnički vjesnik, br.6, sv. 20, str.1063-1070, Prosinac 2013.
- [35] A. V. Nefian, M. H. Hayes, Hidden Markov models for face recognition, IEEE International Conference on Acoustics, Speech and Signal Processing, str.2721–2734, Ožujak 1999.
- [36] M. Aminzadeh, T. Kurfess, Automatic thresholding for defect detection by background histogram mode extents, Journal of Manufacturing Systems, sv. 37, str.83-92, 2015
- [37] S. Dutta, A. Datta, N. Das Chakladar, S. K. Pal, S. Mukhopadhyay, R. Sen, Detection of tool condition from the turned surface images using an accurate grey level co-occurrence technique, Precis Engineering, br.3, sv. 36, str.458–466, 2012
- [38] A. Sarafraz, Computer Vision Online, VxC TSG Image Database for Surface Grading, Miami, 2008, <https://computervisiononline.com/dataset/1105138707>, [25 Lipanj]
- [39] Rosalind Picard, Chris Graczyk, Steve Mann, Josh Wachman, Len Picard, and Lee Campbell, The Media Laboratory, MIT, Cambridge, Massachusetts, 1995, <http://vismod.media.mit.edu/vismod/imagery/VisionTexture/vistex.html>, [04 Rujan]

- [40] S. Jabo, Machine Vision for Wood Defect Detection and Classification, Chalmers University of Technology, Goteorg, Sweden 2011.
- [41] R. W. Conners, C. W. McMillin, K. Lin, R. E. Vasquez-Espiosa, Identifying and Locating Surface Defects in Wood: Part of an Automated Lumber Processing System, IEEE Transactions on patterns analysis and machine intelligence, br.6, vol. pami-5, Studeni 1983.
- [42] J. W. Funck, Y. Zhong, D. A. Butler, C.C. Brunner, J. B. Forrer, Image segmentation algorithms applied to wood defect detection, Computers and Electronics in Agriculture, sv. 41, str.157-179, 2003.
- [43] G. S. Robinson, Edge detection by compass gradient masks, Computer Graphics and Image Processing, sv. 6, str.492-501, Listopad 1977.
- [44] A. Shiozaki, Edge detection using entropy operator, Computer Vision and Image Processing sv. 36, str.1-9, Listopad 1986.
- [45] N. Otsu, A thresholding selection method from grey-level histogram, IEEE Transactions on Systems and Man Cybernetics, sv. SMC-9, str.62-66, 1979.
- [46] J. N. Kapur, P. K. Sahoo, A. K. C. Wong, A new method for grey-level picture thresholding using the entropy of the histogram, Computer Vision, Graphics and Image Processing, sv. 29, str.273-285, Ožujak 1985.
- [47] F. Deravi, S. K. Pal, Grey level thresholding using second-order statistics, Pattern Recognition Letters, sv. 1, str.417-422, 1983.
- [48] O. Silven, Lumber Grading, Visual Inspection of Lumber, University of Oulu, 2000, [www.ee.oulu.fi/~olli/Projects/Lumber.Grading.html](http://www.ee.oulu.fi/~olli/Projects/Lumber.Grading.html), [26. Lipanj]
- [49] E. Meier, The Wood Database, Wood finder 2007, <http://www.wood-database.com/wood-finder/>, [26. Lipanj]

## SAŽETAK

U industrijama je sve veća potražnja za metodama automatiziranog pronalaska pogrešaka na proizvodima prije njihovog puštanja u prodaju. Iz toga razloga razvijene su mnoge metode koje, usmjerene na detekciju pogrešaka putem slike u stvarnom vremenu, pronalaze greške i te proizvode označavaju kao neispravne. U tekstilnoj industriji postoji najviše različitih metoda koje se koriste, zbog brojnih vrsta tkanina i njihovih tekstura. Neke od njih pokazuju zadovoljavajuće rezultate te će sigurno biti još istraživanja kako bi se one poboljšale ili će se stvoriti neke nove metode. Slično je stanje i u keramičkoj industriji, jedini izuzetak je u drvenoj industriji u kojoj se nove metode ne razvijaju istom brzinom kao u prije navedenim industrijama. Kako bi nove metode mogle biti testirane postoje i baze slika koje sadržavaju slike različitih vrsta proizvoda na kojima će se kasnije metode trenirati i testirati.

Ključne riječi: detekcija pogrešaka, obrada slika, tekstil, pločice, drvo,

## **ABSTRACT**

Title: Overview of defect detection methods on various products

In industries, there is an increasing demand for automated defect detection methods on products before they are sold. For this reason, many methods have been developed which, in real-time, are used to detect defections in the image and classify these products as defective. In the textile industry, many different methods are used because there are many types of fabrics and their textiles. Some of them show satisfying results and there will certainly be further research to improve them or some new methods will be created. The situation is similar in the ceramic industry, the only exception is in the wood industry where new methods are not developed at the same rate as in the previously mentioned industries. In order for new methods to be tested, there are image databases that contain images of different types of products on which later methods can be trained and tested.

Key words: defect detection, image processing, textile, tiles, wood,

## ŽIVOTOPIS

Branimir Tomašić rođen je 20. Siječnja 1997. godine u Našicama. Osnovnu školu je upisao i završio u mjestu Koška, u Osnovnoj školi „Ivane Brlić Mažuranić“. 2011. godine upisuje se u Prirodoslovno – matematičku gimnaziju u Osijeku. Nakon završetka srednje škole, 2015. godine upisuje Elektrotehnički fakultet u Osijeku, preddiplomski sveučilišni studij Računarstva. Trenutno je na završnoj godini preddiplomskog studija.

---

Branimir Tomašić

## **DODATNI PRILOZI**

CD s tekstom završnog rada u pdf i docx formatu.