

SVEUČILIŠTE U ZAGREBU  
GRAFIČKI FAKULTET

**Nika Sviben**

# **Metode rastriranja crno bijele slike**

**DIPLOMSKI RAD**

Zagreb, 2016



Sveučilište u Zagrebu  
Grafički fakultet

**Nika Sviben**

# **Metode rastriranja crno bijele slike**

**DIPLOMSKI RAD**

Mentor:  
Doc.dr.sc. Ante Poljičak

Student:  
Nika Sviben

Zagreb, 2016



## SAŽETAK

Rastriranje nije jedan, strogo definiran fotomehanički proces nego opisuje dva procesa. U prvom se kontinuirani tonovi pretvaraju u seriju točaka. U drugom se pomoću raznih metoda mehaničkog otiskivanja otiskuju slike koje simuliraju kontinuirani ton. Osnovne metode digitalnog rastriranja slike su: jednotonska segmentacija, tablično rastriranje, rastriranje matricom nivoa i rastriranje difuzijom greške. HVS metode ispitivanja kvalitete slike su objektivne, kvalitativne procjene slike bazirane na ljudskom vizualnom sustavu. Postoji više metoda baziranih na HVS-u. WSNR se primjenjuje na slike na način da se prvo izračuna razlika slike kontinuiranog tona i obrađene slike te se pogreška ponderira s odazivom frekvencije HVS-a danim sa CSF-om.

U radu je ispitano 1000 crno-bijelih slika rastriranih koristeći 3 metode: tablično rastriranje, rastriranje matricom nivoa i rastriranje difuzijom greške. Rastriranje je provedeno putem programa MATLAB. Nakon rastriranja ispitana je kvaliteta dobivenih slika putem WSNR-a te su uspoređeni rezultati. Rezultati su pokazali kako metoda difuzije greške daje najbolje rezultate rastriranja, matrično rastriranje daje nešto lošije rezultate, a tablično rastriranje, neovisno o rasporedu rasterskih elemenata daje najlošije rezultate. Također, pokazalo se kako je moguće poboljšati kvalitetu slike rastrirane metodom tabličnog rastriranja promjenom rasporeda rasterskih elemenata.

**Ključne riječi:** rastriranje, tablično rastriranje, rastriranje matricom nivoa, difuzija greške, HVS

## **ABSTRACT**

Halftoning is not one strictly defined photomechanical process. It describes two processes. First, continuous tones are converted into a series of dots. Then, images are printed by using various methods of mechanical printing. Printed images simulate continuous tone. Halftoning methods are generally divided according to the structure of the elements into two groups: amplitude modulated (AM) and frequency modulated (FM) halftoning. Basic methods of digital halftoning are monotone segmentation, table halftoning, threshold matrix and error diffusion. HVS test methods are objective image quality measurements based on the human visual system. There are several methods based on the HVS. WSNR is applied to the image by calculating the difference between the continuous tone and the processed image and than weighting the error of the response frequency of HVS with the given CSF.

1,000 black-and-white images where halftoned using three methods: table halftoning, threshold matrix and error diffusion. Halftoning was performed by the program MATLAB. After halftoning, quality measurement of halftoned images was conducted using WSNR and results were compared. Results show that error diffusion method produces halftoned images of best quality, threshold matrix produces halftoned images of lesser quality and table halftoning produces images of worst quality. It is possible to produce better quality images by changing the layout of the elements in the table.

**Key words:** halftoning, table halftoning, threshold matrix, error diffusion, HVS

## SADRŽAJ

<b>1. Uvod</b>	<b>1</b>
<b>2. Teorijski dio</b>	<b>3</b>
2.1. Rastriranje	3
2.2. Povijesni pregled	3
2.3. AM rasterski sustavi	6
2.3.1. Oblik rasterskog elementa	9
2.3.2. Kut rastera	10
2.3.3. Linijatura	10
2.4. FM rasterski sustavi	11
2.5. Hibridni rasterski sustavi	15
2.6. Tablično rastriranje	16
2.7. Matrično rastriranje	17
2.7.1. Rastriranje matricom nivoa	18
2.8. Rastriranje difuzijom greške	22
2.9. Mjerenje kvalitete rastrirane slike putem HVS model	23
2.9.1. Campbellov CSF Model	27
2.9.2. Näsänenov (eksponencijalni) model	28
2.9.3. Miješani Gaussianovi modeli	28
2.9.4. Alpha-Stable HVS modeli	29
2.9.5. Weighted Noise Measurement (WSNR)	30
<b>3. Eksperimentalni dio</b>	<b>33</b>
<b>4. Rezultati i rasprava</b>	<b>35</b>
4.1. Rezultati	35
4.2. Rasprava	37
<b>5. Zaključak</b>	<b>39</b>
<b>6. Literatura</b>	<b>40</b>

## 1. UVOD

Rastriranje je proces pretvorbe slike kontinuiranog tona u binarni uzorak otisnutih i ne otisnutih točaka te se istražuje i razvija više od 120 godina [1]. Kod digitalnog rastriranja provodi se konverzija slike iz višetonske u binarnu koristeći software ili hardware. U zadnja tri desetljeća razvilo se više algoritama za rastriranje. Na primjer matrica nivo, difuzija greške, rastriranje zelenim šumom, DBS (direktno binarno traženje) i difuzija točaka [2]. Fotomehanički proces rastriranja projiciranjem originalne slike kontinuiranog tona kroz raster je zamijenjen RIP (raster image processor) sustavima [3]. Najjednostavnija metoda rastriranja je tablično rastriranje. Kod ove metode različita područja originalne slike zamjenjuju se sa odgovarajućim tablicama (ćelijama). Kod rastriranja matricom nivoa, binarna slika generira se uspoređujući svaki piksel slike kontinuiranog tona sa matricom nivoa neovisnih o slici. Binarna slika je crna kada su sivi tonovi piksela slike veći od odgovarajućih nivoa, a obrnuto je bijela. Nivoi se mogu generirati nasumično ili periodično. [4] Difuzija greške je još jedna metoda putem koje je moguće generirati vrlo kvalitetne binarne slike. Iako algoritam zahtjeva više paralelnih procesa daje bolje rezultate rastriranja za uređaje koji nemaju poteškoća sa rastom rasterskih elemenata. Postoje dvije različite klase kvalitativnih objektivnih načina mjerena. Prve su definirane matematički ili statistički i mogu se koristiti kod proučavanja binarnih rasterskih uzoraka sa konstantnim tonovima sive. Druga klasa su metode mjerena koji uzimaju u obzir karakteristike ljudskog vizualnog sustava (HVS) koji pokušava predvidjeti percipiranu vizualnu kvalitetu. HVS modeli uključuju se u algoritme rastriranja zadnjih 25 godina

Cilj rada je ispitati kvalitetu slika rastriranih s 3 različite metode rastriranja: tabličnim rastriranjem, rastriranjem matricom nivoa i difuzijom greške. Kvaliteta slike ispitati će se koristeći HVS metodu mjerena, WSNR. Ispitivanje će se provesti na 1000 crno bijelih slika.

Teorijski dio rada prvo će se baviti procesom rastriranja. Nakon toga biti će dan povjesni pregled. Potom će biti objašnjeno AM i FM rastriranje. Zatim će se objasniti metode rastriranja korištene u eksperimentalnom dijelu; tablično rastriranje, rastriranje matricom nivoa te metoda difuzije greške. Na kraju će biti objašnjeno mjerjenje kvalitete metodama baziranim na HVS-u te konkretno WSNR metoda koja je korištena u eksperimentalnom dijelu.

## **2. TEORIJSKI DIO**

### **2.1. Rastriranje**

Rastriranje nije jedan, strogo definiran fotomehanički proces nego opisuje dva procesa. U prvom se kontinuirani tonovi pretvaraju u seriju točaka. U drugom se pomoću raznih metoda mehaničkog otiskivanja otiskuju slike koje simuliraju kontinuirani ton [5]. Kod digitalnog rastriranja provodi se konverzija slike iz višetonske u binarnu koristeći software ili hardware. U zadnja tri desetljeća razvilo se više algoritama za rastriranje. Na primjer; matrica nivoa, difuzija greške, rastriranje zelenim šumom, DBS (direktno binarno traženje) i difuzija točaka [2].

Rastriranje je potrebno provesti kako bi se slike mogle otisnuti na binarnim uređajima kao što su ink jet printeri koji mogu ili otisnuti ili ne otisnuti točku. Ljudski vizualni sustav spaja te otisnute ili ne otisnute točke i stvara iluziju kontinuiranih tonova. Ovisno o specifičnom načinu na koji su točke distribuirane, uređaj može reproducirati različite nivoe vjernosti slike s više ili manje zrnatosti. Prema ljudskom vizualnom sustavu, nasumično smještene i izolirane točke, ispravno distribuirane, trebale bi dati sliku najveće kvalitete, zadržavajući oštре rubove i druge fine detalje. Istovremeno, određeni ekrani i uređaji za tiskanje nisu sposobni reproducirati izolirane točke konzistentno od točke do točke. Sukladno tome dolazi do stvaranja artefakata koji znatno degradiraju kvalitetu slike koju bi takva distribucija točaka trebala sačuvati. Zbog toga, mnogi uređaji za tiskanje reproduciraju periodičan uzorak grupiranih točaka koje je lakše reproducirati konzistentno na cijeloj otisnutoj stranici [3].

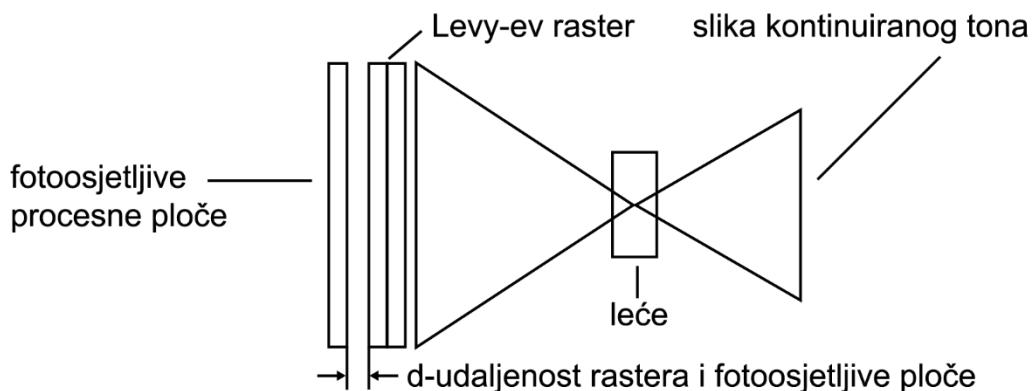
### **2.2. Povijesni pregled**

Proces rastriranja istražuje se i razvija više od 120 godina.[3] Niti jedna osoba ne može biti imenovana kao izumitelj fotomehaničkog procesa rastriranja. William Henry Fox Talbot (Velika Britanija, 1800-1877) izumio je i patentirao tkaneni raster 1852 godine. Može se smatrati da su Talbot, Georg Meisenbach

(Njemačka, 1841–1912), Frederic Ives (SAD, 1856–1937) i Max Levy (SAD, 1857–1926) najviše doprinijeli razvoju procesa rastriranja [5].

Prije nego je analogno rastriranje usavršeno 1880-ih, monokromne fotografije kontinuiranog tona su reproducirane kao linijski crteži koje su izrađivali vrlo iskusni majstori te su ih obično izrađivali urezivanjem na drvenim ili metalnim pločama. Proces rastriranja je omogućio brzu i jeftinu reprodukciju fotografija u novinama i časopisima te je time fotografija postala lukrativna industrija te je pokrenuta i tehnološka revolucija fotografske opreme [3].

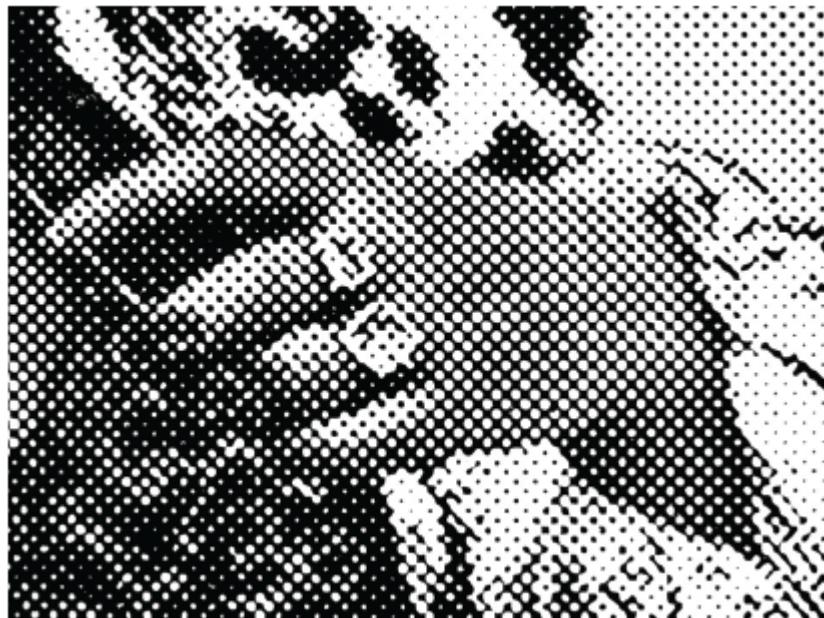
Oko 1850. godine, demonstrirana je mogućnost otiskivanja slika kontinuiranog tona fotografiranjem slike kroz rijetko tkanu tkaninu ili raster smješten na određenoj udaljenosti od fokusne ravnine. U praktičnu upotrebu ušao je 1890-ih kada su rasteri postali komercijalno dostupni. Rani proces rastriranja, fotolitografija, uključivao je projiciranje svjetla s negativa fotografije kontinuiranog tona kroz raster, na primjer fino tkanu svilu, na fotoosjetljivu ploču. Kada bi jarko svjetlo prošlo kroz sitan otvor na svilenom rasteru osvijetlilo bi veću okruglu površinu na ploči.



Slika 1. Shematski prikaz procesa rastriranja[5]

Prigušeno svjetlo bi osvijetlilo manju površinu. Fotoosjetljivi spojevi na površini ploče bi tada stvorili neotopive točke koje bi varirale u veličini ovisno o tonovima na originalnoj fotografiji. Nakon tog procesa na ploči bi ostale povišene točke [3]. Točkasti uzorak je iskorišten kako bi se napravile tiskovne forme za visoki

tisak te je rastrirana slika otisnuta koristeći jednu boju na konačnom supstratu, najčešće papiru.



**Slika 2.** Slika otisnuta tehnikom knjigotiska rastrirana koristeći Ives/Levy raster[5]

Velik broj kvalitetnih otisaka mogao se proizvesti brzo i ekonomično [5]. Rani razvoj procesa rastriranja uključivao je pronađen savršenog rastera. Georg Meisenbach razvio je linearni raster koji se rotirao za 90 stupnjeva tijekom osvjetljavanja ploče kako bi se dobio efekt prekriženih linija. Kasnije su se koristili stakleni rasteri koji su s jedne strane bili obojeni neprozirnom bojom. Mreža paralelnih i jednakim udaljenih linija bila je urezana na neprozirnu stranu. Druga mreža paralelnih i jednakim udaljenih linija urezivala se na neprozirnu površinu paralelnu s prvom. Rasteri su se razlikovali po broju linija po inču koji su bile urezane. Finiji rasteri su stvarali bolju prostornu rezoluciju (detalje), ali je kvaliteta tiskarskog procesa ograničavala finoću rastera [3]. Frederic Ives cementom je spojio dva staklena rastera koji su rotirani za 90 stupnjeva te je stvorio raster od jednog komada. Max Levy usavršio je proizvodnju visoko kvalitetnih rastera i uspješno ih je komercijalno predstavio kroz svoju tvrtku. Razvijeni su i novi tipovi rastera te je proizvodnja rastera postala jeftinija i bolje prilagođena specifičnim potrebama. Patentirano, testirano i predstavljeno je

puno novih tipova rastera, ali je većina brzo odbačena te je standardni Ives/Levy raster ostao neosporni pobjednik za rastersku fotografiju i tisak. Velik broj otiska za koje su korišteni posebni rasteri može se naći u knjigama, časopisima i specijaliziranim publikacijama toga doba [5]. 1940-ih predstavljeni su kontaktni rasteri načinjeni od filma [6]. Film se stavljao direktno u kontakt s neosvjetljenim litografskim filmom. Taj kontaktni raster imao je direktnu kontrolu nad strukturom točaka te je omogućio kontrolu nad linijaturom rastera, oblikom rasterskih elemenata i kutom rastera. Napretkom računala, fotomehanički proces rastriranja koji je predstavljen 1880-ih uglavnom je zamijenjen digitalnim procesom rastriranja. U nekim slučajevima, kao što su sublimacijski printeri, proces rastriranja nije potreban. Ipak takvi printeri nemaju široku upotrebu zbog njihove brzine i potrebe za posebnim bojama i papirom. Kod digitalnog rastriranja, proces projiciranja originalne slike kontinuiranog tona kroz raster je zamijenjen RIP (*raster image processor*) sustavima koji pretvaraju svaki piksel originalne slike u binarnu točku uspoređujući svaki piksel originalne slike s matricom vrijednosti. Pikseli originalnih intenziteta većih od odgovarajućeg nivoa se „uključuju“ odnosno otiskuju u finalnoj rastriranoj slici, a pikseli čiji je intenzitet manji od određenog nivoa se „isključuju“. Za veće slike matrice nivoa se ponavljaju od početka do kraja tako da svaki piksel ima pridružen određeni nivo vrijednosti [3].

### **2.3. AM rasterski sustavi**

Amplitudno modulirano (AM) rastriranje je proces prezentiranja različitih nijansi sive s pravilnom mrežom okruglih rasterskih elemenata koji variraju veličinom. Tamne nijanse sive se postižu velikim skupinama većih rasterskih elemenata, a svijetlije nijanse manjim skupinama manjih rasterskih elemenata.



**Slika 3.** Slika rastrirana AM rasterom[3]

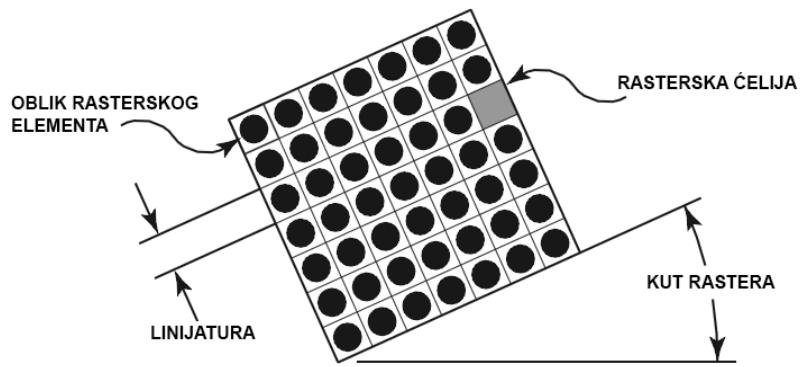
Ovaj način rastriranja se općenito odnosi na rastriranje periodičnim, grupiranim elementima i postiže se putem matrica nivoa gdje se pojedini pikseli uspoređuju s vrijednostima matrice nivoa. Kada su prvi put predstavljeni RIP sustavi su imitirali rasterske uzorke kontaktnih rastera koji su koristili pravilno raspoređene veće skupine rasterskih elemenata. Matrica nivoa je bila mala (8x8, 12x12 ili 16x16) i sastojala se od uzastopnih pragova vrijednosti koji su bili posloženi spiralno tako da su se širili iz centra matrice.

3	9	17	27	25	15	7	1
11	29	38	46	44	36	23	5
19	40	52	58	56	50	34	13
31	48	60	64	62	54	42	21
30	47	59	63	61	53	41	20
18	39	51	57	55	49	33	12
10	28	37	45	43	35	22	4
2	8	16	26	24	14	6	0

**Slika 4.** Spiralni raspoređeni nivoi vrijednosti

Takav raspored vrijednosti davao je pojedinačne grupe piksela centrirane oko svake ćelije te su formirali pravilnu mrežu okruglih rasterskih elemenata koji su varirali u veličini ovisno o tonu. Takva tehnika se općenito odnosi na amplitudno modulirano ili AM rastriranje zato što se modulira veličina otisnutih točaka. Kao i kod kontaktnih rastera, rasterski uzorak je varirao prema linijaturi, obliku rasterskih elemenata te kutu [3].

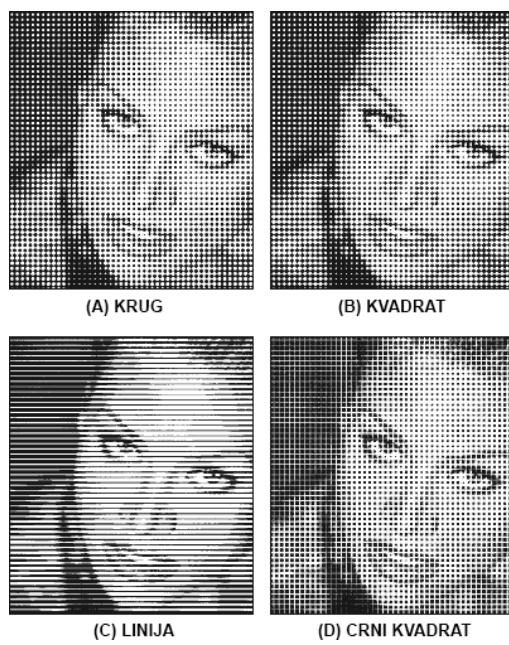
Prednost rastriranja s grupiranim rasterskim elementima je mala zahtjevnost za računalo, stabilna formacija rasterskih elemenata i otpornost na prirast rasterskih elemenata. Zato se često koriste kod tehnika ispisa kao što je elektrofotografija gdje se izolirani rasterski element ne može uvijek pravilo razviti. Jedan od nedostataka rastriranja s grupiranim rasterskim elementima je limitirana mogućnost reprodukcije detalja. Također, pravilan raspored rasterskih elemenata dovodi do mogućnosti stvaranja moiré uzorka kod slika koje imaju sličnu frekvenciju grupiranih rasterskih elemenata. Stoga takva metoda nije pogodna za sve slike posebno za one smanjenje kvalitete koja se može dodatno narušiti [7].



**Slika 5.** Oblik rasterskog elementa, linijatura i kut rastera[3]

### 2.3.1. Oblik rasterskog elementa

Kod opisivanja AM rastera, oblik rasterskog elementa odnosi se na specifičan raspored pragova vrijednosti unutar matrice nivoa. Taj raspored određuje kako skupine variraju veličinom i oblikom ovisno o tonu. Oblik rasterskih elemenata najbolje se raspozna kada je jednak broj bijelih i crnih rasterskih elemenata. Rasterski elementi su najčešće okrugli, četvrtasti ili eliptični. Korišteni su i neki posebni oblici rasterskih elemenata, ali samo za posebne potrebe [3].



**Slika 6.** Oblici rasterskih elemenata[3]

### 2.3.2. Kut rastera

Kut rastera je orijentacije linija rastera prema horizontalnoj osi čija je optimalna vrijednost funkcija ljudskog vizualnog sustava. Smjer rasterskih elemenata je najmanje uočljiv dijagonalno pod kutom od 45 stupnjeva. Iz toga proizlazi da bi za monokromni tisk tisak kut rastriranja trebao biti 45 stupnjeva. Zbog potrebe računala, kutovi rastriranja su obično ograničeni na racionalne kuteve gdje je svaki dio jednake veličine i oblika [3].



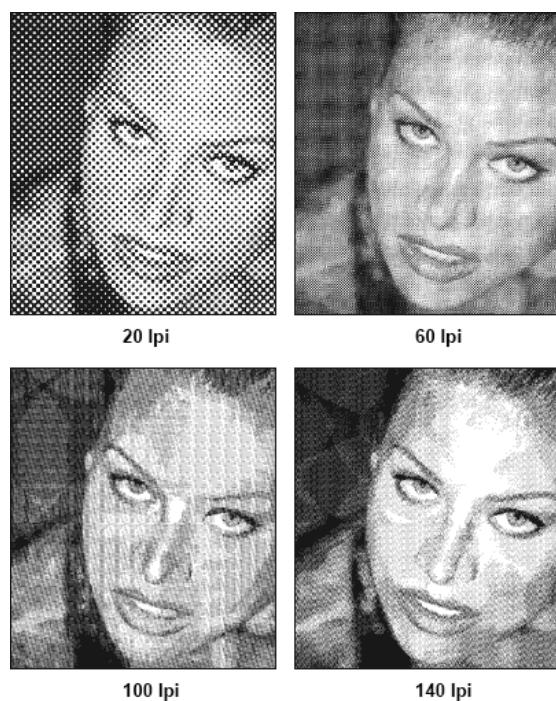
Slika 7. Različiti kutevi rastera[3]

### 2.3.3. Linijatura

Kod AM rastriranja, linijatura je broj linija ili redova rasterskih elemenata po inču finalnog rasterskog uzorka. Kao kod staklenih rastera, finiji rasteri stvarali su uzorke visoke prostorne rezolucije. Linijatura je limitirana rezolucijom uređaja na kojem se vrši tisk jer ovisi o broju jedinstvenih tonova sive koje je moguće otisnuti. Taj je odnos definiran kao

$$\text{linijatura} = \frac{\text{rezolucija uređaja (dpi)}}{\sqrt{\text{broj tonova sive}-1}} \quad (1)$$

Kako bi se predstavilo 256 tonova sive, matrica nivoa mora imati najmanje 255 piksela. To znači da bi veličina čelije trebala biti najmanje  $16 \times 16$  odnosno 256 piksela. Za uređaj rezolucije od 600 dpi to odgovara  $600/16$  odnosno 37,5 linija po inču. Takva linijatura je vidljiva ljudskim okom te se zato stvara snažna, periodična tekstura na otisnutoj slici. Najbolji uređaji mogu otisnuti linijature veće od 150 lpi. Takva linijatura nije vidljiva ljudskim okom kada se promatra s udaljenosti od 10 ili više inča. Zato je potrebno postići kompromis između broja tonova sive i linijature rastrirane slike [3].



**Slika 8.** Različite linijature rastera[3]

## 2.4. FM rasterski sustavi

Zbog slobode koje omogućuju digitalni printeri pojavila se ideja o otiskivanju izoliranih rasterskih elemenata kako bi se smanjila vidljivost rastera (vidljivost individualnih rasterskih elemenata ljudskim okom) umjesto otiskivanja grupiranih rasterskih elemenata. Zadržavanjem konstantne veličine rasterskih elemenata za sve tonove sive, nova tehnika rastriranja je mijenjala udaljenost

između pojedinih elemenata kako bi se postigli svi tonovi sive. Zbog toga je nazvana frekventno modulirano rastriranje odnosno FM rastriranje [3].



**Slika 9.** Slika rastrirana FM rasterom[3]

Rane tehnike FM rastriranja su predložili Bayer i Bryngdahl i davale su uređeni raspored izoliranih točaka.

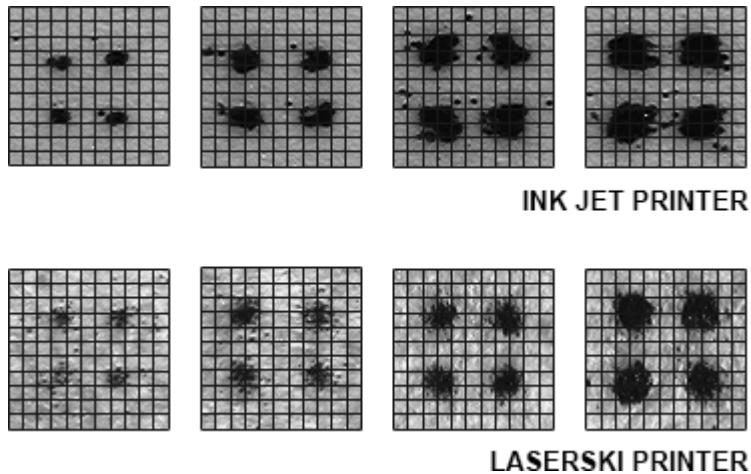
0	58	14	54	3	57	13	53
32	16	46	30	35	19	45	29
8	48	4	62	11	51	7	61
40	24	36	20	43	27	39	23
2	56	12	52	1	59	15	55
34	18	44	28	33	17	47	31
10	50	6	60	9	49	5	63
42	26	38	22	41	25	37	21

**Slika 10.** Bayerova matrica nivoa[3]

Te tehnike, kao i kod AM rastriranja, kvantiziraju svaki piksel neovisno o susjednim pikselima prema matrici nivoa, ali uz korištenje uzastopnih pragova nivoa što je više moguće. Problem s tim ranim tehnikama FM rastriranja je neprirodan izgled rastriranih slika koje uzrokuje periodična struktura. Floyd i Steinberg su predložili novi i bolji pristup FM rastriranju, algoritam difuzije greške. To je adaptivna tehnika koja kvantizira svaki piksel te prosljeđuje vrijednost greške do njegovih susjeda te tako stvara stohastički raspored rastriranih elemenata. Taj proces zahtijevao je veću računalnu snagu, ali su dobiveni uzorci imali znatno veću prostornu rezoluciju od one dobivene skupinama rasterskih elemenata. Nadalje, stohastičkim uzorkom rasterskih elemenata, eliminirana je pojava moiré-a koji se stvarao preklapanjem dva ili više pravilnih uzoraka [3]. Često korišteni FM algoritmi uključuju disperzirani raspored rasterskih elemenata, algoritam difuzije greške te metode bazirane na traženju kao što je direktno binarno traženje (DBS). Difuzija greške je jedna od najčešće korištenih metoda. Iako zahtjeva više računalne snage u usporedbi s ranijim metodama i dalje je vrlo učinkovita. Generalno, FM rastriranje postiže bolju prostornu rezoluciju od AM rastriranja i slobodno je od moiré artefakata. Unatoč tome nedostaje stabilnosti prilikom tiska kako bi se koristila s nekim tehnikama ispisa kao što je elektrofotografija. Kod elektrofotografskih procesa, veličina i oblik rasterskih elemenata znatno varira kod svakog pojedinačnog

otisnutog rasterskog elementa. Takva varijacija može se umanjiti samo kada su rasterski elementi grupirani u skupine. Slike otisnute koristeći izolirane rasterske elemente obično imaju veliku tonsku neujednačenost te postoje zнатне varijacije tona preko cijele slike. Zbog toga se za nepouzdane uređaje kao što su litografske tiskarski strojevi i laserski printeri koristi AM rastriranje [7]. Korištenjem FM rastriranja uređaji maksimiziraju svoju spacialnu rezoluciju te su oslobođeni strogih tolerancija kuta rastera i registra rastera. Također, mogu koristiti više boja kako bi reproducirali veći gamut boja. Iako postoje velike prednosti, FM rastriranje iskoristili su samo ink jet printeri jer imaju mogućnost tiskanja malih izoliranih točaka [3]. Nažalost ink jet printeri su jedini uređaji na kojima je moguće iskoristiti prednosti frekventno moduliranog rastriranja jer je kod velikih rezolucije (2400+ dpi) vrlo teško kontinuirano točno otiskivati izolirane rasterske elemente. Varijacije veličine i oblika rasterskih elemenata tada mogu davati vrlo lošu kvalitetu otisnute slike [3].

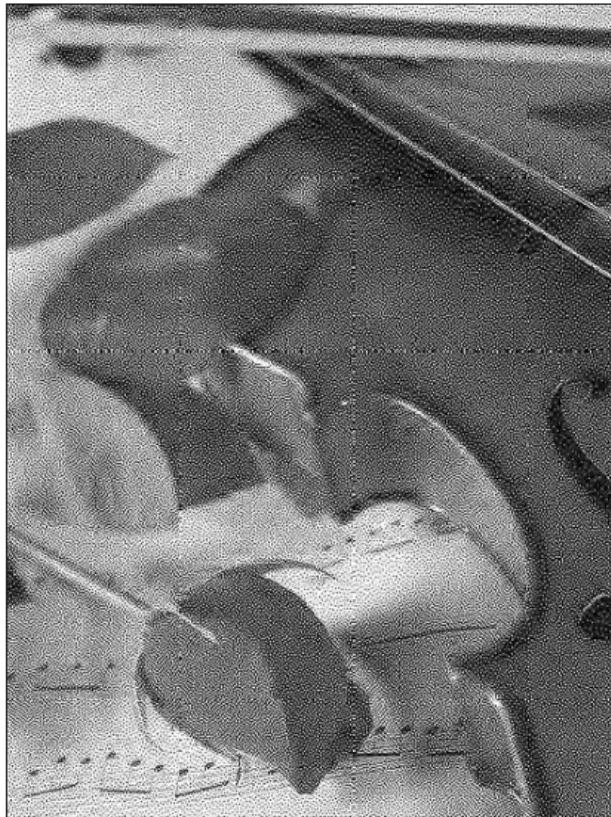
Savršen raster proizvodi točke koje u potpunosti prekrivaju područje uzorka povezano s danim pikselom bez preklapanja područja uzorka susjednih piksela. Savršena crna može se postići otiskivanjem svih piksela. Kod stvarnih uređaja, individualni rasterskih elementi su okrugli, kako bi se postigla savršena crna rasterski elementi moraju biti dovoljno veliki kako bi se pokrilo cijelo područje uzorka. Preklapanjem susjednih područja rezultanti ton je tamniji od frakcije svih piksela koji su otisnuti. Pretpostavljajući da su rasterski elementi otiskivani konzistentno (male varijacije u veličini i obliku kod svakog otisnutog rasterskog elementa), neujednačenost tona može se ispraviti podešavanjem nivoa intenziteta slike prije rastriranja. Količina potrebne kompenzacije ovisi o rasporedu rasterskih elemenata s tim da disperzirani elementi (FM) zahtijevaju veći stupanj korekcije od grupiranih (AM). Ink jet printeri otiskuju otprilike okrugle rasterske elemente. Uz kompenzaciju za distorziju mogu iskoristiti pogodnosti FM rastriranja [3].



**Slika 11.** Rasterski elementi otisnuti ink jet i laserskim printerom[3]

## 2.5. Hibridni rasterski sustavi

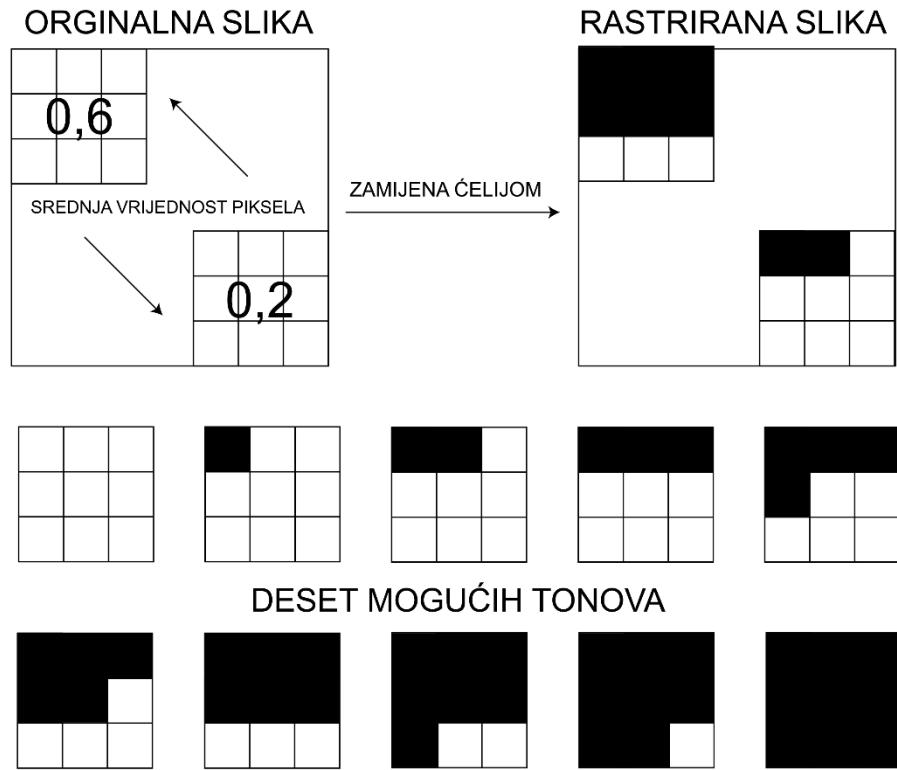
Kako uređaji mogu postizati rezolucije veće od 1200 dpi granice FM rastriranja su dostignute kao i kod AM rastriranja. Zato su se počele istraživati novi načini rastriranja, AM-FM hibridi koji stvaraju skupine rasterskih elemenata koji variraju po tonu, veličini i rasporedu. Kod reprodukcije monokromnih slika AM-FM hibridi generalno mogu dati slabo vidljiv uzorak (visoka prostorna rezolucija) u usporedbi s AM rastriranjem i ako su stohastički ne pokazuju periodičnu strukturu koja dodaje umjetnu teksturu na otisnutoj slici. S jednakom količinom grupiranja takvi rasteri su lakši za otiskivanje pouzdano s malo varijacije u nastalom tonu. Kod reprodukcije boje stohastički hibridi zadržavaju jednake prednosti vezane uz pojavu moiré-a kao i FM rasteri [3].



**Slika 12.** Slika rastrirana hibridnim rasterom[3]

## 2.6. Tablično rastriranje

Najjednostavnija metoda rastriranja je tablično rastriranje. Kod ove metode različita područja originalne slike zamjenjuju se odgovarajućim tablicama (ćelijama). Općenito bi trebalo biti zamijenjeno najmanje svako  $2 \times 2$  područje originalne slike s tablicom. Veličina tablice se određuje prema linijaturi i rezoluciji uređaja. Točnije ovisi o omjeru dpi i lpi vrijednosti. Na primjer, ako pretpostavimo da će svako područje od  $3 \times 3$  piksela biti zamijenjeno  $3 \times 3$  tablicom. Izračuna se srednja vrijednost piksela u svakom  $3 \times 3$  području originalne slike. S obzirom da je tablica veličine  $3 \times 3$  samo deset tonova sive može se dobiti takvom tablicom. Jedan od tih deset tonova je najbliži prosjeku svakog područja od  $3 \times 3$  piksela originalne slike te zamjenjuje to područje na istoj poziciji u rastriranoj slici [8].

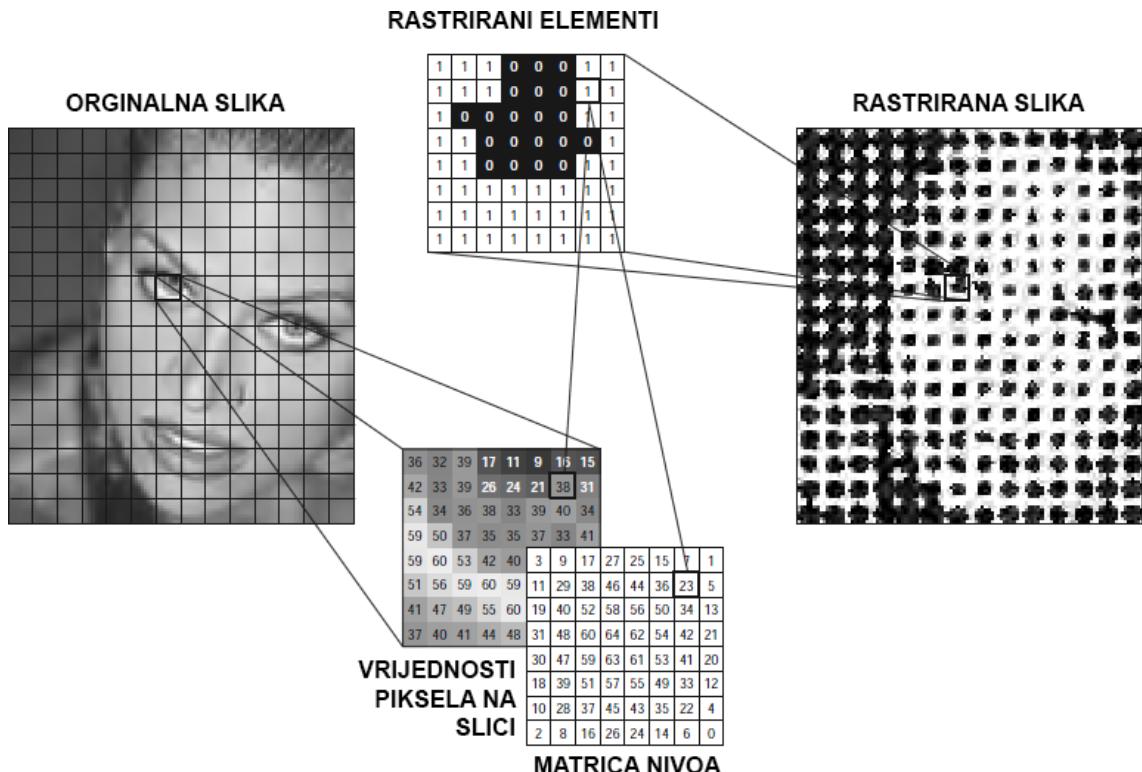


**Slika 13.** Shematski prikaz tabličnog rastriranja

## 2.7. Matrično rastriranje

Digitalno rastriranje je proces generiranja uzorka crno bijelih točaka s binarnim uređajima kao što su printeri, a koji daju dojam originalne slike kontinuiranog tona zbog nedostatka oka kod visokih rezolucija. Razni algoritmi za digitalno rastriranje postižu to spajanjem prostorne modulacije slike kontinuiranog tona s pragovima vrijednosti kako bi reproducirali srednje vrijednosti u određenoj regiji [9]. Binarna slika generira se uspoređujući svaki piksel slike kontinuiranog tona s matricom nivoa neovisnih o slici. Binarna slika je crna kada su sivi tonovi piksela slike veći od odgovarajućih nivoa, a obrnuto je bijela. Nivoi se mogu generirati nasumično ili periodično. Najveća prednost ovih tehnika rastriranja je smanjenje potrebne računalne snage te mogućnost paralelnog izvršavanja. Klasično rastriranje je bilo najpopularnije zbog svoje otpornosti na distorziju kod tiska i zbog sličnosti s tradicionalnim analognim tehnikama rastriranja. Tehnike

rastriranja s disperziranim rasterskim elementima mogu se koristiti ako su nivoi vrijednosti odabrani na način da se uračunava distorzija kod tiska [4].



**Slika 14.** Matrično rastriranje[3]

### 2.7.1. Rastriranje matricom nivoa

Slike kontinuiranog tona moraju se rastrirati kako bi se mogle prikazati na binarnim uređajima kao što su printeri. Uređeni algoritmi su popularan pristup rastriranju. Takvi algoritmi koriste matrice nivoa kako bi aproksimirali vrijednosti sivih tonova. Raspored nivoa u matrici određuje teksturu koja se pojavljuje na rastriranoj slici [10]. Vrijednost rastriranog piksela određuje nivo vrijednosti unutar periodičnog zaslona. Periodični zaslon je obično konstruiran od više matrica nivoa položenih preko površine originalne slike. Raspored nivoa vrijednosti unutar matrice određuje teksturu rastriranja. Obično se koriste male Bayerove matrice te nastaju snažne teksture. Cilj nedavnih istraživanja je

reducirati takve tekture koristeći veće stohastičke matrice: *blue noise* maske i *void-and-cluster* rastere [9].

Kao što je ranije navedeno, kod ovih algoritama rastriranja originalna slika uspoređuje se s periodičnim zaslonom. Taj zaslon se naziva i matrica nivoa ili rasterska matrica. 2D signal  $t(n)$  je periodičan ako postoje dva nezavisna linearna vektora  $N_1$  i  $N_2$  tako da

$$t(n) = t(n + Nk) \quad (2)$$

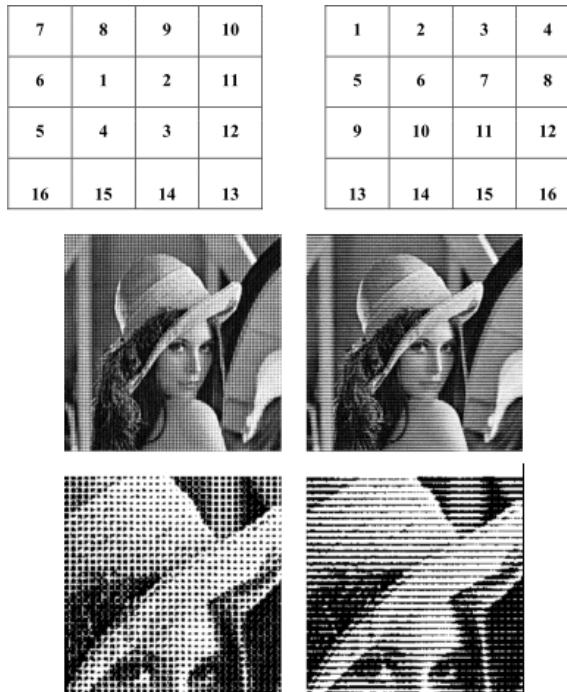
za  $N = [N_1 | N_2]$  i bilo koji cijelobrojni vektor  $k = (k_1, k_2)^T$ . Ovdje  $N$  označava periodičnost matrice. Uređeni algoritam rastriranja za specifičnu matricu može se opisati kao:

$$h(n) = \begin{cases} 1, & \text{if } x(n) \geq t(n) \\ 0, & \text{if } x(n) < t(n) \end{cases} \quad (3)$$

Ovdje se pretpostavlja da je originalna slika normalizirana tako da je  $0 \leq x(n) \leq 1$ .  $h(n) = 0$  označava da je piksel bijel, a  $h(n) = 1$  označava da je crn. Matrica koja se koristi određuje red kojim se točke dodaju rešetci kako se smanjuje svjetlina, a isto tako određuje i kvalitetu slike. Ovisno o matrici algoritam rastriranja ima različite karakteristike. Najjednostavnija matrica je ona koja daje konstantu vrijednost za svaki piksel  $t(n) = 0,5 \forall n_1, n_2$ . Većina detalja na slici kontinuiranog tona gubi se ako se koristi ovakva matrica prilikom rastriranja te je takva rastrirana slika slabo vidljiva [2].

Nivoi vrijednosti su raspoređeni unutar rasterske ćelije čije cijelo područje mora biti pokriveno ponavljajućom periodičnom distribucijom tako da točno jedan nivo vrijednosti postoji za svaki piksel originalne slike. Na primjer, ako se želi dobiti 16 tonova sive tada mora postojati 16 nivoa vrijednosti raspoređenih unutar  $4 \times 4$  matrice. Raspored rasterskih ćelija je takav da je udaljenost od svake od 4

nasuprotnih ćelija uvijek isti. Uz osnovni raspored rasterskih ćelija, raspored nivoa vrijednosti je taj koji najviše utječe na izgled rastrirane slike.



**Slika 15.** Ista slika rastrirana matricama s različitim nivoima vrijednosti[11]

Za kvadratne ćelije, najuniformnija distribucija nivoa vrijednosti postiže se dužinom stranice koja je djeljiva s dva [12].

228	169	110	95	165	177	197	236
154	126	83	51	79	122	150	209
137	67	35	20	32	63	106	193
98	39	8	4	12	47	91	185
114	55	24	16	28	59	134	205
158	130	71	43	75	118	146	232
221	173	142	87	102	161	213	240
248	224	201	181	189	217	244	252

(a)

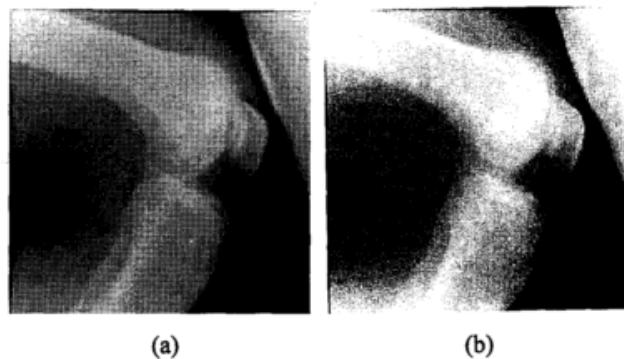
  

4	130	35	161	12	138	43	169
193	67	224	98	201	75	232	106
51	177	20	146	59	185	28	154
240	114	209	83	248	122	217	91
16	142	47	173	8	134	39	165
205	79	236	110	197	71	228	102
63	109	32	158	55	181	24	150
252	126	221	95	244	118	213	87

(b)

**Slika 16.** Matrice nivoa: (a)grupirani rasterski elementi, (b)disperzirani elementi[9]

U matrici na slici 16a nivoi vrijednosti raspoređeni su prema veličini te nastaju rasterski elementi koji se spajaju kako bi formirali veće rasterske elemente. U matrici na slici 16b nivoi vrijednosti su raspoređeni tako da nastaju raspršeni rasterski elementi. Idealni tonovi sive koji nastaju generalnim uređenim algoritmima trebali bi biti proporcionalni broju rasterskih elemenata, ali zbog preklapanja rasterskih elemenata tonovi su obično tamniji. Zato je rastrirana raspršene rasterske elemente [9]. Kod rastriranja s grupiranjem rasterskih elemenata matrica je napravljena kako bi oponašala proces analognog rastriranja. Kada se intenzitet piksela smanji, poveća se rasterski element.



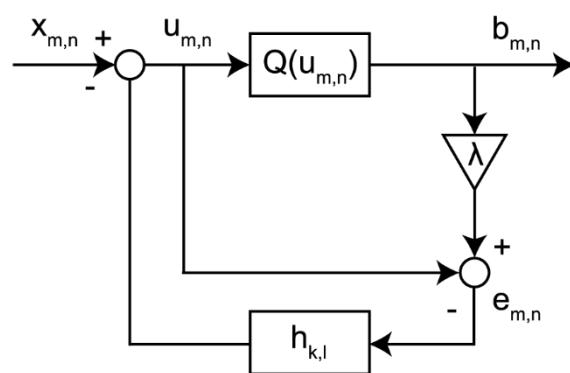
**Slika 17.** Rastrirane slike sa 600 dpi (a) grupirani elementi,(b) disperzirani elementi[9]

Kod rastriranja s disperzijom rasterskih elemenata pravila kreiranja takvih matrica utemeljio je Bayer. U svojim radovima vidljivost neželjenih umjetnih tekstura mjeri se Fourierovom analizom uzorka rasterskih elemenata na različitim nivoima svjetlosti. Kada uzorak rasterskih elemenata na uniformnom dijelu ima komponente različitih valnih duljina, komponente s najdužim valnim duljinama se smatraju najvidljivijima. S tim kriterijem Bayer je dizajnirao optimalne rasterske matrice. S takvim matricama više je detalja vidljivo na rastriranim slikama nego na slikama rastriranim s grupiranim rasterskim elementima. Iako se rastriranjem s raspršenim rasterskim elementima dobiva više detalja u praksi se koristi rastriranje s grupiranim elementima zbog prirasta rasterskih elemenata. Do prirasta dolazi zbog ne optimalnog rada tiskarskih uređaja. Iako bi idealni uređaji trebali proizvoditi rasterske elemente

predefiniranih oblika kao što je krug, to u stvarnosti nije tako zbog širenja boje u susjedne rasterske elemente. Rastriranje grupiranjem elemenata je otpornije na takav prirast jer kako se intenzitet piksela smanjuje točka raste oko rasterskog elementa te smanjuje efekt prirasta na rastriranu sliku [2].

## 2.8. Rastriranje difuzijom greške

Difuzija greške je još jedan algoritam rastriranja koji se često koristi. Algoritam su predstavili Floyd i Steinberg. Iako algoritam zahtjeva više paralelnih procesa daje bolje rezultate rastriranja za uređaje koji nemaju poteškoća s prirastom rasterskih elemenata [2]. Difuzija greške je algoritam rastriranja baziran na regijama. Izlazna vrijednost se određuje prema ulaznim vrijednostima sivih tonova, nivou vrijednosti i vrijednostima greške rastriranja piksela u susjedstvu. Greška povezana s aproksimacijom je propagirana do neprocesuiranih susjednih piksela te tako kompenzira aproksimativnu grešku preko cijele regije. Algoritmi difuzije greške razlikuju se veličinom i oblikom aproksimativnih regija te redu kojim se obrađuju pojedine regije. Većina tehnika koristi regije od jednog piksela s više puteva koji se procesuiraju. Druge koriste više regija piksela kako bi se generirale skupine rasterskih elemenata [10].



Slika 18. Shematski prikaz algoritma difuzije greške

Standardni algoritam za difuziju greške prikazan je na slici 18. Unoseći crno bijelu višetonsku sliku čiji je dinamički raspon  $[0, \lambda]$ . Unos vrijednosti  $x_{m,n}$  obično se procesира od vrha do dna svakog reda i s lijeva prema desnom unutar svakog reda. Izlazna vrijednost  $b_{m,n}$  difuzije greške može se dobiti iz jednadžbe

$$b_{m,n} = Q(u_{m,n}) = \begin{cases} 1 & u_{m,n} \geq \lambda/2 \\ 0 & u_{m,n} < \lambda/2 \end{cases} \quad (4)$$

$$u_{m,n} = x_{m,n} - \sum_{k,l \in S} h_{k,l} e_{m-k, n-l} \quad (5)$$

$$e_{m,n} = \lambda b_{m,n} - u_{m,n} = \lambda Q(u_{m,n}) - u_{m,n} \quad (6)$$

Ovdje  $u_{m,n}$  označava modificiranu vrijednost višetonske slike  $x_{m,n}$ . Kvantizator greške  $e_{m,n}$  na bilo kojoj  $(m, n)$  je definiran kao razlika modificirane višetonske i binarne slike. Prošle greške se filtriraju i oduzimaju od trenutne vrijednosti slike  $x_{m,n}$  prije nego što se kvantizira kako bi se dobila binarna vrijednost  $b_{m,n}$ , gdje je  $h_{k,l}$  matrica difuzije greške, a  $S$  regija podrške za  $h_{k,l}$ . U većini sustava matrica zadovoljava uvjet [9]

$$\sum_{k,l \in S} h_{k,l} = 1 \quad (7)$$

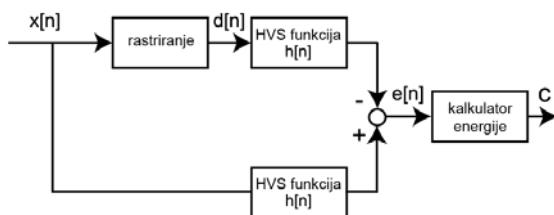
Tehnika difuzije greške daje oštire slike nego konvencionalne tehnike rastriranja, ali je vrlo osjetljiva na distorzije uređaja za tisk [13].

## 2.9. Mjerenje kvalitete rastrirane slike putem HVS model

Jedan način na koji se može opisati digitalno rastriranje je potraga za kvantiziranim slikom na kojoj su artefakti minimalno vidljivi. Kako bi se takav pristup primijenio u praksi prvo je potrebno pronaći računalni model kojim je moguće izračunati vidljivu grešku kojim će biti moguće rangirati slike automatski. Model se može uključiti u sam algoritam rastriranja ili se može koristiti nakon rastriranja kako bi se ocijenile rastrirane slike. U posljednjem slučaju može se koristiti kako bi se rangirali algoritmi rastriranja. Postoje dvije različite klase kvalitativnih objektivnih načina mjerenja. Prve su definirane

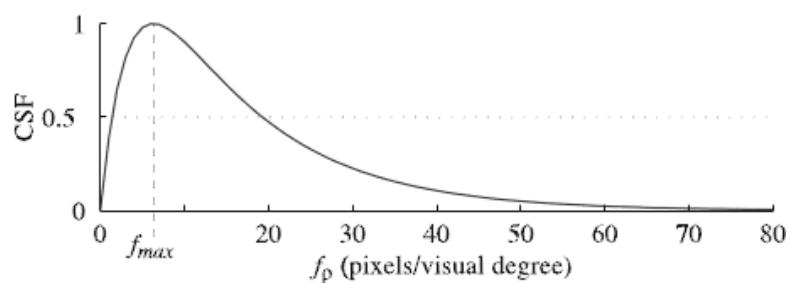
matematički ili statistički i mogu se koristiti kod proučavanja binarnih rasterskih uzoraka s konstantnim tonovima sive. Takve mjere omogućuju fundamentalno razumijevanje veze točaka koje imaju određenu distribuciju. Koriste se kako bi se olakšalo računanje i zahtijevaju manju računalnu snagu. Također, neovisne su o uvjetima promatranja i individualnim promatračima. Druga klada su metode mjerena koji uzimaju u obzir karakteristike ljudskog vizualnog sustava (HVS) koji pokušava predvidjeti percipiranu vizualnu kvalitetu. HVS modeli uključuju se u algoritme rastriranja zadnjih 25 godina [14].

Kada se slika promatra s udaljenosti nije moguće ispravno percipirati sliku. Ljudsko oko primjenjuje nisko pojasni filter na sliku, a ta se HVS (*human visual system*) funkcija može eksperimentalno izmjeriti [2]. Kod reprodukcije slike kontinuiranog tona vidljivost rastera odnosi se na vidljivost ili sposobnost opažanja binarnih rasterskih elemenata kada se gleda otisnuta slika. Idealan algoritam rastriranja je onaj koji minimalizira tu vidljivost. S obzirom da ljudsko oko zapaža distorzije na određenim spajjalnim frekvencijama više nego na drugima mjerena vidljivosti rastera počinje od ljudskog vizualnog sustava (HVS).[3] Pretpostavljajući da postoji originalna višetonska slika i različite rastrirane slike te iste višetonske slike, potrebno je saznati percipiranu grešku rastriranja (PHE) za svaku od tih slika. S obzirom da slika prvo prolazi kroz model HVS funkcije, PHE rastrirane slike, s obzirom na originalnu višetonsku sliku, je razlika percipirane rastrirane slike i percipirane višetonske slike. S obzirom da je model linearan, računa se razlika HVS funkcija rastrirane i originalne slike. Energija rezultirajuće slike je PHE. Računanje PHE za određenu sliku i uz danu HVS funkciju prikazano je niže [2].



**Slika 19.** Shematski prikaz računanja PHE

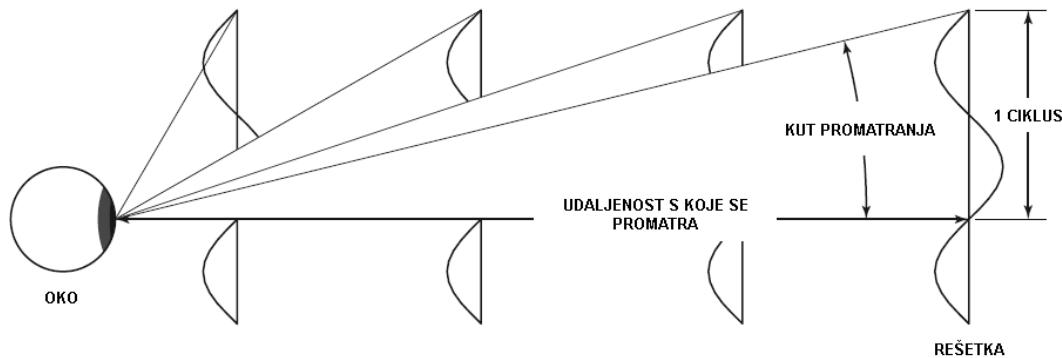
Ne samo da je model HVS-a nužan za razvoj bilo koje tehnike rastriranja nego se sam model može podešavati kako bi davao bolju teksturalnu kvalitetu dobivenih rasterskih uzoraka. Stoga se performansa danog rasterskog algoritma može maksimizirati ispravnim razvojem poboljšanih modela HVS-a. Modeli HVS-a predloženi su kako bi pružili kvantitativnu mjeru distorzije slike kako ju vidi ljudsko oko. U smislu mjerjenja tekture rastera, model HVS-a je linearan nepromjenjiv filter s pomakom baziran na PSF (*point spread function*) funkciji ili CSF (*contrast sensitivity function*) funkciji ljudskog oka [3].



**Slika 20.** Krivulja osjetljivosti na kontrast[3]

Kada je predložen HVS model baziran na odazivu oka na stimulanse u prostornoj domeni, funkcija koja se dobiva je PSF, a derivirana je prema činjenici koju je naveo Whestheimer; pod nikakvim okolnostima točkasti objekti ne mogu se zapravo prikazati kao točke zbog više fizičkih i geometrijskih optičkih faktora. Zbog toga točkasti objekt daje važnost retinalnoj distribuciji svjetlosti koja je zvonolikog oblika u presjeku. Ta distribucija je PSF oka i ima važnost ne samo kada je objekt točka nego u bilo kojem slučaju kada je potrebno znati distribuciju svjetlosti za objekt koji je kompleksniji od točkastog izvora svjetlosti s obzirom da bilo koji vizualni objekt može biti predstavljen kao skup točaka. Eksperimentalno mjerjenje PSF funkcije oka vrši se putem instrumenata dizajniranih za mjerjenje cijele refraktivne pogreške oka, a zovu se aberometri [3].

U domeni prostorne frekvencije HVS model je baziran na MTF (*modulation transfer function*) ili CSF funkciji ljudskog oka. Takva funkcija pokušava karakterizirati odaziv promatrača na određene prostorne frekvencije.



**Slika 21.** Sinusoidna rešetka[3]

Kao što je prikazano na slici 21 eksperiment se sastoji od sinusoidne rešetke gdje se modulacija kontrasta rešetke može mjeriti kao omjer razlike maksimuma i minimuma svjetlosti reflektirane o rešetku s sumom broja dva. Frekvencija rešetke varira od nižih do viših frekvencija za svaki eksperiment. Za određene jednakoj udaljenoj frekvenciji uzima se subjektivna mjera koju je osjetio promatrač te se koristi omjer stvarnog kontrasta slike i kontrasta koji je naveo promatrač kao osjetljivost na kontrast ljudskog oka za točnu frekvenciju. Osjetljivost oka je vrlo visoka kod niskih frekvencija, ali kako se frekvencija povećava oko počinje slabije uočavati realni kontrast rešetke i osjetljivost opada do nule.[3] CSF ima važnu ulogu jer određuje rezoluciju slike, povećanje njene kvalitete te određuje dizajn rastera [14].

Kada se uzimaju zajedno PSF i CSF stvaraju Fourierov par,  $h(x, y)$  u prostornoj domeni te  $H(u, v)$  ( $u, v$  u stupnjevima/radijanima) u domeni frekvencije. Inverzna Fourierova transformacija  $H(u, v)$  daje  $\bar{h}(\bar{x}, \bar{y})$ ,  $\bar{x}, \bar{y}$  su u stupnjevima. Za pretvorbu tih angularnih jedinica u jedinice na otisnutoj stranici, kada se dužina  $x$  gleda s udaljenosti  $D$  naspram kuta  $\bar{x}$  te zadovoljava

$$\bar{x} = \left(\frac{180}{\pi}\right) \left(\arctan\left(\frac{x}{D}\right)\right) \approx \frac{180x}{\pi D} \quad (8)$$

za  $x \ll D$ . Stoga ako se pretpostavi da uređaj ima rezoluciju  $R$  (dpi) diskretan filter koji karakterizira HVS model u prostornoj domeni biti će dan

$$h[m, n] = \frac{180^2}{\pi^2 D^2} \bar{h}\left(\frac{180m}{\pi RD}, \frac{180n}{\pi RD}\right) \quad (9)$$

Termin  $S \equiv RD$  naziva se skalarni parametar. Kim i Allebach eksperimentirali su s različitim vrijednostima  $S$  u HVS modelima kod istraživanja direktnog binarnog traženja (iterativni algoritam rastriranja) te su demonstrirali zašto taj parametar, koji bi u teoriji morao biti precizno određen prema odabranoj udaljenosti gledanja i rezoluciji uređaja, u stvarnosti služi kao slobodni parametar koji se može podešiti kako bi se dobila željena kvaliteta rasterske teksture. Ponašanje skalarnog parametra je takvo da kada se poveća rezolucija tiska vizualni odaziv promatrača smanjuje se do određenog broja ciklusa po stupnju stoga je širina pojasa HVS filtera u frekvencijskoj domeni smanjena na količinu proporcionalnu povećanju udaljenosti ili rezolucije. Na primjer, ako promatrač gleda otisnutu stranicu s veće udaljenosti ili ako je rezolucija veća očekuje se gubitak mogućnosti raspoznavanja detalja kao što su rasterski elementi na stranici. To znači da će se slika promatraču činiti više homogena. Suprotan efekt događa se ako se udaljenost ili rezolucija smanje. Tada se povećava širina pojasa HVS modela i tekstura rastriranja postaje vidljivija [3].

### 2.9.1. Campbellov CSF Model

Iz eksperimenata prikazanih na slici 21 Campbell et al. predložili su model funkcije osjetljivosti na kontrast koristeći jednodimenzionalnu jednadžbu

$$CSF(f_p) = k \left( \exp(-2\pi f_p \alpha) - \exp(-2\pi f_p \beta) \right) \quad (10)$$

gdje su  $\alpha$  i  $\beta$  proizvoljne konstante koje su kasnije Analoui i Allebach definirali kao 0,012 i 0,046. Parametar  $k$  je konstanta proporcionalna prosječnoj iluminaciji i obično je postavljenja tako da je  $\max_{f_p} CSF(f_p) = 1$  (kada je  $f_p = f_{max} = \ln(\alpha/\beta)/[2\pi(\alpha - \beta)]$ ) [3].

Pad osjetljivosti koji je predložen ovim modelom odgovara promjeni sinusoidne rešetke koja je tako spora da ima ne zamjetan gradijent. Za potrebe rastriranja taj pad se obično ignorira. Nije razvijen niti jedan vizualni model koji u potpunosti objašnjava odaziv HVS-a na sve moguće stimulanse. HVS je očito nisko pojasni u prirodi, ali CSF model ne karakterizira HVS u potpunosti kao što je vidljivo kod rastriranja [3].

### 2.9.2. Näsänenov (eksponencijalni) model

Kao alternativni model ljudskog vizualnog sustava koji prepostavlja radikalnu simetriju, Näsänenov model je radikalno simetrična eksponencijalna funkcija radikalne frekvencije  $\rho$  koja se opsežno koristi u digitalnom rastriranju. Model je definiran kao

$$H(\rho) = \exp(-kp) \quad (11)$$

$$h(r) = \frac{k}{(2\pi)^2} \frac{1}{\left(\frac{k}{2\pi} + r^2\right)^{\frac{3}{2}}} \quad (12)$$

gdje je  $L = 11 \text{ cd/m}^2$  prosječna luminancija te su  $c = 0,525$  i  $d = 3,91$  konstante zbog kojih model odgovara eksperimentalnim podacima [3].

### 2.9.3. Miješani Gaussianovi modeli

Iako se Näsänenov model pokazao kao adekvatna aproksimacija HVS modela za iterativne metode rastriranja kao što je direktno binarno traženje, Kim i Allebach su predložili novu i bogatiju klasu HVS modela koja postiže bolje rezultate rastriranja. Ti modeli su bazirani na miješanim Gaussianovim funkcijama čija je funkcionalna forma

$$H^2(\rho) = 2\pi\kappa_1\sigma_1^2 \exp(-2\pi^2\sigma_1^2\rho^2) + \dots + 2\pi\kappa_2\sigma_2^2 \exp(-2\pi^2\sigma_2^2\rho^2) \quad (13)$$

$$(h * h)(r) = k_1 \exp\left(-\frac{r^2}{2\sigma_1^2}\right) + k_2 \exp\left(-\frac{r^2}{2\sigma_2^2}\right) \quad (14)$$

gdje \* označava konvoluciju, a konstante  $\kappa_1, \kappa_2, \sigma_1$  i  $\sigma_2$  se određuju eksperimentalno. Prednost ovih modela je mogućnost optimalizacije njihove frekvencijske responzivnosti u smislu širine pojasa pomoću različitih setova parametara. Takva fleksibilnost nije moguća s Näsänenovim eksponencijalnim modelom. Raznovrsnost dobivena s miješanim Gaussianovim modelom ima i manu, javlja se znatno više parametara. Ukupno četiri parametra karakterizira ovaj model pa podešavanje postaje delikatan zadatak. Kim i Allebach nisu mogli pronaći jedan jedinstven model za direktno binarno traženje koji je radio za sve tonove. Stoga su predložili korištenje dva različita Gaussianova modela koji se nadopunjaju. Prvi model ima parametre  $(\kappa_1, \kappa_2, \sigma_1, \sigma_2) = (43.2, 38.7, 0.02, 0.06)$  koji daje glatku teksturu ali s kockastim artefaktima. Alternativno, drugi model ima parametre  $(\kappa_1, \kappa_2, \sigma_1, \sigma_2) = (19.1, 42.7, 0.03, 0.06)$  i daje homogenu teksturu posebno u srednjim tonovima, ali je tekstura grublja nego kod prvog modela [3].

#### 2.9.4. Alpha-Stable HVS modeli

Gonzalez et al. Uveli su korištenje alfa stabilnih funkcija za HVS modeliranje koristeći funkcije koje opisuju alfa stabilne nasumične varijable. Ovi modeli su bogatiji nego miješani Gaussianovi modeli (Gaussianove nasumične varijable su podskup alfa stabilnih nasumičnih varijabli) te su jednostavnije za karakterizaciju zbog manjeg broja parametara. Empirijske aproksimacije PSF funkcije (dobivene mjeranjem odaziva ljudskog oka na prostorne stimulanse) imaju analitičku formu karakterističnih funkcija alfa stabilnih nasumičnih varijabli. Stoga stabilni modeli odgovaraju empirijskim mjerama te istovremeno daju jedinstvene matematičke karakteristike koje daju dobre vizualne rezultat. Rad Whesteimer-a modelira oblik PSF-a prema

$$h(r) = 0,952 \exp(-2,95|r|^{1,36}) + 0,048 \exp(-2,43|r|^{1,74}) \quad (15)$$

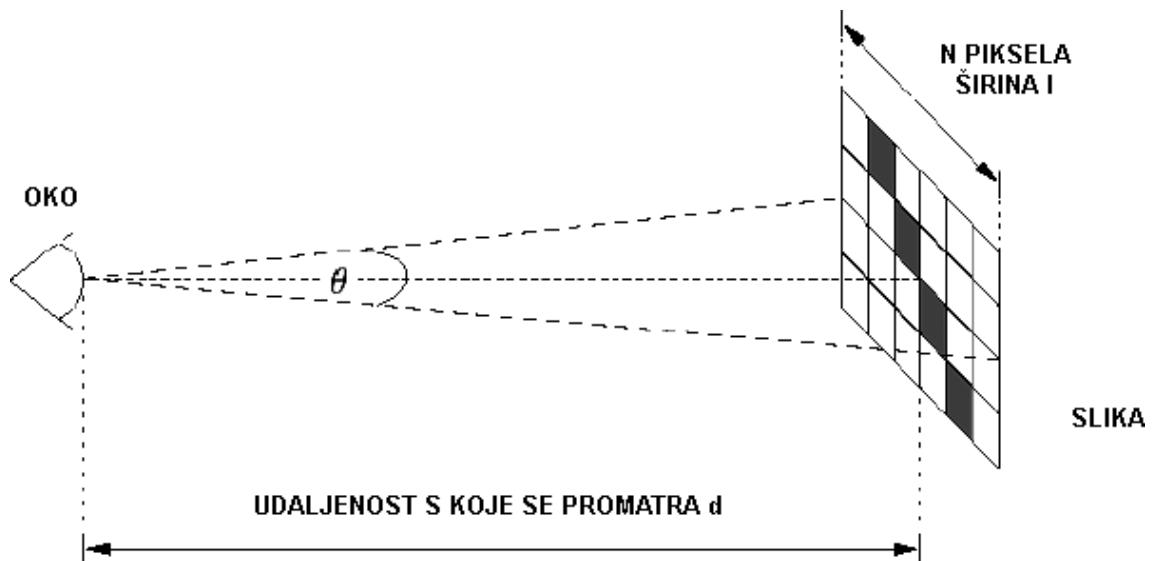
Koji je formom blizu karakteristične funkcije alfa stabilnih distribucija. Ako PSF HVS modela ima takvu formu njegov CSF će imati algebarske repove stoga bi bilo dobro koristiti modele čiji su repovi teži od onih dobivenih eksponencijalnim

i miješanim Gaussianovim modelima. Ta činjenica pruža osnovu za korištenje alfa stabilnih modela za karakterizaciju HVS-a [3].

### 2.9.5. Weighted Noise Measurement (WSNR)

Ranije opisani HVS modeli su izraženi u ciklusima po stupnju naspram retine. S obzirom da rastriranje ovisi o činjenici da ljudsko oko djeluje kao nisko pojasni filter, znanstvenici su koristili te modele kako bi opisali okolinu niskog kontrasta ljudskog vizualnog sustava. Modificiran pristup koji se koristiti kako bi se primijenili HVS modeli napravio je Sullivan et al. Jer su uzeli u obzir blagi pad vizualne osjetljivosti u dijagonalnom smjeru (ljudsko oko je osjetljivije na horizontalne i vertikalne sinusoidne uzorke nego na dijagonalne).

S obzirom da je CSF funkcija kutne frekvencije, veličina i udaljenost s koje se promatra slika moraju se uzeti u obzir kada se određuje odaziv HVS-a. Za slike koje će biti prikazane na zaslonu računala ili otisnute na papiru može se izračunati maksimalna kutna frekvencija retine za određenu sliku i udaljenost s koje se promatra.



**Slika 22.** Računanje kutne frekvencije oko. Prikazan je horizontalan smjer.[14]

Analiza koja slijedi odnosi se samo na horizontalan smjer. Za izračunavanje vertikalnog smjera može se primijeniti analogni postupak. Kut slike naspram oka u horizontalnom smjeru je dan s  $\theta = 2 \tan^{-1}(l/2d) \approx l/d$  radijana kada je  $\theta$  male vrijednosti. Maksimalna kutna frekvencija je određena Nyquistovom frekvencijom. Na toj frekvenciji susjedni pikseli alterniraju iz crne u bijelu te daju kutnu frekvenciju od jednog ciklusa na dva piksela ili  $\pi$  radijana po pikselu. S obzirom da postoji  $N$  piksela horizontalno na slici, komponenta Nyquistove frekvencije ima  $N/2$  ciklusa ili  $N\pi$  radijana. Stoga postoji  $N\pi$  ciklusa u kutu od  $l/d$  radijana. Kutna frekvencija je

$$f_a = \frac{N\pi d}{l} \text{ (radijani)} \quad (16)$$

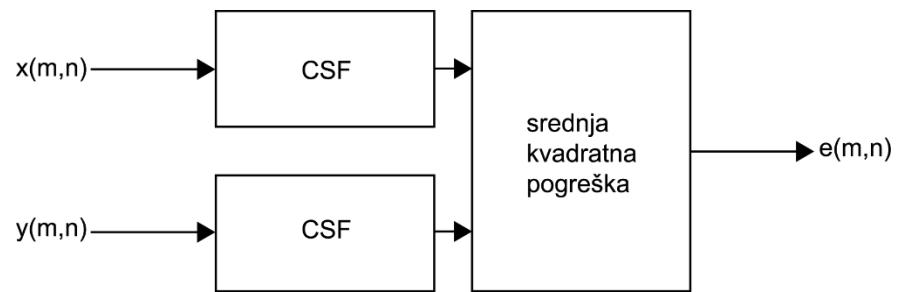
$$f_a = \frac{N\pi d}{360l} \text{ (ciklusi/stupnjevi)} \quad (17)$$

Na primjer, za sliku veličine 512x512 piksela, otisnutoj veličine 180 mm te gledanoj s udaljenosti od 1000 mm, maksimalna kutna frekvencija je otprilike 25 ciklusa po stupnju. Maksimalna kutna frekvencija može se izračunati ako se zna broj piksela na slici, veličina slike te udaljenost s koje se gleda slika.

Diskretna Fourierova transformacija (DFT) slike se zatim množi točku po točku s CSF tako da je dio slike na određenoj kutnoj frekvenciji ponderiran s vrijednosti CSF-a na toj frekvenciji. Rezultat je DFT slike koji vodi jednakom odazivu kada se gleda s vizualnim sustavom s ravnim CSF-om kao kod originalne slike kada se gleda s HVS-om. Kada su dane dvije verzije slike veličine  $M \times N$  piksela, jedna čista (označena s  $x$ ) i druga binarna (označena s  $y$ ), WSNR (*weighted signal-to-noise ratio*) za binarnu sliku računa se na sljedeći način

$$WSNR(dB) = 10 \log_{10} \left( \frac{\sum_{u,v} |(X(u,v)C(u,v))|^2}{\sum_{u,v} |((X(u,v)-Y(u,v))C(u,v))|^2} \right) \quad (18)$$

Gdje  $X(u, y)$ ,  $Y(u, v)$  i  $C(u, v)$  predstavljaju DFT ulaznu sliku, izlaznu sliku i CSF te vrijedi  $0 \leq u \leq M - 1$  i  $0 \leq v \leq N - 1$ . WSNR je definiran kao omjer prosječne ponderirane snage signala i prosječne ponderirane snage šuma gdje je ponder izведен iz CSF-a.

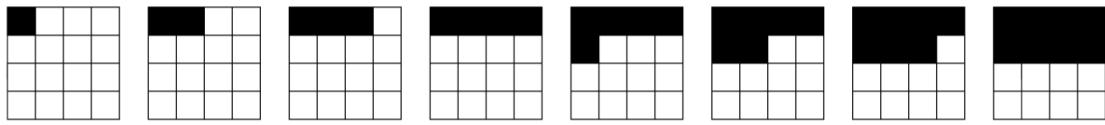


**Slika 23.** Ponderirana razlika orginalne i rastrirane slike

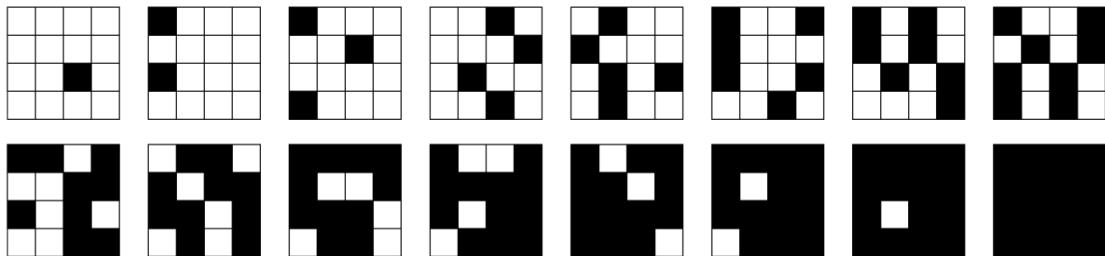
Kvalitativne mjere bazirane na linearnom HVS-u kao WSNR se primjenjuju na slike na način da se prvo izračuna razlika slike kontinuiranog tona i obrađene slike te se pogreška ponderira s odazivom frekvencije HVS-a danim sa CSF-om. Takve kvalitativne mjere uzimaju u obzir dimenzije slike, udaljenost s koje se slika gleda, rezoluciju tiska i iluminaciju prostora. [14]

### **3. EKSPERIMENTALNI DIO**

Rastrirano je 1000 slika s četiri različite metode rastriranja. Fotografije su preuzete nasumično sa stranice koja dopušta korištenje i izmjenu fotografija (<https://unsplash.com/>). Na slikama su različiti uzorci s različitim nivoima sive boje. Fotografije su obrađene na način da su obrezane na veličinu 512x512 pixela, pretvorene u *grayscale* te konvertirane u TIFF format. Preuzimanje i obrada fotografija napravljeno je automatski putem skripta koje se nalaze u prilogu. Rastriranje je provedeno u programu MATLAB (MathWorks, verzija R2016a). Četiri metode rastriranja koje su korištene su rastriranje matricom nivoa, difuzijom greške te tablično rastriranje koje je provedeno dva puta s različito raspoređenim rasterskim elementima. Skripte korištene kod rastriranja matricom nivoa i difuzijom greške preuzete su iz gotovog *toolbox-a*, *Halftoning Toolbox for MATLAB*, koji je preuzet sa stranice <http://users.ece.utexas.edu/~bevans/projects/halftoning/toolbox/>. Kod rastriranja matricom nivoa korišten je algoritam koji daje rastriranu sliku sa 17 tonova sive te disperziranim rasterskim elementima. Za rastriranje difuzijom greške korišten je klasičan algoritam koji su razvili Robert W. Floyd i Louis Steinberg. Kreirane su dvije skripte za tablično rastriranje. Obje skripte zamjenjuju dio slike veličine 4x4 s matricom veličine 4x4. Korištenjem tablice 4x4 moguće je postići 17 tonova sive boje. Razlikuje se način na koji se popunjavaju matrice koje zamjenjuju dio slike. Kod prve skripte elementi se popunjavaju redom s lijeva na desno, od prvog do zadnjeg reda. Kod druge skripte elementi se nasumično popunjavaju. Obje skripte nalaze se u prilogu.



(a)



(b)

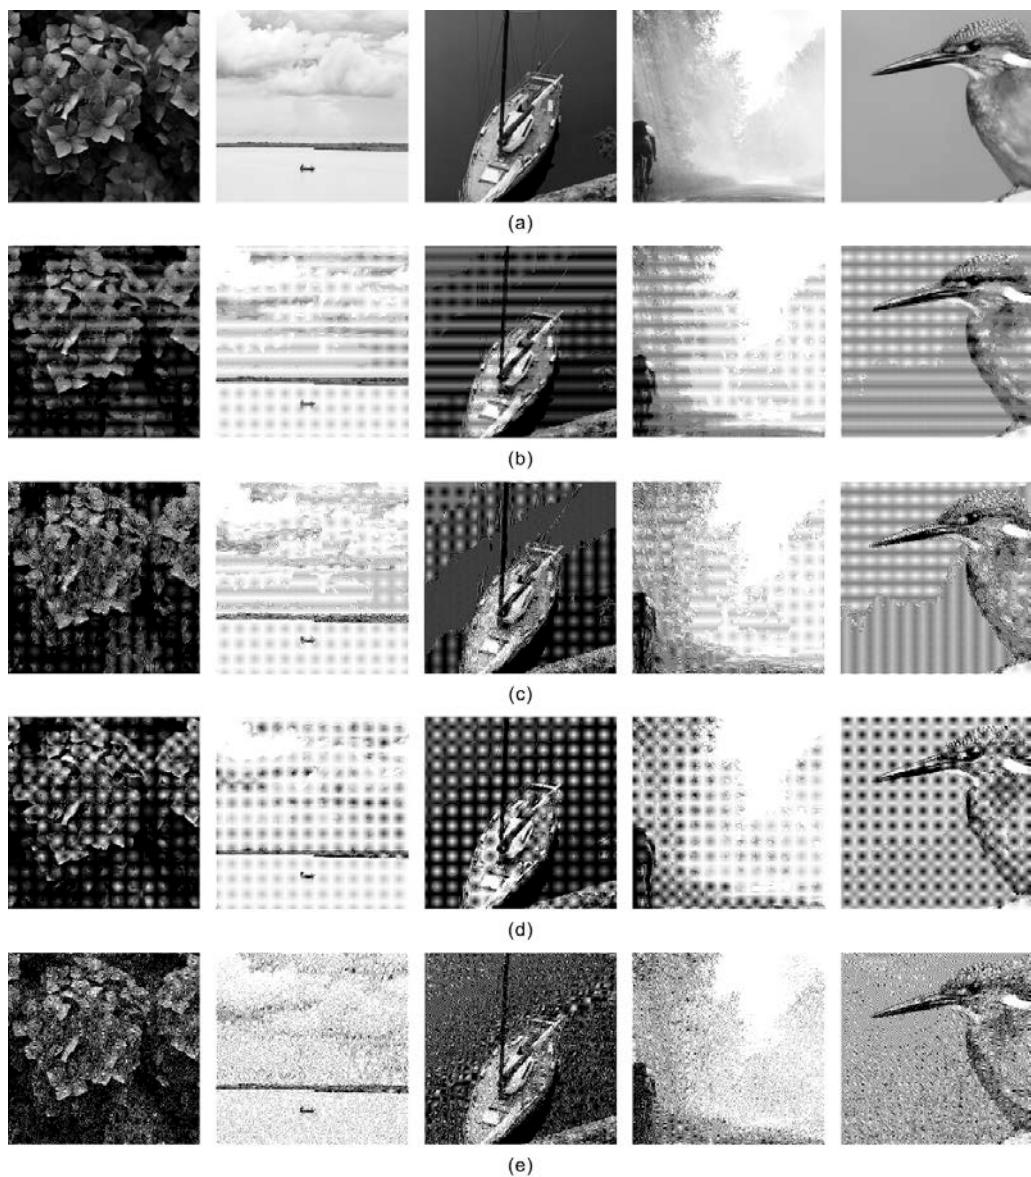
**Slika 24.** Redoslijed popunjavanja elemenata u tablici: (a) prva skripta (b) druga skripta

Nakon rastriranja izračunat je WSNR za svaku sliku pojedinačno. Skripta za izračun je također preuzeta iz ranije navedenog toolbox-a. U toj skripti koristi se vrijednost HSV-a koju su predložili Mannos i Sakrison, a modificirali Mitsa i Varkur. Statistička obrada podataka izvršena je pomoću programa MATLAB. Analiza razlika između različitih metoda rastriranja izvedena je univarijantnim ANOVA testovima te *post hoc* (Tukey-Kramer) analizom.

## 4. REZULTATI I RASPRAVA

### 4.1. Rezultati

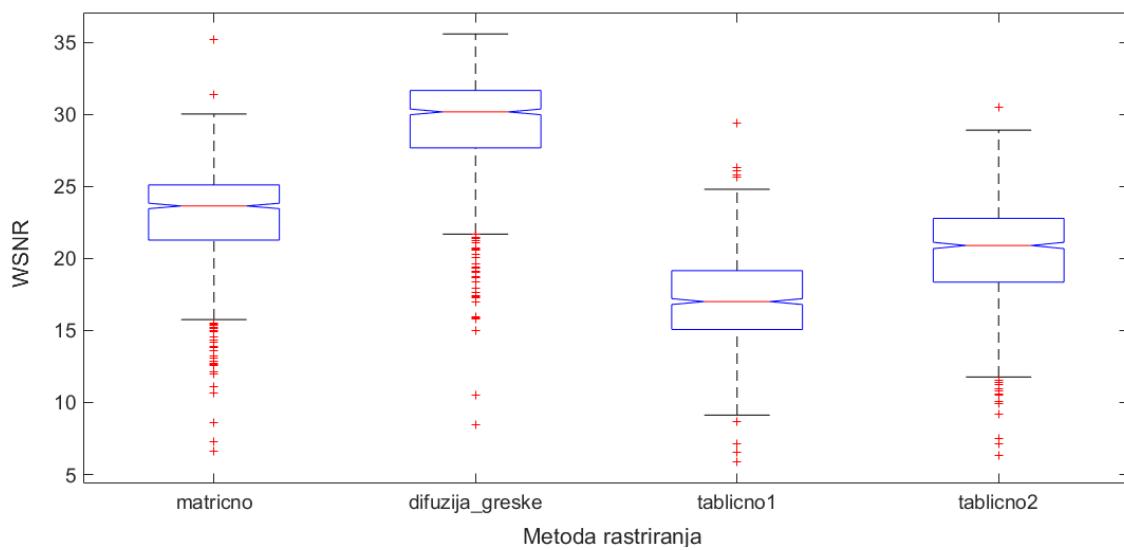
Kod prezentiranja rezultata rastriranja različitim metodama koristiti će se 5 nasumično odabranih slika koje su korištene. Rezultati rastriranja svim korištenim metodama prikazani su na slici 26.



**Slika 25.** Slike rastrirane s četiri korištene metode: (a) orginale slike (b) tablično 1 (c) tablično 2 (d) matrično (e) rastriranje difuzijom greške

U prilogu se nalazi uvećana slika rastrirana sa sve četiri korištene metode te originalna slika. Na slici su bolje vidljivi detalji te razlike između različitih metoda rastriranja.

WSNR vrijednosti značajno su se razlikovale između slika rastriranih različitim metodama ANOVA ( $F(3)=2539.03$   $p<0.05$ ). Kod mjerena kvalitete rastrirane slike putem WSNR vrijednosti, veća vrijednost znači da je kvaliteta rastrirane slike veća. Metoda difuzije greške dala je najbolje rezultate što je vidljivo iz vrijednosti WSNR-a koje su bile najviše za ovu metodu. Matrica rastriranja je nešto lošija, a metode tabličnog rastriranja su pokazale najlošije rezultate. Isto je vidljivo na slici 29. Na slici tablično 1 označava metodu tabličnog rastriranja kod koje se rasterski elementi popunjavaju redom, a tablično 2 označava metodu tabličnog rastriranja kod koje se rasterski elementi popunjavaju nasumično.



**Slika 26.** Prikaz srednjih vrijednosti WSNR-a za različite metode rastriranja

Razlike u vrijednostima WSNR-a vidljive su u tablici 1. Postoji značajna razlika između WSNR vrijednosti kod svih metoda rastriranja.

**Tablica 1.** Rezultati *post hoc* testova za vrijednosti WSNR-a kod različitih metoda rastriranja

Metoda rastriranja	Usporedba s drugom metodom	Min	Max	Razlika u srednjim vrijednostima	p- vrijednost
Matrično	Difuzija greške	-6,64	-5,90	-6,27	$3,77 \cdot 10^{-9}$
Matrično	Tablično 1	5,54	5,92	6,29	$3,77 \cdot 10^{-9}$
Matrično	Tablično 2	2,33	2,70	3,08	$3,77 \cdot 10^{-9}$
Difuzija greške	Tablično 1	11,81	12,18	12,56	$3,77 \cdot 10^{-9}$
Difuzija greške	Tablično 2	8,60	8,97	9,34	$3,77 \cdot 10^{-9}$
Tablično 1	Tablično 2	-3,59	-3,21	-2,84	$3,77 \cdot 10^{-9}$

## 4.2. Rasprava

Tabličnim rastriranjem postižu se najlošiji rezultati jer se dio detalja slike gubi prilikom zamjene djela slike tablicom koja je najbliža prosjeku vrijednosti piksela. Bolja linijatura rastrirane slike može se dobiti korištenjem manje tablice, ali će se tada smanjiti broj tonova sive. Na primjer, tablicom veličine 2x2 moguće je dobiti pet tonova sive, a tablicom 4x4 moguće je dobiti 17. Ipak kada se mijenja dio slike 2x2 rastrirana slika zadržati će puno više detalja originalne slike. Metoda tabličnog rastriranja se zbog lošije kvalitete rastrirane slike više ne koristi u praksi te je iz rezultata vidljivo kako zaista daje znatno lošiju kvalitetu rastrirane slike od ostalih korištenih metoda.

Kod rastriranja metodom matričnog rastriranja svaki piksel originalne slike uspoređuje se s matricom nivoa pa se time gubi znatno manje detalja u usporedbi s tabličnim rastriranjem. U eksperimentalnom dijelu korištena je matrica s kojom se postiže 17 tonova sive kao i kod tabličnog rastriranja. Iz rezultata je vidljiva velika razlika između srednjih vrijednosti WSNR-a kod

matričnog rastriranja i obje metode tabličnog rastriranja. Korištena matrica stvara grupirane rasterske elemente. Iako se rastriranjem s raspršenim rasterskim elementima postižu bolji rezultati nego rastriranjem s grupiranim rasterskim elementima, srednje vrijednosti WSNR-a kod matričnog rastriranja bile su znatno veće nego kod tabličnog rastriranja s raspršenim rasterskim elementima.

Rastriranjem difuzijom greške također se svaki piksel posebno obrađuje, ali se uzima u obzir i greška koja ostaje te se raspoređuje na piksele u susjedstvu. Time se postiže najbolja kvaliteta jer se zadržava najveći broj informacija. Također, ovom metodom dobiva se rastrirana slika s raspršenim rasterskim elementima kojima se postiže veća kvaliteta slike. Iz rezultata je vidljivo kako je srednja vrijednost WSNR vrijednosti kod rastriranja metodom difuzije greške značajno veća od svih ostalih metoda rastriranja. Ova metoda rastriranja, uz modifikacije, koristi se u praksi i danas jer je moguće postići dobre rezultate uz malu računalnu zahtjevnost.

Kod tabličnog rastriranja postignuto je poboljšanje rastrirane slike promjenom rasporeda rasterskih elemenata. Prva skripta dala je najlošije rezultate, a kod druge skripte su rezultati WSNR-a bili značajno veći.

Kod prvog načina rastriranja rasterski elementi povećaju se na način da ostaju grupirani te se zapravo povećava veličina rasterskog elementa. Kod drugog načina rasterski elementi se nasumično povećavaju te ne ostaju povezani. Prema ljudskom vizualnom sustavu, nasumično raspoređeni i izolirani rasterski elementi dati će najveću kvalitetu slike [3]. Također, pravilni raspored rasterskih elemenata stvara uzorak na koji je ljudski vizualni sustav osjetljiv pa time narušava kvalitetu rastrirane slike. Raspršeni rasterski elementi ne stvaraju takav uzorak pa je i kvaliteta rasterske slike veća. Razlika srednjih vrijednosti WSNR-a kod tabličnog rastriranja 1 i 2 je statistički značajan te se tabličnim rastriranjem 2 postižu bolji rezultati.

## **5. ZAKLJUČAK**

U ovom radu proučavane su razlike između različitih metoda rastriranja. Korištene su četiri metode rastriranja. Tablično rastriranje je provedeno dva puta s različito raspoređenim rasterskim elementima unutar tablice s kojom se zamjenjuje dio originalne slike. Ostale dvije metode su matrično rastriranje i metoda difuzije greške. Kvaliteta rastriranih slika izmjerena je pomoću WSNR-a.

Eksperimentalni dio sastojao se od rastriranja slika, mjerena kvaliteta slika te statističke analize. Korišteno je 1000 slika te su iste slike rastrirane sa sve četiri metode.

Rezultati su pokazali kako se tabličnim rastriranjem postižu najlošiji rezultati. Isto vrijedi za obje metode tabličnog rastriranja. Matričnim rastriranjem postižu se bolji rezultati od metode tabličnog rastriranja, a rastriranjem difuzijom greške postižu se najbolji rezultati. Ovakvi rezultati objašnjavaju zašto se i nakon 50 godina rastriranje difuzijom greške i dalje koristi u reprodukcijskim sustavima niske rezolucije kao što su stolni printeri.

Kod tabličnog rastriranja pokazano je kako se promjenom rasporeda rasterskih elemenata unutar tablice može utjecati na kvalitetu rastrirane slike. Nasumičnim rasporedom rasterskih elemenata postignut je značajno bolji rezultat.

## 6. LITERATURA

- [1] D. L. Lau and G. R. Arce, *Modern Digital Halftoning*, Second Edi. Boca Raton: CRC Press, 2008.
- [2] M. Mese and P. P. Vaidyanathan, “Recent advances in digital halftoning and inverse halftoning methods,” *IEEE Trans. Circuits Syst. I Fundam. Theory Appl.*, vol. 49, no. 6, pp. 790–805, 2002.
- [3] S. Edition, C. Barker, N. Pistrang, R. Elliott, H. Betram, W. B. Thomas, A. K. J. Forest, and M. John, *Modern Digital Halftoning*, Second Edi., vol. 344. 2008.
- [4] T. Pappas, “Digital Halftoning Techniques for Printing,” *Recent Prog. Digit. Halftoning*, 1994.
- [5] D. C. Stulik and A. Kaplan, *The Atlas of Analytical Signatures of Photographic Processes*. 2013.
- [6] R. Ulichney, “A Review of Halftoning Techniques,” *Spie*, vol. Vol. 3963, pp. 378–391, 2000.
- [7] Z. He and C. A. Bouman, “AM/FM halftoning: digital halftoning through simultaneous modulation of dot size and dot density,” *J. Electron. Imaging*, vol. 13, no. 2, p. 286, 2004.
- [8] S. Gooran, “Digital Halftoning Sasan Gooran,” no. May, 2013.
- [9] X. Cao, D. Jiang, and C. Zheng, “Hardcopy printing of medical images based on different methods of halftoning,” in *Engineering in Medicine and Biology Society, 1998. Proceedings of the 20th Annual International Conference of the IEEE*, 1998, vol. 20, no. 2, pp. 571–574.
- [10] O. Verevka and J. W. Buchanan, “Halftoning with Image-Based Dither Screens,” in *Proceedings of the 1999 conference on Graphics interface '99*, 1999, pp. 167–174.

- [11] A. Tausif Aijazi, “Hybrid Colour Halftoning,” 2010.
- [12] F. R. of G. Jorg, Wild (Technische Universitat Minchen Munich, “Design of multilevel threshold matrices for ordered dither digital halftoning, optimized for edge sharpness, detail reproduction and texture,” in *CompEuro '89., “VLSI and Computer Peripherals. VLSI and Microelectronic Applications in Intelligent Peripherals and their Interconnection Networks”, Proceedings.*, 1989, pp. 43–45.
- [13] T. Pappas, “Digital Halftoning Techniques for Printing,” *Recent Prog. Digit. Halftoning*, 1994.
- [14] P. Axelson, “Quality Measures of Halftoned Images Quality Measures of Halftoned Images ( A Review ) Per-Erik Axelson,” *Sci. Technol.*, 2003.

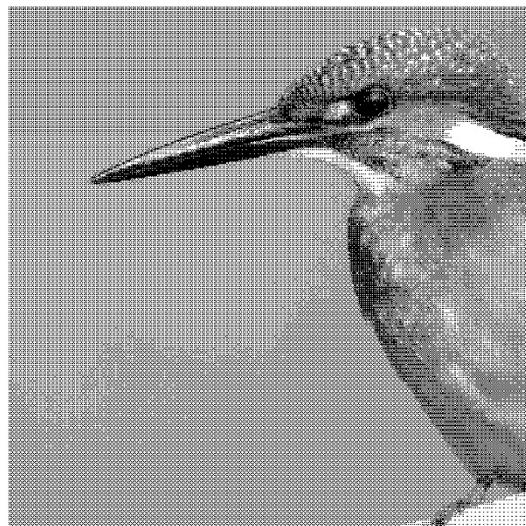
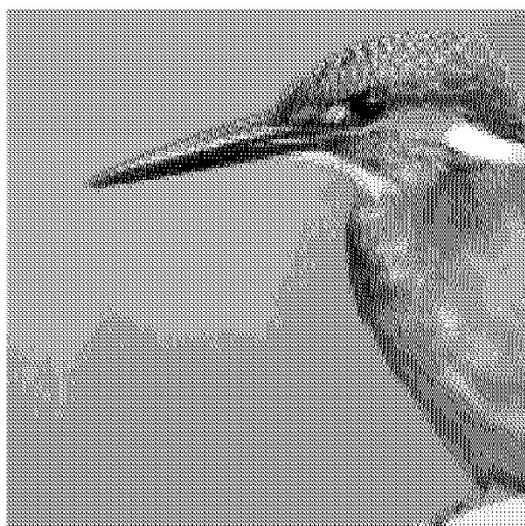
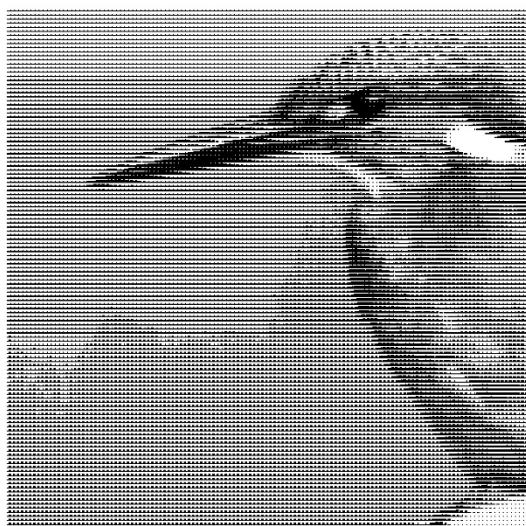
## **Prilozi**

Prilog 1. – Uvećana slika rastrirana s četiri korištene metode

Prilog 2. – Skripta korištena za tablično rastriranje 1

Prilog 3. - Skripta korištena za tablično rastriranje 2

**Prilog 1.** Uvećana slika rastrirana s četiri korištene metode: orginal, tablično rastriranje 1, tablično rastriranje 2, matrično rastriranje, rastriranje difuzijom greške



## Prilog 2. Skripta korištena za tablično rastriranje 1

```
function [out] = tablicno3 (img)
    blocks = {[0 0 0 0; 0 0 0 0; 0 0 0 0; 0 0 0 0], [1 0 0 0; 0 0 0 0;
0 0 0 0; 0 0 0 0], [1 1 0 0; 0 0 0 0; 0 0 0 0; 0 0 0 0], [1 1 1 0; 0 0
0 0; 0 0 0 0; 0 0 0 0], [1 1 1 1; 0 0 0 0; 0 0 0 0; 0 0 0 0], [1 1 1
1; 1 0 0 0; 0 0 0 0; 0 0 0 0], [1 1 1 1; 1 1 0 0; 0 0 0 0; 0 0 0 0],
[1 1 1 1; 1 1 1 0; 0 0 0 0; 0 0 0 0], [1 1 1 1; 1 1 1 1; 0 0 0 0; 0 0
0 0], [1 1 1 1; 1 1 1 1; 1 0 0 0; 0 0 0 0], [1 1 1 1; 1 1 1 1; 1 1 1 1;
1 1 0; 0 0 0 0], [1 1 1 1; 1 1 1 1; 1 1 1 0; 0 0 0 0], [1 1 1 1; 1 1 1 1;
1 1 1 1; 0 0 0 0], [1 1 1 1; 1 1 1 1; 1 1 1 1; 1 0 0 0], [1 1 1 1; 1 1
1 1; 1 1 1 1; 1 1 1 0], [1 1 1 1; 1 1 1 1; 1 1 1 1; 1 1 1 1];
a=1;

% Potrebno je dodati BlockerMean
% (https://uk.mathworks.com/matlabcentral/fileexchange/24812-blockmean)
% Računa prosjekе za podskupove matrice
averages = BlockMean(img,4,4);
while a <= row
    for k = 1:size(averages)
        prosjek = averages(a,k);
        if prosjek <= 15
            out{a,k} = blocks{1};
        elseif prosjek > 15 && prosjek <= 30
            out{a,k} = blocks{2};
        elseif prosjek > 30 && prosjek <= 45
            out{a,k} = blocks{3};
        elseif prosjek > 45 && prosjek <= 60
            out{a,k} = blocks{4};
        elseif prosjek > 60 && prosjek <= 75
            out{a,k} = blocks{5};
        elseif prosjek > 75 && prosjek <= 90
            out{a,k} = blocks{6};
        elseif prosjek > 90 && prosjek <= 105
            out{a,k} = blocks{7};
        elseif prosjek > 105 && prosjek <= 120
            out{a,k} = blocks{8};
        elseif prosjek > 120 && prosjek <= 135
            out{a,k} = blocks{9};
        elseif prosjek > 135 && prosjek <= 150
            out{a,k} = blocks{10};
        elseif prosjek > 150 && prosjek <= 165
            out{a,k} = blocks{11};
        elseif prosjek > 165 && prosjek <= 180
            out{a,k} = blocks{12};
        elseif prosjek > 180 && prosjek <= 195
            out{a,k} = blocks{13};
        elseif prosjek > 195 && prosjek <= 210
            out{a,k} = blocks{14};
        elseif prosjek > 210 && prosjek <= 225
            out{a,k} = blocks{15};
        elseif prosjek > 225 && prosjek <= 240
            out{a,k} = blocks{16};
        else
```

```

        out{a,k} = blocks{17};
    end
end
a=a+1;
end
out = cell2mat(out);

```

### Prilog 3. Skripta korištena za tablično rastriranje 2

```

function [out] = tablicno4 (img)
blocks = {[0 0 0 0; 0 0 0 0; 0 0 0 0; 0 0 0 0], [0 0 0 0; 0 0 0 0;
0 0 1 0; 0 0 0 0], [1 0 0 0; 0 0 0 0; 1 0 0 0; 0 0 0 0], [1 0 0 0; 0 0
1 0; 0 0 0 0; 1 0 0 0], [0 0 1 0; 0 0 0 1; 0 1 0 0; 0 0 1 0], [0 1 0
0; 1 0 0 0; 0 1 0 1; 0 1 0 0], [1 0 0 1; 1 0 0 0; 1 0 0 1; 0 0 1 0],
[1 0 1 0; 1 0 1 0; 0 1 0 1; 0 0 0 1], [1 0 0 1; 0 1 0 1; 1 0 1 0; 1 0
1 0], [1 1 0 1; 0 0 1 1; 1 0 1 0; 0 0 1 1], [0 1 1 0; 1 0 1 1; 1 1 0
1; 0 1 0 1], [1 1 1 1; 1 0 0 1; 1 1 1 0; 0 1 1 0], [1 0 0 1; 1 1 1 1;
1 0 1 1; 0 1 1 1], [1 0 1 1; 1 1 0 1; 1 1 1 1; 1 1 1 0], [1 1 1 1; 1 0
1 1; 1 1 1 1; 0 1 1 1], [1 1 1 1; 1 1 1 1; 1 0 1 1; 1 1 1 1], [1 1 1
1; 1 1 1 1; 1 1 1 1];
x = size(img);
row = x/4;
a=1;

% Potrebno je dodati BlockerMean
% (https://uk.mathworks.com/matlabcentral/fileexchange/24812-blockmean)
% Računa prosjekte za podskupove matrice
averages = BlockMean(img,4,4);
while a <= row
    for k = 1:size(averages)
        prosjek = averages(a,k);
        if prosjek <= 15
            out{a,k} = blocks{1};
        elseif prosjek > 15 && prosjek <= 30
            out{a,k} = blocks{2};
        elseif prosjek > 30 && prosjek <= 45
            out{a,k} = blocks{3};
        elseif prosjek > 45 && prosjek <= 60
            out{a,k} = blocks{4};
        elseif prosjek > 60 && prosjek <= 75
            out{a,k} = blocks{5};
        elseif prosjek > 75 && prosjek <= 90
            out{a,k} = blocks{6};
        elseif prosjek > 90 && prosjek <= 105
            out{a,k} = blocks{7};
        elseif prosjek > 105 && prosjek <= 120
            out{a,k} = blocks{8};
        elseif prosjek > 120 && prosjek <= 135
            out{a,k} = blocks{9};
        elseif prosjek > 135 && prosjek <= 150
            out{a,k} = blocks{10};
        elseif prosjek > 150 && prosjek <= 165
            out{a,k} = blocks{11};
        elseif prosjek > 165 && prosjek <= 180
            out{a,k} = blocks{12};
    end
    a=a+1;
end

```

```
elseif prosjek > 180 && prosjek <= 195
    out{a,k} = blocks{13};
elseif prosjek > 195 && prosjek <= 210
    out{a,k} = blocks{14};
elseif prosjek > 210 && prosjek <= 225
    out{a,k} = blocks{15};
elseif prosjek > 225 && prosjek <= 240
    out{a,k} = blocks{16};
else
    out{a,k} = blocks{17};
end
a=a+1;
end
out = cell2mat(out);
```