UDK 004.932

# ODREĐIVANJE USMJERENOSTI SADRŽAJA DIGITALNIH SLIKA KORIŠTENJEM *FAN* FILTARA DIRECTIONALITY ASSESSMENT OF DIGITAL IMAGES CONTENT USING *FAN* FILTERS

Marino BIBULIĆ – Miroslav VRANKIĆ –Viktor SUČIĆ

**Sažetak**: U ovom je radu predložena metoda određivanja usmjerenosti sadržaja digitalnih slika. U tu su svrhu projektirane skupine filtara sa svojstvima različitog propuštanja samo određenih prostornih frekvencija. Područje propuštanja takvih filtara je klinastog oblika s određenim zakretom s obzirom na frekvencijske osi. Rezultati određivanja usmjerenosti sadržaja prikazani su za sintetske slike prostornih valova kao i za neke realne slike.

Ključne riječi: - digitalna obrada slike

*- fan* filtri

- McClellanova transformacija

**Summary:** In this paper, we propose a method for assessing the directionality of digital images' content. For that purpose, special filter groups are designed that allow the passage of only predefined spatial frequency content. The passband of the filters is wedge-shaped with a predetermined rotation with respect to the frequency axes. Directionality assessment results are presented for both synthetic images of spatial waves and some real-world images.

Keywords:

digital image processing *fan* filters
McClellan transform

# 1.UVOD

Određivanje usmjerenosti sadržaja digitalnih slika ima široke primjene u raznim područjima počevši od prepoznavanja otisaka prstiju pa sve do nadzora oceana. Iako su metode određivanja usmjerenosti sadržaja digitalnih slika u zadnjem desetljeću znatno uznapredovale i postale vrlo sofisticirane, u ovom je radu predložena jedna relativno jednostavna metoda. Iako jednostavna, ova metoda daje dobre rezultate i primjenjiva je kako na umjetno generiranim tako i na realnim slikama.

U svrhu određivanja usmjerenosti sadržaja digitalnih slika projektiraju se 2-D usmjereni filtri. Kod takvih filtara područje propuštanja u domeni frekvencije je u obliku dvaju klinastih područja međusobno simetričnih oko ishodišta (slika 5). Zbog takva se oblika ti filtri nazivaju još i *fan* filtri (*engl. fan = lepeza, ventilator*).

S pomoću skupine takvih filtara iste kutne širine područja propuštanja u frekvenciji, ali s različitim zakretima u odnosu na frekvencijske osi određivat će se kut usmjerenosti sadržaja slike. Filtriranje iste slike sa skupinom takvih filtara dat će skupinu slika u kojima su zadržane spektralne komponente samo određenih usmjerenosti. Na osnovi tih rezultata filtracije razvijena je numerička mjera [1] koja

# **1.INTRODUCTION**

Determination of the directionality of digital images' content has found many different applications ranging from fingerprint recognition, for example, to ocean surveillance applications. Methods for directionality assessment have evolved significantly in the last decade, and some have become very sophisticated. Even though it is rather simple, the method proposed in this paper gives good results, and it is applicable to a wide range of images, from synthetic to real-world images.

In order to determine directionality of image content, two-dimensional directional filters are designed. Such filters have a double wedge-shaped passband as shown in Figure 5. Because of their specific passband shape, these filters are named *fan* filters.

Using a group of such filters, with a passband of the same angular width, but having different rotations with respect to the frequency axes, an angle which determines the directionality of the image content is obtained. Filtering of the same image with the group of fan filters results in a collection of images in which only the frequency content of a certain direction is maintained. A numerical method is developed which uses these images in order to detect dominant image directions [1]. It is shown that local dominant image directions can be also derived by using određuje koji su dominantni smjerovi u slici. Kako je prikazano u nastavku, primjenom te metode na segmente slike moguće je određivanje lokalnih dominantnih smjerova u slici. Takav prikaz orijentacije posebno je zanimljiv na slikama otiska prsta čiji je sadržaj (linije otiska) orijentiran u različitim smjerovima po cijeloj slici. the proposed method and splitting the image into a number of segments. Knowing the localized directionality of the image is useful, for example, in fingerprint image analysis in which content (fingerprint lines) is oriented in different directions throughout the image.

# 2. PROJEKTIRANJE 2-D FIR FAN FILTARA

2-D FIR *fan* filtri mogu se realizirati s pomoću McClellanove transformacije [2] koja pretvara prototipni 1-D filtar u 2-D filtar. Frekvencijski odziv 1-D FIR filtra nulte faze može se zapisati kao:

# 2. DESIGN OF 2-D FIR FAN FILTERS

2-D FIR *fan* filters can be designed by using the McClellan transform [2] which transforms a prototype 1-D filter into a 2-D filter. The frequency response of a zero-phase 1-D FIR filter can be generally written as:

$$H(\omega) = \sum_{n=0}^{N} a(n) T_n(\cos \omega), \qquad (1)$$

gdje  $T_n(\cdot)$  predstavlja *n*-ti Chebyshevljev polinom. Transformacija 1-D filtra u 2-D filtar izvodi se supstitucijom varijabli, tj. uvodi se transformacijska funkcija koja pretvara 1-D frekvencijsko područje u 2-D frekvencijsko područje adekvatno za realizaciju 2-D filtra [3], [4]: where  $T_n(\cdot)$  is the n-th order Chebyshev polynomial [2]. The 1-D to 2-D filter transformation is performed by variable substitution, i.e. a transformation function is introduced that transforms a 1-D frequency domain into a 2-D frequency domain, which is appropriate for 2-D filter design [3], [4]:

$$H(\omega_{1},\omega_{2}) = H(\omega)\Big|_{\cos\omega = F(\omega_{1},\omega_{2})} = \sum_{n=0}^{N} a(n)T_{n}(F(\omega_{1},\omega_{2})),$$
(2)

where  $F(\omega_1, \omega_2)$  is given as:

gdje je  $F(\omega_1, \omega_2)$ :

$$F(\omega_1, \omega_2) = t_{00} + t_{01} \cos(\omega_1) + t_{10} \cos(\omega_2) + t_{11} \cos(\omega_1) \cdot \cos(\omega_2).$$
(3)

Stvoreno 2-D frekvencijsko područje ovisi o parametrima transformacije  $t_{00}$ ,  $t_{01}$ ,  $t_{10}$  i  $t_{11}$ . Ti parametri povezuju lomnu frekvenciju 1-D prototipnog filtra sa željenim oblikom frekvencijske karakteristike 2-D filtra. Transformacijska funkcija stvara 2-D frekvencijsko područje u obliku koncentričnih kružnica gdje se lomnom frekvencijom 1-D filtarskog prototipa određuje propusno i nepropusno područje filtra (slike 1, 2 i 3).

From (3), it can be observed that  $F(\omega_1, \omega_2)$  depends on the transform parameters  $t_{00}$ ,  $t_{01}$ ,  $t_{10}$ , and  $t_{11}$ . These parameters link the cut-off frequency of the 1-D prototype filter with the desired shape of a 2-D filter's frequency response. The transformation function creates a 2-D frequency domain shaped as concentric rings with the 1-D cut-off frequency determining the pass-band and stop-band of a newly designed filter (Figures 1, 2, and 3).



Slika 1. Koncentrične konture za dobivanje 2-D filtra Figure 1. Concentric contours needed to obtain a 2-D filter



Slika 2. 1-D niskopropusni filtarski prototip Figure 2. 1-D low-pass filter prototype



Slika 3. 2-D niskopropusni filtar Figure 3. 2-D low-pass filter

Za razliku od navedenog primjera dizajniranja niskopropusnog filtra, *fan* filtri propuštaju prostorne frekvencije samo određenih kutova, pa parametri bivaju određeni na drukčiji način. Promatrajući relaciju (3) može se postaviti niz uvjeta koji omogućavaju realizaciju *fan* filtra. Budući da je  $|\cos \omega| \le 1$ ,  $F(\omega_1, \omega_2)$  mora također zadovoljavati  $|F(\omega_1, \omega_2)| \le 1$ . Ako se usporedi prikaz 1-D frekvencija  $\omega = 0$  i  $\omega = \pi$ , u odnosnu na odgovarajuće točke u 2-D frekvencijskom području, onda se parametri od  $F(\omega_1, \omega_2)$  u relaciji (3) mogu postaviti u odnosu: As opposed to the example of a low-pass filter, *fan* filters pass spatial frequencies only for a certain angular direction, so the transform parameters are obtained in a different way. Based on the equation (3), a number of constraints can be derived that enable specification of the fan filter. Since  $|\cos \omega| \le 1$ ,  $F(\omega_1, \omega_2)$  must be chosen such that  $|F(\omega_1, \omega_2)| \le 1$ . By comparing the 1-D frequencies  $\omega = 0$  and  $\omega = \pi$ , with the equivalent 2-D frequency points the transformation parameters that define  $F(\omega_1, \omega_2)$  are found to be related such that:

$$t_{00} = t_{11} (4) t_{10} = 1 + t_{01}$$

Da bi se ispunio uvjet nejednakosti  $|F(\omega_1, \omega_2)| \le 1$ , parametri iz relacije (4) moraju zadovoljavati relaciju: For the condition  $|F(\omega_1, \omega_2)| \le 1$  to hold, parameters in equation (4) must also satisfy the following relation:

$$|t_{11}| \le \min\{1 + t_{01}, -t_{01}\}.$$
(5)

U ovom slučaju transformacijska funkcija stvara 2-D frekvencijsko područje u obliku kutno pomaknutih pravocrtnih linija koje prolaze kroz ishodište 2-D frekvencijskog područja (slika 4). 1-D filtarski prototip niskog je propusta i određuje koje će linije predstavljati propusno, a koje nepropusno područje *fan* filtra.



*Slika 4. Klinaste konture za realizaciju* fan filtra *Figure 4. Wedge-like contours needed to obtain a* fan filter

Zbog određivanja dominantnog smjera sadržaja slike, *fan* filtri moraju se rotirati u 2-D frekvencijskom području i moraju biti promjenjivog kuta  $\alpha$  propusnog područja. Promjenjivi kut propusnog područja (kut filtra  $\alpha$ ) određuje parametre transformacije [5]. Kut propusnog područja  $\alpha$  kod takvih filtara iznosi od 5° do maksimalno 45°.

Filtri su realizirani u programskom paketu MATLAB 7.01. Omogućeno je proizvoljno mijenjanje željenoga kuta filtra, reda filtra i metode implementacije. *Fan* filtri realiziraju se s pomoću funkcija *fsamp2*, *fwind1* i *fwind2*. Funkcija *fsamp2* realizira 2-D FIR filtar upotrebom frekvencijskog otipkavanja. Pomoću funkcija *fwind1* i In this way, the transform function creates a 2-D frequency area in the shape of angularly shifted straight lines which pass through the origin of a 2-D frequency plane (Figure 4). The low-pass 1-D filter prototype defines which lines belong to the passband and which belong to the stopband of the *fan* filter.



Slika 5. Frekvencijska karakteristika 2-D fan filtra Figure 5. Frequency response of a 2-D fan filter

For the purpose of image directionality assessment, *fan* filters must be rotated in a 2-D frequency plane, and must have the ability to change the angular width  $\alpha$  of the pass-band. The pass-band filter angle  $\alpha$  determines the transform parameters [5] of such filters, which have values between 5° and 45°.

The filters are realized in the MATLAB 7.01 environment. The following parameters can be freely changed: pass-band angle, filter order, and implementation method. The *Fan* filters are designed by using one of the following functions: *fsamp2*, *fwind1*, and *fwind2*. The *fsamp2* function gives a 2-D FIR filter based on the frequency sampling method. The *fwind1* and *fwind2* functions

*fwind2* mogu se realizirati 2-D FIR filtri upotrebom metoda vremenskih otvora [1]. Funkcija *fwind1* koristi jednodimenzionalnu vremensku metodu, a funkcija *fwind2* koristi dvodimenzionalnu metodu. Kao i kod funkcije *fsamp2* dizajn filtra bazira se na željenom frekvencijskom odzivu. Da bi se s pomoću spomenutih funkcija moglo realizirati *fan* filtar, potrebno je odrediti matricu željenoga frekvencijskog odziva. Ideja je primjenjivanje McClellanova algoritma za realizaciju tzv. 2-D matrične maske. Stvorenoj maski omogućava se promjena dimenzija (tj. promjena reda filtra), promjena oblika (tj. kut filtra) ovisno o željenom kutu *fan* filtra te rotacija u prostoru od 0° do 180°. Primjeri filtara dobiveni za iste specifikacije, ali s različitim metodama prikazani su na slikama 6, 7 i 8. yield 2-D FIR filters that are obtained by using the windowing methods [1]. The *fwind1* function uses the one-dimensional temporal method, while the *fwind2* function uses the two-dimensional method. Similarly as with the *fsamp2* function, the filter design is based on the ideal frequency response. In order to design a *fan* filter by using the above mentioned functions, it is necessary to determine a matrix that represents a desired frequency response. The 2-D matrix mask is obtained using the McClellan algorithm. The mask can be resized (i.e. the filter order can be changed), reshaped (i.e. the angle can be changed) depending on the desired filter angle, and rotated in within the range of 0° to 180°. Examples of fan filters derived for the same specifications but realized with different methods are shown in figures 6, 7, and 8.



Slika 6. 2-D fan filtar reda 51 i kuta 25° (metoda fsamp2) Figure 6. 2-D fan filter of order 51, and angle 25° (fsamp2 method)

Slika 7. 2-D fan filtar reda 51 i kuta 25° (metoda fwind1) Figure 7. 2-D fan filter of order 51, and angle 25° (fwind1 method)

Slika 8. 2-D fan filtar reda 51 i kuta 25° (metoda fwind2) Figure 8. 2-D fan filter of order 51, and angle 25° (fwind2 method)

Za filtraciju slike koristit će se skupina filtara istog kuta  $\alpha$ , ali s različitim stupnjem rotacije  $\delta$  područja propuštanja. Korak rotacije iznosi 180°/ $\delta$ .

# 3. ODREĐIVANJE DOMINANTNOG SMJERA SADRŽAJA DIGITALNE SLIKE

Skupina projektiranih *fan* filtara primjenjuje se na analiziranoj slici. Konvolucija slike *x* i impulsnog odziva svakoga pojedinog filtra  $h_{\alpha,\delta}$  daje filtriranu sliku

For image processing, a group of filters is be used that have the same pass-band angle  $\alpha$ , but different rotation angles  $\delta$ . The rotation step is determined as 180°/ $\delta$ .

# **3. ASSESSING DOMINANT DIRECTION OF THE IMAGE CONTENT**

A group of the designed *fan* filters is applied to the image to be analyzed. Convolution of the image *x*, and the impulse response of each filter  $h_{\alpha,\delta}$  results in the filtered image:

$$y_{\alpha,\delta}[n_1,n_2] = \sum_{k_1} \sum_{k_2} x[l_1,l_2] h_{\alpha,\delta}[n_1 - l_1,n_2 - l_2],$$
(6)

koja zadržava dio frekvencijskog sadržaja originalne slike koji odgovara klinastom području frekvencija kutne širine  $2\alpha$  i rotiranom za kut  $\delta$  s obzirom na frekvencijske osi. Na svakoj dobivenoj slici vrši se diskretna Fourierova transformacija: which retains part of the frequency content of the original image that corresponds to the wedge-shaped pass-band area with the angular width of  $2\alpha$  and the rotation angle of  $\delta$  degrees with respect to the frequency axes. Discrete Fourier transform is applied to each image obtained in this way::

$$Y_{\alpha,\delta}[k_1,k_2] = \sum_{n_1=0}^{N_1-1} \sum_{n_2=0}^{N_2-1} y[n_1,n_2] \cdot e^{-j(\frac{2\pi}{N_1}n_1k_1 + \frac{2\pi}{N_2}n_2k_2)}.$$
(7)

Predložena mjera usmjerenosti određene slike za parametre  $\alpha$  i  $\delta$  dobiva se kao:

The proposed directionality measure for the given image depends on the parameters  $\alpha$  and  $\delta$ , and it is defined as:

$$M(\alpha,\delta) = \sum_{k_1=0}^{K_1-1K_2-1} |Y_{\alpha,\delta}[k_1,k_2]|.$$
(8)

Veća vrijednost za M odgovara većoj usmjerenosti sadržaja slike za odgovarajući kut  $\delta$ . Dominantni smjer slike odgovarat će koraku filtracije koji je rezultirao najvećim M.

# 4. REZULTATI

#### 4.1. Analiza slika prostornih sinusnih valova

Grafičko korisničko sučelje za određivanje dominantnog smjera sadržaja slike realizirano je pomoću programskog paketa MATLAB 7.01 (slika 9).

image for the given angle  $\delta$ . The dominant image direction corresponds to the filtering step which results in the largest value of *M*.

Larger values of M indicate greater directionality of an

# 4. RESULTS

#### 4.1. Analysis of spatial sine wave images

The graphical user interface (GUI) for the assessment of dominant image direction has been implemented in MATLAB 7.01 (Figure 9).



Slika 9. Grafičko korisničko sučelje za određivanje dominantnog smjera sadržaja digitalne slike Figure 9. GUI for the assessment of dominant image direction

Slika 10 prikazuje sinusne prostorne valove perioda 10 i kuta 80°. Njihov spektar, odnosno logaritam amplitudnog

Figure 10 represents spatial sine waves with the period of 10 and the orientation angle of 80°. The logarithm of

spektra, prikazan je na slikama 10 i 11. Metoda implementacije *fan* filtara je *fwind2*. Na slikama 12, 13 i 14 prikazana su tri slučaja određivanja dominantnog smjera sadržaja slike sinusnih valova (kuta 80° i perioda 10) za tri različite skupine *fan* filtara.



Slika 10. Prikaz slike i logaritamskog spektra sinusnih valova perioda 10 i kuta 80°

Figure 10. Image of sine waves with the period of 10 and the angle of 80° (left), and the logarithm of the magnitude spectrum

x 10<sup>4</sup>

12

10

niera

oģ

20 40 60 80 100 120

korakom od 20°

20° steps

140 160

prostorni kut (stupani)

Slika je usmjerena po 80 stupnje

Slika 13. Prikaz mjere M slike

fan filtra reda 21 i kuta 20° s

sinusnih valova realiziran pomoću

Figure 13. Measure M for the sine-

filters of order 21 and angle 20° with

wave image obtained by using fan

180



Slika 12. Prikaz mjere M slike sinusnih valova realiziran pomoću fan filtra reda 21 i kuta 45° s korakom od 10°

Figure 12. Measure M for the sinewave image obtained by using fan filters of order 21 and angle 45° with 10° steps

Najbolji prikaz dominantnog smjera sadržaja slike dobiva se uporabom *fan* filtra kuta 20° i koraka filtracije 20° (slika 13). U ostalim prikazima primjećuje se mala pogreška u estimaciji smjera sadržaja slike. Slika 12 prikazuje *fan* filtar kuta 45° koji filtrira sliku u koracima po 10°. U rezultatu filtracije primjećuje se da mjera usmjerenosti poprima konstantnu vrijednost na intervalu od 45° oko the magnitude spectrum is shown in Figures 10 and 11. The *fwind2* method has been used to obtain a group of *fan* filters. Figures 12, 13, and 14 show examples of determining a dominant orientation of the same spatial sine-wave image using three different groups of *fan* filters.



Slika 11. 3-D prikaz logaritamskog spektra sinusnih valova Figure 11. 3-D view of the logarithm of the

magnitude spectrum



Slika 14. Prikaz mjere M slike sinusnih valova realiziran pomoću fan filtra reda 21 i kuta 5° s korakom od 5°

Figure 14. Measure M for the sinewave image obtained by using fan filters of order 21 and angle 5° with 5° steps

The best detection of a dominant image direction is obtained by using the *fan* filter of an angle of 20° and a filtration step of 20° (Figure 13). The other two examples show small errors in estimating the dominant direction of the image content. Figure 12 shows the results of using a *fan* filter of an angle of 45° and filtration steps of 10°. The results show that the directionality measure has a constant

stvarne vrijednosti dominantnog smjera sadržaja slike. Slika 14 prikazuje rezultate filtracije slike dobivene korištenjem *fan* filtara kuta 5° i koraka filtracije 5°. U ovom je slučaju estimirana vrijednost smjera približno točna. Pogreška koja se primjećuje posljedica je premalog reda filtra s obzirom na kut filtra.

Kako je vidljivo iz prethodnih primjera, o širini filtra  $\alpha$  značajno ovisi uspješnost estimacije dominantnog smjera slike. Optimalna širina filtra  $\alpha$  ovisi i o frekvenciji sinusnih valova. Na slikama 17 i 18 prikazuje se usporedba analize dvaju sinusnih valova kuta 60° (spektri prikazani na slikama 15 i 16) i različitih frekvencija. Filtracija je u obama slučajevima provedena s*fan* filtrima uz iste parametre.



Slika 15. Prikaz logaritamskog spektra sinusnih valova perioda 5 i kuta 60°

Figure 15. Logarithm of the magnitude spectrum for sine waves with period 5 and orientation 60°



Slika17. Prikaz mjere M sadržaja sinusnih valova perioda 5 i kuta 60° pomoću fan filtra reda 51 i kuta 20° s korakom filtracije od 20°

Figure 17. Measure M for the sine waves with the period of 5 and the 60° orientation obtained with fan filters of order 51, angle 20° and filtration step of 20°

value at the interval of  $45^{\circ}$  around the true value of the dominant direction. Figure 14, on the other hand, shows the results obtained by using *fan* filters of the angle  $5^{\circ}$  and the filtration step  $5^{\circ}$ . In this case, the estimation error is much smaller, and it is a result of the filter order being too small for the given angle value.

As shown in previous examples, the dominant direction estimation strongly depends on the filter angle  $\alpha$ . The optimal  $\alpha$  also depends on the frequency of the sine waves. Figures 17 and 18 compare the analysis of two sine waves oriented at 60° (spectra shown in Figures 15 and 16), having different frequencies. In both cases, *fan* filters with the same set of parameters are used.



Slika 16. Prikaz logaritamskog spektra sinusnih valova perioda 30 i kuta 60° Figure 16. Logarithm of the magnitude spectrum for



Slika 18. Prikaz mjere M sadržaja sinusnih valova perioda 30 i kuta 60° pomoću fan filtra reda 51 i kuta 20° s korakom filtracije od 20°

Figure 18. Measure M for the sine waves with the period of 30 and the 60° orientation obtained with fan filters of order 51, angle and filtration step of 20°

Iz priloženih slika 17 i 18 primjećuje se da se istim kutom *fan* filtra sinusnim valovima većih frekvencija bolje određuje dominantan smjer nego onima manjih frekvencija. Razlog je u odstupanju stvarne frekvencijske karakteristike filtra od idealnoga klinastog oblika. To je odstupanje veće na nižim frekvencijama pa na tim frekvencijama dolazi do preklapanja propusnih područja filtara iz iste skupine. Zbog toga su na slici 18 prikazi vrijednosti *M* za ostale smjerove veliki u okolini stvarnog smjera sadržaja slike.

# 4.2. Analiza realnih slika

Fotografija pod nazivom *face* sa slike 19 ima znatno raznolikiji frekvencijski sadržaj od umjetno generiranih slika sinusnih valova. Analiza je provedena pomoću dvaju različitih oblika *fan* filtara. U prvom se slučaju koristi *fan* filtar kuta 10°, reda 51 i koraka filtracije 10°, a u drugom se slučaju koristi *fan* filtar 45°, reda 51 i koraka filtracije 10°. Na slikama 20 i 21 prikazani su rezultati dobiveni korištenjem ovih filtara. Slika 22 prikazuje detalj šešira filtrirane slike u slučaju filtriranja slike s *fan* filtrom kuta 10°, a slika 23 prikazuje isti detalj u slučaju filtriranja s *fan* filtrom kuta 45°. Iz rezultata je vidljivo da *fan* filtar kuta 10° i koraka filtracije 10° jasno određuje kut od 90° kao dominantni smjer sadržaja slike. From Figures 17 and 18 it can be seen that for the same angular width, a *fan* filter better detects the orientation of sine waves of higher frequencies than sine waves of lower frequencies. This is due to the fact that a designed *fan* filter slightly differs from the ideal wedge shape, with the larger differences for lower frequencies. Therefore, in the area of lower frequencies the pass-bands of rotated fan filters overlap. This causes the value of M in Figure 18 to be rather large for the angles closer to the true sine-wave direction.

#### 4.2. Analysis of real-world images

A photo called *face*, shown in Figure 19, has a frequency content that is much more diverse than in the case of synthetic sine-wave images. Image analysis is performed by using two differently shaped *fan* filters. In the first case, we used a *fan* filter with the angular width of 10°, order 51, and the filtration step of 10°. In the second case, we used a *fan* filter with the angular width of 45°, and the order of 51, and the filtration step of 10°. Figures 20 and 21 show the obtained results. Figure 22 shows a part of the hat in the filtered image with the 10° *fan* filter, while Figure 23 shows the same details obtained with the 45° *fan* filter. It is evident that the 10° *fan* filter with the 10° *fan* filter with the 10° filtration step clearly detects the 90° angle as the dominant direction of the image content.



*Slika19. Prikaz slike 'face' (lijevo) s pripadajućim logaritamskim spektrom (desno) Figure19. The 'face' image (left) and the appropriate logarithm of its magnitude spectrum (right)* 



Slika 20. Prikaz mjere M za sliku 'face' pomoću fan filtra reda 51 i kuta 10° s korakom filtracije od 10° Figure 20. Measure M for the 'face' image obtained with the fan filters of the order 51, the angle 10° and the filtration step of 10°



Slika 22. Filtrirani detalj šešira slike 'face' na kutu filtracije 90° s fan filtrom kuta 10° Figure 22. Filtered detail of the hat obtained with the 10° fan filter rotated at 90°

#### 4.3. Lokalna analiza slike otiska prsta

Jedan je od zanimljivih primjera određivanje dominantne orijentacije primjer analize slike otiska prsta [6,7]. Kao što se vidi na primjeru sa slike 24, linije otiska prsta poprimaju različite smjerove na različitim dijelovima slike. U svrhu analize lokalnih smjerova ta je slika podijeljena u 9 dijelova, kao što je prikazano na slici 25, i na svakom od njih je proveden postupak određivanja dominantnog smjera. Slika 26 prikazuje vrijednosti mjere M cijele slike, dok slika 27 daje prikaz lokalne usmjerenosti slike otiska prsta temeljene na vrijednostima mjere M za svaki dio slike.



Slika 21. Prikaz mjere M za sliku 'face' pomoću fan filtra reda 51 i kuta 45° s korakom filtracije od 10° Figure 21. Measure M for the 'face' image obtained with the fan filters of the order 51, the angle of 45° and the filtration step of 10°



Slika 23. Filtrirani detalj šešira slike 'face' na kutu filtracije 90° s fan filtrom kuta 45° Figure 23. Filtered detail of the hat obtained with the 45° fan filter rotated at 90°

#### 4.3. Local analysis of the fingerprint image

Let us next determine the dominant direction of a fingerprint image [6,7]. Fingerprint lines take various directions for different parts of the image (see Figure 24). In order to analyze local directions, the image is split into 9 parts, as shown in Figure 25. The procedure for determining a dominant direction is performed for each of the 9 subimages. Figure 26 gives the measure M values for the whole image, and Figure 27 displays the local directionalities of the fingerprint image based on the measure M for each subimage.



Slika 24. Prikaz slike otiska prsta Figure 24. A fingerprint image



Slika 26. Mjera M slike otiska prsta Figure 26. Measure M for the fingerprint image

# 5. ZAKLJUČAK

U ovom je radu predložena metoda određivanja usmjerenosti sadržaja digitalne slike temeljena na korištenju skupine *fan* filtara koji propuštaju samo određene prostorne frekvencije. Pokazano je da ta metoda, uz na odgovarajući način podešene parametre filtara, daje dobre rezultate određivanja dominatnog smjera kako u sintetskim tako i realnim slikama. Iz dobivenih rezultata zaključujemo da korišteni filtri čije je područje klinastog oblika bolje određuju dominantni smjer slika čiji je frekvencijski sadržaj koncentriran na višim frekvencijama. Praktične primjene te metode ilustrirane su na realnim slikama uključujući i sliku otiska prsta.



*Slika 25. Prikaz podijeljene slike otiska u 9 dijelova Figure 25. Division of the fingerprint image into 9 subimages* 



*Slika 27. Lokalna usmjerenost slike otiska prsta Figure 27. Local directionalities for the fingerprint image* 

# 5. CONCLUSION

In this paper, we have proposed a method for assessing the directionality of the content of a digital image. The method is based on using *fan* filters which only pass certain spatial frequencies. It was shown that the method, with the appropriately chosen parameters, gives good results in determining a dominant direction for both synthetic and real-world images. The obtained results have also shown that the filters with the wedge-shaped pass-band can better detect a dominant direction in images whose frequency content is concentrated in a higher frequency range. The applicability of the method has been illustrated on real life examples including the fingerprint image. Uz podjelu slike na više dijelova ili čak adaptivnu nejednoliku podjelu slike prije primjene predložene metode omogućila bi se još kvalitetnija estimacija lokalnih smjerova u slici.

U ovom je radu korištena jednostavna i numerički nezahtjevna L1 norma za izračun mjere usmjerenosti *M*. U budućim će radovima biti razmotrene različite norme i uspoređena njihova uspješnost u određivanju usmjerenosti sadržaja digitalnih slika.

# LITERATURA REFERENCES

- [1] Bibulić M.: *Dvodimenzionalni usmjereni filtri za obradu digitalnih slika*, diplomski rad, Tehnički fakultet Sveučilišta u Rijeci, 2007.
- [2] McClellan J. H.: *The Design of Two Dimensional Digital Filters by Transformation*, in Proc. 7th Ann. Princeton Conf. Inform. Sci. Syst., 1973, pp. 247-251
- [3] Psarakis E. Z., Mertzios V. G., and Alexiou G. P.: Design of Two-dimensional Zero Phase FIR Fan Filters via the McClellan Transform, IEEE Transactions on Circuits and Systems, vol. 37, Januar 1990, pp. 10-16
- Pei S. C., and Shyu J. J., *Design of 2-D FIR* Digital Filters by McClellan Transformation and Least Eigencontour Mapping, IEEE Transactions on Circuits and Systems, vol. 40, September 1993, pp. 546-555

Izvornoznanstveni članak

Adresa autora/Authors' address Marino Bibulić Kunfin 3, Vabriga 52465 Tar Dr. sc. Miroslav Vrankić, dipl. ing. Doc. dr. sc. Viktor Sučić, dipl. ing. Tehnički fakultet Sveučilišta u Rijeci Vukovarska 58 51000 Rijeka, Hrvatska Even more efficient estimation of the image directions can be achieved by splitting an image into a larger number of subimages, or performing adaptive and nonuniform divisions before the proposed methods are applied.

In this paper, we have used a rather simple and numerically inexpensive norm, the L1 norm, to calculate the directionality measure M. In our future works, different norms will be considered, and their performances in directionality assessment compared.

- [5] Young-Seog S. and Young H. L.: Formulas for McClellan Transform Parameters in Designing 2-D Zero-Phase FIR Fan Filters, IEEE Signal Processing Letters, vol. 3, No. 11, November 1996, pp. 291 - 293
- [6] Chikkerur S. S., Cartwright A. N., and Govindaraju V.: Fingerprint Image Enhancemet using STFT Analysis, Center for Unfied Biometrics and Sensor, University at Buffalo, NY, USA
- [7] http://www.cubs.buffalo.edu/fingerrecog.shtml

Original scientific paper