Brza Fourierova tranformacija i njezina primjena u obradi slike

Pejić, Denis

Undergraduate thesis / Završni rad

2015

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:200:853097

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2025-03-21**

Repository / Repozitorij:

Faculty of Electrical Engineering, Computer Science and Information Technology Osijek

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

ELEKTROTEHNIČKI FAKULTET

Sveučilišni studij

BRZA FOURIEROVA TRANSFORMACIJA I NJEZINA PRIMJENA U OBRADI SLIKE

Završni rad

Denis Pejić

Osijek, 2015.

SADRŽAJ

1.UVOD 1
1.1.Zadatak završnog rada 1
2.FOURIEROVA ANALIZA 2
2.1.Fourierov red 3
2.2.Fourierova transformacija (FT) 4
2.3.2D Fourierov red 5
2.4.2D Fourierova transformacija 5
2.5.Svojstva Fourierove transformacije 6
3.VREMENSKI DISKRETNA FOURIEROVA ANALIZA 9
3.1.Vremenski diskretni Fourierov red 9
3.2.Vremenska diskretna Fourierova transformacija 10
3.3.2D vremenska diskretna Fourierova transformacija 13
3.4.Dvodimenzionalna DFT 13
3.5.Svojstva DFT 14
3.6.Primjena DFT na mirnu sliku 17
4.BRZA FOURIEROVA TRANSFORMACIJA (FFT) 19
4.1.Razvoj FFT 19
4.2.Metode FFT 20
5.PRIMJENA FFT-A NA SLIKU POMOĆU PROGRAMA MATLAB 23
6.ZAKLJUČAK 31
7.SAŽETAK 32
8.ABSTRACT 33
9. LITERATURA 34
10. ŽIVOTOPIS 38

7.SAŽETAK

U ovom radu je primjenjena brza Fourierova transformacija u obradi slike pomoću programa matlab. Vremenska diskretna Fourierova transformacija predstavlja Fourierovu transformaciju za vremenske diskretne signale. U obradi digitalne slike vremenska diskretna Fourierova transformacija se proširila na 2D vremensku diskretnu Fourierovu transformaciju, zato što je digitalna slika dvodimenzionalna. Primjenom 2D vremenske diskretne Fourierove transformacije na matricu slike, pretvorba slike se vrši iz prostorne domene u frekvencijsku domenu. U obradi slike razlikuje se prostorno i frekvencijsko područje. Slike su filtrirane u frekvencijskoj domeni. Filtriranje u frekvencijskoj domeni zahtjeva manju računsku složenost. Prevođenjem frekvencijskog filtera u konvolucijsku masku dobije se aproksimacija najmanje kvadratne greške[35]. Ako je frekvencijski filtar realan i simetričan, tada će konvolucijska maska biti također realna i simetrična. U slučaju nemogućnosti određivanja dovoljno dobre maske za aproksimaciju filtra ili ako aproksimacijom filtra dobivamo veliku konvolucijsku masku, tada se filtriranje provodi u frekvencijskom području. Iz tog razloga filtriranje u frekvencijskoj domeni zahtjeva manju računsku složenost za razliku sa konvolucijom s velikim maskama.

Ključne riječi: FT, DTFT, 2D DTFT, FFT algoritam, prostorna domena, frekvencijska domena, FR, digitalna slika.

Fast Fourier Transform and its Application in Image Processing

8.ABSTRACT

In this work was applied fast Fourier transformation in picture processing with program matlab. Time discrete Fourier transform presents Fourier transform of discrete-time signals. In digital image processing time discrete Fourier transform expands to two-dimensional time discrete Fourier transform, because the digital image is two-dimensional. By applying the two-dimensional discrete-time Fourier transform on the matrix image, image conversion is made from the spatial domain to the frequency domain. In image processing it differs spatial and frequency domain. Pictures are filtered in frequency domain. Filtering in frequency domain require lower calculation complexity. By transfering frequency filter in convolution mask it gets approximation of least square mistake. If the frequency filter is realistic and simetric, then convolution mask will also be realistic and simetric. In cases where determination of mask for approximation filter isn't good enough or if with approximation of filter results with large convolution mask, then filtering is carried out in frequency domain. Because of that reason filtering in frequency domain requests lower calculation complexity compared to convolution with large masks.

Key words: FT, DTFT, 2D DTFT, FFT algorithm, spatial domain, frequency domain, FR, digital image.