

VŠB – Technická univerzita Ostrava

FAKULTA ELEKTROTECHNIKY A INFORMATIKY

Katedra kybernetiky a biomedicínského inženýrství



DOKTORSKÁ DISERTAČNÍ PRÁCE

VŠB – Technická univerzita Ostrava

FAKULTA ELEKTROTECHNIKY A INFORMATIKY

Katedra kybernetiky a biomedicínského inženýrství

Vývoj metod zpracování obrazového signálu

Doktorská disertační práce

Ostrava 2014

Ing. Radim Hercík

školitel: doc. Ing. Jiří Koziorek, Ph.D.

Abstrakt

Tato disertační práce se zabývá vývojem metod zpracování obrazového signálu v průmyslovém prostředí. Zaměřuje se na oblast segmentace obrazu s následnou identifikací a klasifikací segmentů obrazu. Cílem vývoje těchto metod je zachování spolehlivosti a přesnosti rozpoznávací schopnosti systému i v případě snížení kvality vstupních obrazových dat.

Teoretickým přínosem práce je optimalizace segmentačních metod založených na metodě semínkového vyplňování oblastí. Práce rozvíjí přístupy v oblasti klasifikace a identifikace segmentů obrazu na principu parametrické a korelační analýzy. Za tímto účelem práce pojednává o nově vyvinuté metodě reprezentace segmentů obrazu. Vyvinutá metoda využívá převodu dvourozměrného signálu segmentu obrazu na jednorozměrný periodický signál, na principu zápisu matematického vyjádření pomocí polárních souřadnic. Tato metoda přináší zcela nový pohled na matematickou reprezentaci segmentů obrazu. Optimalizuje a zjednodušuje aplikaci korelačních funkcí v procesu identifikace a klasifikace oblastí.

Praktickým přínosem práce je přihláška patentu s názvem „Distribuovaný autonomní mobilní rozpoznávací systém“ a zároveň přihláška užitečného vzoru s názvem „Zařízení pro distribuovaný autonomní mobilní rozpoznávací systém“.

Klíčová slova

Segmentace obrazu, Semínkové vyplňování oblastí, Binarizace, Klasifikace objektů, Konvexní množina, Polární souřadnicový systém, FFT, Korelační funkce, Korelační koeficient, Fourierova řada, Shannon-Kotelnikovův teorém, SCADA

Abstract

This dissertation work is focus on the development of methods for image signal processing in industrial environments. Focusing on image segmentation with subsequent identification and classification of image segments. The aim of the development of these methods is to maintain the reliability and accuracy of recognition capabilities of the system, even if a reduction in the quality of the input image data.

The contribution of this work on theoretical area is to optimize the segmentation methods based on the seed filling areas. The work develops approaches to classification and identification of segments the image on the principle of a parametric correlation analysis. For this reason, the work deals with the newly developed method of representation of the image segments. The developed method utilizes the conversion of two-dimensional image signal segment of the one-dimensional periodic signal on the principle of mathematical expressions using polar coordinates. This method brings a whole new perspective on a mathematical representation of the image segments. Optimizes and simplifies the application of correlation functions in the process of identification and classification of areas.

The contribution of this work on practical area is the patent application entitled "Distributed Autonomous mobile recognition system" and also a utility model application entitled "Device for distributed autonomous mobile recognition system".

Keywords

Image segmentation, Method of the seed feeling area, Binarization, Object classification, Convex area, Polar coordinate system, FFT, Correlation function, Correlation coefficient, Fourier series, Shannon-Kotelnikov theorem, SCADA

Prohlašuji, že jsem tuto disertační práci vypracoval samostatně. Uvedl jsem všechny literární prameny a publikace, ze kterých jsem čerpal.

V Ostravě, dne

Ing. Radim Hercík

Chtěl bych poděkovat svému školiteli doc. Ing. Jiřímu Koziorkovi, Ph.D, za jeho odborné i formální vedení při řešení práce. Rovněž děkuji své přítelkyni Petře a svým rodičům za trpělivost a podporu při realizaci této práce i během samotného studia.

Seznam použitých symbolů a zkratk:

2D	Dvourozměrný prostor, obrazový signál o definované výšce a šířce
Blob	Spojité oblasti v obraze, oblasti se stejnými vlastnostmi
DSP	Digitální signálový procesor
FFT	Fast Fourier Transform
Framework	Softwarová struktura, která slouží jako podpora při vývoji softwarových aplikací
KTT*	Kruhová tvarová transformace*
MAD	Median Absolute Deviation
RGB	Red-Green-Blue, Barevný model aditivního míchání barev
RT	Real-time
TAČR	Technologická agentura České republiky
OS	Operační systém
PAL	Phase Alternating Line, standard barevného kódování signálu
YUV	Barevný model obrazu, Y-jasová složka, U,V barevná složka obrazu
SCADA	Supervisory Control and Data Acquisition
UPV	Úřad průmyslového vlastnictví

* Zkratky jsou definovány níže v textu

a_0, a_n, b_n	Koeficienty Fourierovy řady
c_n	Koeficient funkce křivosti hranice objektu
C	Třídy algoritmu K-means
E	Velikost energie, energie hranice
$f(p)$	Prahovací funkce
$f(t)$	Fourierova řada
$f(\varphi)$	Funkce kruhové tvarové transformace
$f'(\varphi)$	Vlastní derivace funkce kruhové tvarové transformace

G	Gradient hranového detektoru
h	Práh binarizace
H_x	Výška segmentu obrazu v pixelech
J	Jakobián transformace do polárních souřadnic
$k(s)$	Funkce průběhu křivosti hranice objektu
L	Délka křivky kruhové tvarové transformace
σ	Standardní odchylka rozdělení
o	Obvod segmentu v obraze
O	Objekt
p	Pixel, korelační koeficient
P_x, P_y	Souřadnice středu segmentu v obraze
r	Poloměr, vzdálenost od středu
R, R_{AB}, R_{12}	Korelační funkce, vzájemná korelační funkce signálu
S	Obsah segmentu v obraze
τ	Posun signálu
T	Perioda signálu
$ v $	Velikost vektoru
V	Odchylka rozdílů uvnitř shluků algoritmu K-means
W_y	Šířka segmentu obrazu v pixelech
x, y	Pozice pixelu, bodu segmentu
μ_d	Průměrná vzdálenost pixelu od hranice objektu
μ_j	Hodnota vektoru algoritmu K-means
ϖ_v	Kmitočet vzorkování signálu
ϖ_m	Kmitočet vzorkovaného signálu
$\Delta\varphi$	Velikost kroku kruhové tvarové transformace
ψ	Goniometrická funkce převodu do kartézských souřadnic

Obsah

Úvod.....	1
1. Formulace cílů práce v teoretické oblasti.....	2
1.1. Oblast techniky.....	2
1.2. Cíle práce.....	2
1.3. Systém průmyslového zpracování obrazového signálu.....	3
2. Metody průmyslového zpracování obrazu.....	6
2.1. Metody segmentace obrazu.....	6
2.1.1. Segmentace prahováním.....	7
2.1.2. Segmentace prostřednictvím hranové detekce.....	8
2.1.3. Metody založené na hledání regionu.....	11
2.1.4. Barevná segmentace.....	13
2.1.5. Algoritmus záplava, Watershed.....	14
2.2. Jednoznačná identifikace segmentů v obraze.....	15
2.2.1. Indexace oblastí „barvením“.....	15
2.2.2. Semínkové vyplňování.....	18
2.2.2.1. Rekurzivní metoda.....	18
2.2.2.2. Implementace pomocí vlastního zásobníku.....	19
2.2.2.3. Řádková varianta semínkového vyplňování.....	20
2.2.3. Maticový optimalizovaný návrh semínkového vyplňování.....	20
2.2.4. Parametrický popis.....	23
2.2.5. Houghova transformace.....	27
2.2.6. Popis skupinou vektorů.....	29
2.2.7. Popis tvaru objektu pomocí průběhu křivosti jeho hranice.....	30
3. Kruhová tvarová transformace.....	32
3.1. Konvexní oblast a konvexní bod v \mathbb{R}^2	33
3.2. Shannon-Kotelnikův teorém ve vztahu ke KTT.....	34
3.3. Popis funkce KTT Fourierovou řadou.....	36
3.4. Transformace z prostoru X, Y do r, φ	41
3.5. Převod středu transformace v prostoru X, Y do r, φ	42
3.6. Transformace z prostoru r, φ do X, Y	44
3.7. Periodičnost funkce kruhové tvarové transformace.....	44
3.8. Délka a obsah křivky kruhové tvarové transformace.....	45
4. Klasifikace objektů.....	51
4.1. Parametrický popis segmentu.....	51

4.2. Kruhovost.....	52
4.3. Energie hranice.....	52
4.4. Průměrná vzdálenost pixelu od hranice.....	53
4.5. Parametrická analýza a klasifikace segmentu.....	53
4.6. Parametrický popis ve vztahu ke kruhové tvarové transformaci.....	55
4.7. Klasifikace kruhové tvarové transformace korelační funkcí.....	58
5. Verifikace vyvinutých metod.....	65
5.1. Verifikace maticového návrhu semínkového vyplňování.....	66
5.2. Verifikace kruhové tvarové transformace.....	70
6. Přínos práce v praktické oblasti.....	81
7. Další rozvoj práce.....	82
Shrnutí.....	83
Literatura.....	85
Reference	
Vlastní publikace související s disertační prací.....	89
Vlastní publikace ostatní.....	90
Užité vzory.....	91
Funkční vzorky.....	92
Výzkumné aktivity.....	92
Zahraniční působení a stáže.....	92
Pedagogická činnost.....	93
Ostatní.....	93
Seznam Obrázků.....	94
Seznam Tabulek.....	95

Přílohy:

Vyjádření spolupůvodců o předmětu průmyslového vlastnictví

Nedílnou součástí této práce je také CD s elektronickou verzí této práce a zdrojovými kódy implementovaných navržených metod za účelem verifikace v programu Matlab.

Úvod

Vývoj metod zpracování obrazového signálu jsou jednou z nejvíce rozvíjených oblastí v technické praxi. Metody zpracování obrazového signálu zahrnují širokou škálu oblastí zpracování obrazových signálů. Do této oblasti spadají veškeré operace, které upravují či transformují, analyzují či jinak pracují s obrazovým signálem. Metody zpracování obrazového signálu můžeme rozdělit na dvě základní oblasti, a to oblast komerčního zpracování obrazového signálu a oblast průmyslového zpracování obrazového signálu. Do oblasti komerčního zpracování obrazového signálu patří metody zpracování videa, úpravy fotografií či 3D grafika. Dále pak metody a algoritmy vyhodnocení obrazu pro zabezpečovací systémy, jako rozpoznání tváře, detekce osob či jiných prvků. Tato práce se věnuje oblasti průmyslového zpracování obrazu, kde je potřeba jednoznačně vyhodnocovat a klasifikovat zájmové oblasti a prvky obrazu. Typickým příkladem aplikace průmyslového zpracování obrazu je kontrola kvality, čtení strojových kódů a označení produktů či jiné kritické operace řízení výrobního procesu na základě vyhodnocení obrazových dat. Při řešení těchto úkolů průmyslového zpracování obrazu musí být zajištěna spolehlivost systému. Jsou kladeny vysoké požadavky na jednoznačnost identifikace požadovaných informací, segmentů a prvků obrazu.

Tato práce se soustřeďuje na vývoj algoritmů a metod zpracování obrazových dat v průmyslovém prostředí a jejich implementaci se zaměřením na jednoznačnou identifikaci a parametrizaci prvků v obraze. Práce přináší přehled základních segmentačních algoritmů a metod se zaměřením na optimalizaci některých těchto přístupů, při zachování jejich spolehlivosti a jednoznačnosti výstupu. Hlavní myšlenka spočívá ve vývoji nových přístupů k identifikaci segmentů obrazu, jejich popisu a klasifikaci založenou na portfoliu stávajících metod segmentace obrazu při zachování jejich jednoznačnosti i při snížení kvality vstupní obrazové informace, což je jedním ze základních problémů současných systémů zpracování obrazu.

Cílem práce je poskytnout nový přístup klasifikace segmentů obrazu pomocí metod průmyslového zpracování obrazového signálu, zvýšit rychlost a efektivitu klasifikace a identifikace těchto segmentů pro použití v oblasti průmyslového zpracování obrazu. Na systémy průmyslového zpracování obrazu jsou kladeny vysoké požadavky z pohledu rychlosti, spolehlivosti a jednoznačnosti poskytovaných rozpoznávaných dat. Jedním ze základních nedostatků současných systémů je právě citlivost systému na kvalitu vstupních obrazových dat.

Vyvíjené metody zpracování obrazového signálu jsou součástí distribuovaného autonomního mobilního systému pro řízení a monitorování průmyslových procesů vyvíjeného v rámci řešení projektu TAČR TA01010632 „Inovace SCADA systém pro monitorování stavu v reálném čase“. Ověření efektivit a spolehlivost vyvinutých přístupů a metod je realizováno

v rámci jejich implementace, jako součást distribuovaného autonomního mobilního systému pro řízení a monitorování průmyslových procesů.

1. Formulace cílů práce v teoretické oblasti

Tato kapitola se věnuje definici klíčových prvků disertační práce, uvádí oblast techniky a cíle práce, dále uvádí a popisuje metodiku navrhovaného řešení.

1.1. Oblast techniky

Disertační práce, její zaměření, cíle a praktický přínos spadají do oblasti systémů průmyslového zpracování obrazu a velkých objemů dat, distribuovaných systémů pro řízení a monitorování průmyslových procesů. Metody vyvíjené v rámci této disertační práce naleznou uplatnění v systémech průmyslového zpracování obrazu.

Teoretickým přínosem práce je optimalizace vybraných segmentačních metod, založených na prahovacích úrovních, dále pak prohloubení problematiky klasifikace těchto segmentů a prvků obrazu pomocí parametrických vyjádření s ohledem na optimálnost jejich identifikace za pomoci korelačních funkcí.

Přínos práce v teoretické oblasti se nachází především v realizaci rozpoznávacích systémů s potřebou segmentace obrazu s následnou klasifikací těchto segmentů a prvků obrazu. Metody vyvíjené v rámci této disertační práce budou implementovány jako součást inferenčního mechanismu distribuovaného autonomního mobilního systému pro řízení a monitorování průmyslových procesů v reálném čase.

1.2. Cíle práce

Cílem práce v teoretické oblasti je zejména vývoj metod průmyslového zpracování obrazového signálu v oblasti segmentace a klasifikace zájmových prvků a oblastí obrazu. Systémy průmyslového zpracování obrazu jsou kritickými systémy z pohledu jejich přesnosti, spolehlivosti a rychlosti. Klíčovým prvkem těchto systémů jsou tedy metody segmentace a klasifikace prvků obrazového signálu, které poskytují množinu rozpoznávaných identifikovaných dat. Cílem práce je optimalizace vybraných segmentačních metod a vývoj nových přístupů v rámci klasifikace nalezených segmentů. Optimalizací segmentačních metod se v tomto kontextu rozumí vylepšení současně používaných metod pro indexaci segmentů a jejich parametrizaci. Práce si současně klade za cíl vývoj metod klasifikace a identifikace nalezených segmentů obrazu při zachování spolehlivosti a přesnosti

rozpoznávací schopnosti systému i v případě snížení kvality vstupních obrazových dat, respektive snížení informační věrohodnosti jednotlivých segmentů.

Cílem práce v praktické oblasti je návrh a implementace optimalizovaných a vyvinutých metod v rámci vývoje distribuovaného autonomního mobilního systému, pro řízení a monitorování průmyslových procesů, vyvíjeného v rámci řešení projektu TAČR TA01010632 „Inovace SCADA systému pro monitorování stavu v reálném čase“ a jejich ověření v praktickém použití.

Vyvíjené metody naleznou uplatnění v oblasti průmyslového zpracování obrazu, rozšíří a prohloubí portfolio současně používaných metod a přístupů. Tyto metody jsou vyvíjeny jako součást distribuovaného systému pro autonomní analýzu a vyhodnocení obrazových dat zobrazeného na obrázku č.1., a budou implementovány v rámci modulu rozpoznávacího a rozhodovacího interferenčního mechanismu praktické části této práce. Analyzované a rozpoznané informace a data z vyvíjených metod systému pak mohou být předávány nadřazeným řídicím systémům, které tyto informace dále využívají.

1.3. Systém průmyslového zpracování obrazového signálu

Vyvíjené metody zpracování obrazového signálu jsou součástí distribuovaného autonomního mobilního systému pro řízení a monitorování průmyslových procesů jako nedílná součást rozhodovacího a rozpoznávacího inferenčního mechanismu. Tento systém je vyvíjen v rámci řešení projektu TAČR TA01010632 „Inovace SCADA systém pro monitorování stavu v reálném čase“.

Podstata vyvíjeného distribuovaného autonomního mobilního systému:

Podstatou vyvíjeného systému je distribuovatelnost výpočetního výkonu a jednotlivých operací. Vyvíjený systém se skládá z řady mobilních autonomních rozpoznávacích jednotek, které spolu navzájem komunikují za účelem sdílení dat, výpočetního výkonu a jednotlivých operací. Toto komunikační propojení může být realizováno jako drátové, bezdrátové anebo kombinace obou těchto typů propojení.

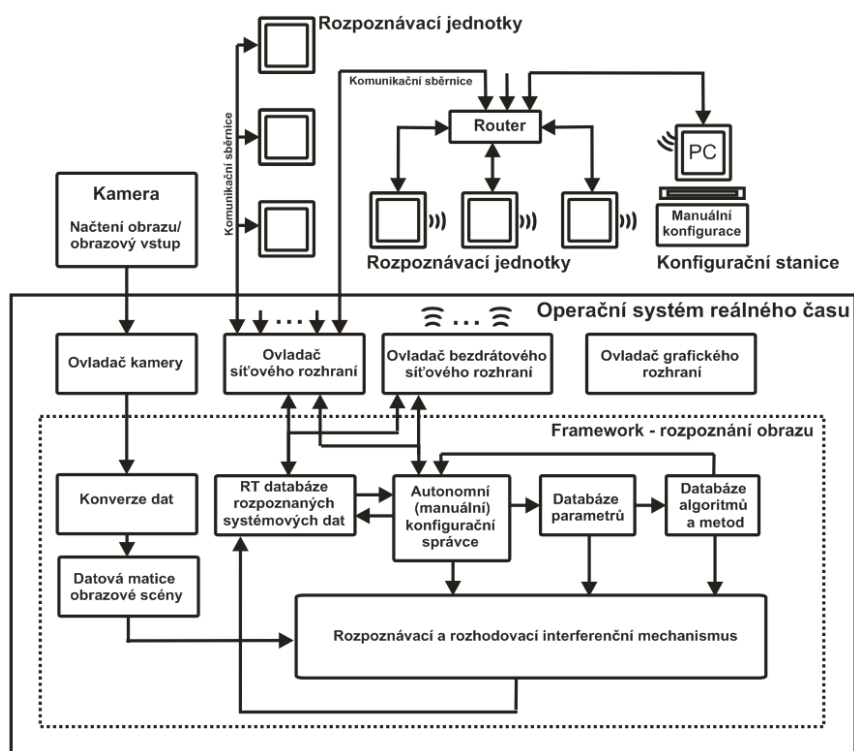
Vyvíjené mobilní autonomní rozpoznávací jednotky spolu komunikují prostřednictvím distribuovaného síťového propojení. Rovněž je podstatné, že vyvíjený rozpoznávací systém, obsahuje inferenční rozhodovací mechanismus, na který je napojena databáze rozpoznávaných systémových dat běžící v reálném čase, ze které mohou být data přenášena přes autonomního konfiguračního správce a ovladače síťového rozhraní do jiných autonomních mobilních jednotek anebo nadřazených řídicích systémů.

Rovněž je podstatné, že vyvíjený distribuovaný autonomní mobilní systém zpracuje data získaná z externích zařízení v rozpoznávacím systému, vyhodnotí je na základě dat získaných z konfiguračních databází a tato získaná data se zpětně uloží do databáze rozpoznávacích systémových dat běžící v reálném čase. Uložená data jsou následně distribuována do nadřazených řídicích systémů, anebo ostatních autonomních mobilních jednotek. Zároveň je rozpoznávací systém schopen autonomně rozhodnout, která externí zařízení napojená na síť a informace z nich získaná využije.

Mobilní autonomní rozpoznávací jednotka vyvíjeného systému se skládá z hardwaru vybaveného pamětmi, procesorem a periferiemi jako je síťové rozhraní, grafické rozhraní nebo kamerovým vstupem a případně dalších komponent. Na vyvíjeném zařízení je instalován operační systém reálného času. Na RT OS je implementován Framework rozpoznávacího systému, který se skládá z autonomního konfiguračního správce, databáze parametrů, databáze algoritmů a metod, dále z databáze rozpoznávacích systémových dat a rozpoznávacího a rozhodovacího interferenčního mechanismu.

A konečně je podstatné, že vyvíjený distribuovaný autonomní mobilní systém je bezdrátově konfigurovatelný, anebo je možné jej konfigurovat pomocí jakékoliv komunikační sítě. Po této konfiguraci je distribuovaný autonomní mobilní systém schopen pracovat zcela nezávisle na externím konfiguračním zařízení.

Koncepce distribuovaného autonomního mobilního systému je zobrazen na obr.1.



Obr.1. Metodika a struktura vyvíjeného systému

Podstata a cíle práce:

Středem disertační práce bude modul rozpoznávacího a rozhodovacího interferenčního mechanismu a implementace příslušných vyvinutých metod tohoto modulu. Podstatou rozpoznávacího a rozhodovacího inferenčního mechanismu je poskytovat informace o zájmových oblastech v obrazovém signálu v rámci předdefinovaných funkčních parametrů.

Tyto informace reprezentují množinu identifikovaných a rozpoznávaných dat, která musí poskytovat dostatečně abstraktní popis tohoto obrazového signálu za účelem redukce a odstranění redundantních obrazových dat, dále pak snadné identifikace klíčových informací, objektů a závislostí v obrazovém signálu. Tato data mohou být přímo předávána dalším nadřazeným řídicím systémům, nebo sdílena v rámci distribuované architektury autonomního rozpoznávacího systému pro vyhodnocení obrazového signálu anebo zpracována za účelem specifikace a extrakce konkrétních informací pomocí aditivních metod.

Práce se zaměřuje na metody segmentace a klasifikace a jednoznačné identifikace a popisu zájmových oblastí a prvků v obraze. Úkolem segmentačních metod je nalezení a rozdělení vlastního obrazu na segmenty, oblasti se společnými vlastnostmi. Metody klasifikace a identifikace vhodným způsobem popisují a jednoznačně identifikují nalezené segmenty obrazu. Skupina těchto metod a přístupu ke zpracování obrazu redukuje redundantní a nadbytečná data obrazu a poskytuje řídicím a měřicím systémům jednoznačné informace o zájmových prvcích a oblastech obrazového signálu.

Paralelismus zpracování dat v rámci distribuovaného systému

Sekvenční povaha zpracování dat neumožňuje plně využít metody paralelního zpracování dat na více-jádrových procesorech. Konvenční přístup metod zpracování obrazu vyžaduje, aby byly jednotlivé kroky zpracování obrazu prováděny postupně. Není například možné provádět korelace obrazových dat v okamžiku, kdy ještě nebyla předzpracována a připravena metodami pre-procesingu. Paralelní zpracování dat na více-jádrových procesorech je tak značně limitováno. Tento paralelismus zpracování dat může být s výhodou využit v rámci implementace jednotlivých metod zpracování obrazu, kdy lze paralelizovat jednotlivé operace prováděné v rámci této metody. Jednotlivé metody zpracování obrazu však až na speciální případy paralelizovat nelze. To limituje zpracování obrazu z pohledu rychlosti a efektivity zpracování dat.

V rámci vyvíjeného systému je paralelismus zpracování obrazových dat řešen v rámci mobilních autonomních rozpoznávacích jednotek. Tyto jednotky zpracovávají obrazový signál takovým způsobem, že každá z jednotek zpracovává obrazový signál z příslušné kamery samostatně pomocí metod zpracování obrazu mající sekvenční povahu zpracování, přičemž navzájem sdílejí jednotlivé mezivýsledky rozpoznávacích metod a rozpoznaná data.

Tento přístup umožňuje paralelizovat zpracování obrazových dat z více kamerových zdrojů. Jedná se o formu paralelního zpracování dat v rámci distribuovaného výpočetního systému.

2. Metody průmyslového zpracování obrazu

Vývoj metod zpracování obrazového signálu je velmi široká oblast vědního zkoumání zaměřená na analýzu, práci a operace s obrazovým signálem, za účelem jeho změny do požadované podoby či extrakce zájmových oblastí anebo informací v něm obsažených.

Tato práce se soustředí na vývoj metod inferenčního a rozhodovacího mechanismu vyvíjeného systému, specifikovaného v úvodních kapitolách této práce. Jeho úkolem je poskytovat především informace o zájmových oblastech v obrazovém signálu v rámci předdefinovaných funkčních parametrů.

Tuto část vědní disciplíny vývoje metod zpracování obrazu nazýváme segmentací obrazu. Segmentace obrazu je skupina metod, založených na různých principech digitálního zpracování obrazu a slouží k rozdělení vlastního obrazového signálu na oblasti se společnými vlastnostmi.

Společnými vlastnosti rozumíme například barevnost, tvar či velikost objektů v obrazovém signálu, dále pak například popředí anebo pozadí obrazu.

K jednoznačnému popisu těchto segmentů se společnými vlastnostmi nám slouží metody identifikace segmentů v obraze. Tyto metody popisují daný segment obrazu pomocí statistických, parametrických, vektorových či jiných matematických vyjádření.

2.1. Metody segmentace obrazu

Segmentační metody slouží k rozdělení vlastního obrazu na segmenty, oblasti se společnými vlastnostmi. Společnou vlastností segmentů, respektive objektů obrazu je například barevná či jasová podobnost, tvarová nebo velikostní podobnost, či jakýkoliv jiný charakteristický prvek daného objektu.

V literatuře jsou popsány desítky segmentačních algoritmů, ale neexistuje univerzální metoda, která by mohla být úspěšná pro všechny aplikace a typy obrazu. [33] Je možné říci, že algoritmus či metoda vyvinutá pro jednu třídu obrazu nelze použít pro třídy ostatní.

K detekci těchto společných vlastností objektů a jejich segmentaci je k dispozici rozsáhlá skupina segmentačních metod. Tyto metody lze rozdělit do několika základních skupin tak, jak ukazuje Obr.2. [32].



Obr.2. Přehled segmentačních metod

V oblasti průmyslového zpracování obrazu se nejvíce uplatňují právě metody segmentace založená na prahování a metody segmentace vycházející z detekce hran (edge-base). Výstupem těchto metod je zpravidla nejjednodušší forma segmentu – binární obraz. Binární obraz je vhodný zejména proto, že jej lze snadno měřit a klasifikovat, a to z důvodu jeho jednoznačnosti, což je jeden ze základních předpokladů při nasazení aplikací zpracování obrazu v průmyslovém prostředí.

V následujících kapitolách budou popsány nejvíce používané metody segmentace obrazu v oblasti průmyslového zpracování obrazové informace.

2.1.1. Segmentace prahováním

Prahování, neboli binarizace je jedna z nejstarších technik segmentace obrazu. Cílem prahování obrazu je rozdělení vlastního obrazu na dvě třídy - oblasti se společnými vlastnostmi. Toto rozdělení provádíme na základě prahu binarizace. Snahou je nalezení funkce, pro kterou bude platit, že všechny hodnoty nižší než práh binarizace jsou pozadím obrazu (log. 0), a všechny hodnoty vyšší než práh binarizace jsou hledanými, segmentovanými objekty obrazu (log. 1). Tento proces může být jednoduše vyjádřen pomocí rovnice (3).

$$f(p) = \begin{cases} 0 & p \geq h \\ 1 & p < h \end{cases} \quad (1)$$

V barevném modelu RGB pak pro příklad platí pro segmentační funkci prahováním následující vztah (2).

$$f(p_{(x,y)}) = \begin{cases} 0 & P_{(R,G,B)} \geq h \\ 1 & P_{(R,G,B)} < h \end{cases} \quad (2)$$

Kde: p je pixel
 h je práh binarizace

Samotný princip binarizace je snadný a velmi efektivní. Problémem metody binarizace je nalezení optimálního prahu binarizace. Existuje řada metod, která se snaží najít ideální prah na základě analýzy obrazu, jeho histogramu, případně s přihlédnutím k jiným vlastnostem. Zde patří například integrální prahovací funkce či metoda hledání optimálního prahu založená na vyhledání dvou tříd rozptylů hodnot histogramu, zvaná Otsu. Často nelze nalézt ideální prah binarizace pro celý obraz. Zde se pak ve velké míře používají lokální fikce adaptivního prahování či lokální prahovací funkce, které využívají různé hodnoty prahu pro různé regiony obrazu.

2.1.2. Segmentace prostřednictvím hranové detekce

Segmentace založená na detekci hran, představuje velkou rodinu segmentačních algoritmů. Základním stavebním kamenem těchto algoritmů jsou informace o hranách v obraze. Obecně lze říci, že se sestávají ze dvou různých fází. V první fázi se jedná o nalezení hran, a ve druhé fázi se na základě těchto hran vyhledávají hranice vzniklých segmentů. Metod pro detekci hran v obraze je celá řada. Vzájemně se odlišují v přístupu a definici hrany v obraze. Tato rozdílnost přístupu a definice přináší rozdílné výsledky a tím interpretaci jednotlivých segmentů. [35] Každý přístup vytváří nový obraz, jakousi mapu hran, na základě které se vytvoří konečné segmenty obrazu.

Metody detekce hran

Hrany v obraze jsou nejčastěji reprezentovány náhlou změnou jasu anebo barev v obrazovém signále. Metody detekce těchto nespojitostí, hran spočívají v nalezení lokálních maxim v případě první derivace signálu nebo v nalezení průchodu nulou v případě druhé derivace signálu. V počítačovém zpracování obrazu se využívá konvoluce obrazu s maskou, která aproximuje první nebo druhou derivaci. Mezi nejznámější případy konvoluce s maskou patří Robertsův operátor, Sobelův operátor anebo operátor Prewitt. [34]

Operátor Roberts

Nejstarší a velmi jednoduchý je Robertsův operátor, který používá jen okolí 2 x 2 aktuálního pixelu. Jeho konvoluční masky jsou definovány vztahy

$$G_x = \begin{bmatrix} -1 & 0 \\ 0 & 1 \end{bmatrix} \quad G_y = \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix} \quad (3)$$

Nevýhodou Robertsova operátoru je velká citlivost na šum, neboť okolí použité pro aproximaci je malé.

Výpočet gradientu pixelu (4):

$$b'(x, y) = |b(x, y) - b(x+1, y+1)| + |b(x+1, y) - b(x, y+1)| \quad (4)$$

Operátor Sobel

Sobelova detekce hran zvýrazňuje všechny hrany obsažené v obraze bez ohledu na směr. Algoritmus je aplikován jako vektorový součet dvou směrových hranových operátorů. Výsledný obraz je z původního transformován tak, že místa s konstantní hodnotou jasu jsou transformována do černých ploch, naopak místa s měnícím se jasnem jsou transformována do bílých míst.

Vertikální a horizontální směrová maska (5):

$$G_x = \begin{bmatrix} -1 & 0 & +1 \\ -2 & 0 & +2 \\ -1 & 0 & +1 \end{bmatrix} * A \quad G_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ +1 & +2 & +1 \end{bmatrix} * A \quad (5)$$

A je vstupní matice obrazu

$$G = \sqrt{G_x^2 + G_y^2} \quad (6)$$

Operátor Prewitt

Operátor Prewitt aproximuje první derivaci. Gradient je odhadován v okolí 3x3 pro osm směrů. Vybrána je ta maska s osmi, které odpovídá největší modul gradientu. Můžeme přirozeně vytvářet i větší masky s podrobnějším směrovým rozlišením. 8 základních masek má následující tvar

Výpočet gradientu pixelu (7):

$$G_x = \begin{bmatrix} -1 & 0 & +1 \\ -1 & 0 & +1 \\ -1 & 0 & +1 \end{bmatrix} * A \quad G_y = \begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ +1 & +1 & +1 \end{bmatrix} * A \quad (7)$$

A je vstupní matice obrazu, je dána vztahem

$$G = \sqrt{G_x^2 + G_y^2} = |G_x + G_y| \quad (8)$$

Cannyho hranový detektor

Canny přistoupil k návrhu hranového detektoru jako k optimalizační úloze, nejprve definoval základní požadavky na optimální hranový detektor a teprve potom tuto optimalizační úlohu začal řešit.

Canny definoval požadavky na optimální hranový detektor takto [35][36]:

1. Minimální počet chyb (musí být detekovány všechny hrany, nesmí být detekována místa, která hranami nejsou)
2. Přesnost (poloha hrany musí být určena co nejpřesněji)
3. Jednoznačnost (odezva na jednu hranu musí být jedna, nesmí docházet ke zdvojení)

Cannyho hranový detektor je založen na konvoluci Gausiánu s obrazovým signálem a následné derivace ve směru signálu. Výstup detektoru je poté prahován za účelem určení významných hran. Za účelem zachování spojitostí hran je využito prahování s hysterezí. Cannyho hranový detektor využívá průchodu druhé derivace nulou. Vykazuje velmi dobré výsledky v rámci citlivosti na šum i při hodnotách prahu nastavených na hodnotu nula. Naopak metody využívající pro detekci hran pouze první derivaci obrazové funkce, některé hrany nenaleznou vůbec. Při prahování nastaveném na hodnotu nula se projeví jejich velká citlivost na šum. [35]

Základní kroky řešení Cannyho hranového detektoru tak spočívají ve čtyřech základních krocích, kterými jsou: [36]

1. Eliminace šumu (Gaussovým filtrem)

Vztah pro výpočet dvourozměrné varianty Gausiánova filtru je následující (9):

$$G_{(x,y)} = \frac{1}{2\pi\sigma^2} \cdot e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (9)$$

Kde x, y souřadnice pixelu v obraze
 σ standardní odchylka rozdělení (běžně 1 až 1.4)

Výpočet se obvykle realizuje pomocí konvoluce, kdy je vypočtena pouze konvoluční maska, která se poté aplikuje na celý obraz.

2. Určení gradientu (první derivace)

Pro určení gradientu se využije některý ze standardně používaných operátorů, tedy Sobel, Roberts anebo například Prewitt. Jako nejvhodnější se ovšem v mnoha případech ukazuje použití práce Sobelova operátoru, který není příliš citlivý na šum a vrací nejen velikost gradientu, ale také jeho směr což je potřeba pro další kroky výpočtu.

3. Nalezení lokálních maxim (thinning)

Cílem tohoto kroku je nalezení lokálních maxim z matice nalezených gradientů, respektive odebrat body, jenž nejsou lokálními maximy. Tímto zajistíme, že hrana bude detekována jen v místě s nejvyšším gradientem.

Implementace tohoto kroku je řešena tím způsobem, že se prohledává okolí gradientu a zjišťuje se, zda-li jsou okolní hodnoty gradientu nižší než gradient středu. Aby byl gradient uznán jako hrana, musí být hodnoty okolních gradientů nižší než hodnota gradientu středu v daném směru gradientu.

Toto lze obecně vyjádřit vztahem (10)

$$E_1 < E \quad \& \quad E < E_2 \quad (10)$$

4. Eliminace nevýznamných hran (thresholding)

V tomto okamžiku máme označeny veškeré hrany v obraze, a to i ty nevýznamné nebo hrany způsobené šumem v obraze. Aplikací prahu s hysterezí nalezneme pouze ty hrany, které jsou podstatné.

Zvolíme tedy minimální (T1) a maximální (T2) hodnotu (prahu), mezi kterými může gradient kolísat. Pokud hodnota gradientu daného pixelu leží nad větším prahem T2, je přímo označen jako hranový. Pokud posuzujeme bod, jehož hodnota leží mezi T1 a T2, pak je „uznán“ jedině pokud sousedí s bodem, který už byl jako hrana označen dříve.

Implementačně je tento postup řešen pomocí rekurzivní funkce.

2.1.3. Metody založené na hledání regionu

Metody založené na principu hledání regionu se snaží o rozčlenění obrazu do maximálních souvislých homogenních oblastí na základě zvoleného parametru. Tímto parametrem můžou být například jasové vlastnosti, textura, barva, model obrazu a další. Tyto metody mnohdy neposkytují stejné výsledky jako metody založené na detekci hran či prahováním, protože jsou řešeny jako kombinace různých metod.

Metody založené na hledání regionu jsou vhodné pro obrazy zatížené šumem a obrazy, kde se obtížně vyhledávají hrany. Nejčastěji kombinují metody spojování a štěpení oblastí, watershed a shlukové analýzy (Mean-shift, K-means). [32]

Segmentační metoda Mean-shift shlukuje body obrazu na základě podobnosti jejich vzhledu a blízkosti jejich pozic pomocí konvergence do lokálních maxim spojeného souřadnicového a intenzitního prostoru.

Algoritmus segmentační metody Mean-shift lze popsat následovně:


Vstup: množina vzorků (bodů v N-rozměrném prostoru)

1. Definice tvaru a okna

2. Pro všechny vzorky vypočti:

- Lokální maximum hustoty vzorků uvnitř okna kolem aktuálního vzorku (mean pozice)
- Posuň (shift) pozici vzorku do maxima
- Opakuj, dokud se mění pozice maxima
- Zapamatuj si poslední pozici

3. Shlukujeme ty vzorky, které dokonvergovaly do stejného maxima (s určitou tolerancí). Oblasti, ze které vzorky konvergují do stejné oblasti, říkáme *basin of attraction*.




Obr. 3. Princip segmentační metody Mean-shift [39][40]

Segmentační algoritmus K-means iterativně hledá hodnoty vektorů μ_j (středů shluků) tak, že minimalizuje střední odchylku mezi zadanou množinou dat a vektory, které mají k těmto datům nejmenší euklidovskou vzdálenost a rozděluje je do předem daného počtu shluků (tříd) K: C_1, C_2, \dots, C_K

Tento algoritmus pracuje tak, že přiřadí každý bod do shluku, jemuž středu je nejbližší. Středů shluků se při každém běhu algoritmu znovu spočítají jako aritmetické průměry všech bodů shluku. Cílem je dosáhnout co nejmenších rozdílů uvnitř shluků. (11)

$$V = \sum_{i=1}^k \sum_{x_j \in S_i} (x_j - \mu_i)^2 \quad (11)$$

Kde je k shluků S_i , i je od 1 po k a μ_i je střed shluku, nebo průměr bodů $x_j \in S_i$. [39]



Obr.4. Příklad aplikace K-means segmentační metody [40]

2.1.4. Barevná segmentace

V literatuře je popsáno mnoho algoritmů založených na principu barevné segmentace.[22] Principem těchto algoritmů a metod je citlivost na barevnou informaci v obraze. Segmentem se v tomto případě rozumí oblast s definovanou barevnou charakteristikou. V rámci metod segmentace na základě barvy mohou být použity běžně používané segmentační metody, například segmentační metody založené na principu hledání hran, kdy jsou hrany detekovány jako změny barevného tónu v obraze, nikoliv jako změny jasu obrazu. Pomocí barevné segmentace lze snadno oddělit regiony se stejnou jasovou hodnotou avšak jiným barevným tónem. Barevné segmentační metody pracují s barevnými modely RGB anebo YUV.

Model RGB využívá principu aditivního míchání barev. Každá barva je udána mohutností tří základních barev – komponent (červené - **Red**, zelené – **Green** a modré – **Blue**). Model tak nedefinuje absolutní hodnotu jasu. Mohutnost každé barvy je vyjádřena v rozsahu 0 až 1, kde smíchání mohutností všech barev s hodnotou 0 představuje zcela černou barvu a smíchání barev z mohutností 1 představuje absolutně bílou barvu.

Model YUV Je založen na myšlence, že je lidské oko citlivější ke změnám jasu než barev. K popisu barvy používá tříprvkový vektor $[Y,U,V]$, kde Y je jasová složka a U a V jsou barevné složky. Barevné složky se pohybují v rozsahu od -0.5 do +0.5, jasová složka má rozsah od 0 do 1. Model se nejčastěji používá v televizním vysílání v normě PAL.

2.1.4. Algoritmus Záplava, Watershed

Algoritmus Záplava, neboli Watershed je segmentační metoda na bázi matematické morfologie. Hlavní myšlenka spočívá v přístupu k obrazu, kdy je na obraz nahlíženo jako na reliéf krajiny, který je postupně zaplavován vodou. Princip algoritmu je tak velmi jednoduchý. Voda pramenící v nížinách, postupně zaplňuje místa v obraze, s nízkou hodnotou. Tím jak voda neustále přibývá, zaplavuje stále větší a větší oblasti. V místech, kde hrozí, že se vodní záplavové oblasti spojí, jsou vytvořeny pomyslné hráze, které umožní ponechat jednotlivé zaplavované segmenty odděleny. [38]

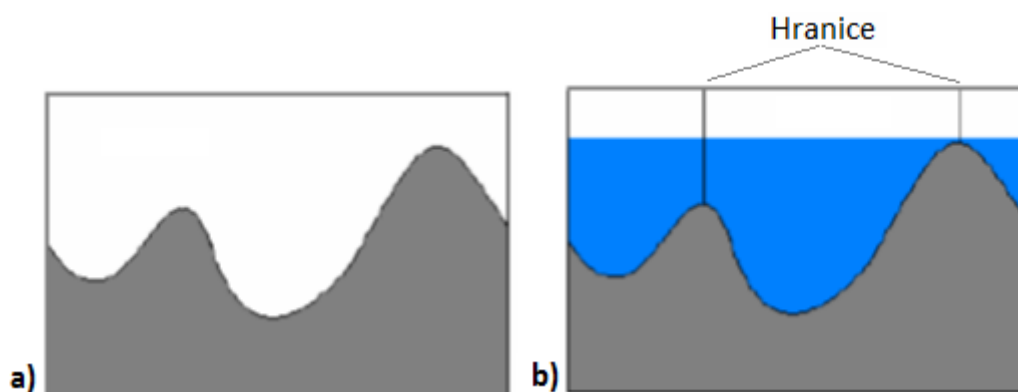
Tato segmentační metoda tedy vychází z geografie, kde je obraz chápán jako terén anebo geografický reliéf, kde nejčastěji jas obrazu, určuje výšku terénu. (černá nejnižší body, bílá nejvyšší). Výpočet algoritmu začíná nejnižším bodem a končí v okamžiku, kdy jsou zaplaveny všechny body obrazu. Každý segment je označen stejným unikátním indexem.

Pro obrazy, které jsou zatíženy šumem a vytvářejí tam příliš mnoho oblastí existují modifikované varianty, které vstupní obraz upravují například pomocí filtrace, hráze jsou povolovány až od určité výšky, nebo se následně příliš malé regiony přiřadí větším sousedním regionům. [32]

Postup implementace algoritmu je následující:

1. nalezení nejnižšího bodu – lokálního minima
2. postupné zaplavování oblastí, v místech kde by došlo ke spojení segmentů jsou vytvářeny hráze
3. Výpočet algoritmu je ukončen v okamžiku zaplavení všech bodů obrazu.

Princip algoritmu je zobrazen na obrázku č.5.



Obr.5. Segmentace pomocí algoritmu Záplava (funkce obrazu – vlevo, výsledná segmentace - vpravo) [32]

2.2. Jednoznačná identifikace segmentů v obraze

Jednoznačná identifikace segmentů v obraze je jedním ze základních předpokladů průmyslového nasazení aplikací počítačového vidění a zpracování obrazu v průmyslové praxi. Nejjednodušší formou segmentu je právě binární podoba tohoto segmentu. Binární obraz segmentu je jednoznačně definován a určen jeho parametry a lze jej snadno klasifikovat. Každý reálný obraz obsahuje zpravidla více než jeden segment. Jsou-li segmenty definovány jako binární obrazy vzniklé segmentací založenou na prahovací funkci či podobné, je potřeba jednotlivé segmenty označit a jednoznačně určit. Označení jednotlivých binárních obrazových segmentů se zabývají metody indexace oblastí.

2.2.1. Indexace oblastí „barvením“

Metoda detekce spojitostí v obraze analyzuje binární obraz a vyhledává v něm spojitě části plochy. Každé spojitě oblasti v obraze je přiřazeno pořadové číslo, vypočte se velikost její plochy a určí souřadnice, na kterých se v obraze nachází. [19]

Spojité oblasti je v binárním obraze reprezentována množinou hodnot o logické úrovni 1 (true), které k sobě přiléhají a to plochou (modul připojení 4), nebo plochou a bodovým dotykem (modul připojení 8). [19]



Obr.6. Modul připojení 4 (vlevo), modul připojení 8 (vpravo)

Výsledkem je matice o stejné velikosti jako původní matice vstupního binárního obrazu. Pixely označené hodnotou 0 (false) reprezentují „pozadí“ obrazu. Pixely označeny hodnotou 2 a vyšší tvoří spojitou plochu (objekt). Ukázka vstupní a výstupní matice je zobrazena na Obr. 7. [6]

1	0	0	0	1	1	1	1	1
1	1	0	0	0	0	0	1	1
1	1	0	0	0	0	0	0	0
1	1	0	1	1	1	0	0	0
1	1	0	1	0	1	0	0	0
1	1	0	1	0	1	0	1	1
1	0	0	1	0	1	0	1	1

2	0	0	0	4	4	4	4	4
2	2	0	0	0	0	0	4	4
2	2	0	0	0	0	0	0	0
2	2	0	3	3	3	0	0	0
2	2	0	3	0	3	0	0	0
2	2	0	3	0	3	0	5	5
2	0	0	3	0	3	0	5	5

Obr. 7. Ukázka vstupní matice (vlevo) a výstupní matice (vpravo)

Pořadová čísla jsou jednotlivým spojitým plochám přiřazována od číslice 2 právě proto, aby bylo možno odlišit již nalezené spojitosti od původního binárního obrazu. [15]

Metoda nalezení spojitosti pomocí referenčních tabulek

Algoritmus metody pro vyhledávání spojitostí (Blob) je založen na principu „Two-pass“ kde se přiřazení pořadových značek objektům provádí ve dvou cyklech průchodu matice obrazu. V prvním cyklu se k obrazovým bodům přiřadí dočasná příslušnost k dané třídě objektů a v následujícím cyklu se tyto dočasné příslušnosti nahradí konečnými značkami, reprezentující daný objekt.

Funkční princip tohoto algoritmu lze vyjádřit následovně. V prvním cyklu tohoto algoritmu jsou postupně procházeny všechny řádky binární obrazové matice. Přičemž každému pixelu v řádku s logickou hodnotou (true) je přiřazeno dočasné referenční označení. Toto dočasné referenční označení je stejné pro všechny sousedící pixely obrazu o logické hodnotě 1 (true).

V rámci zefektivnění algoritmu se při tomto průchodu řádků a přidělování dočasných označení přihlíží i k pixelům v řádku předcházejícím, přičemž v případě, že označovaný pixel přiléhá k pixelu s již přiřazeným dočasným identifikačním označením, je toto dočasné označení tímto pixelem přejmuto. Logická funkce prvního průchodu cyklu zobrazuje Obr. 8.

1	1	1	0	0	1	1	0	1
0	1	0	0	1	1	0	0	1
0	0	1	1	1	0	0	0	1
0	0	0	0	0	0	0	1	1
1	1	1	0	0	0	0	0	0
1	1	1	0	1	0	1	1	1
0	0	1	0	1	1	1	0	0
1	1	1	0	0	1	0	0	1
0	0	0	0	0	0	0	1	0

->

2	2	2	0	3	0	4	0	5
0	1	0	0	1	1	0	0	1
0	0	1	1	1	0	0	0	1
0	0	0	0	0	0	0	1	1
1	1	1	0	0	0	0	0	0
1	1	1	0	1	0	1	1	1
0	0	1	0	1	1	1	0	0
1	1	1	0	0	1	0	0	1
0	0	0	0	0	0	0	1	0

->

2	2	2	0	3	0	4	0	5
0	2	0	0	3	3	0	0	5
0	0	2	2	2	0	0	0	5
0	0	0	0	0	0	0	5	5
6	6	6	0	0	0	0	0	0
6	6	6	0	7	0	8	8	8
0	0	6	0	7	7	7	0	0
9	9	9	0	0	7	0	0	10
0	0	0	0	0	0	0	10	0

Obr. 8. Logická funkce prvního cyklu „Two-pass“ algoritmu vyhledávání spojitostí

Současně je při prvním cyklu „Two-pass“ algoritmu vyhledávání spojitostí utvářena tzv. referenční tabulka. Referenční tabulka obsahuje reference na hodnoty dočasného označení pixelů, jež společně sousedí. Příklad takovéto referenční tabulky pro výše uvedený příklad je zobrazen na Obr. 9. Každý řádek referenční tabulky obsahuje dočasné značky, které k sobě náležejí.

2	3	4
5	x	x
6	9	x
7	8	x
10	x	x

Obr. 9. Referenční tabulka

Druhý cyklus „Two-pass“ provede přetypování dočasného referenčního označení takovým způsobem, že veškeré nalezené dílčí spojitosti sjednotí stejným konečným pořadovým číslem

označující dané objekty. Toto spojení dílčích nalezených spojitostí v prvním cyklu průchodu binární obrazové matice je provedeno na základě vytvořené referenční tabulky.

Současně jsou v druhém cyklu „Two-pass“ algoritmu vyhledání spojitostí nalezeny parametry objektů. Jedním z těchto parametrů je plocha objektů, která je dána skutečným počtem pixelů, z nichž je daný spojitý objekt složen. Dalším důležitým parametrem je poloha objektů v obrazové matici. Poloha může být určena souřadnicemi středu, výškou a šířkou objektu anebo souřadnicemi krajních poloh pixelů jak v ose „x“ tak „y“.

Tyto dva zápisy jsou navzájem ekvivalentní, to znamená, že lze jednotlivé formy převádět navzájem.

2	2	2	0	0	2	2	0	5
0	2	0	0	2	2	0	0	5
0	0	2	2	2	0	0	0	5
0	0	0	0	0	0	0	5	5
6	6	6	0	0	0	0	0	0
6	6	6	0	7	0	7	7	7
0	0	6	0	7	7	7	0	0
6	6	6	0	0	7	0	0	1 0
0	0	0	0	0	0	0	1 0	0


Obr. 10. Výsledek druhého průchodu cyklu „Two-pass“ algoritmu vyhledávání spojitostí

Existuje celá řada modifikací, využívající tento princip. Tyto modifikace optimalizují práci s referenčními tabulkami a upravují algoritmus pro funkci s modulem připojení 4 anebo 8. Žádný z dostupných algoritmů či modifikací ovšem neodstraňuje potřebu dvojitého procházení obrazové matice bodů a tvorbu referenčních tabulek.

Algoritmus pracuje s původní binární obrazovou maticí, čímž dochází k úspoře operační paměti tím, že není vytvářena druhá „pracovní kopie“ obrazové matice.

2.2.2. Semínkové vyplňování

Metoda semínkového vyplňování oblastí je založena na myšlence semínka, od kterého se postupně označují jednotlivé body segmentu. Uvnitř segmentu, jenž je reprezentován stejným indexem, jako ostatní segmenty obrazu je umístěno semínko, nesoucí unikátní index. Tímto indexem jsou poté postupně označovány všechny okolní body segmentu. Označená oblast se tak postupně zvětšuje až do okamžiku, kdy jsou označeny všechny body oblasti. Semínko může být umístěno do libovolného bodu segmentu, respektive spojitosti.[41] Semínkové vyplňování může být použito pro modul připojení 4 a 8. Princip metody semínkového vyplňování je zobrazen na Obr.11. [32]



Obr. 11. Princip semínkového vyplňování

Metoda semínkového vyplňování může být implementována pomocí rekurzivní funkce nebo pomocí vlastního zásobníku. Nevýhodou metody semínkového vyplňování je to, že některé pixely mohou být mnohokrát testovány. Toto snižuje efektivitu a rychlost algoritmu. Výhodou řešení však je, že je metoda účinná pro libovolně velké a tvarově složité objekty.

2.2.2.1. Rekurzivní metoda

Principem rekurze je opakované vnořené volání stejné funkce (podprogramu) sama sebou. Rekurzivní volání představuje nebezpečí v tom, že nelze dobře kontrolovat, kolikrát rekurze nastane, respektive kolikrát bude funkce vnořena sama do sebe. Rekurzivní volání potřebuje zajistit uchování kontextu funkce, která volání inicializovala. V případě mnohonásobného vnoření stejné funkce do sebe vznikají velké požadavky a režie na uchování kontextu funkce. Zde lze hovořit o nepřímém zásobníku. Tento nepřímý zásobník je tvořen na úrovni volání programu, a je prakticky nemožné jej efektivně řídit. Chyba v rekurzivní funkci, například nesplnění podmínky pro ukončení rekurze může způsobit zahlcení programové paměti a tím selhání programu.

Ukázka implementace metody semínkového vyplňování pomocí rekurzivní funkce je zobrazen na Obr.12.

```

void Seminko (int x,int y,int index)
{
    if (bod[x,y] == 1)
    {
        bod[x,y]=index;
        Seminko (x+1,y,index);
        Seminko (x-1,y,index);
        Seminko (x,y+1,index);
        Seminko (x,y-1,index);
    }
}

```

Obr.12. Příklad implementace semínkového vyplňování pomocí rekurzivní funkce

Rekurzivní volání je však prakticky nepoužitelné, protože každý pixel může být testován několikrát, navíc dochází k mnohonásobnému zanoření rekurze, jenž nelze efektivně řídit. Rekurzivní volání lze implementovat jako volání cyklu s vlastním zásobníkem. [32][41]

2.2.2.2. Implementace pomocí vlastního zásobníku

Rekurzivní volání může být převedeno na iterační volání cyklu s vlastním zásobníkem a to částečně automaticky, neboť mezi nimi existují korelační vztahy. Použití cyklu a zásobníku jsme schopni vytvořit zjednodušenou variantu přímé rekurze s více než jedním rekurzivním voláním. Při rekurzi je opakovaně volána funkce tak dlouho, dokud není ukončena podmínka rekurzivního volání. V každém kroku cyklu se vytváří nová varianta lokálních proměnných. Zásobník reprezentuje model FIFO, kdy je poslední prvek zásobníku odebírán jako první. Jinými slovy do zásobníku přidáváme proměnné, které jsou odebírány v opačném pořadí. Rekurzivní funkce je tak nad objektem v jednom kroku volána m krát s hloubkou rekurze n . [42]

Popišme nyní základní postup převodu rekurzivního volání na model s použitím zásobníku[41]:


Mějme objekt „ O “, který obsahuje lokální proměnné, parametry a informaci o hloubce rekurze, objekt „ o “ vznikne zpracováním objektu „ O “ v rekurzivním kroku s hloubkou iterace i . Postup převodu do cyklu je tedy následující:

1. Inicializujeme prázdný zásobník S , $i = 1$
2. Přidáme do zásobníku S objekt „ O “
3. Pokud $i < n$, opakuj nad objektem „ O “ m -krát proceduru:
 - a. Vytvoření z „ O “ nový objekt „ o “ stejné třídy, $o = Z(O)$
 - b. Inkrementuj hloubku rekurze i pro objekt o : $i = i + 1$
 - c. Přidej objekt „ o “ do zásobníku S

V průběhu vykonávání cyklu vznikne m nových objektů, představujících m volání rekurzivní procedury. [32]

2.2.2.3. Řádková varianta semínkového vyplňování

Řádková varianta semínkového vyplňování snižuje počet přístupů do programové paměti. Princip algoritmu spočívá ve vyplňování souvislých vodorovných úseků a prohledávání intervalů nad a pod těmito úseky. Každá vodorovná řada vnitřních bodů nad, respektive pod daným úsekem tvoří nový úsek, který je zpracováván. Algoritmus je iniciován vložením semínka do oblasti segmentu obrazu.



Obr. 13. Řádková varianta semínkového vyplňování

2.2.3. Maticový optimalizovaný návrh semínkového vyplňování

Maticový optimalizovaný návrh semínkového vyplňování je optimalizovanou variantou klasické metody semínkového vyplňování. Tento maticový optimalizovaný návrh je původním návrhem.

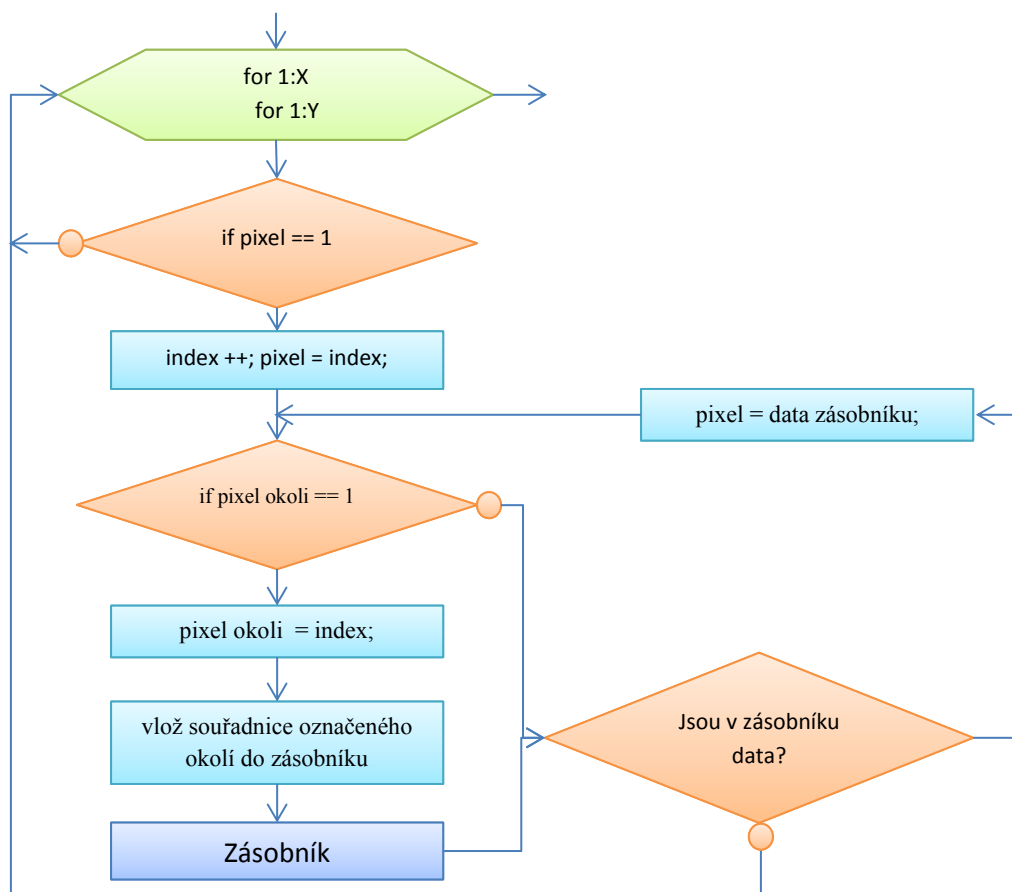
Obrazová matice je v tomto řešení procházena pouze jednou (One-pass) a jsou kontrolovány hodnoty jednotlivých pixelů v binární obrazové matici. Pokud je hodnota pixelu rovna logické hodnotě 0 (false), nevykouvává se žádná akce a cyklus průchodu binární obrazové matice běží dále. V případě kdy je hodnota pixelu v logické hodnotě 1 (true) dojde k umístění semínka do označovaného segmentu, současně dojde k inkrementaci indexu o jedničku (první spojitost je označena hodnotou „index“ = 2). Dále je tomuto pixelu přiřazena hodnota indexu a do zásobníku jsou uloženy pozice všech okolních bodů tohoto pixelu, které jsou ovšem předtím také označeny tímto indexem. Pokud je modul připojení spojitosti 4, jsou uloženy do zásobníku souřadnice čtyř okolních bodů, pokud je modul připojení pixelů spojitosti roven 8mi, jsou do zásobníku uloženy pozice všech osmi indexovaných okolních bodů. Následně je kontrolováno, zda zásobník obsahuje data, pokud ne, je řízení navráceno hlavnímu cyklu, který prochází binární obrazovou matici. Pokud zásobník obsahuje data, je z tohoto zásobníku vyjmut jeden z pixelů a jsou kontrolovány jeho okolní body. Pokud je logická hodnota rovna 0 (false) anebo jinému indexu, je proveden skok do místa algoritmu, ve kterém dochází k testování obsahu dat v zásobníku. V případě, že je logická hodnota pixelu rovna 1 (true), poté je proveden skok do místa algoritmu, ve kterém je pixelu přiřazena hodnota indexu, současně jsou tímto indexem označeny i jeho okolní body a souřadnice těchto bodů je vložena do zásobníku. Tato vnitřní smyčka se opakuje tak dlouho, dokud

zásobník obsahuje data. Princip optimalizovaného maticového návrhu semínkového vyplňování je zobrazen na Obr. 14.

Hlavní výhodou této optimalizované varianty oproti původní metodě semínkového vyplňování je, že nikdy nedojde k vložení souřadnic stejného pixelu do zásobníku a tím opakování jeho testování. Toto výrazně redukuje množství dat ukládaných do zásobníku.

Výsledkem tohoto původního nově vyvinutého algoritmu je označení všech spojitých oblastí v celé binární obrazové matici bez ohledu na jejich rozsah či složitost. Principem tohoto řešení je tak pouze jediný průchod celé binární obrazové matice, přičemž v okamžiku, kdy je nalezen pixel neoznačené spojitosti, jsou postupně ukládány a odebírány pozice okolních bodů pixelů náležící této spojitosti do doby, než dojde k označení celé spojitosti.

Tento vyvinutý algoritmus může být snadno rozšířen o výpočet obsahu plochy každé spojitosti nebo její pozice. Podstatnou výhodou tohoto řešení je snížení počtu cyklů průchodu původní binární obrazové matice. Algoritmus zároveň pracuje s původní binární obrazovou maticí, čímž dochází k úspoře operační paměti tím, že není vytvářena druhá „pracovní kopie“ obrazové matice.



Obr. 14. Princip optimalizovaného návrhu původního funkčního algoritmu pro vyhledávání spojitostí

Příklad implementace popsaného algoritmu pomocí vlastního zásobníku v programu Matlab je následující:

```
function [images]=fce_Blob(images)

[Y,X]=size(images); % výchozí nastavení proměnných
hledej=0;           % pomocná proměnná, udává pozice adres
co = 1;

for x = 1:X        % zajistí se kontrola
    for y = 1:Y    % všech bodů snímku (spojitostí)
        if images(y,x) == 1 % pokud je nalezen neoznačený bod spoj.
            co=co+1;        % urči pořadové číslo spojitosti
            images(y,x) = co;% přiřadí pořadové číslo spojitosti
            vektor(1,1) = x; % souřadnice x bodu do vektoru hledání
            vektor(1,2) = y; % souřadnice y bodu do vektoru hledání
            hledej=1;      % nastav příznak vyhledávání
        end

        while hledej > 0    % zkontroluj příznak hledání, označuj
            % spojitost, dokud nejsou označeny všechny její body
            sx=vektor(hledej,1); % načti z vektoru hledání x souřadnici
            sy=vektor(hledej,2); % načti z vektoru hledání y souřadnici
            hledej=hledej-1;    % dekrementuj příznak vyhledávání
            % prohledej okolí bodu, pokud neleží mimo matici
            if sy+1 <= Y
                if images(sy+1,sx)== 1 % jestliže je okolní bod součástí
                    images(sy+1,sx)=co;% označ jej
                    hledej=hledej+1;    % inkrementuj příznak vyhledávání
                    vektor(hledej,1)=sx; % přidej nalezený bod souř. x
                    vektor(hledej,2)=sy+1;% přidej nalezený bod souř. y
                end
            end
            % prohledej okolí bodu, pokud neleží mimo matici
            if sy-1 > 0
                if images(sy-1,sx)== 1 % jestliže je okolní bod součástí
                    images(sy-1,sx)=co;% označ jej
                    hledej=hledej+1;    % inkrementuj příznak vyhledávání
                    vektor(hledej,1)=sx; % přidej nalezený bod souř. x
                    vektor(hledej,2)=sy-1;% přidej nalezený bod souř. y
                end
            end
            % prohledej okolí bodu, pokud neleží mimo matici
            if sx+1 <= X
                if images(sy,sx+1)== 1 % jestliže je okolní bod součástí
                    images(sy,sx+1)=co;% označ jej
                    hledej=hledej+1;    % inkrementuj příznak vyhledávání
                    vektor(hledej,1)=sx+1;% přidej nalezený bod souř. x
                    vektor(hledej,2)=sy;  % přidej nalezený bod souř. y
                end
            end
            % prohledej okolí bodu, pokud neleží mimo matici
            if sx-1 > 0
                if images(sy,sx-1)== 1 % jestliže je okolní bod součástí
                    images(sy,sx-1)=co;% označ jej
                    hledej=hledej+1;    % inkrementuj příznak vyhledávání
                    vektor(hledej,1)=sx-1; % přidej nalezený bod souř. x
                    vektor(hledej,2)=sy;  % přidej nalezený bod souř. y
                end
            end
        end % konec cyklu hledání (while)
    end
end
```

2.2.4. Parametrický popis

Každý spojitý objekt lze popsat pomocí skupiny základních parametrů. Mezi tyto parametry patří obsah spojitosti, obvod spojitosti, poloha a rozměr objektu v obrazové matici.

Obsah spojitosti je roven sumě všech pixelů, které k dané spojitosti náležejí. Tento vztah lze vyjádřit následující rovnicí (12).

$$S = \sum pix > 0 \quad (12)$$

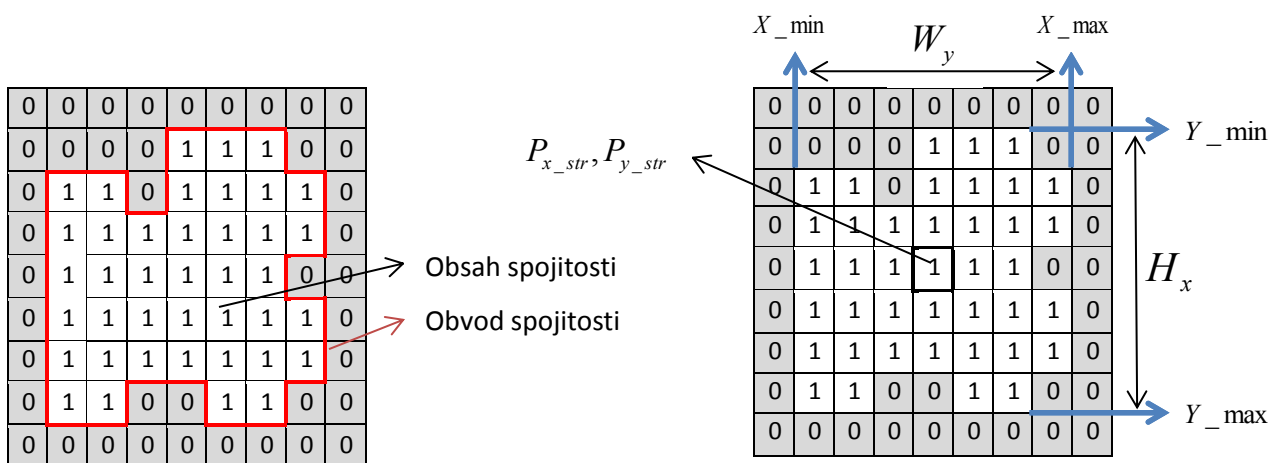
Obvod spojitosti je dán souhrnným počtem všech hran pixelů, které náležejí dané spojitosti a zároveň hraničí s pixely o logické úrovni 0 (false). Obvod lze vyjádřit vztahem (13).

$$Obvod = \sum (hran \rightarrow pix_{obj} \& pix_0) \quad (13)$$

Pozice či poloha objektu v obrazové matici (relativní nebo absolutní) může být určena souřadnicemi středu (P_{x_str}, P_{y_str}), výškou (H_x) a šířkou (W_y) objektu, nebo souřadnicemi krajních poloh pixelů jak v ose „x“ tak „y“. Nejčastěji používaným zápisem je zápis pomocí krajních poloh pixelů. Tyto krajní polohy lze vyjádřit proměnnými $X_min, X_max, Y_min, Y_max$. Tyto dva zápisy jsou navzájem ekvivalentní, to znamená, že jednotlivé formy lze převádět navzájem (14).

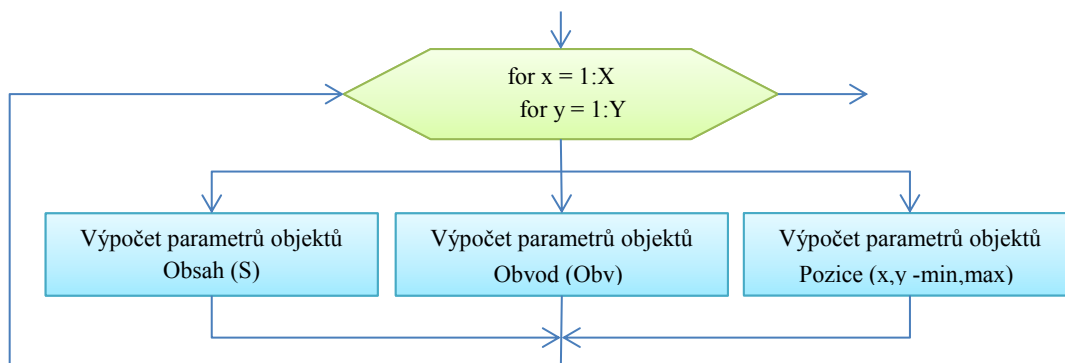
$$\begin{aligned} H_x &= X_max - Y_min & P_{x_str} &= \frac{H_x}{2} + X_min \\ W_y &= Y_max - Y_min & P_{y_str} &= \frac{W_y}{2} + Y_min \end{aligned} \quad (14)$$

Jednotlivé parametry jsou vyznačeny na obrázku číslo 15.




Obr. 15. Obsah (bíle) a obvod (červeně) spojitosti (vlevo), pozice spojitosti (vlevo)

Všechny definované parametry objektů (obsah, obvod a pozice), mohou být vypočteny v jediném cyklu průchodu obrazových bodů, neboť jsou tyto operace navzájem nezávislé. Pro zkrácení výpočetního času mohou být výpočty jednotlivých parametrů prováděny paralelně. Na Obr. 16 je znázorněn vývojový diagram paralelního nezávislého výpočtu parametrů objektů.



Obr. 16. Paralelní výpočet parametrů objektů

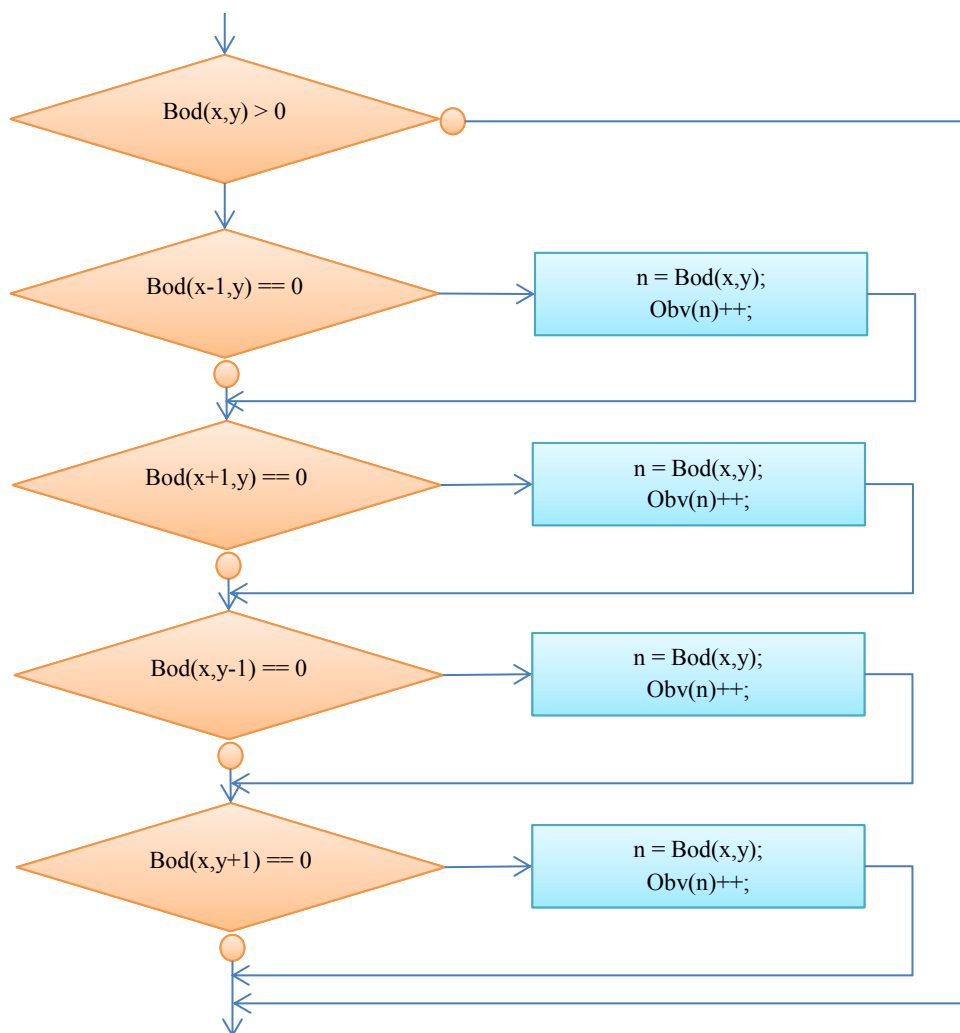
Algoritmické řešení výpočtu obsahu objektu vychází z jeho definice, tedy, že obsah spojitě oblasti je roven sumě všech pixelů, které k dané spojitosti náleží. Obr. 17 ukazuje vývojový diagram implementace bloku pro výpočet obsahu zobrazeném na Obr. 16. Vstupem vývojového diagramu jsou jednotlivé hodnoty obrazových bodů po zpracování funkcí Blob.



Obr. 17. Výpočet obsahu objektů

Algoritmus výpočtu obsahu pracuje tak, že jsou postupně procházeny všechny body „blobovaného“ obrazu. Pokud je při průchodu touto maticí nalezen bod, jehož hodnota je větší než nula, dojde k inkrementaci hodnoty vektoru obsahu o jedničku na pozici, která odpovídá hodnotě tohoto bodu. Výstupem je vektor dat, o délce odpovídající maximální hodnotě bodu nacházejícím se v procházené matici. Tento vektor obsahuje informace o obsahu všech objektů v této matici.

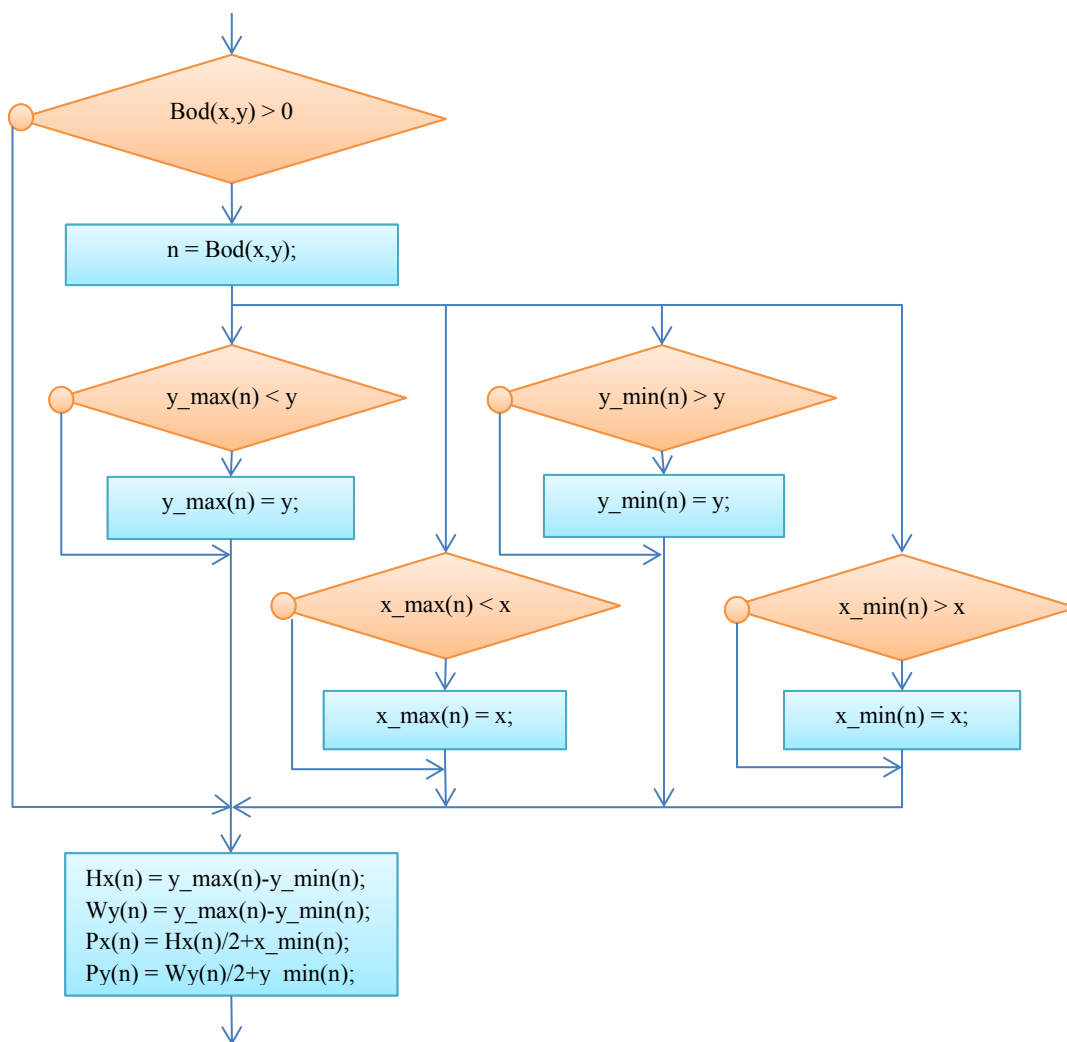
Algoritmické řešení výpočtu obvodu vychází z jeho definice, tedy, že obvod spojitě oblasti je dán souhrnným počtem všech přechodů pixelů, které náleží dané spojitě oblasti s pixely o logické úrovni nula (false). Obr. 18 ukazuje vývojový diagram implementace bloku pro výpočet obvodu objektů. Vstupem vývojového diagramu jsou jednotlivé hodnoty obrazových bodů po zpracování funkcí Blob.



Obr. 18. Výpočet obvodu objektů

Algoritmus výpočtu obvodu pracuje tak, že jsou postupně procházeny všechny body označeného obrazu. Pokud je při průchodu nalezen bod, jehož hodnota je větší než nula, je ověřeno, zda-li nesousedí s bodem o logické hodnotě nula. Pokud ano, dojde k inkrementaci vektoru obvodu o jedničku na pozici odpovídající hodnotě bodu tolikrát, kolik je nalezeno nulových sousedních bodů. Výstupem je vektor dat o délce, odpovídající maximální hodnotě bodu nacházejícím se v procházené matici. Tento vektor obsahuje informace o obvodu všech objektů v této matici.

Algoritmické řešení výpočtu pozice objektu vychází z jeho definice, tedy určení jeho krajních souřadnic s následným dopočtem středu. Obr. 19 ukazuje vývojový diagram implementace části kódu pro výpočet pozice objektů definovaného jeho krajními pozicemi s následným dopočtem středu objektu z těchto souřadnic. Vstupem vývojového diagramu jsou jednotlivé hodnoty obrazových bodů po zpracování funkcí Blob.



Obr. 19. Výpočet pozice objektů

Algoritmus výpočtu pozice pracuje tak, že jsou postupně procházeny všechny body „blobovaného“ obrazu. Pokud je při průchodu nalezen bod, jehož hodnota je větší než nula, pokud ano, je ověřeno, zdali poloha bodu vyhovuje doposud nalezeným hodnotám, tedy leželi v doposud zaznamenaném rozmezí. Pokud tomu tak není, jsou informace těchto hodnot aktualizovány tak, aby vyhovovaly aktuální poloze pixelu a zároveň všem předešlým nalezeným pozicím bodů. Výstupem je vektor dat o délce, odpovídající maximální hodnotě bodu nacházejícím se v procházené matici se čtyřmi řádky, kde jednotlivé řádky udávají minimální a maximální hranici bodů, náležících objektu a to vždy v ose „x“ a „y“ matice. Tento vektor obsahuje informace o poloze všech objektů v této matici.

2.2.5. Houghova transformace

Houghova transformace je metoda pro nalezení parametrického popisu objektů v obraze. Při implementaci je třeba znát analytický popis tvaru hledaného objektu. Proto je tato metoda používána pro detekci jednoduchých objektů v obraze jakou jsou přímky, kružnice, elipsy, atd. Houghova transformace je používána především pro segmentaci objektů, jejichž hranice lze popsat jednoduchými křivkami.[11] Hlavní výhodou této metody je robustnost vůči nepravidelnostem a porušení hledané křivky. Houghova transformace se využívá k nalezení parametrů matematického modelu hledaného objektu za předpokladu známých vstupních dat (obrazové matice). [7]


Nalezení přímek v obraze metodou Houghovy transformace

Metoda nalezení přímek v obrazovém signálu pomocí Houghovy transformace využívá parametrické vyjádření přímky v rovině. Parametrické vyjádření přímky je dáno vztahem (15)

$$r = x \cdot \cos \varphi + y \cdot \sin \varphi \quad (15)$$

kde r je délka normály od přímky k počátku souřadnic, φ je úhel mezi normálou a osou x , viz. Obr. 20. [6]

Houghova transformace je implementována tak, že v prvním kroku je Houghův prostor diskretizován. Každý element tohoto prostoru, který nazýváme akumulční buňka je vynulován. Každý bod (x_i, y_i) je transformován do diskretizované křivky (r, φ) , přičemž hodnota akumulčních buněk podél této křivky je inkrementována. Souřadnice maxima v akumulční rovině $(r_{\max}, \varphi_{\max})$ jsou parametry hledané přímky v obraze. [3]



Obr. 20. Parametrický popis přímky

Nalezení kružnic v obraze metodou Houghovy transformace

Metoda nalezení kružnic v obraze pomocí Houghovy transformace využívá stejný princip, jako metoda nalezení přímek, s tím rozdílem, že rovnice parametrického vyjádření přímky je nahrazena rovnicí parametrického vyjádření kružnice (16). [10]

$$\begin{aligned}x &= a + r \cdot \cos(\varphi) \\ y &= b + r \cdot \sin(\varphi)\end{aligned}\quad (16)$$

kde r je poloměr kružnice, $[a, b]$ je její střed a $\varphi \in (0, 2\pi)$ je proměnný parametr. Parametry a, b a r jsou hledané parametry. V tomto případě výpočetní náročnost algoritmu vzroste, protože dochází k hledání tří parametrů, tudíž i Houghův prostor bude mít dimenzi 3. [5]


Obecná rovnice kružnice je v kartézském souřadnicovém systému (x, y) dána středem $[a, b]$ a poloměrem r , kde množina všech bodů (x, y) vyhovuje rovnici (17). [22]

$$(x - a)^2 + (y - b)^2 = r^2 \quad (17)$$

Pokud se střed kružnice nachází v počátku soustavy souřadnic $(0, 0)$, lze tento vzorec zjednodušit na (18). [6]

$$x^2 + y^2 = r^2 \quad (18)$$


Kružnice se středem v počátku soustavy souřadnic s poloměrem jedna se nazývá jednotková kružnice. [1]



Obr. 21. Parametrický popis kružnice.

2.2.6. Popis skupinou vektorů

Každý obecně definovaný objekt může být popsán skupinou vektorů, které definují jeho hraniční křivky. Na základě této skupiny lze vektor zcela přesně rekonstruovat původní tvar objektu a určit jeho další parametry, jako obvodovou délku, která je dána součtem délek všech vektorů, plochu objektu a další parametry. Příklad popisu pomocí skupiny je uveden na Obr.22.



Obr.22. Popis skupinou vektorů

Každý vektor je definován počátečním a konečným bodem, jenž je projekcí X, Y souřadnicového prostoru. Vektor je tak definován jako uspořádanou dvojici bodů (19).

$$|v| = [x_1, y_1; x_2, y_2] \quad (19)$$

Nevýhodou tohoto popisu je velikost množiny, respektive počet vektorů který definuje obecně složitý tvar segmentu. Počet vektorů v této skupině je přímo závislý na složitosti tvaru segmentu, kde každá změna tvaru segmentu odpovídá novému vektoru v této skupině. Existuje řada modifikací tohoto skupinového vektorového popisu. Žádná z nich však neodstraňuje tuto základní nevýhodu.

Dalším problémem je analýza segmentu popsána takovouto skupinou vektorů, neboť nelze provádět přímou korelační funkci, je potřeba používat specializované vyhodnocovací algoritmy a metody.

2.2.7. Popis tvaru objektu pomocí průběhu křivosti jeho hranice


Z elementární teorie křivek je známo, že průběh $k(s)$ křivosti křivky jednoznačně určuje až na její polohu (platí pro rovinné křivky a pojmem křivost rozumíme první křivost). Nabízí se možnost využít této skutečnosti tak, že pro rozpoznávání objektů využijeme příznaků odvozených z průběhu křivosti jejich hranice. Obr.23. ukazuje křivku (hranici segmentu, objektu) a odpovídající průběh $k(s)$ křivosti. Je zřejmé, že funkce $k(s)$ je periodická s periodou T , což je délka křivky. Funkci $k(s)$ lze proto rozvinout ve Fourierovu řadu [15]:

$$k(s) = \sum_{-\infty}^{\infty} c_n \exp\left[j2\pi n \frac{s}{T}\right] \quad (20)$$

kde


$$c_n = \frac{1}{T} \int_0^T k(s) \exp\left[-j2\pi n \frac{s}{T}\right] \quad (21)$$

Integrační konstanta, respektive perioda T , je specifická pro každý segment, respektive hranici segmentu. Velikost periody závisí na délce hranice segmentu. Hlavní tvary objektu lze popsat pomocí amplitud určitého počtu nejnižších frekvenčních složek. Vyšší složky popisují pro rozpoznání zpravidla méně významné tvarové detaily, může se též jednat o šumy. Prakticky lze průběh křivosti hranice získat například tak, že skupinami po sobě jdoucích pixelů tvořících hranici prokládáme kruhové oblouky nebo jinou vhodnou křivku. V případě kruhového oblouku platí mezi jeho poloměrem a křivostí jednoduchý vztah $k = 1/r$. V případě aproximace hranice množinou kruhových oblouků má pak funkce $k(s)$ po částech konstantní průběh. Prokládáme-li obecnější křivku s parametrickou rovnicí $x = x(s)$, pak pro křivost máme $k(s) = |x''(s)|$ (z diferenciální geometrie křivek je známo, že uvedený vztah platí pro takovou parametrizaci křivky, kde parametr s měří délku oblouku). Kromě prokládání kruhových oblouků nebo křivek byla navržena také řešení, kde je informace o průběhu křivosti získávána analýzou řetězce popisujícího tvar hranice ve Freemanově kódu. [15]



Obr.23. Objekt a průběh křivosti po obvodě [15]

Ve Freemanově kódu je křivka popsána od jednoho ze svých konců. Postupně jsou zapisovány kódy směrů tak, jak křivka postupuje od jednoho pixelu k druhému. [15] Kódování směrů ukazuje Obr.24. vlevo a příklad kódování vpravo.



Obr.24. Kódování směrů ve Freemanově kódu(vlevo),Kódování tvaru křivky pomocí Freemanova kódu (0001221012)(vpravo) [15]

3. Kruhová tvarová transformace

Parametrický popis charakterizuje objekt z pohledu jeho geometrických a matematických vlastností, dostatečně však nereflektuje skutečný tvar segmentu obrazu a nelze jej na základě tohoto popisu rekonstruovat do jeho skutečné původní podoby. Za tímto účelem byla vyvinuta zcela nová původní metoda nazývaná kruhová tvarová transformace, která vychází z matematické metody zápisu v polárních souřadnicích. Tato nová metoda transformuje původní segment obrazu ze souřadnicového systému do X, Y do nového souřadnicového systému r, φ (polárních souřadnic). Tato transformace převádí veškeré parametry objektu a je zpětně reverzibilní beze zbytku, to znamená, že lze zcela rekonstruovat tvar a velikost skutečného objektu v souřadnicovém systému X, Y . Transformace je definována pro jakýkoliv konvexní bod uvnitř segmentu.

Transformaci souřadnicového systému lze vyjádřit (22)


$$\text{transformace } X, Y \rightarrow r, \varphi \quad (22)$$

Metoda kruhové tvarové transformace definuje segment jako funkční závislost dle vztahu (23)

$$r = f(\varphi) \quad (23)$$

Principem transformace je převod tvarového vyjádření segmentu v souřadnicovém systému X, Y tím způsobem, že je od středu objektu v tomto systému definována vzdálenost r k okraji segmentu v celém intervalu $(0, 2\pi)$ radiánů, respektive $(0^\circ, 360^\circ)$. Výhodou kruhové tvarové transformace je převod dvoudimenzionální funkční závislosti na jednodimenzionální signál. Toto vyjádření lze s výhodou využít pro popis objektu, protože umožňuje zpětně získat informace o rozměru segmentu, jeho obsahu či obvodu. Současně lze toto vyjádření využít při identifikaci segmentu v rámci korelačních funkcí. Každé takto získané vyjádření popisu segmentu je unikátní a koresponduje s parametry segmentu v obraze.

Princip kruhové tvarové transformace je ukazuje Obr.25.



Obr.25. Princip tvarové kruhové transformace

3.1. Konvexní oblast a konvexní bod v \mathbb{R}^2

Všechny níže uvedené matematické vztahy a rovnice jsou uvedeny pro konvexní bod náležící zkoumanému segmentu 2D obrazu. Jestliže existuje v segmentu obrazu alespoň jeden konvexní bod, lze pro něj aplikovat výše uvedenou transformaci. Všechny případy budou definovány v \mathbb{R}^2 , protože segmenty obrazu se nacházejí v dvourozměrném prostoru.

Definice: Parametrická diferenciální křivka je diferenciální pro $\varphi: I \rightarrow \mathbb{R}^2$ v otevřeném intervalu $I = (a, b)$, v množině reálných čísel z \mathbb{R} do \mathbb{R}^2 .

Skupina $\langle \varphi \rangle := \varphi(I) = \{\varphi(t) : t \in I\} \subset \mathbb{R}^2$ geometrický obraz křivky φ .

Křivka je uzavřená, když $I = \langle a, b \rangle$, $(a, b \in \mathbb{R}; a < b)$ a $\varphi(a) = \varphi(b)$. $\varphi(a)$ (resp. $\varphi(b)$) se nazývá výchozí bod, respektive konečný bod.

Křivka je uzavřená, jestliže φ je uzavřená a navíc má $t_1, t_2 \in \langle a, b \rangle$, $0 < |t_1 - t_2| < b - a \Rightarrow \varphi(t_1) \neq \varphi(t_2)$.

Nechť $S \subseteq \mathbb{R}^2$, pak S nazveme konvexní, jestliže pro všechna x a y v C a pro všechna t v intervalu $\langle 0, 1 \rangle$, bodu $(1 - t)x + ty$ náleží do množiny C . Jinými slovy platí, že pro každý bod existuje úsečka, jenž spojuje x a y v množině C .

V případě, kdy pro hledaný segment neexistuje konvexní bod, je potřeba přistoupit k rozdělení segmentu na subsegmenty, reprezentované jako sumu konvexních oblastí. V případě dělení segmentu na řadu subsegmentů s vlastnostmi konvexní oblasti může být použit například algoritmus Ekoule, Peyrin nebo Odet. [46]

3.2. Shannon-Kotelnikův teorém ve vztahu ke KTT

Každý segment obrazu v prostoru X, Y je definován maticí pixelů, a tvoří dvourozměrný signál, který můžeme považovat za analogovou projekci daného segmentu. Principem KTT je popis segmentu obrazu pomocí zápisu do polárních souřadnic r, φ s krokem $\Delta\varphi$.

Aby při převodu KTT nedocházelo ke ztrátě informace o původním prostoru X, Y do polárního prostoru r, φ musí být zachována platnost Shannon-Kotelnikova teorému (Nyquistova teorému). Shannon-Kotelnikův teorém tímto definuje maximální velikost kroku převodu $\Delta\varphi$ pro daný segment v prostoru X, Y . Obecně lze říci, že velikost kroku závisí na tvaru segmentu, respektive rychlosti změny tvaru segmentu. Je-li segment v prostoru X, Y popsán ostrými hranami (například čtverec), pak musí být krok transformace $\Delta\varphi$ nekonečně malý, aby nedošlo ke ztrátě, respektive zkreslení informace o jeho tvaru. Abychom mohli zcela rekonstruovat tvar segmentu, musí být křivka tvaru segmentu hladká a spojitá, a současně musí být zachován Shannon-Kotelnikův teorém.

Shannon-Kotelnikův teorém


Základní podmínkou správného vzorkování je požadavek, aby vzorkovací průběh bylo možno převést zpět, tedy rekonstruovat jej na původní průběh bez ztráty informace. Tuto podmínku vyjadřuje tzv. Shannon-Kotelnikův vzorkovací teorém, kterým určuje potřebný vzorkovací kmitočet vzhledem k nejvyššímu kmitočtu spektra vzorkovacího signálu. [48][49]

$$\omega_v \geq 2 \cdot \omega_m \quad (24)$$

respektive

$$\omega_{r,\varphi} \geq 2 \cdot \omega_{X,Y} \quad (25)$$


Vzorkovací kmitočet ω_v musí být roven nejméně dvojnásobku nejvyššího kmitočtu spektra vzorkovacího kmitočtu ω_m .



Obr. 26: Amplitudové kmitočtové spektrum pro $\omega_v \geq 2 \cdot \omega_m$ [48]

Není-li podmínka splněna, dochází k překrytí sousedních period spektra, což má za následek znehodnocení vzorkovacího signálu. [48][49]

$$\omega_v < 2 \cdot \omega_m \quad (26)$$



Obr. 27: Amplitudové kmitočtové spektrum pro $\omega_v < 2 \cdot \omega_m$ [48]

Musí tedy platit, že frekvence vzorkování KTT, respektive krok $\Delta\varphi$ musí být nejméně dvakrát nižší, než je nejvyšší frekvence, respektive rychlost změny tvaru segmentu v prostoru X, Y .

3.3. Popis funkce KTT Fourierovou řadou

Výstupem kruhové tvarové transformace je vektor vzorkovaných dat. Tento vektor je diskrétním popisem funkce $f(r, \varphi)$ při zachování Shannon-Kotelnikova teorému $\omega_{r, \varphi} \geq 2 \cdot \omega_{X, Y}$.

Abychom mohli výstup kruhové tvarové transformace zpracovat analyticky, je potřeba popsat diskrétní signál analytickým vyjádřením. Využijeme znalosti, že libovolný periodický průběh můžeme nahradit nekonečnou trigonometrickou Fourierovou řadou.

Jestliže můžeme ze signálu o určité základní frekvenci vytvořit přidáním vyšších harmonických libovolný periodický průběh, je logické předpokládat, že je možné libovolný obecný periodický průběh převést na řadu harmonických průběhů. Tato řada je obecně nekonečná a může mít tvar: [50]

$$f(t) = A_0 + A_1 \cdot \sin(\omega t + \varphi_1) + A_2 \cdot \sin(2\omega t + \varphi_2) + A_3 \cdot \sin(3\omega t + \varphi_3) + \dots \quad (27)$$

kde A_0 stejnosměrná složka

A_n amplituda n-té harmonické, n - přirozené číslo v rozsahu 1 až ∞

(A_1 amplituda základní harmonické, A_2, A_2, \dots amplitudy vyšších harmonických)

φ_n fáze n-té harmonické

Řadu lze také psát ve tvaru:

$$f(t) = A_0 + \sum_{n=1}^{\infty} A_n \sin(n \cdot \omega t + \varphi_n) \quad (28)$$

Pro výpočet se tato řada převádí na standardní tvar Fourierovy řady, v níž jsou jednotlivé harmonické frekvence určeny sinovými a kosinovými složkami.

Fourierova řada

Libovolný periodický průběh můžeme nahradit nekonečnou trigonometrickou Fourierovou řadou:

$$f(t) = a_0/2 + a_1 \cdot \cos \omega t + a_2 \cdot \cos 2\omega t + a_3 \cdot \cos 3\omega t + \dots \\ + b_1 \cdot \sin \omega t + b_2 \cdot \sin 2\omega t + b_3 \cdot \sin 3\omega t + \dots \quad (29)$$

kteřou lze také psát ve tvaru:

$$f(t) = \frac{a_0}{2} + \sum_{n=1}^{\infty} (a_n \cos n\omega t + b_n \sin n\omega t) \quad (30)$$

Koeficienty a_0, a_n, b_n lze určit výpočtem integrálů:

$$a_n = \frac{2}{T} \int_0^T f(t) \cdot \cos n\omega t \, dt \quad (31a)$$

$$b_n = \frac{2}{T} \int_0^T f(t) \cdot \sin n\omega t \, dt \quad (31b)$$

Povšimněme si, že pro stejnosměrnou složku a_0 je $\cos 0 = 1$ a proto

$$a_0 = \frac{2}{T} \int_0^T f(t) \, dt \quad (32)$$

V příručkách [Bartsch: Matematické vzorce] je pro zjednodušení funkce času převedena na úhel x ($x = \omega t$), perioda je pak 2π . Vzorce pro výpočet koeficientů pak budou:

$$a_n = \frac{1}{\pi} \int_0^{2\pi} f(x) \cdot \cos nx \, dx \quad (33)$$

$$b_n = \frac{1}{\pi} \int_0^{2\pi} f(x) \cdot \sin nx \, dx \quad (34)$$

$$a_0 = \frac{1}{\pi} \int_0^{2\pi} f(x) \, dx \quad (35)$$

Pro použití těchto vzorců je však nutné, aby průběh signálu byl definován matematicky. Samozřejmě je také třeba umět takový integrál vypočítat. Pro zjednodušení jsou v příručkách uvedeny vzorce pro základní průběhy (impulsní, obdélníkový, trojúhelníkový, pilový, lichoběžníkový atd.). Kromě toho jsou u některých průběhů určité koeficienty nulové. [50]

Numerická metoda výpočtu koeficientů Fourierovy řady


U průběhů získaných měření bývá obtížné převést diskretizovaná data na analytickou funkci. V takovém případě je možné řešení provést numericky. Při tomto způsobu nejprve rozdělíme periodu signálu 2π na konečný počet stejných dílků s velikostí $\Delta x = 2\pi/c$ a v jejich koncových bodech určíme hodnoty funkce y_k . Tím vyjádříme spojitou funkci konečným

počtem hodnot, vzorků. Čím je větší počet dílků, tím je přesnější výsledek. Zároveň s tím, se ale zvětšuje množství potřebných výpočtů.

Pro určení n harmonických složek musíme volit počet dílků $c \geq 2n + 2$.

Nyní můžeme integrály pro výpočet koeficientů Fourierovy řady nahradit přibližným výpočtem výsledné plochy integrálu tím, že pro každý vzorek vynásobíme hodnotu funkce sinem nebo kosinem příslušného úhlu $n \cdot x_k$. Po vynásobení hodnotou Δx dostaneme plochu obdélníku o šířce Δx a výšce, která představuje hodnotu vypočtené funkce. Sečtením těchto obdélníčků získáme přibližnou hodnotu hledaného integrálu. Tato metoda se proto nazývá obdélníková. [50]

Protože všechny obdélníky mají stejnou šířku, přejdou vzorce pro výpočet koeficientů na tvar:



Obr.28. Vzorový signál

$$a_n = \frac{2}{c} \sum_{k=1}^c y_k \cos nx_k \quad (36)$$

$$b_n = \frac{2}{c} \sum_{k=1}^c y_k \sin nx_k \quad (37)$$

Stejnoseměrná složka bude:

$$a_0 = \frac{2}{c} \sum_{k=1}^c y_k \quad (38)$$

Je zřejmé, že bude nutné provést značný počet výpočtů, proto bude vhodné použít pro záznam výsledků tabulku, nebo přímo tabulkový kalkulátor.

$$c = 12$$

$$\Delta x = 0,52 \text{ rad}$$


harmonická:					1.		2.		3.		4.	
k (vzorek)	y_k (funkce)	x_k (úhel)	$\cos x_k$	$\sin x_k$	$y_k \cdot \cos x_k$	$y_k \cdot \sin x_k$	$y_k \cdot \cos 2x_k$	$y_k \cdot \sin 2x_k$	$y_k \cdot \cos 3x_k$	$y_k \cdot \sin 3x_k$	$y_k \cdot \cos 4x_k$	$y_k \cdot \sin 4x_k$
1	2,0	0,52	0,87	0,50	1,73	1,00	1,00	1,73	0,00	2,00	-1,00	1,73
2	4,6	1,05	0,50	0,87	2,30	3,98	-2,30	3,98	-4,60	0,00	-2,30	-3,98
3	5,0	1,57	0,00	1,00	0,00	5,00	-5,00	0,00	0,00	-5,00	5,00	0,00
4	4,8	2,09	-0,50	0,87	-2,40	4,16	-2,40	-4,16	4,80	0,00	-2,40	4,16
5	4,0	2,62	-0,87	0,50	-3,46	2,00	2,00	-3,46	0,00	4,00	-2,00	-3,46
6	2,0	3,14	-1,00	0,00	-2,00	0,00	2,00	0,00	-2,00	0,00	2,00	0,00
7	1,4	3,67	-0,87	-0,50	-1,21	-0,70	0,70	1,21	0,00	-1,40	-0,70	1,21
8	0,6	4,19	-0,50	-0,87	-0,30	-0,52	-0,30	0,52	0,60	0,00	-0,30	-0,52
9	-1,0	4,71	0,00	-1,00	0,00	1,00	1,00	0,00	0,00	-1,00	-1,00	0,00
10	-1,8	5,24	0,50	-0,87	-0,90	1,56	0,90	1,56	1,80	0,00	0,90	-1,56
11	-1,2	5,76	0,87	-0,50	-1,04	0,60	-0,60	1,04	0,00	1,20	0,60	1,04
12	1,0	6,28	1,00	0,00	1,00	0,00	1,00	0,00	1,00	0,00	1,00	0,00
součet	21,4				-6,3	18,1	-2,0	2,4	1,6	-0,2	-0,2	-1,4
a_0	3,57			a_n / b_n	-1,05	3,01	-0,33	0,40	0,27	-0,03	-0,03	-0,23
A_0	1,78			A_n	3,19		0,52		0,27		0,23	
				φ_n	1,91		2,26		-0,12		-1,71	

Tab.1. Příklad Numerické metody výpočtu koeficientů Fourierovy řady

Grafická metoda pro určení koeficientů Fourierovy řady

Přesnost této metoda není velká, ale může usnadnit pochopení významu předchozích výpočtů a dalších úvah v následující metodě.

Především je nutné si uvědomit, že vynásobením hodnoty funkce y_k sinem a kosinem příslušného úhlu vlastně určuje souřadnice koncového bodu vektoru délky y_k , natočeného v tomto úhlu. Součty jednotlivých složek lze vyjádřit graficky jako součet těchto vektorů. [50]




Obr.29. Vzorový signál

Pro znázornění postupu použijeme předchozí průběh.

Z grafu vybereme hodnoty y_1 až y_{12} a znázorníme je jako vektory. Připravíme hvězdicí s dvanácti polopřímkami, s dělením po 60° . Pro konstrukci koeficientů 1. harmonické vyneseme na tyto směry hodnoty y_1 až y_{12} provedeme jejich součet. Pro konstrukci koeficientů 1. harmonické vyneseme hodnoty y_1 až y_{12} postupně na směry s dvojnásobným úhlem a provedeme součet. Amplitudu a fázi, případně kosinové a sinové složky určíme z výsledného vektoru, směřujícímu ke konci vektoru y_{12} . [50]

Obdobný postup použijeme pro stanovení 3. a 4 harmonické.



Obr.30. Grafická metoda pro určení koeficientů Fourierovy řady [50]


3.4. Transformace z prostoru X, Y do r, φ

Kruhová tvarová transformace nenese informaci o pozici objektu v obraze. V případě kruhové tvarové transformace je proto vždy nutno posunout střed segmentu na pozici $[0,0]$ v souřadnicovém prostoru X, Y před zahájením samotné transformace. Posun středu objektu v souřadnicovém systému X, Y provádíme tak, aby pozice $[0,0]$ byla zároveň konvexním bodem segmentu. Transformace není definována pro nekonvexní body transformace. Současně je posun středu do konvexního bodu podstatný proto, že následně umožňuje definovat vzájemný posun polohy více segmentů v prostoru. Tato definice je podstatná v případě vzájemných korelací signálů transformace. Posun segmentu do počátku souřadnicového systému v prostoru X, Y lze vyjádřit dle vztahu (39)

$$\begin{aligned} x &= x' - P_x \\ y &= y' - P_y \end{aligned} \quad (39)$$

Kde P_x, P_y je střed segmentu v souřadnicovém prostoru X, Y
 x', y' je původní pozice bodů segmentu v souřadnicovém prostoru X, Y
 x, y je pozice bodů segmentu posunutého do počátku souřadnicového systému

Posun segmentu do počátku souřadnicového systému je znázorněn na obr.31.



Obr.31. Posun segmentu do počátku souřadnicového systému X, Y

Segment nacházející se v počátku soustavy souřadnic pak můžeme snadno transformovat do prostoru r, φ . Vzdálenost r je definována vztahem (40)

$$r = \sqrt{x^2 + y^2} \quad (40)$$

Kde r je amplituda funkce $r = f(\varphi)$
 x, y je pozice bodu segmentu v systému X, Y posunutého do jeho počátku


Vztah (41) uvádí převodovou závislost mezi prostorem X, Y a r, φ

$$\varphi = \arcsin\left(\frac{x}{r}\right) = \arcsin\left(\frac{x}{\sqrt{x^2 + y^2}}\right)$$

$$\varphi = \arccos\left(\frac{y}{r}\right) = \arccos\left(\frac{y}{\sqrt{x^2 + y^2}}\right)$$
(41)

3.5. Převod středu transformace v prostoru X, Y do r, φ

Funkce $f(\varphi)$ je odvislá nejen od tvaru segmentu, ale také od pozice středu transformační funkce. I přesto, že tvar, obvod či obsah segmentu nejsou závislé na středu transformace, výsledný funkční průběh $f(\varphi)$ se může značně lišit. Podstatou změny se relativní posun obou segmentů v prostoru X, Y . Tyto segmenty vždy obepínají střed soustavy souřadnicového prostoru X, Y , přesto nemusejí být shodné. Problematika je ukázána na Obr. 32.



Obr. 32. Dopad posunu středu tvarové kruhové transformace na průběh funkce $f(\varphi)$

Na obr.32. je znázorněna transformace stejného segmentu z prostoru X, Y do prostoru r, φ při posunu pozice tohoto segmentu vůči počátku soustavy souřadnic prostoru X, Y . Z obrázku je vidět, že i přes stejnou velikost, obsah a tvar segmentu je průběh funkce $f_1(\varphi)$ a $f_2(\varphi)$ zcela rozdílný. Přesto funkce $f_1(\varphi)$ a $f_2(\varphi)$ popisují tentýž segment.

Platí, že obvod, obsah a ostatní parametry téhož objektu jsou si rovny. (42)

$$\begin{aligned} o_{f_1(\varphi)} &= o_{f_2(\varphi)} \\ S_{f_1(\varphi)} &= S_{f_2(\varphi)} \end{aligned} \quad (42)$$

Ze znalosti transformační funkce $f_1(\varphi)$ a $f_2(\varphi)$ lze vypočítat vzájemný posun středů $[v, \alpha]$ při zpětné transformaci. Tento posun lze určit tak, že vypočteme posuv x' na ose X a y' na ose Y v prostoru X, Y

$$\begin{aligned} x' &= f_1(\varphi) - f_2(\varphi) & \varphi = 0^\circ \\ y' &= f_1(\varphi) - f_2(\varphi) & \varphi = 90^\circ \end{aligned} \quad (43)$$

Velikost vektoru posunu je pak dána vztahem (44)

$$v = \sqrt{x'^2 + y'^2} \quad (44)$$

Velikost úhlu α vektoru (v, α) se pak vypočte dle funkce „*math.atan2*“ nebo dle kvadrantu, ve kterém vektor leží následovně (45)(46)(47)(48):

Kvadrant I:

$$\alpha = \arctg \frac{x'}{y'} \quad (45)$$

Kvadrant II:

$$\alpha = \arctg \frac{x'}{y'} + 90^\circ \quad (46)$$

Kvadrant III:

$$\alpha = \arctg \frac{x'}{y'} + 180^\circ \quad (47)$$

Kvadrant IV:

$$\alpha = 360^\circ - \arctg \frac{x'}{y'} \quad (48)$$

Vzájemný posun středů je tak dán vektorem (v, α) a může být určen přímo z funkce a $f_1(\varphi)$ a $f_2(\varphi)$

3.6. Transformace z prostoru r, φ do X, Y

Kruhová tvarová transformace nenese informaci o poloze segmentu v originálním obraze. Proto zpětná transformace provede projekci segmentu do souřadného systému X, Y se středem v souřadnicích $[0,0]$.

Převodní vztah je definován rovnicí (49)

$$\begin{aligned}\sin(\varphi) &= \frac{x}{r} \\ \cos(\varphi) &= \frac{y}{r}\end{aligned}\quad (49)$$

Jednoduchou úpravou a substitucí (23) $r = f(\varphi)$ za r získáme rovnici zpětné transformace kruhové tvarové transformace (50)

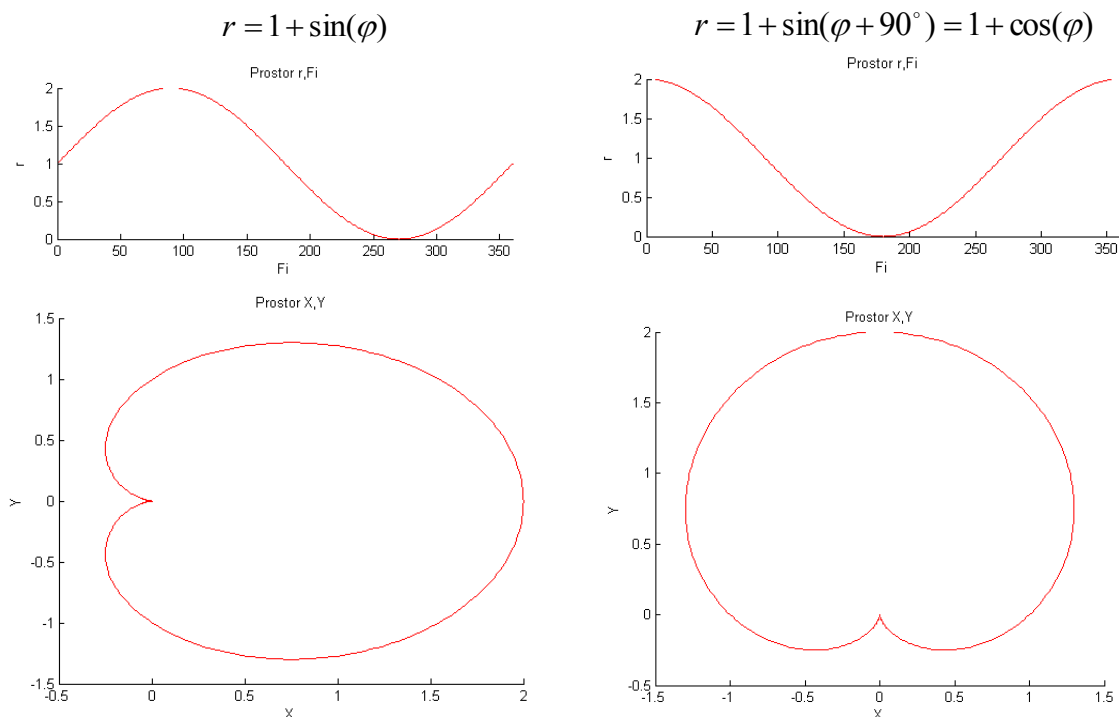
$$\begin{aligned}x &= \sin(\varphi) \cdot f(\varphi) \\ y &= \cos(\varphi) \cdot f(\varphi)\end{aligned}\quad (50)$$

3.7. Periodičnost funkce kruhové tvarové transformace

Kruhová tvarová transformace je definována pro celý obor reálných čísel, tedy pro $R \in (-\infty, \infty)$. Funkce (23) $r = f(\varphi)$ proto existuje pro celý definiční obor $R \in (-\infty, \infty)$. Z principu je tak funkce kruhové tvarové transformace periodická s periodou $T = 2\pi = 360^\circ$.

Periodičnost funkce úzce souvisí s rotací objektu v obraze. Rotace objektu je definována jako fázový posun funkce, kde fázový posun odpovídá rotaci segmentu v obraze.

Příkladem je posun fáze funkce $1 + \sin(\varphi) \rightarrow 1 + \sin(\varphi + 90^\circ)$, respektive $1 + \sin(\varphi) \rightarrow 1 + \cos(\varphi)$. Příklad uvádí zpětnou transformaci funkce kruhové tvarové transformace v prostoru r, φ do prostoru X, Y .



Obr.33. Příklad rotace objektu jako vlastnost fázového posunu

Z příkladu je zřejmé, že posun fáze o 90° má za následek rotaci segmentu v prostoru X, Y okolo vlastní osy o 90° po směru hodinových ručiček, tedy doprava.

3.8. Délka a obsah křivky kruhové tvarové transformace

Obsah rovinného oboru křivky histogramu lze vyjádřit jako (51) integrál křivky histogramu v intervalu $\langle 0, \varphi \rangle$. [21]

$$S = \int_0^{360} f(\varphi) d\varphi \quad (51)$$

Při výpočtu délky křivky kruhové tvarové transformace předpokládejme, že $f(\varphi)$ je spojitá funkce v intervalu $\langle 0^\circ, 360^\circ \rangle$ jenž má vlastní derivaci $f'(\varphi)$ ve všech bodech intervalu $\langle 0, \varphi \rangle$, vyjma konečných bodů; v těchto výjimečných bodech definujeme význam symbolu $f'(\varphi)$ jakkoliv. Pak křivka $f(\varphi)$ má konečnou délku danou rovnicí (52). [21]

$$L = \int_0^{360} \sqrt{1 + (f'(\varphi))^2} d\varphi \quad (52)$$


Tvarová kruhová transformace definuje průběh funkčního vyjádření $r = f(\varphi)$ pro speciální případy tvaru segmentu s definovaným středem. Níže je uvedeno zobrazení kruhové tvarové

transformace pro vybrané funkční závislosti $f(\varphi)$. Zobrazení je realizováno do prostoru X, Y a r, φ .

Předpis funkce $f(\varphi)$:

$$f(\varphi) = k = 1 \quad \varphi \in \langle 0^\circ, 360^\circ \rangle \quad (53)$$

Projekce tvarové kruhové transformace do prostoru X, Y a r, φ :




Obr.34. Projekce tvarové kruhové transformace do prostoru X, Y a r, φ pro vztah (53)

Předpis funkce $f(\varphi)$:

$$f(\varphi) = \sin(\varphi) \quad \varphi \in \langle 0^\circ, 360^\circ \rangle \quad (54)$$

Projekce tvarové kruhové transformace do prostoru X, Y a r, φ :




Obr.35. Projekce tvarové kruhové transformace do prostoru X, Y a r, φ pro vztah (55)

Předpis funkce $f(\varphi)$:

$$f(\varphi) = \cos(\varphi) \quad \varphi \in \langle 0^\circ, 360^\circ \rangle \quad (56)$$

Projekce tvarové kruhové transformace do prostoru X, Y a r, φ :




Obr.36. Projekce tvarové kruhové transformace do prostoru X, Y a r, φ pro vztah (55)

Předpis funkce $f(\varphi)$:

$$f(\varphi) = 1 + \sin(\varphi) \quad \varphi \in \langle 0^\circ, 360^\circ \rangle \quad (56)$$

Projekce tvarové kruhové transformace do prostoru X, Y a r, φ :




Obr.37. Projekce tvarové kruhové transformace do prostoru X, Y a r, φ pro vztah (56)

Předpis funkce $f(\varphi)$:

$$f(\varphi) = \sin(2\varphi) \quad \varphi \in \langle 0^\circ, 360^\circ \rangle \quad (57)$$

Projekce tvarové kruhové transformace do prostoru X, Y a r, φ :




Obr.38. Projekce tvarové kruhové transformace do prostoru X, Y a r, φ pro vztah (57)

Předpis funkce $f(\varphi)$:

$$f(\varphi) = \sin(2\varphi + 45^\circ) \quad \varphi \in \langle 0^\circ, 360^\circ \rangle \quad (58)$$

Projekce tvarové kruhové transformace do prostoru X, Y a r, φ :




Obr.39. Projekce tvarové kruhové transformace do prostoru X, Y a r, φ pro vztah (58)

Předpis funkce $f(\varphi)$:

$$f(\varphi) = \sin(2\varphi + 90^\circ) \quad \varphi \in \langle 0^\circ, 360^\circ \rangle \quad (60)$$

Projekce tvarové kruhové transformace do prostoru X, Y a r, φ :




Obr.40. Projekce tvarové kruhové transformace do prostoru X, Y a r, φ pro vztah (60)

Předpis funkce $f(\varphi)$:

$$f(\varphi) = \sin(4\varphi) \quad \varphi \in \langle 0^\circ, 360^\circ \rangle \quad (61)$$

Projekce tvarové kruhové transformace do prostoru X, Y a r, φ :




Obr.41. Projekce tvarové kruhové transformace do prostoru X, Y a r, φ pro vztah (61)

Předpis funkce $f(\varphi)$:

$$f(\varphi) = \sin(\varphi) \cdot \cos(\varphi) \quad \varphi \in \langle 0^\circ, 360^\circ \rangle \quad (62)$$

Projekce tvarové kruhové transformace do prostoru X, Y a r, φ :




Obr.42. Projekce tvarové kruhové transformace do prostoru X, Y a r, φ pro vztah (62)

Předpis funkce $f(\varphi)$:

$$f(\varphi) = \varphi \quad \varphi \in \langle 0^\circ, 360^\circ \rangle \quad (63)$$

Projekce tvarové kruhové transformace do prostoru X, Y a r, φ :




Obr.43. Projekce tvarové kruhové transformace do prostoru X, Y a r, φ pro vztah (63)

Předpis funkce $f(\varphi)$:

$$f(\varphi) = \varphi^2 \quad \varphi \in \langle 0^\circ, 360^\circ \rangle \quad (64)$$

Projekce tvarové kruhové transformace do prostoru X, Y a r, φ :




Obr.44. Projekce tvarové kruhové transformace do prostoru X, Y a r, φ pro vztah (64)

Předpis funkce $f(\varphi)$:

$$f(\varphi) = \sqrt{\varphi} \quad \varphi \in \langle 0^\circ, 360^\circ \rangle \quad (65)$$

Projekce tvarové kruhové transformace do prostoru X, Y a r, φ :



Obr.45. Projekce tvarové kruhové transformace do prostoru X, Y a r, φ pro vztah (65)

4. Klasifikace objektů

Klasifikace objektů identifikuje a třídí objekty, respektive segmenty obrazu. Základním posláním třídění objektů je nalezení segmentů, které navzájem tvoří logický celek, mají společné vlastnosti, jako je tvar, velikost, obvod či obsah. Třídění lze na základě mnoha kritérií, skupiny tříděných segmentů mohou obsahovat segmenty na základě nejrůznějších logických kritérií, které je navzájem svazují.

Třídění objektů je nejčastěji prováděno na základě porovnání jejich vlastností a parametrů, tímto se ve zpracování obrazu zabývají především metody parametrické analýzy objektu.

Identifikace objektů je proces, kdy se snažíme objekt jednoznačně určit, tedy identifikovat a přiřadit mu určitý logický význam či kontext.

Identifikace objektu se ve zpracování obrazu provádí nejčastěji korelací segmentu se vzorovou maskou, respektive sadou vzorů. Výsledkem korelace je pak informace o tom, které masce ze sady vzorů se daný segment nejvíce blíží, a s jakou pravděpodobností je tento segment právě objektem reprezentovaným korelační maskou, respektive korelačním vzorem.

V praxi se provádí nejprve třídění a až následně identifikace segmentů. Třídění je relativně rychlá operace, která identifikuje segmenty našeho zájmu. Následná identifikace metodami korelační analýzy určí význam, či to, co tyto segmenty v obraze reprezentují.

4.1. Parametrický popis segmentu

Každý objekt obrazu, respektive segment obrazu se vyznačuje skupinou parametrů či vlastností. Na základě těchto parametrů lze segmenty efektivně třídít a pro specifické případy provádět i vlastní identifikaci segmentů bez nutnosti použití korelační analýzy.

Mezi základní parametry patří:

- výška a šířka segmentu
- obvod a obsah segmentu
- tvar segmentu
- pozice segmentu v obraze

Jako vlastnost segmentu pak můžeme označit vzájemný vztah jeho parametrických veličin, tedy například poměr výšky k šířce, či poměr obsahu k obvodu. Současně lze za vlastnosti segmentu považovat jejich vzájemnou polohu (skupinová vlastnost segmentů v obraze).


4.2. Kruhovost

Nechť L, S označují délku hranice objektu a jeho plochu. Kruhovost je pak definována vztahem

$$C = \frac{L^2}{S} \quad (66)$$

Pro kruh, vychází hodnota kruhovosti $C = 4\pi$, pro čtverec je $C = 16$, pro objekty nepravidelného tvaru jsou hodnoty vyšší. Poznamenejme, že hodnota 4π pro kruh vychází z teoretické délky hranice. V závislosti na výpočetním postupu se může skutečná délka hranice zjištěná v digitalizovaném obraze od délky teoretické lišit (zkreslení vlivem digitalizace). [15]

Na Obr.46. je teoretická délka čtvrt-oblouku 5π . Prakticky zjištěná délka jeho digitalizovaného obrazu je však 20. Pokud by popsáný jev byl při rozpoznávání na závadu, lze mu čelit vyhlazením tvaru hranice. Je například možné, jistým počtem pixelů hranice proložit křivku. Délku této křivky lze pak chápat jako délku odpovídající části hranice. [15]



Obr.46. K rozdílu mezi teoretickou a skutečnou hranicí, Teoretická délka 5π , skutečná je 20. [15]

4.3. Energie hranice

Předpokládejme, že známe průběh křivosti $k(s)$ hranice objektu. Obvod objektu je T . Příznak „energie hranice“ koncentruje informaci o průběhu funkce $k(s)$ do jediné hodnoty.

$$E = \frac{1}{T} \int_0^T [k(s)]^2 ds \quad (67)$$

Uvažujeme-li různé objekty se stejnou plochou, pak nejmenší energie hranice vychází pro kruh, a to $E = (1/R)^2$. Pro složitější tvary jsou hodnoty energie hranice vyšší.


4.4. Průměrná vzdálenost pixelu od hranice

Nechť d_i označuje vzdálenost i -tého pixelu objektu od hranice objektu, jehož plocha je S . Protože by bylo zdlouhavé pro každý pixel objektu vypočítávat vzdálenost euklidovskou, rozumíme zde vzdáleností počet řad pixelů, které leží mezi hranicí a uvažovaným pixelem. (Obr.47.) Průměrnou vzdálenost μ_d pixelu od hranice pak rozumíme hodnotu

$$\mu_d = \frac{1}{N} \sum_{i=1}^N d_i \quad (68)$$

Kde N je celkový počet pixelů objektu. Koncentrovanou informací o tvaru objektu nese pak například příznak

$$S = \frac{S}{\mu_d^2} \quad (69)$$



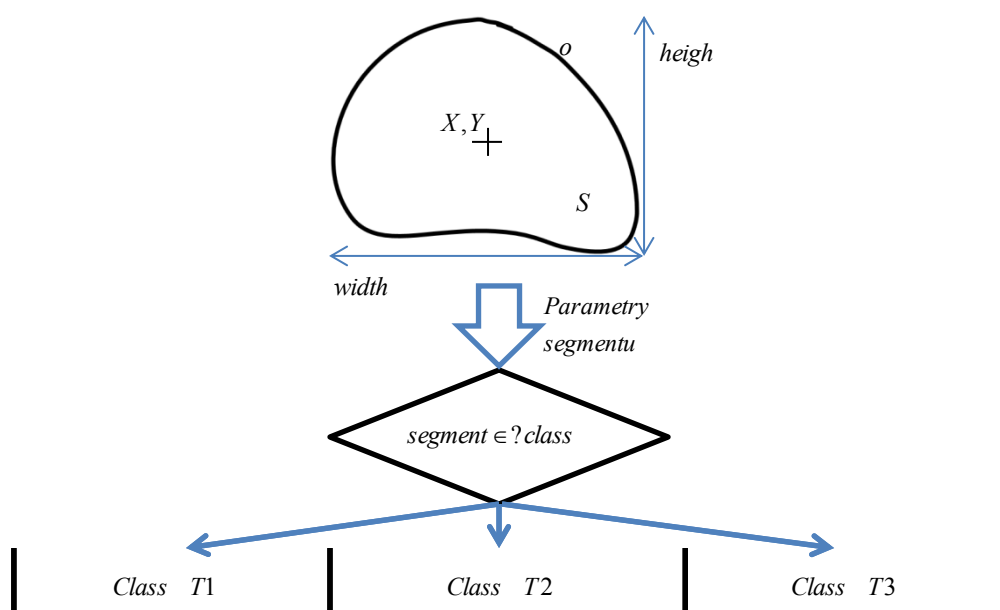
Obr.47. Vzdálenost pixelu od hranice [15]

4.5. Parametrická analýza a klasifikace segmentu

Parametrická analýza spočívá ve zkoumání parametrů segmentu takovým způsobem, že lze provést klasifikaci, neboli třídění segmentů do logických skupin na základě předem stanovených kritérií.

Jednotlivé třídy mohou obsahovat segmenty, které mají například obvod či obsah ve stanoveném intervalu, které jsou příliš malé či velké, nebo objekty, jejich vzájemná poloha je menší než stanovená mez. Kritérií, které lze použít jako podmínku pro zařazení segmentu do

daných tříd lze nalézt nekonečně mnoho. Princip třídění na principu parametrické analýzy je uveden na obr.48.



Obr.48. Třídění segmentů metodami parametrické analýzy

Klasifikace segmentu s využitím parametrické analýzy identifikuje daný segment bez potřeby aplikace korelační funkce, vzorové masky či sady vzorových obrazů segmentu. Metoda klasifikace segmentu s využitím parametrické analýzy využívá geometrických vlastností segmentu. Tato metoda nemůže být použita ve všech případech, protože je platná pouze na geometricky definované objekty, respektive segmenty. Principem je zkoumání platnosti geometrických vztahů v rámci segmentu.

Uveďme příklad klasifikace pro tři různé geometrické obrazce nacházející se v obraze. Necht' jsou těmito obrazci segmenty reprezentující kruh, čtverec a obdélník. Úkolem metody klasifikace s využitím parametrické analýzy je jednoznačně rozhodnout a identifikovat tyto segmenty bez využití korelační funkce.

Jak již bylo uvedeno, metoda klasifikace segmentu zkoumá geometrické závislosti uvnitř segmentu. Tyto geometrické závislosti lze pro každý segment obecně definovat následovně:

Kruh:

$$S = \pi \frac{a^2}{4} \quad (70a)$$

$$o = \pi \cdot a \quad (70b)$$

Čtverec:

$$S = a^2 \quad (71a)$$

$$o = 4 \cdot a \quad (71b)$$

Obdélník:

$$S = a \cdot b \quad (72a)$$

$$o = 2 \cdot a + 2 \cdot b \quad (72b)$$

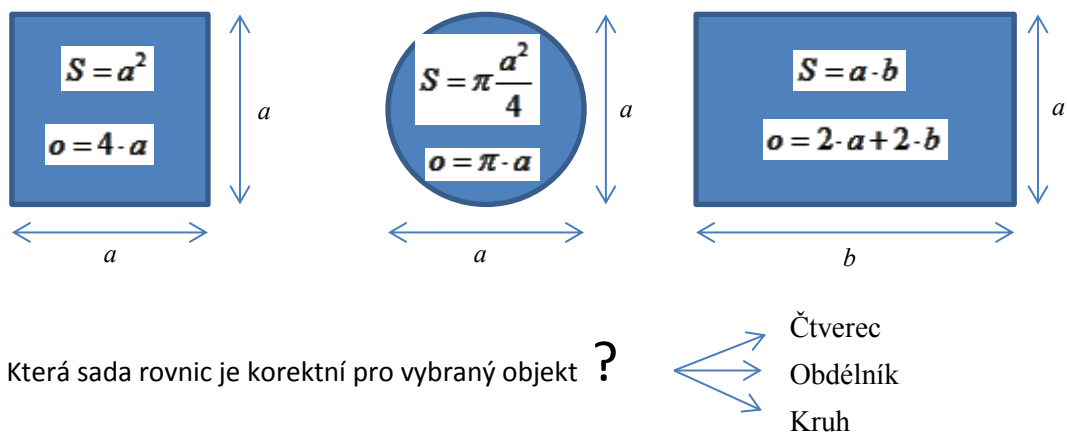
Kde: S je obsah objektu

o je obvod objektu

a je šířka a výška objektu, u kruhu průměr

b je šířka objektu v případě obdélníku

Metoda ověří platnost předepsaných geometrických závislostí, respektive definovaných matematických vztahů. Tyto rovnice (geometrické závislosti) jsou platné vždy pouze pro definovaný obrazec, v tomto případě kruh, čtverec nebo obdélník. Výsledkem je tedy vždy jednoznačná identifikace segmentu. Tato metoda je rychlá, efektivní a nevyžaduje ke své činnosti vstupní sadu vzorů či masky segmentů, jenž se snažíme identifikovat. Obr.49 ukazuje popsanou problematiku.




Obr.49. Klasifikace segmentů s využitím parametrické analýzy.

4.6. Parametrický popis ve vztahu ke kruhové tvarové transformaci

Obsah a obvod segmentu obrazu

Výpočet obvodu a obsahu se provádí v polárním souřadnicovém systému. (Jedná se o druh zpětné KTT transformace, přičemž dochází k extrakci pouze specifických informací obsažených v jejím funkčním vyjádření). Polární souřadnicový systém je dvourozměrný systém, ve kterém se každý bod v rovině určí na základě vzdálenosti od počátečního bodu a úhlem definovaným k tomuto bodu tak, jak bylo vytvořeno původní funkční vyjádření.



Obr. 50: Princip převodu polárních souřadnic do systému XY

Radiální souřadnice, neboli přenosová funkce kruhové tvarové transformace je označována jako $f(\varphi)$, s parametrem φ . V našem případě přenosová funkce $f(\varphi)$ závisí úhlu φ . Přenosová funkce $f(\varphi)$ je vypočtena kruhovou tvarovou transformací. Úhel φ je vždy v intervalu od $\langle 0, 2\pi \rangle$, protože přenosová funkce je vždy vypočtena pro jednu celou otočku okolo počátečního bodu. Obecně platí, že polární souřadnice r a φ jsou převedeny do kartézských souřadnic x a y pomocí goniometrické funkce sinus a kosinus podle vztahu:

$$\begin{aligned} \psi_1(r, \varphi) &:= x = r \cos \varphi, \\ \psi_2(r, \varphi) &:= y = r \sin \varphi. \end{aligned} \tag{73}$$

Každý bod na hranici v kartézských souřadnicích závisí na funkci $\psi: \mathbb{R}^2 \rightarrow \mathbb{R}^2$, $\begin{bmatrix} x \\ y \end{bmatrix} = \psi([r, \varphi])$. Jedním ze způsobů, jak vypočíst plochu objektu, je pomocí dvojného integrálu. Tento dvojný integrál se provádí přes parametr $dxdy$. Tento parametr je poté nahrazen $|J|dr d\varphi$, kde J je Jacobian transformace do polárních souřadnic na kartézské souřadnice. Pro naši transformaci je dán:

$$J = \begin{bmatrix} \frac{\partial \psi_1(r, \varphi)}{\partial r} & \frac{\partial \psi_1(r, \varphi)}{\partial \varphi} \\ \frac{\partial \psi_2(r, \varphi)}{\partial r} & \frac{\partial \psi_2(r, \varphi)}{\partial \varphi} \end{bmatrix} = \begin{bmatrix} \cos \varphi & -r \sin \varphi \\ \sin \varphi & r \cos \varphi \end{bmatrix}, \tag{74}$$

$$|J| = r \cos^2 \varphi + \sin^2 \varphi = r. \tag{75}$$

Pro dvojný integrál tak bude platit:

$$\iint_{\Omega} f(x, y) dx dy = \iint_{\Omega^*} f(r \cos \varphi, r \sin \varphi) \cdot r dr d\varphi, \tag{76}$$

kde $f(x, y)$ je spojitá funkce. Dvojný integrál udává obsah na základě přenosové funkce v prostoru Ω . Prostor Ω^* je prostor oblasti Ω v polárních souřadnicích.

Výpočet obsahu S segmentu v prostoru X, Y na základě rovnice přenosové funkce kruhové tvarové transformace (23)

Obsah S segmentu lze vypočítat při znalosti funkčního předpisu (23) kruhové tvarové transformace analyticky přímo, bez potřeby provádět zpětnou transformaci do prostoru X, Y . Toto analytické řešení se provádí počtem v polárních souřadnicích.

Obsah se vypočte na základě výše uvedených vztahů a definic. Funkce $f(x, y) = 1$, protože pak je obsah v prostoru Ω vypočitatelný. Prostor Ω odpovídá prostoru Ω^* ohraničený přenosovou funkcí $f(\varphi)$. Prostory Ω a Ω^* jsou konvexní. Toto je nutná podmínka pro náš případ. Obsah je vypočten na základě následujícího vztahu:

$$S = \int_0^{2\pi} \left(\int_0^{f(\varphi)} r dr \right) d\varphi = \int_0^{2\pi} \left(\left[\frac{r^2}{2} \right]_0^{f(\varphi)} \right) d\varphi = \frac{1}{2} \int_0^{2\pi} (f(\varphi))^2 d\varphi. \quad (77)$$

Výpočet obvodu o segmentu v prostoru X, Y na základě rovnice přenosové funkce kruhové tvarové transformace:

Výpočet obvodu je náročnějším úkolem, protože je k výpočtu potřeba derivace přenosové funkce $f(\varphi)$. Funkce $\psi: \mathbb{R} \rightarrow \mathbb{R}^2, \begin{bmatrix} x \\ y \end{bmatrix} = \psi([\varphi])$ závisí pouze na φ takže

$$\begin{aligned} \psi_1(\varphi) &:= x = f(\varphi) \cos \varphi, \\ \psi_2(\varphi) &:= y = f(\varphi) \sin \varphi. \end{aligned} \quad (78)$$

Univerzální vzorec pro výpočet délky křivky (o) je definován následovně:

$$o = \int_0^{2\pi} \sqrt{(\psi_1(\varphi)')^2 + (\psi_2(\varphi)')^2}. \quad (79)$$

Pro tento vztah je nutné formulovat derivaci ψ_1 a ψ_2 , proto

$$\begin{aligned} \psi_1'(\varphi) &:= x' = f'(\varphi) \cos \varphi - f(\varphi) \sin \varphi, \\ \psi_2'(\varphi) &:= y' = f'(\varphi) \sin \varphi + f(\varphi) \cos \varphi. \end{aligned} \quad (80)$$

Výkon ψ_1 a ψ_2 je poté dán vztahem

$$\begin{aligned}(\psi_1'(\varphi))^2 &= (f'(\varphi))^2 \cos^2 \varphi - 2f'(\varphi) f(\varphi) \sin \varphi \cos \varphi + (f(\varphi))^2 \sin^2 \varphi, \\(\psi_2'(\varphi))^2 &= (f'(\varphi))^2 \sin^2 \varphi + 2f'(\varphi) f(\varphi) \sin \varphi \cos \varphi + (f(\varphi))^2 \cos^2 \varphi.\end{aligned}\quad (81)$$

Suma

$$(\psi_1(\varphi)')^2 + (\psi_2(\varphi)')^2 = (f'(\varphi))^2 + (f(\varphi))^2. \quad (82)$$

Obvod segmentu v prostoru X, Y je dán vztahem

$$o = \int_0^{2\pi} \sqrt{[f'(\varphi)]^2 + [f(\varphi)]^2} d\varphi \quad (83)$$


4.7. Klasifikace kruhové tvarové transformace korelační funkcí

Korelační funkce se používá k určení vztahu mezi dvěma signály, podobnosti jejich průběhů v závislosti na jejich vzájemném posunutí. Korelační funkce může být vyjádřena jak pro spojité, tak pro diskrétní signály. Tyto signály mohou být jen jednodimenzionálním (vektorovým) signálem nebo vícerozměrným signálem.

Signálem $w(t)$ rozumíme závislost nějaké veličiny w na čase t například napětí, proud, zvuk, vlnění nebo hodnot. Velikost závislosti obou signálů pak určuje vzájemná energie: [51][50]

$$E_{12} = \int_{-\infty}^{\infty} w_1(t + \tau) \cdot w_2(t) dt \quad (84)$$

Nulovou vzájemnou energii mají signály podle Obr.51 signál $w_1(t)$ nahradíme posunutým signálem $w_1(t + \tau)$.




Obr.51 Ortogonální posunuté signály [50]

Korelační funkce R_{12} je tedy měřítkem:

$$R_{12} = \int_{-\infty}^{\infty} w_1(t + \tau) \cdot w_2(t) dt = \int_{-\infty}^{\infty} w_1(t) \cdot w_2(t + \tau) dt \quad (84)$$

Změníme-li τ tak, že se signály z Obr.52 (vlevo) začínají překrývat, je $R_{12}(\tau)$ nenulové. Pro $\tau = \tau_0$ se signály překrývají a R_{12} nabývají maximální hodnoty. Při dalším zvyšování τ se R_{12} opět zmenšuje, viz Obr.52 (vpravo).[50]



Obr.52. Výpočet a průběh korelační funkce pro signály z Obr.50.[50]

Dosažením $\tau = 0$ do rovnice (84) dostáváme, že korelační funkce pro nenulové posunutí je rovna vzájemné energii $R_{12}(0) = E_{12}$. Tvar vzájemné korelační funkce pro dva reálné periodické signály o periodě T je:[51]

$$R_{12}(\tau) = \frac{1}{T} \int_{-T/2}^{T/2} w_1(t+\tau) \cdot w_2(t) dt = \frac{1}{T} \int_{-T/2}^{T/2} w_1(t) \cdot w_2(t+\tau) dt \quad (85)$$

Vzájemná korelační funkce je měřítkem rychlosti změn funkční hodnoty v čase.[52] Vyjadřuje závislost hodnot jednoho a téhož signál, je-li $w_1(t) = w_2(t)$. Pro níž platí $R(0) = E$. [50]

Korelační funkce dvou signálů se nazývá vzájemná korelační funkce (86). Pokud jsou signály $w_A(t)$ a $w_B(t)$ identické, pak je možné oba signály označit jako $w(t)$. V tomto případě se jedná o autokorelační funkci. Pro spojitý informační signál je pak korelační funkce vyjádřena vztahem (87): [14]

$$R_{AB}(\tau) = \int_{-\infty}^{\infty} w_A(t) w_B(t+\tau) d\tau \quad (86)$$

$$R(\tau) = \int_{-\infty}^{\infty} w(t) w(t+\tau) d\tau \quad (87)$$

Podobně pro diskrétní informační signál je autokorelační funkce vyjádřena vztahem číslo (89).

$$R_{AB}[v] = \sum_{n=-\infty}^{\infty} w_A[n] w_B[n+v] \quad (88)$$

$$R[v] = \sum_{n=-\infty}^{\infty} w[n]w[n+v] \quad (89)$$

kde $v = \dots, -2, -1, 0, +1, +2, \dots$

Vzájemná korelační funkce dvou signálů kruhové tvarové transformace je definována vztahem (90)

$$R_{AB}(\gamma) = \int_{-\infty}^{\infty} f_A(\varphi)f_B(\varphi+\gamma)d\varphi \quad (90)$$

Autokorelační funkce dvou signálů kruhové tvarové transformace je definována vztahem (91)

$$R(\gamma) = \int_{-\infty}^{\infty} f(\varphi)f(\varphi+\gamma)d\varphi \quad (91)$$

Vzájemná korelační funkce dvou signálů kruhové tvarové transformace v diskrétní oblasti je definována vztahem (92)

$$R_{AB}[v] = \sum_{n=-\infty}^{\infty} f_A[n]f_B[n+v] \quad (92)$$

Autokorelační funkce dvou signálů kruhové tvarové transformace v diskrétní oblasti je definována vztahem (93)

$$R[v] = \sum_{n=-\infty}^{\infty} f[n]f[n+v] \quad (93)$$

Metody korelační analýzy

Přímá korelační funkce

Funkce počítá koeficient shody p mezi maticí A a B , kde A a B je matice o stejném rozměru. Koeficient shody p je vypočten dle vztahu (94). [9][12]

$$p = \frac{\sum_x \sum_y (A_{(x,y)} \times B_{(x,y)})}{x \cdot y} \quad (94)$$

Kde $A_{(x,y)} \times B_{(x,y)}$ je exkluzivní logický součet (XNOR)

Tato korelační metoda může být aplikována pouze na binární matice dat.

Výpočet korelačního koeficientu

Funkce počítá korelační koeficient p mezi maticí A a B , kde A a B je matice o stejném rozměru. Korelační koeficient p je vypočten dle vztahu (95). [20]

$$p = \frac{\sum_x \sum_y (A_{(x,y)} - \bar{A}) \cdot (B_{(x,y)} - \bar{B})}{\sqrt{\left(\sum_x \sum_y (A_{(x,y)} - \bar{A})^2 \right) \cdot \left(\sum_x \sum_y (B_{(x,y)} - \bar{B})^2 \right)}} \quad (95)$$

Kde \bar{A} je aritmetický průměr všech prvků matice A


\bar{B} je aritmetický průměr všech prvků matice B

Korelační funkce se používá k určení vztahu mezi dvěma signály, podobnosti jejich průběhů v závislosti na jejich vzájemném posunutí. V tomto případě slouží k porovnání obrazového signálu s jeho hledaným vzorem. Koeficient shody p mezi obrazovým signálem A a B reprezentuje míru podobnosti těchto dvou obrazových signálů. V praxi se využívá k identifikaci a třídění obrazových dat.

Korelační koeficient

Nejjednodušším vztahem dvou proměnných je vztah lineární, jehož míru lze zjistit korelačním koeficientem.

Lineární závislost dvou statistických veličin lze postihnout vynesáním proměnných do grafu. V případě korelace nestanovujeme rovnici přímky závislosti (to je úlohou lineární regrese), ale můžeme si přímku představit jako vyjádření lineárního vztahu a z odchylek bodů od přímky pak odhadnout míru tohoto vztahu.[53]



Obr. 53. Příklad korelačního koeficientu pro rozložení bodů v dvourozměrném prostoru

Pro korelační koeficient platí:

- Nabývá hodnot od -1 do $+1$, které značí zcela přesný lineární vztah (záporný nebo kladný).
 - V případě kladné korelace hodnoty obou proměnných zároveň stoupají.
 - V případě záporné korelace hodnota jedné proměnné stoupá a druhé klesá.
 - V případě neexistence lineárního vztahu $r = 0$.
- Je nezávislý na jednotkách původních proměnných, je bezrozměrný.
- Při změně pořadí proměnných se výše korelačního koeficientu nemění.
- Korelační koeficient je platný pouze v rozmezí daném použitými daty.
- Korelační koeficient výrazně odlišný od nuly není důkazem funkčního vztahu proměnných [53]

Výpočet korelačního koeficientu

se liší podle typu zkoumaných statistických proměnných. V případě, že náhodné veličiny X a Y jsou kvantitativní náhodné veličiny se společným dvourozměrným normálním rozdělením, je pro konkrétní hodnoty $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ výběrový korelační koeficient dán vztahem

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (96) \quad \text{Pearsonův korelační koeficient}$$

Součty čtverců ve jmenovateli jsou $n-1$ násobkem výběrových rozptylů. Proto se často setkáváme s jednodušším vyjádřením Pearsonova korelačního koeficientu [53]

$$r = \frac{s_{xy}}{s_x s_y}, \quad (97)$$

kde s_x je směrodatná odchylka proměnné X , s_y směrodatná odchylka proměnné Y a s_{xy} takzvaná kovariance proměnných X a Y


$$s_{xy} = \frac{1}{n-1} \sum (x_i - \bar{x})(y_i - \bar{y}) \quad (98)$$

Správná interpretace Pearsonova korelačního koeficientu předpokládá, že obě proměnné jsou náhodné veličiny a mají společné dvourozměrné normální rozdělení. Potom nulový korelační koeficient znamená, že veličiny jsou nezávislé. Pokud není splněn předpoklad dvourozměrné normality, z nulové hodnoty korelačního koeficientu nelze usuzovat na nic víc, než že veličiny jsou nekorelované. [53]

Korelační koeficient může být nadhodnocen:

1. vlivem třetí (skryté) proměnné
2. přítomností odlehlých hodnot

3. data jsou složena z podskupin objektů



Obr. 54. Přítomnost odlehlých hodnot (vlevo), podskupina objektů (vpravo)

V případě ordinálních dat nebo odchylek od předpokladů rozložení dat (odlehlá pozorování, jiné než normální rozložení proměnných, nelinearita vztahu) je vhodnější použít neparametrický koeficient korelace

$$r = 1 - \frac{6 \sum (Rx_i - Ry_i)^2}{n(n^2 - 1)} \quad (99) \quad \text{Spearmanův koeficient korelace,}$$

kde Rx_i a Ry_i jsou pořadí hodnot x_i a y_i .

Kromě Spearmanova korelačního koeficientu existují i další neparametrické korelační koeficienty jako např. Kendelovo τ .

Hodnocení výše korelačního koeficientu:

Metoda rozměrového efektu (účinku) :

$r = 0,1$	malý,
$r = 0,3$	střední,
$r = 0,5$	velký.

Statistické metody

Testuje se hypotéza H_0 , že výběr pochází z dvourozměrného normálního rozdělení, v němž je korelační koeficient nulový. Za platnosti H_0 : $\rho = 0$, má veličina

$$t = r \sqrt{\frac{n-2}{1-r^2}} \quad (100) \quad \text{rozdělení } t \text{ o } n-2 \text{ stupních volnosti, kde } n \text{ je počet dvojic } (x_i, y_i).$$

Pokud korelační koeficient ρ není roven nule, nemají jeho výběrové hodnoty normální rozdělení se střední hodnotou ρ . Výše uvedený vzorec se proto nehodí pro test hypotézy rovnosti korelačního koeficientu nenulové hodnotě. Je třeba hodnotu r pomocí vhodné transformace "normalizovat". Nejpoužívanější transformace je dána logaritmickým vztahem

$$z = \frac{1}{2} \ln \frac{1+r}{1-r} \quad (101)$$

Hodnoty z mají pro velký počet pozorování přibližně normální rozložení bez ohledu na to, jak velký je korelační koeficient ρ . Výběrová chyba veličiny z má jednoduchý tvar [53]

$$1/\sqrt{n-3} \quad (102)$$

Pro test hypotézy $\rho = \rho_0$ pak použijeme testové kritérium U

$$U = (z - z_0) \sqrt{n-3} \quad (103)$$

přičemž z_0 získáme pomocí logaritmické transformace, kde za r dosadíme ρ_0 . Chceme-li testovat hypotézu o shodě dvou nebo více korelačních koeficientů postupujeme obdobně.

Různé praktické důvody, ale zejména potřeba vyjádřit se současně o větším počtu proměnných, např. o prospěchu žáka v různých předmětech, vedou často k vícerozměrnému přístupu ke korelační analýze. Při současném zpracování n proměnných hodnotíme korelační koeficienty $n(n-1)/2$ dvojic proměnných, které sestavujeme do **korelační matice**, jejíž řádky i sloupce jsou věnovány postupně první až n -té proměnné. Na průsečíku i -tého řádku a j -tého sloupce je tedy uveden korelační koeficient r_{ij} i -té a j -té proměnné. Korelační matice je čtvercová a na diagonále obsahuje jedničky, protože $r_{ij} = 1$. Má tudíž tvar [53]

$$\begin{bmatrix} 1 & r_{12} & \dots & r_{1n} \\ r_{21} & 1 & \dots & r_{2n} \\ \vdots & \vdots & & \\ r_{n1} & r_{n2} & & 1 \end{bmatrix} \quad (104)$$

5. Verifikace vyvinutých metod

Verifikace byla provedena v prostředí Matlab, který slouží k simulaci a modelování technických procesů a matematických výpočtů. Veškeré prezentované výsledky jsou původními výstupy implementovaných simulací a programů. Prezentovaná data slouží jako podklad prezentovaných teoretických tezí, verifikují funkci navržených a optimalizovaných metod a poskytují srovnání s existujícími metodami v rámci stanovených funkčních parametrů.

Kapitola 5.1. se věnuje srovnání klasické metody „barvení“ oblastí využívající referenčních tabulek s optimalizovanou maticovou metodou semínkového vyplňování. Cílem je prokázat teoretické předpoklady, kterými je vyšší efektivita a úspora paměti v případě „barvení“ velkého množství objektů s relativně malým obsahem. Druhým předpokladem je nižší počet iterací algoritmu metody pro skupiny objektů s definovanými vlastnostmi, což je simulováno měřením času provedení metody. Tento přístup byl zvolen vzhledem ke zcela rozdílnému funkčnímu algoritmu obou metod, kde nelze korektně srovnat počet iterací jenž je potřeba vykonat.

Kapitola 5.2. se věnuje verifikaci původní vyvinuté metodě kruhové tvarové transformace, která je založena na transformaci dvourozměrného signálu, respektive segmentu obrazu v prostoru X,Y do periodického analogového signálu. Metoda provádí převod ve dvou základních krocích. Prvním krokem je převod na diskrétní signál, jenž využívá principu převodu souřadnicového systému X,Y do polárních souřadnic r, φ . Následně je provedena aproximace Fourierovou řadou, čímž je nalezeno analytické vyjádření diskretizovaného signálu. První část této kapitoly se věnuje verifikaci teorie převodu segmentů obrazu na tento signál a jeho zpětné reprezentace, přičemž se soustředí na problematiku vzorkovacího teorému a přesnosti reprezentace. Druhá část se věnuje srovnání rychlosti a přesnosti korelace segmentů v prostoru X,Y a nalezeného analytického, respektive diskrétního signálu transformace.

Cílem verifikace není provést implementaci vyvinutých metod v reálném průmyslovém prostředí, ale prokázat správnost prezentovaných hypotéz a teorií. Vyvinuté metody byly implementovány jako součást rozhodovacího a rozpoznávacího inferenčního mechanismu v projektu TAČR TA01010632 „Inovace SCADA systém pro monitorování stavu v reálném čase“ a jsou nyní nasazeny v reálných průmyslových aplikacích. Jako příklad lze uvést využití metod v rámci řídicího systému elektrárny Stonava, kde slouží jako součást automatického kamerového detekčního systému pro monitorování hladiny kotlů.

5.1. Verifikace maticového návrhu semínkového vyplňování

Obě metody „barvení“ oblastí byly implementovány v prostředí programu Matlab. Srovnáním implementace obou metod má za cíl ověřit teoretické předpoklady vlastností algoritmu řešení. Těmi jsou menší nároky na využitou operační paměť u optimalizovaného řešení metody vyhledání spojitostí, dále vyšší rychlost zpracování vlivem snížení počtu cyklů průchodů matice obrazu.







Srovnání bylo provedeno na dvou sadách binárních obrazů o rozlišení 640x480 pixelů. Sada binárních obrazů první skupiny slouží k verifikaci rychlosti zpracování a množství využívané operační paměti v závislosti na plošné velikosti objektu. Sada binárních obrazů druhé skupiny slouží k verifikaci rychlosti zpracování a množství využívané operační paměti v závislosti na počtu objektů v obraze.

Srovnání rychlosti běhu obou metod bylo provedeno měřením času, za který se metoda provede. Měření bylo provedeno na počítači s operačním systémem Windows 7 Profesional, procesorem Intel Core i7-2630QM, 2,0 GHz a operační pamětí 4 GB.

Předpoklad snížení nároků na využitou operační paměť nelze zcela korektně ověřit v rámci simulace algoritmu, a může být jen velmi těžko vypočtena. Optimalizovaný návrh metody vyhledání spojitostí využívá tzv. zásobníku dat, což je pole, jehož velikost je závislá na tvaru a ploše konkrétní spojitosti a v průběhu vykonávání algoritmu metody se neustále dynamicky mění. Velikost referenční tabulky pro „two-pass“ metodu vyhledání spojitostí se během zpracování neustále navyšuje. Pro účel verifikace využívání operační paměti byla současná funkce doplněna o ukládání informace o jejím využití a průběhu.

Verifikace vlastností algoritmu v závislosti na plošné velikosti spojitostí

Testovací skupina obsahuje vždy pouze jedinou spojitost stejné relativní složitosti. Jednotlivé spojitosti se liší pouze svým obsahem, respektive velikostí. První testovací skupina binárních obrazů pro ověření vlastností algoritmů v závislosti na plošné velikosti spojitosti je zobrazena na Obr.55.

Testovací obrázek 1	Testovací obrázek 2	Testovací obrázek 3	Testovací obrázek 4	Testovací obrázek 5	Testovací obrázek 6
					

Obr.55. První testovací skupina binárních obrazů pro ověření vlastností algoritmů v závislosti na plošné velikosti spojitosti

Srovnáním obou metod na této testovací skupině binárních obrazů byla získána následující data, uvedena v tabulce 2 a 3.

	<i>test1.bmp</i>	<i>test2.bmp</i>	<i>test3.bmp</i>	<i>test4.bmp</i>	<i>test5.bmp</i>	<i>test6.bmp</i>
Metoda referenčních tabulek	25,265 ms	27,530 ms	29,654 ms	32,349 ms	35,593 ms	42,038 ms
Metoda semínkového vyplňování s maticovým přístupem	18,290 ms	21,091 ms	22,168 ms	25,032 ms	29,169 ms	32,466 ms

Tab.2. Srovnání rychlosti běhu metod vyhledání spojitých oblastí v závislosti na změně plochy spojitosti


	<i>test1.bmp</i>	<i>test2.bmp</i>	<i>test3.bmp</i>	<i>test4.bmp</i>	<i>test5.bmp</i>	<i>test6.bmp</i>
Metoda referenčních tabulek	660 B	990 B	1320 B	1650 B	1980 B	2310 B
Metoda semínkového vyplňování s maticovým přístupem	1096 B	2367 B	4437 B	7390 B	11008 B	14056 B

Tab.3. Srovnání využití operační paměti během vykonávání metod vyhledání spojitých oblastí v závislosti na velikosti plochy spojitosti

Ze získaných výsledků je patrné, že optimalizovaný návrh maticové metody semínkového vyplňování je pro testovanou skupinu obrazů z pohledu rychlosti zpracování rychlejší přibližně o 10% proti klasickému návrhu metody založenému na principu tvorby retenčních tabulek, a to bez ohledu na velikost spojitosti v obraze. Současně vykazuje optimalizovaný návrh maticové metody semínkového vyplňování mnohem vyšší nároky na využití operační paměti a to tím větší, čím větší je velikost spojitě oblasti v obraze.

Verifikace vlastností algoritmu v závislosti na počtu spojitých oblastí

Testovací skupina obsahuje různý počet spojitostí stejné velikosti a tvaru. Druhá testovací skupina binárních obrazů pro ověření vlastností algoritmů v závislosti na počtu spojitých oblastí je zobrazena na Obr.56.



Obr.56. Druhá testovací skupina binárních obrazů pro ověření vlastností algoritmů v závislosti na počtu spojitých oblastí v obraze.

Srovnáním obou metod na této testovací skupině binárních obrazů byla získána následující data, uvedena v tabulce 4 a 5.

	<i>test1.bmp</i>	<i>test2.bmp</i>	<i>test3.bmp</i>	<i>test4.bmp</i>	<i>test5.bmp</i>	<i>test6.bmp</i>
Metoda referenčních tabulek	25,265 ms	26,530 ms	29,654 ms	35,349 ms	47,593 ms	62,038 ms
Metoda semínkového vyplňování s maticovým přístupem	19,290 ms	20,091 ms	23,168 ms	28,032 ms	38,169 ms	52,466 ms


Tab.4. Srovnání rychlosti běhu metod vyhledání spojitých oblastí v závislosti na počtu spojitostí

	<i>test1.bmp</i>	<i>test2.bmp</i>	<i>test3.bmp</i>	<i>test4.bmp</i>	<i>test5.bmp</i>	<i>test6.bmp</i>
Metoda referenčních tabulek	666 B	1332 B	2654 B	5302 B	10634 B	18618 B
Metoda semínkového vyplňování s maticovým přístupem	2095 B	2095 B	2095 B	2095 B	2095 B	2095 B

Tab.5. Srovnání využití operační paměti během vykonávání metod vyhledání spojitých oblastí v závislosti na počtu spojitostí

Stejně jako v případě první skupiny testovacích obrázků je i zde optimalizovaný návrh maticové metody semínkového vyplňování rychlejší přibližně 10% proti metodě založené na principu referenčních tabulek. Lze tedy prohlásit, že rychlost zpracování je u optimalizovaného návrhu maticové metody semínkového vyplňování vyšší, a to bez ohledu na velikost nebo tvar jednotlivých spojitostí v obraze. Srovnáním nároků na využití operační paměti během zpracování obou algoritmů je zřejmé, že metoda pracující s referenčními tabulkami je neoptimální v případě, kdy se v obraze nachází velké množství spojitostí. To je dáno především tím, že dochází k utváření referenční tabulky, jenž je společná pro všechny spojitosti v obraze, a tím kumulaci dat operační paměti počítače. Optimalizovaný návrh maticové metody semínkového vyplňování je z pohledu využití operační paměti počítače mnohem vhodnější, neboť nezáleží na počtu spojitých oblastí, které se v obraze nacházejí, ale pouze na jejich nominální velikosti.

Graf na obrázku 57. zobrazuje průběh využití operační paměti počítače během zpracování obou algoritmů. Graf je zobrazen pro testovací obrázek číslo 4, tedy binární obraz obsahující osm spojitých oblastí stejného tvaru a nominální velikosti. Graf zobrazuje množství využití operační paměti na základě jednotlivých iterací obou algoritmů. Vzhledem k rozdílné metodice a principu obou algoritmů nelze přesně srovnat množství využití operační paměti v jednotlivých okamžicích, respektive iteracích algoritmu a to především proto, že každý z algoritmů vyková rozdílný počet těchto iterací za různý čas.



Obr.57. Využití operační paměti funkcí během zpracování testovacího obrázku 4.

Srovnáním obou metod označování spojitostí „barvením“ bylo zjištěno, že původní optimalizovaný návrh maticové metody semínkového vyplňování je efektivnějším řešením z pohledu rychlosti zpracování bez ohledu na nominální velikost spojitě oblasti, nebo jejich počet, dále je optimálnější z pohledu využití operační paměti počítače v případech, kdy je v obraze velké množství spojitých oblastí s nevelkou nominální plochou, a to i v případě jejich vysoké tvarové složitosti. Metody založené na principu vytváření referenčních tabulek vykazují nižší nároky na využití operační paměti počítače v případě malé tvarové složitosti jednotlivých spojitostí nebo v případě nízkého počtu spojitých oblastí v obraze.

Výhodou původního optimalizovaného návrhu maticové metody semínkového vyplňování je minimalizace potřebné paměti, protože metoda pracuje přímo na původní matici bez potřeby ukládat při výpočtu matice do paměti a současně nevytváří referenční tabulku dat. Čas výpočtu algoritmu je závislý na počtu a celkové velikosti spojitých oblastí.

5.2. Verifikace kruhové tvarové transformace

Navržená metoda kruhové tvarové transformace transformuje dvourozměrný signál, respektive segment obrazu v souřadnicovém systému X,Y na jednorozměrný signál. Principem je převod souřadnicového systému X,Y do polárních souřadnic, respektive systému r,φ . Tímto převodem se získává diskretizovaný signál, který je následně aproximován Fourierovou řadou. Výsledkem je analytický popis jednorozměrným signálem, respektive funkční závislostí $r = f(\varphi)$.

Prvním krokem implementovaného simulačního programu je výpočet diskretizovaného vektoru dat. Krok simulace je vždy 1 stupeň v rámci celé periody signálu $0^0 - 360^0$, respektive $0 - 2\pi$. Tento diskretizovaný signál popíšeme Fourierovou řadou s definovaným počtem harmonických složek. Následně vykreslíme průběh diskretizovaného signálu a signálu definovaného Fourierovou řadou, současně provedeme výpočet originálního tvaru segmentu z původního diskretizovaného signálu a signálu definovaného Fourierovou řadou (105).

$$f(\varphi) = \frac{a_0}{2} + \sum_{n=1}^{\infty} (a_n \cos n.\omega\varphi + b_n \sin n.\omega\varphi) \quad (105)$$

Koeficienty a_n, b_n nejsou v rámci verifikačních případů uvedeny, protože nemají příslušnou vypovídací hodnotu. Současně není uveden ani konkrétní tvar Fourierovy řady, ale pouze grafická reprezentace verifikovaných dat a principů.


Obecně platí, že čím vyšší jsou změny tvaru objektu, tím vyšší počet harmonických složek je zapotřebí ke korektnímu popsání tvaru segmentu. U objektů s ostrými hranami konverguje počet harmonických složek k nekonečnu.

Verifikace popisu segmentu tvarovou kruhovou transformací ve tvaru $r = f(\varphi)$

Skupinu segmentů, pro nichž je provedena verifikace je zobrazena na Obr.č.58. Jedná se o sadu 6ti základních obrazců, představujících svým tvarem kruh, obecný Blob nebo deformovaný tvar kruhu, dále pětiúhelník, čtverec, pěticípou hvězdu a segment ve tvaru srdce.

Kruhová tvarová transformace je definována pouze pro segmenty obrazu, které mají nejméně jeden konvexní bod. Předpokládejme, pro tyto základní segmenty obrazu, které jsou souměrné podle počátku, nebo některé z jejich os mají konvexní bod právě v jejich středu (včetně segmentu ve tvaru obecného blobu).

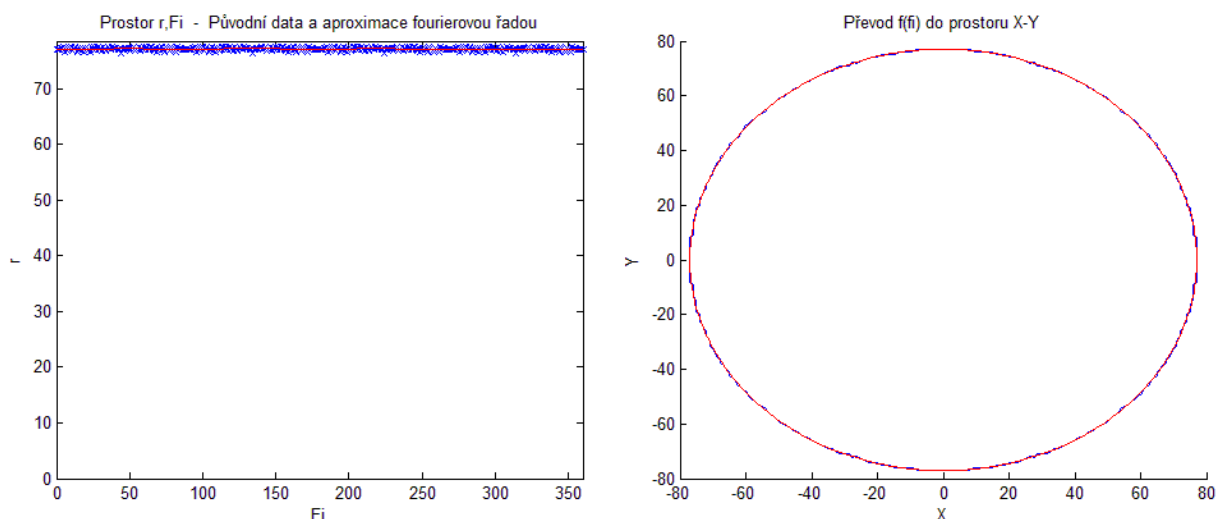
Jako konvexní bod transformace byl tedy zvolen geometrický střed objektu, respektive těžiště.



Obr. 58. Testovací originální segmenty obrazu (zleva: kružnice, obecný segment, pětiúhelník, čtverec, pěti-cípá hvězda a srdce)

Segment obrazu ve tvaru kružnice

Kružnice je v rámci kruhové tvarové transformace reprezentována lineární funkcí, která je z pohledu tvarové kruhové transformace dána pouze jediným koeficientem a_0 a ostatní koeficienty jsou nulové. Koeficient a_0 má na tvar segmentu vliv z pohledu morfologie, a to tím způsobem, že umožňuje snadno měnit velikost segmentu, ať už ve smyslu jeho zvětšení nebo zmenšení.

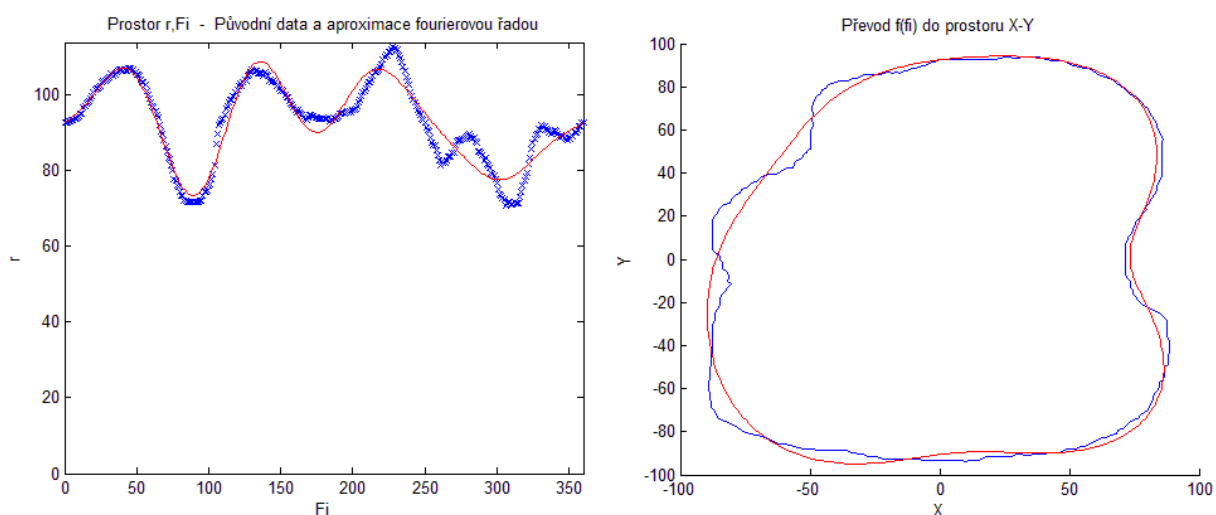


Obr. 59. Kruhová tvarová transformace -aproximace kružnice Fourierovou řadou s 1 harmonickou složkou


V případě obecného tvaru segmentu kruhu je aproximace tvaru dostatečná při užití 1 harmonické složky, respektive konstanty a_0 Fourierovy řady.

Obecný tvar segmentu obrazu

Předmětem verifikace je v tomto případě obecný tvar segmentu zobrazený na obrázku č. 58. Segment byl pomocí kruhové tvarové transformace popsán diskretním signálem, vektorem dat (Obr.60. a Obr.61. vlevo, modře). Následně byl tento diskretní signál proložen Fourierovou řadou s 5-ti harmonickými složkami (Obr.60. vlevo, červeně) a 15-ti harmonickými signály (Obr.61. vlevo, červeně). Rekonstruovaný tvar signálu (Obr.60. a Obr.61. vpravo) zobrazuje rekonstrukci tvaru segmentu z Obr.58. pomocí zpětné kruhové tvarové transformace, kdy došlo k převodu obrazu zpět do souřadnicového systému X,Y. Rekonstrukce původního diskretizovaného signálu je zobrazena modře a rekonstrukce na základě analytického vyjádření získaného aproximací Fourierovou řadou je zobrazena červeně.



Obr. 60. Kruhová tvarová transformace -aproximace obecného segmentu Fourierovou řadou s 5-ti harmonickými složkami




Obr. 61. Kruhová tvarová transformace - aproximace obecného segmentu Fourierovou řadou s 15-ti harmonickými složkami


Při proložení tvaru diskretního signálu Fourierovou řadou musí být dodržen Shannon-Kotelnikův teorém, tedy nejvyšší harmonická složka musí mít nejméně dvojnásobnou frekvenci oproti nejvyšší frekvenci v aproximovaném signálu. V případě obecného tvaru segmentu je aproximace tvaru dostatečná při užití 15-ti harmonických složek, při použití 5-ti harmonických složek lze pozorovat značné zkreslení tvaru signálu, a tím i zkreslení původního tvaru segmentu obrazu.

Segment obrazu ve tvaru pětiúhelníku

Předmětem verifikace je v tomto případě segment ve tvaru pětiúhelníku zobrazený na Obr.58. Segment byl pomocí kruhové tvarové transformace popsán diskretním signálem, vektorem dat (Obr.62. a Obr.63. vlevo, modře). Následně byl tento diskretní signál proložen Fourierovou řadou s 5-ti harmonickými signály (Obr.62. vlevo, červeně) a 15-ti harmonickými signály (Obr.63. vlevo, červeně). Rekonstruovaný tvar signálu (Obr.62. a Obr.63. vpravo) zobrazuje rekonstrukci tvaru segmentu z Obr.58. pomocí zpětné kruhové tvarové transformace, došlo k převodu obrazu zpět do souřadnicového systému X,Y. Rekonstrukce původního diskretizovaného signálu je zobrazena modře a rekonstrukce na základě analytického vyjádření získaného aproximací Fourierovou řadou je zobrazena červeně.



Obr. 62. Kruhová tvarová transformace -aproximace pětiúhelníku Fourierovou řadou s 5-ti harmonickými složkami




Obr. 63. Kruhová tvarová transformace -aproximace pětiúhelníku Fourierovou řadou s 15-ti harmonickými složkami


V případě pětiúhelníkového tvaru segmentu je aproximace tvaru dostatečná při užití 15-ti harmonických složek, při použití 5-ti harmonických složek lze pozorovat značné zkreslení tvaru signálu, a tím i zkreslení původního tvaru segmentu obrazu.

Segment obrazu ve tvaru srdce

Předmětem verifikace je v tomto případě segment ve tvaru srdce zobrazený na obrázku č. 58. Segment byl pomocí kruhové tvarové transformace popsán diskretním signálem, vektorem dat (Obr.64. a Obr.65. vlevo, modře). Následně byl tento diskretní signál proložen Fourierovou řadou s 5-ti harmonickými signály (Obr.64. vlevo, červeně) a 15-ti harmonickými signály (Obr.64. vlevo, červeně). Rekonstruovaný tvar signálu (Obr.64. a Obr.65. vpravo) zobrazuje rekonstrukci tvaru segmentu z Obr.58. pomocí zpětné kruhové tvarové transformace, došlo k převodu obrazu zpět do souřadnicového systému X,Y. Rekonstrukce původního diskretizovaného signálu je zobrazena modře a rekonstrukce na základě analytického vyjádření získaného aproximací Fourierovou řadou je zobrazena červeně.



Obr. 64. Kruhová tvarová transformace -aproximace „srdce“ Fourierovou řadou s 5-ti harmonickými složkami




Obr. 65. Kruhová tvarová transformace -aproximace „srdce“ Fourierovou řadou s 15-ti harmonickými složkami


V případě segmentu ve tvaru srdce je aproximace tvaru dostatečná při užití 15-ti harmonických složek, při použití 5-ti harmonických složek lze pozorovat značné zkreslení tvaru signálu, a tím i zkreslení původního tvaru segmentu obrazu.

Segment obrazu ve tvaru čtverce

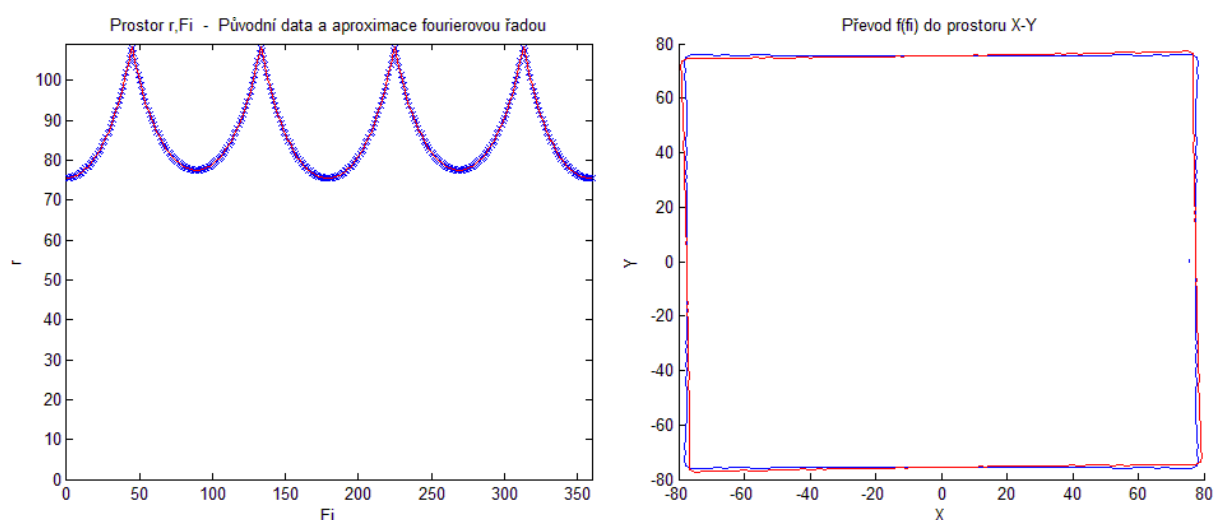
Předmětem verifikace je v tomto případě segment ve tvaru čtverce zobrazený na obrázku č. 58. Segment byl pomocí kruhové tvarové transformace popsán diskretním signálem, vektorem dat (Obr.66. a Obr.67. a Obr.68. vlevo, modře). Následně byl tento diskretní signál proložen Fourierovou řadou s 5-ti harmonickými signály (Obr.66. vlevo, červeně), 15-ti harmonickými signály (Obr.67. vlevo, červeně) a 150-ti harmonickými signály (Obr.68. vlevo, červeně). Rekonstruovaný tvar signálu (Obr.66., Obr.67. a Obr.68. vpravo) zobrazuje rekonstrukci tvaru segmentu z Obr.58. pomocí zpětné kruhové tvarové transformace, došlo k převodu obrazu zpět do souřadnicového systému X,Y. Rekonstrukce původního diskretizovaného signálu je zobrazena modře a rekonstrukce na základě analytického vyjádření získaného aproximací Fourierovou řadou je zobrazena červeně.



Obr. 66. Kruhová tvarová transformace -aproximace čtverce Fourierovou řadou s 5-ti harmonickými složkami



Obr. 67. Kruhová tvarová transformace -aproximace čtverce Fourierovou řadou s 15-ti harmonickými složkami

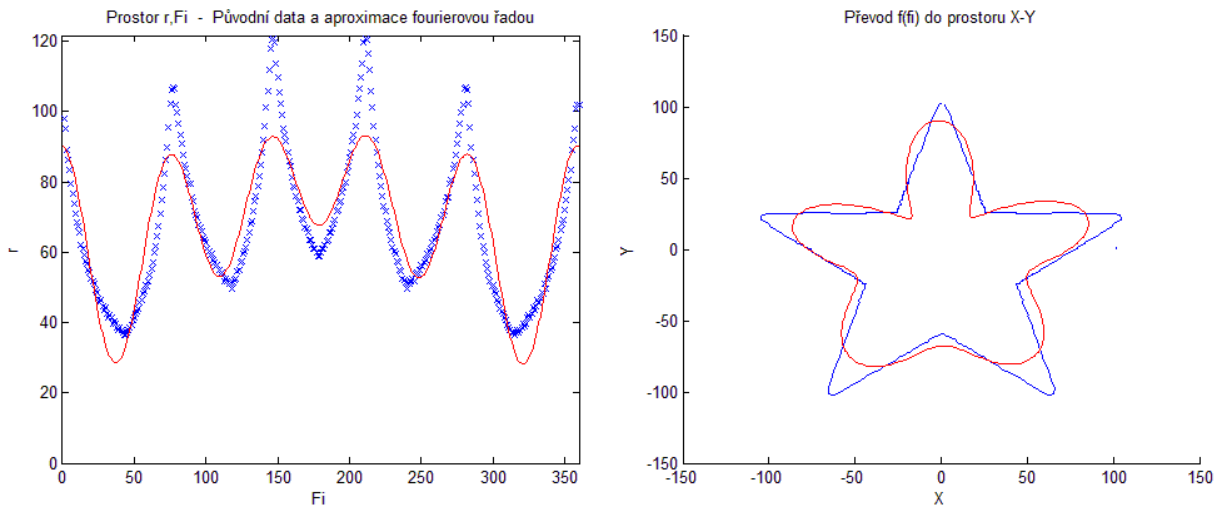


Obr. 68. Kruhová tvarová transformace -aproximace čtverce Fourierovou řadou s 150-ti harmonickými složkami

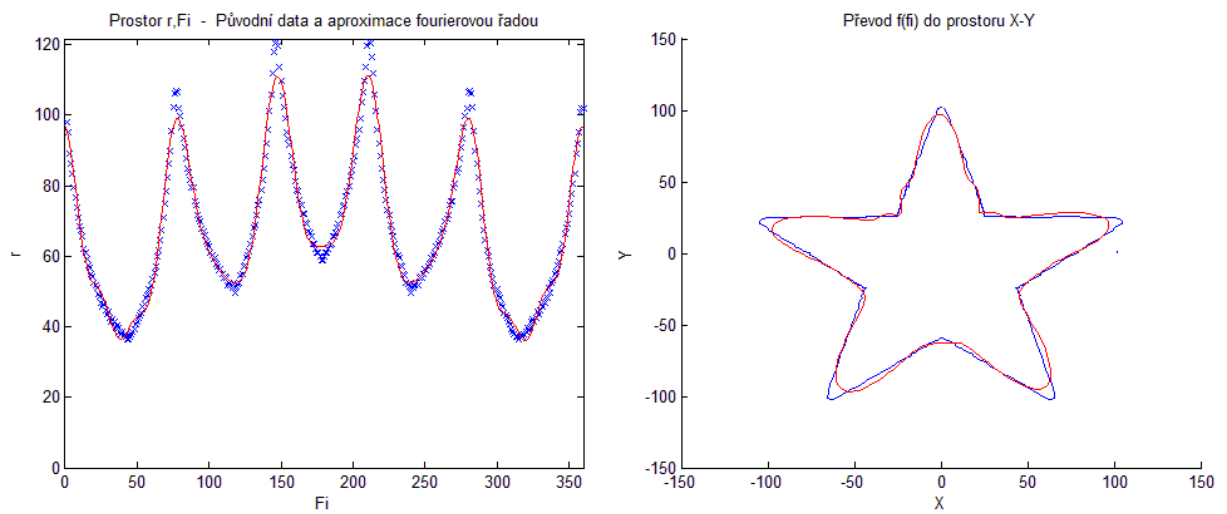
V případě segmentu ve tvaru čtverce je aproximace tvaru dostatečná při užití 150-ti harmonických složek, při použití 5-ti a 15-ti harmonických složek lze pozorovat značné zkreslení tvaru signálu, a tím i zkreslení původního tvaru segmentu obrazu, přičemž použití 5ti harmonických složek nereflektuje skutečný tvar segmentu obrazu.

Segment obrazu ve tvaru pěticípé hvězdy

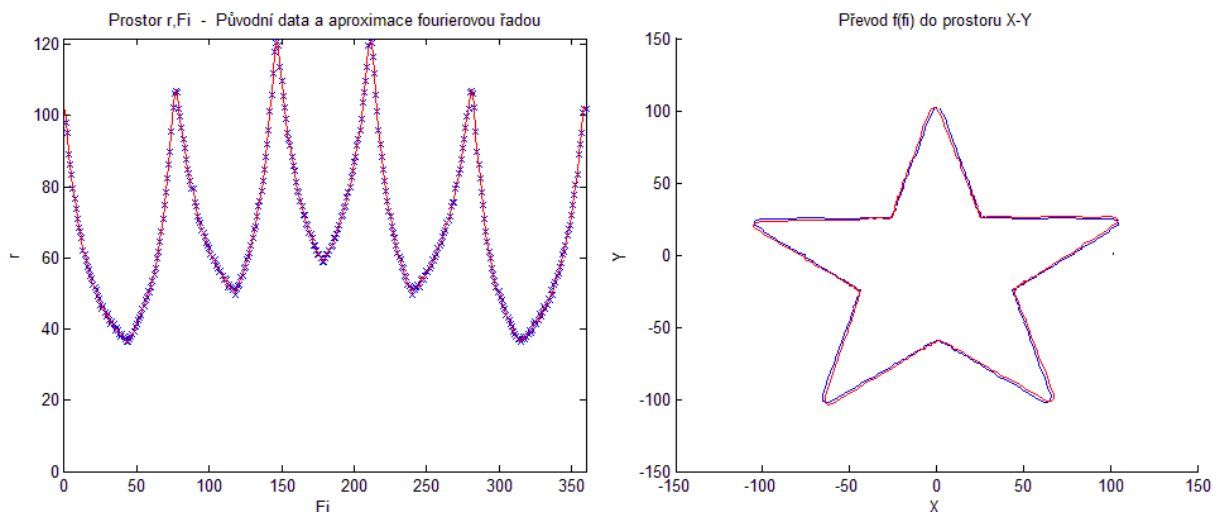
Předmětem verifikace je v tomto případě segment ve tvaru pěticípé hvězdy zobrazený na Obr.58. Segment byl pomocí kruhové tvarové transformace popsán diskrétním signálem, vektorem dat (Obr.69. a Obr.70. a Obr.71. vlevo, modře). Následně byl tento diskrétní signál proložen Fourierovou řadou s 5-ti harmonickými (Obr.69. vlevo, červeně), 15-ti harmonickými signály (Obr.70. vlevo, červeně) a 150-ti harmonickými signály (Obr.71. vlevo, červeně). Rekonstruovaný tvar signálu (Obr.69., Obr.70. a Obr.71 vpravo) zobrazuje rekonstrukci tvaru segmentu z Obr.58. pomocí zpětné kruhové tvarové transformace, došlo k převodu obrazu zpět do souřadnicového systému X,Y. Rekonstrukce původního diskretizovaného signálu je zobrazena modře a rekonstrukce na základě analytického vyjádření získaného aproximací Fourierovou řadou je zobrazena červeně.



Obr. 69. Kruhová tvarová transformace -aproximace čtverce Fourierovou řadou s 5-ti harmonickými složkami



Obr. 70. Kruhová tvarová transformace -aproximace čtverce Fourierovou řadou s 15-ti harmonickými složkami



Obr. 71. Kruhová tvarová transformace -aproximace čtverce Fourierovou řadou s 150-ti harmonickými složkami

V případě segmentu ve tvaru pěticípé hvězdy je aproximace tvaru dostatečná při užití 150-ti harmonických složek, při použití 15-ti harmonických složek lze pozorovat zkreslení tvaru

signálu, a tím i zkreslení původního tvaru segmentu obrazu, použití 5-ti harmonických složek nereflektuje skutečný tvar segmentu obrazu.

Pro praktické využití tvarové kruhové transformace je nutné definovat počet harmonických složek signálu takovým způsobem, aby co nejlépe reprezentoval skutečný tvar a parametry zkoumaného segmentu. Koeficient, který vyjadřuje míru, s jakou Fourierova řada aproximuje skutečný tvar segmentu obrazu lze vyjádřit například autokorelací (106) diskretizovaného signálu se signálem definovaným Fourierovou řadou.

$$R_{12}(\varphi) = \frac{1}{T} \int_{-T/2}^{T/2} f_1(\varphi + \tau) \cdot f_2(\varphi) dt = \frac{1}{T} \int_{-T/2}^{T/2} f_1(\varphi) \cdot f_2(\varphi + \tau) dt \quad (106)$$

Pro segmenty s ostrými tvary konverguje počet harmonických složek k nekonečnu, chceme-li dosáhnout zcela přesného popisu tvaru segmentu obrazu. V praxi je popis Fourierovou řadou s nekonečným, respektive velmi vysokým počtem harmonických složek téměř nemožný. Z tohoto důvodu tolerujeme mírné zkreslení, což nám umožňuje výrazně redukovat počet harmonických složek, kterými lze tvar objektu popsat. Verifikací bylo prokázáno, že vyšší počet harmonických složek než 150 není potřeba. Každý segment obrazu reprezentovaný maticí pixelů má alespoň v lokálním okolí pixelu ostrou hranu (každý pixel je definován jako prvek matice, tedy čtvercový objekt definované barvy a jasu). Popis Fourierovou řadou tak jako vedlejší efekt vyhlazuje tato lokální pixelová zkreslení tvaru obrazu.

Srovnání efektivity korelace standardního 2D obrazu s korelací signálu TKT

Tvarová kruhová transformace popisuje segment obrazu jednorozměrným periodickým signálem. Tento signál může být vyjádřen v diskretním nebo analytickém tvaru. Segment obrazu v prostoru X,Y je definován maticí prvků o rozměru tohoto segmentu. Teoretickým předpokladem je podstatné zvýšení efektivity, respektive rychlosti korelace v případě provádění korelační funkce, respektive autokorelační funkce těchto signálů.

Zvýšení rychlosti korelační funkce aplikované na signál vytvořený kruhovou tvarovou transformací vychází z předpokladu snížení iteračních cyklů, které je potřeba během výpočtu autokorelační funkce vykonat. Poměrné zvýšení rychlosti lze vyjádřit pomocí koeficientu e (107).

$$e = \frac{\text{length}(img) \cdot \text{heigh}(img)}{\text{length}(f(\varphi))} \quad (107)$$

Teoretický předpoklad byl nasimulován v prostředí Matlab. Níže uvedená Tab.6. zobrazuje výsledek času zpracování autokorelační funkce pro všech 6 vzorových segmentů zobrazených na Obr.58. Vzhledem ke zřejmému počtu iteračních cyklů bylo provedeno také měření času

zpracování. Autokorelační funkce signálu kruhové tvarové transformace byla prováděna na původním diskretizovaném signálu, s krokem 1° ($length(f(\varphi)) = 360^\circ$).

Koeficient e' vyjadřující poměrné zvýšení rychlosti na základě času lze vyjádřit jako (108):

$$e' = \frac{Corr_time(img)}{Corr_time(f(\varphi))} \quad (108)$$

Tabulka 7 uvádí výsledky simulace v prostředí Matlab.

Segment	Dimenze segmentu X,Y	Dimenze $f(\varphi)$	Čas korelace segmentu v prostoru X,Y (mS)	Čas korelace funkce $f(\varphi)$ (mS)	e	e'
Kruh	160 x 160 pix	360 vzorků	5,324 mS	0,125 mS	71	42
Obecný tvar	180 x 200 pix	360 vzorků	6,762 mS	0,146 mS	100	46
Pětiúhelník	195 x 185 pix	360 vzorků	6,715 mS	0,133 mS	100	50
Čtverec	160 x 160 pix	360 vzorků	5,632 mS	0,142 mS	71	39
Pěticípá hvězda	210 x 210 pix	360 vzorků	7,343 mS	0,147 mS	122	49
Srdce	197 x 200 pix	360 vzorků	6,929 mS	0,138 mS	109	50

Tab.6. Relativní zvýšení rychlosti autokorelační funkce $f(\varphi)$, *Autokorelační funkce byla vypočtena dle vztahu (106)

Z Tab.6 je patrné, že vykonání korelační funkce je pro danou sadu testovacích segmentů obrazu vyšší průměrně 46-ti násobně. Při srovnání s teoretickým předpokladem založeným pouze na množství iteračních kroků vidíme, že reálná hodnota zvýšení rychlosti a efektivity je přibližně poloviční. To je dáno především tím, jakým způsobem je korelační funkce implementována, respektive potřebou provádět výpočetní operace, které nejsou přímo závislé na počtu iterací samotného výpočtu.

Vzájemná korelační funkce kruhové tvarové transformace

Vzájemnou korelační funkcí tvarové kruhové transformace rozumíme korelaci původního diskretizovaného signálu transformace se signálem proloženým Fourierovou řadou. Cílem je verifikovat vhodnost použití vyjádření Fourierovou řadou jako analytického vyjádření minimalizací odchylky korelačního koeficientu.

Prvním krokem je transformace segmentu obrazu pomocí kruhové tvarové transformace na diskretizovaný periodický jednorozměrný signál. Následně se na tomto signále provede proložení Fourierovou řadou s definovaným počtem harmonických složek. Tyto dva signály navzájem koreluje, přičemž se snažíme prokázat, že se korelační koeficient těchto signálů blíží jedné tím více, čím lépe Fourierova řada aproximuje tento diskretizovaný periodický signál.

Verifikace je provedena pro všech 6 segmentů obrazu zobrazených na Obr.58. Verifikaci provádíme pro definovanou řadu harmonických složek, a to pro 1, 3, 5, 10, 15, 50, 100 a 150 harmonických složek. Tab.7. uvádí výsledky vzájemné korelační funkce těchto signálů pro definované segmenty obrazu a počet harmonických složek Fourierovy řady.

Počet harmonických složek	Kruh	Obecný tvar	Pětiúhelník	Čtverec	Pěticípá hvězda	Srdce
	Korelační koeficient p_n					
1	$p_1 = 0,9236$	$p_1 = 0,3283$	$p_1 = 0,6325$	$p_1 = 0,1044$	$p_1 = 0,3993$	$p_1 = 0,4699$
3	$p_3 = 0,9850$	$p_3 = 0,7838$	$p_3 = 0,7796$	$p_3 = 0,5378$	$p_3 = 0,4094$	$p_3 = 0,8467$
5	$p_5 = 0,9863$	$p_5 = 0,9460$	$p_5 = 0,9673$	$p_5 = 0,9368$	$p_5 = 0,8996$	$p_5 = 0,9670$
10	$p_{10} = 0,9863$	$p_{10} = 0,9956$	$p_{10} = 0,9916$	$p_{10} = 0,9832$	$p_{10} = 0,9765$	$p_{10} = 0,9956$
15	$p_{15} = 0,9864$	$p_{15} = 0,9978$	$p_{15} = 0,9964$	$p_{15} = 0,9933$	$p_{15} = 0,9900$	$p_{15} = 0,9990$
50	$p_{50} = 0,9866$	$p_{50} = 0,9996$	$p_{50} = 0,9994$	$p_{50} = 0,9996$	$p_{50} = 0,9996$	$p_{50} = 0,9998$
100	$p_{100} = 0,9872$	$p_{100} = 0,9998$	$p_{100} = 0,9996$	$p_{100} = 0,9997$	$p_{100} = 0,9998$	$p_{100} = 0,9999$
150	$p_{150} = 0,9912$	$p_{150} = 0,9999$	$p_{150} = 0,9998$	$p_{150} = 0,9998$	$p_{150} = 0,999$	$p_{150} = 0,9999$

Tab.7. Vzájemná korelační funkce původního diskretizovaného signálu s analytickým vyjádřením signálu Fourierovou řadou

Korelační koeficienty uvedené v Tab.7 byly vypočteny dle vztahu (95). Z výsledků je patrné, že pro popis kružnice je postačující jediná harmonická složka. Obecně lze poté prohlásit, že pro popis libovolného objektu, respektive libovolného testovaného segmentu je dostačující popis pomocí 15-ti harmonických složek. Při popisu 15-ti harmonickými složkami je koeficient vzájemné korelační funkce vždy vyšší než $p=0,99$. Korelační koeficient s touto hodnotou ukazuje na zcela minimální a prakticky již zanedbatelné zkreslení původního tvaru segmentu.

Verifikací jsme prokázali teoretické předpoklady vyvinutí metody tvarové kruhové transformace, a to především její praktický vliv na rychlost identifikace segmentů pomocí korelačních funkcí, dále schopnost věrně reprezentovat tvar segmentů složitých tvarů a segmentů s ostrými hranami. Verifikací bylo prokázáno, že kruhová tvarová transformace je zpětně reverzibilní, to znamená, že nedochází ke ztrátě informací o tvaru, velikosti, či jiných vlastnostech segmentu obrazu. Kruhová tvarová transformace se také vyznačuje tím, že umožňuje segmenty obrazu reprezentované maticí bodů (pixelů), vyjádřit ve formě jednorozměrného periodického signálu, jenž může být dán v analytickém tvaru jako funkce $f(\varphi)$ a popsán Fourierovou řadou s definovaným počtem harmonických složek.

6. Přínos práce v praktické oblasti

Praktický přínos práce spočívá ve vývoji a optimalizaci metod zpracování obrazu. Praktickým přínosem práce je optimalizace metody semínkového vyplňování oblastí „barvením“ takovým způsobem, že dochází k úspoře potřebné operační paměti a času během výpočtu metody pro specifikované množiny segmentů obrazu.

Druhým významným praktickým přínosem práce je vývoj původní metody nazývané Kruhová Tvarová Transformace, která umožňuje popsat segment obrazu reprezentovaný maticí prvků jako jednorozměrný, periodický signál, který lze analyticky vyjádřit ve formě Fourierovy řady.

Prezentované metody jsou součástí distribuovaného autonomního mobilního rozpoznávacího systému, řešeného v projektu TAČR TA01010632 „Inovace SCADA systém pro monitorování stavu v reálném čase“.

Výstupem této práce je podání patentové přihlášky s názvem „Distribuovaný autonomní mobilní rozpoznávací systém“ EV.č. PV 2012-616 a zároveň přihlášky užitého vzoru s názvem „Zařízení pro distribuovaný autonomní mobilní rozpoznávací systém“ EV.č. PUV 2012-26830 jichž jsem spolupůvodcem.

Přihlášený užiténý vzor EV.č. PUV 2012-26830 byl dne 19.11.2012 zapsán úřadem průmyslového vlastnictví. Řízení o zapsání patentu EV.č. PUV 2012-26830 stále probíhá, a úřad průmyslového vlastnictví ke dni konání obhajoby této disertační práce o udělení patentu nerozhodl.

Vyvíjené řešení je využitelné v oblasti automobilových systémů, robotiky, monitorovacích a zabezpečovacích systémů a řízení průmyslových procesů.

7. Další rozvoj práce

Další rozvoj práce by se měl zaměřovat na definici kruhové tvarové transformace pro segmenty, jenž nemají vlastní konvexní bod. Zde se naskýtá řešení ve formě rozdělení segmentu na menší subsegmenty, konvexní oblasti například pomocí algoritmu Ekoule, Perin nebo Odet. Tyto algoritmy pracují tak, že rozdělí nekonvexní oblast na řadu menších konvexních oblastí. Středem dalšího rozvoje práce by pak měl být způsob práce s těmito subsegmenty, jejich analýza a identifikace.

Práce by se měla zaměřit na definici kruhové tvarové transformace v rámci většího množství konvexních subsegmentů. Je potřeba definovat algoritmy a metody následné syntézy signálu transformace. Současně je podstatné definovat analytické řešení pro získání parametrů segmentu z tohoto signálu a dále pak metodiku vzájemné korelace signálů.

Další směr rozvoje metody kruhové tvarové transformace spočívá v definici matematického aparátu pro jednoznačnou identifikaci segmentu na základě vzájemné korelace signálů kruhové tvarové transformace, jenž jsou prostorově posunuty, respektive, které mají různě umístěny vlastní konvexní body, které jsou středem transformace. V tomto případě musí být před zahájením korelace signálů určen vzájemný posun středů transformace tak, aby bylo možno jeden ze signálů vhodně korigovat.

Metoda kruhové tvarové transformace má vysoký potenciál i v oblasti komprese dat, respektive komprese informací o segmentech obrazu. Umožňuje efektivně popsat segment obrazu jak z pohledu jeho parametrů (obvod, obsah, velikost apod.) tak i z pohledu jeho tvaru. Metoda kruhové tvarové transformace navíc zohledňuje i relativní umístění segmentu v prostoru v mezích definice středu transformace, respektive konvexního bodu transformace segmentu.

Zajímavou oblastí ve vztahu k definici konvexního bodu segmentu je i definice vzájemného transformačního vztahu s metodou popisu segmentu pomocí křivostí hrany. Ve speciálních případech může být derivací funkce křivosti hrany získána funkce metody kruhové tvarové transformace. Obecně toto ovšem neplatí, protože metoda křivosti hrany nemá jednoznačně definovanou periodu T , respektive perioda T závisí na délce hrany segmentu. Dále je metoda křivosti hrany nezávislá na konvexním bodu segmentu, a proto v řadě případů derivací její funkce získáme nesprávné řešení, respektive získané řešení není funkcí metody kruhové tvarové transformace.

Tato disertační práce může sloužit jako základ dalšímu výzkumu a vývoji metod parametrické analýzy a identifikace segmentů obrazu.

Shrnutí

Tato práce se soustředí na popis a vývoj metod zpracování obrazového signálu v průmyslovém prostředí, se zaměřením na metody segmentace, klasifikace a identifikace těchto segmentů v obrazu. Cílem práce je optimalizace stávajících metod zpracování obrazu a vývoj nových metod zpracování obrazu za účelem zvýšení jejich rychlosti a efektivity při zachování přesnosti a spolehlivosti v rámci identifikace a klasifikace daných segmentů obrazu ve smyslu zvýšení jejich robustnosti, tj. zachování přesnosti a spolehlivosti detekce prvků obrazové scény při sníženém poměru výkonu obrazového signálu k výkonu obrazového šumu.

V práci je uveden základní přehled všech nejčastěji používaných segmentačních algoritmů a metod. V rámci optimalizace stávajících segmentačních metod přináší práce nový pohled na metodu semínkového vyplňování oblastí (vyplňování barvením). Nová optimalizovaná metoda využívá maticového okolí pixelu, přičemž v jediném iteračním kroku označuje všechny okolní pixely, čímž výrazně redukuje množství referenčních bodů, které se vkládají do zásobníku pro označení v dalším iteračním cyklu. Výhodou tohoto přístupu je, že metoda z principu její funkce zajišťuje, že zásobník nebude obsahovat duplicitní souřadnice bodů, které je potřeba dále zpracovat. Nový návrh metody semínkového vyplňování s maticovým přístupem vylepšuje vlastnosti původní metody. Metoda není implementována pomocí rekurzivního volání, ale pomocí algoritmu s vlastním zásobníkem, což přináší značné výhody v souvislosti s kontrolou a řízením přístupu k využívané paměti. Teoretické předpoklady byly ověřeny matematickým modelem implementovaným v Matlabu.

Práce dále pojednává o návrhu původní, nově vyvinuté metody nazývané Kruhová Tvarová Transformace. Tato metoda popisuje segment obrazu reprezentovaný maticí pixelů pomocí jednorozměrného periodického diskrétního signálu, respektive pomocí Fourierovy řady s definovaným počtem harmonických složek, která tento signál vyjadřuje v analytickém tvaru. Transformace je zpětně reverzibilní, což znamená, že z vytvořeného periodického signálu transformace lze zpětně plně rekonstruovat původní segment obrazu beze ztráty informace o jeho tvaru, velikosti, či jiných parametřích. Kruhová Tvarová Transformace umožňuje klasifikovat segment obrazu tak, že lze na základě analytického vyjádření periodického signálu transformace přímo určit vlastnosti segmentu, jako je plocha, obvod segmentu, jeho velikost či relativní pozice a řadu dalších parametřích. Jednotlivé parametry segmentu mohou být také snadno měněny pouhou změnou parametřích periodického signálu. Například změnou konstantní složky signálu lze měnit velikost objektu, posunem fáze signálu lze pak segment rotovat a další. Transformace poskytuje značnou výhodu také v případě identifikace segmentu pomocí korelační funkce. Korelační funkce segmentů reprezentovaných maticí bodů koreluje dvourozměrný signál, čímž prudce narůstá počet iteračních cyklů korelace, které je potřeba vykonat, současně prudce narůstají nároky využití

paměti během výpočtu funkce. Periodický signál Kruhové Tvarové Transformace vyjádřený v analytickém nebo diskretním tvaru je jednorozměrný a lze jej snadno korelovat s požadovanými signály. Korelace segmentů obrazu vyjádřených signálem transformace je tak výrazně rychlejší a efektivnější jak z pohledu času, tak z pohledu využití paměti během výpočtu korelační funkce.

Teoretickým přínosem práce je prohloubení problematiky metod zpracování obrazu a poskytuje přehled nejčastěji používaných metod segmentace obrazu. Teoretickým přínosem je optimalizace metody semínkového vyplňování oblastí s maticovým přístupem. Teoretickým přínosem práce je také prohloubení problematiky klasifikace a identifikace segmentů obrazu. Práce přináší zcela nový pohled na způsob popisu a reprezentace segmentů obrazu reprezentovaných jako periodický jednorozměrný signál.

Praktickým přínosem práce je implementace matematického modelu optimalizované metody semínkového vyplňování s maticovým přístupem a implementace matematického modelu a principů původní nově vyvinuté metody nazývané Kruhová Tvarová Transformace. Implementované metody signálu jsou součástí distribuovaného autonomního mobilního systému pro řízení a monitorování průmyslových procesů vyvíjeného v rámci řešení projektu TAČR TA01010632 „Inovace SCADA systém pro monitorování stavu v reálném čase“. Pro tento vyvíjený systém byl zapsán užitečný vzor s názvem „Zařízení pro distribuovaný autonomní mobilní rozpoznávací systém“ EV.č. PUV 2012-26830 a zároveň podána přihláška patentu týkající se metodiky vyvíjeného systému s názvem „Distribuovaný autonomní mobilní rozpoznávací systém“ EV.č. PV 2012-616“.

Další vývoj práce spatřuji v prohloubení teorie Kruhové Tvarové Transformace, především specifikaci matematického aparátu v případě, že segment obrazu nemá vlastní konvexní bod, jenž by byl použit jako výchozí bod transformace. Zde lze metodu upravit takovým způsobem, že lze pomocí existujících matematických metod lze rozdělit segment na menší množství konvexních oblastí, respektive oblastí s vlastním konvexním bodem. Oblastí dalšího rozvoje práce by pak měl být způsob práce s těmito subsegmenty, jejich analýza a identifikace. Předložená disertační práce může sloužit jako základ dalšímu výzkumu a vývoji metod zpracování obrazu.

Literatura

- [1] ATTIYA, H. a WELCH, J. *Distributed computing: fundamentals, simulations, and advanced topics*. 2nd ed. Hoboken, NJ: Wiley. ISBN 04-714-5324-2
- [2] COUCH, L.W. *Digital and analog communication systems: fundamentals, simulations, and advanced topics*. 7th ed. Hoboken, NJ: Prentice Hall, 2007, 751 s. ISBN 01-314-2492-0.
- [3] HAĆ, A. *Wireless sensor network designs: fundamentals, simulations, and advanced topics*. 7th ed. Hoboken, NJ: J. Wiley, c2003, xiv, 391 p. ISBN 0-470-86736-1
- [4] JOHN, C. *Designing embedded hardware*. Vyd. 1. O'Reilly, 2003, 298 s. ISBN 05-960-0362-5..
- [5] GIBSON, J. *Image and video processing*. Southern Methodist university : Academic Press, 2000. 891 s.
- [6] GONZALEZ, C.; WOODS E. a EDDINS S. *Digital Image processing using MATLAB*. 2nd ed. Natick: Gatesmark Publishing, xviii, 826 s. ISBN 978-0-9820854-0-0.
- [7] O'GORMAN, L.; SAMMON M. a SEUL M. *Practical algorithms for image analysis: description, examples, programs, and projects*. 2nd ed. Cambridge, 2008, vi, 349 s. ISBN 978-0-521-88411-2.
- [8] SZELISKI, R. *Computer Vision: Algorithms and Applications*. London: Springer, 2010, xx, 812 s. ISBN 978-1-84882-934-3.
- [9] DUDA, R. *Pattern classification*. 2nd ed. New York: J. Wiley, 2001. ISBN 04-710-5669-3.
- [10] KAMEN, E.W.; HECK, B. *Fundamentals of Signals and Systems*. New Jersey : Prentice Hall Inc, 2000.
- [11] COUCH, L.W. *Modern communication systems: principles and applications*. New York: Prentice Hall, c1995. ISBN 00-232-5286-3.
- [12] COUCH, L.W. *Digital and analog communication systems*. 6th ed. Upper Saddle River, c2001, xxv, 758 s., [2] l. příl. ISBN 01-308-9630-6.
- [13] HLAVÁČ, V; SEDLÁČEK, M. *Zpracování signálu a obrazu*. 2. Praha: BEN – technická literatura, 2007. 255 s. ISBN 978-80-01-03110-0

- [14] DOBEŠ, M. *Zpracování obrazu a algoritmy v C#*. 1. české. Praha : BEN - technická literatura, 2008. 144 s. ISBN 978-80-7300-233-6.
- [15] SOJKA, E. *Digitální zpracování a analýza obrazu*. Ostrava : VŠB - Technická Univerzita Ostrava, 2000. 136 s.
- [16] KUKAL, J. Rozpoznávání obrazu. *Automatizace*. 2008, s. 754 - 756.
- [17] NEVRIVA, P. *Analýza signálů a soustav*, BEN, Praha 2000.
- [18] ZHAO, M. *Image Thresholding Techniques : Based On Fuzzy*
- [19] PITAS, I. *Digital Image Processing Algorithms and Application*. 1st ed. NewYork(USA): John Wiley & Sons, 2000. 418 s. ISBN 0-471-37739-2.
- [20] BRIŠ, R. *Exploratorní analýza proměnných*. Ostrava., 2005. VŠB-TUO.
- [21] JARÍK V. *Integrální počet I*, Academia, nakladatelství České akademie věd, Mové Město, 1973, 42 str, 5 vydání, 10000 výtisků.
- [22] PAL, N. R., PAL, S.K.: *A review on image segmentation techniques*, Pattern Recognition, 1993.
- [23] LUKEŠ, J. a MALÝ J. *Measure and integral*. 2nd ed. Prague: Matfyzpress, 2005, 225 s. ISBN ISBN 80-86732-68-1.
- [24] KOPÁČEK, J. *Matematická analýza nejen pro fyziky (III)*. 3., upr. vyd. Praha: Matfyzpress, 2007. ISBN 978-80-7378-020-3
- [25] DOUGHERTY, G. *Digital image processing for medical applications*. 1st ed. Cambridge: Cambridge University Press, xii, 447 s. ISBN 978-0-521-86085-7.
- [26] HEŘMÁNEK, L. *Sbírka příkladů z matematiky I ve strukturovaném studiu*. Vyd. 1. Praha: Vysoká škola chemicko-technologická, 204 s. ISBN 80-708-0574-9.
- [27] GONZALEZ, R. a WOODS R. *Digital image processing*. Reading, Mass.: Addison-Wesley, c1992. ISBN 02-015-0803-6.
- [28] RUSS, J.C. *The image processing handbook*. 6th ed. CRC Press, 2011, xviii, 867 p. ISBN 978-143-9840-450.
- [29] GONZALEZ, C. a WOODS R. *Digital image processing*. Upper Saddle River, c2008, xxii, 954 s. ISBN 01-316-8728-X.
- [30] FIŘT, J. a HOLOTA, R. *Digitalizace a zpracování obrazu*. 2012. vyd. Plzeň, Dostupné z: <http://home.zcu.cz/~holota5/publ/DigZprO.pdf>
- [31] HSV. In: *Wikipedia: the free encyclopedia* [online]. San Francisco (CA): Wikimedia Foundation, 2001- [cit. 2013-12-10]. Dostupné z: <http://cs.wikipedia.org/wiki/HSV>

- [32] Regionální segmentace a shlukování. [online]. [cit. 2013-12-10]. Dostupné z: <http://www.uamt.feec.vutbr.cz/vision/TEACHING/MPOV/06%20-%20Regionalni%20segmentace%20a%20shlukovani.pdf>
- [33] KOVÁŘ, B. *Identifikace zóny zájmu v obraze*. Praha, 1998. Dostupné z: euler.fd.cvut.cz/publikace/files/1998_AOI.pdf. Diplomová práce. ČVUT Praha.
- [34] KŘÍŠEK, P. Filtrace obrazu. ČVUT - PRAHA. [online]. Praha, 2000 [cit. 2013-12-10]. Dostupné z: <http://www.volny.cz/krizekp1/zso/uloha3.html>
- [35] Implementace detekce hran v obraze na vícejádrovém signálovém procesoru [online]. www.comtel.cz/files/download.php?id=5466, [cit. 2013-12-10].
- [36] Cannyho hranový detektor. In: *Wikipedia: the free encyclopedia* [online]. San Francisco (CA): Wikimedia Foundation, 2001- [cit. 2013-12-10]. Dostupné z: http://cs.wikipedia.org/wiki/Cannyho_hranov%C3%BD_detektor
- [37] TIPPNER, A. a ŽÍDEK V. Implementace segmentace obrazu na bázi rustu oblastí do prostředí GIS GRASS. 2009, s. 10. Dostupné z: http://gis.vsb.cz/GIS_Ostrava/GIS_Ova_2009/sbornik/Lists/Papers/015.pdf
- [38] STRAKA, S. *Segmentace obrazu*. Brno, 2009. Diplomová práce. Masarykova univerzita, Fakulta Informatiky. Vedoucí práce Mgr. Radka Pospíšilová
- [39] KUČERA J. Shluková analýza. [online]. 2000 [cit. 2013-12-10]. Dostupné z: http://is.muni.cz/th/172767/fi_b/5739129/web/web/kmeans.html
- [40] PETERSON, J.P. K-mean. [online]. 2010 [cit. 2013-12-10]. Dostupné z: <http://pypr.sourceforge.net/kmeans.html>
- [41] Počítačová grafika 2006 , PV – KID – UPCE. [online]. [cit. 2014-03-14]. Dostupné z: http://school.lynn.cz/grafika/prednasky/PG_2006_P04_Vyplnovani_4s.pdf
- [42] BAYER, Tomáš. *Základní techniky návrhu algoritmu, : Iterativní algoritmy. Převod rekurze na iteraci* [online]. Přírodovědecká fakulta UK, Praha, 2012 [cit. 2013-12-10].
- [43] BOUCHALA, P. *Matematická analýza 3*, Ostrava: VŠB - Technická univerzita, 2005.
- [44] BURDA, P. a DOLEŽALOVÁ, J. *Matematika III*. 1. vyd. Ostrava: VŠB - Technická univerzita. 310 s. ISBN 80-248-1195-2.
- [45] *Polar coordinate system* [online]. [cit. 2014-01-21]. Dostupné z: http://en.wikipedia.org/wiki/Polar_coordinate_system
- [46] 2012, PELIKÁN, J. *Rekonstrukce objektů a vizualizace objemových dat*, FU MINI. [online]. [cit. 2014-01-21]. Dostupné z: <http://statnice.dqd.cz/mgr-szz:in-gra:8-gra>
- [47] COHEN, D.; LEE, T. a SKLAR, D. *Precalculus with unit-circle trigonometry*. 4th ed. /. Belmont, CA: Thomson Brooks/Cole, c2006, 1. vyd. (various pagings). ISBN 05-342-5337-7.

- [48] BALÁTĚ, J. Automatické řízení. 2., přepracované vyd. Praha: BEN, 663 s. ISBN 80-730-0148-9
- [49] VAŠEK, V.: *Teorie automatického řízení II*. VUT v Brně, Brno, 1990.
- [50] KROLICZEK, F. *Sběr a zpracování dat pomocí LabView*. Brno, 2012. Bakalářská práce. VUT Brno, FEKT. Vedoucí práce Ing. Soňa Šedivá, Ph.D.
- [51] HRDINA, Z., VEJRAŤKA, F.: *Signály a soustavy*, vyd. Praha:2010 ČVUT, 234 s.
- [52] POSPÍŠIL, J.: *Teorie signálu a experimentu*, 1. vyd. Olomouc: Univerzita Palackého, 1993. 165 s. ISBN 80-706-7325-7.
- [53] ŠKALOUDOVÁ, A. *Korelační koeficient*, Univerzita Karlova. Praha, 2013, 5 s.

Vlastní publikace související s disertační prací

- [54] SROVNAL, Jr.,V.; MACHACEK, Z.; HERCIK, R.; SLABY, R.; SROVNAL V.; *Intelligent Car Control and Recognition Embedded System*, In Proceedings of International Multiconference on Computer Science and Information Technology, IMCSIT 2010, 18.-20. October 2010, Wisła, Poland, pp.831-836, IEEE CFP0964E, ISBN 978-83-60810-22-4, ISSN 1896-7094.
- [55] MACHACEK, Z.; SLABY, R.; HERCIK, R.; KOZIOREK, J.: *Advanced System for Consumption Meters with Recognition of Video Camera Signal*. Elektronika Ir Elektrotechnika Issue: 10(126), p.4 2012.
- [56] MACHACEK, Z., HERCIK, R., SLABY, R., *Smart User Adaptive System for Intelligent Object Recognizing*, In Studies of Computational Intelligence, New Challenges for Intelligent Information and Database Systems, Springer-Verlag Berlin, Germany, Volume 351, pp. 197-206. 2011. ISBN 978-3-642-19952-3.
- [57] SLABY, R.; HERCIK, R.; MACHACEK, Z. *Compression methods for image processing implementation into the low capacity device*, In Technical Gazette, Volume 20, No.6, 2013, p. 1087-1090, ISSN 1330-3651.
- [58] HERCIK, R.; SLABÝ, R. a MACHACEK, Z. *Image Processing for Low-power Microcontroller Application*. Przegląd elektrotechniczny. 2012, R 88, 12a, s. 343-346. ISSN 0033-2097.
- [59] HERCIK, R.; SROVNAL, V.; STANKUS, M.; SLABY R.; VANUS J. *Autonomous Recognition System for Traffic Signs Detection from Camera Images*. In: PDeS 2013, 10.3182/20130925-3-CZ-3023.00045, Ostrava: VSB-TUO, 2013.
- [60] HERCIK, R.; SLABY, R.; MACHACEK, Z.; KOZIOREK, J.. *Correlation methods of OCR algorithm for traffic sign detection implementace in microcontrollers*. In: International Joint Conference CISIS'12-ICEUTE'12-SOCO'12 Special Sessions: Advances in intelligent systems and computing. 1st ed. New York: Springer, 2012, s. 381-389. ISBN 978-3-642-33017-9ISSN 2194-5357.

Vlastní publikace ostatní

- [61] VANUS, J.; KOZIOREK, J.; HERCIK, R.; *The design of the voice communication in Smart Home Care*. 2013 36th International Conference on Telecommunications and Signal Processing (TSP). IEEE, 2013, s. 561-564. DOI: 10.1109/TSP.2013.6613996. Dostupné z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6613996>
- [62] VANUS, J.; KOZIOREK, J.; HERCIK, R.; *Design of a Smart Building Control with View to the Senior Citizens' Needs*. In: PDeS 2013, 10.3182/20130925-3-CZ-3023.00045, Ostrava: VSB-TUO, 2013.
- [63] HERCIK, R. *Safe HMI and Car to Car Communication*. In: WOFEX 2013: proceedings. Ostrava, VŠB-TUO, 2013, s. 6. ISBN 978-80-248-3073-5.
- [64] SLABÝ, R.; STANKUS, M.; HERCIK, R.; SROVNAL, V. *Graphical User Interface for Automatic Driver Loading*. In: TRANSCOM 2013: 10-th EUROPEAN CONFERENCE OF YOUNG RESEARCHERS AND SCIENTISTS. Žilina: EDIS-Žilina University publisher, 2013, p. 107-110. ISBN 978-80-554-0692-3.
- [65] CAMPOS, F.; HERCIK, R.; NEMEC, L.; SANTANA-ALONSO, A. *Interdisciplinary approach to renewable energy storage global planning*. In: WOFEX 2012: proceedings. Ostrava, 2012, s. 6. ISBN 978-80-248-2769-8.
- [66] HERCIK, R.. *Kamerové čipy v měření – srovnání dostupných technologií*. In: Workshop Perspektivní projekty vývoje řídicích a senzorických technologií 2012. Brno: LITERA Brno, 2012, s. 4. ISBN 978-80-214-4527-7.

Užitné vzory:

Název: Autonomní systém pro bezkontaktní analýzu stavu měřiče spotřeby
Zapsáno dne: 26.9.2013
Původci: Zdeněk Macháček, Zdeněk Masný, Radim Hercík, Roman Slabý, Jiří Koziorek
Číslo ochranného dokumentu: PUV 25906

Název: Zařízení pro distribuovaný autonomní mobilní rozpoznávací systém
Zapsáno dne: 19.11.2012
Původci: Vilém Srovnal, Radim Hercík, Martin Stankuš, Roman Slabý
Číslo ochranného dokumentu: PUV 24601

Název: Zařízení pro automatickou detekci a komunikaci se zařízeními na průmyslových komunikačních sítích
Zapsáno dne: 6.5.2013
Původci: Roman Slabý, Martin Stankuš, Radim Hercík, Vilém Srovnal
Číslo ochranného dokumentu: PUV 25308

Název: Modulární systém pro monitorování a transformaci standardů sériové komunikace
Zapsáno dne: 6.5.2013
Původci: Radim Hercík, Roman Slabý, Zdeněk Macháček
Číslo ochranného dokumentu: PUV 25306

Funkční vzorky:

Název: Modul komunikační a řídicí jednotky pro monitorování a řízení průmyslových procesů
Ev.Č.: 089/14-10-2013_F
Původci: Radim Hercík, Vilém Srovnal, Martin Stankuš, Roman Slabý

Název: Přípravek pro měření teploty a komunikaci prostřednictvím CAN sběrnice s ostatními zařízeními
Ev.Č.: 088/14-10-2013_F
Původci: Roman Slabý, Vilém Srovnal, Radim Hercík, Martin Stankuš

Název: Nádstavbový systém rozpoznávající hodnotu na ciferníku měřiče spotřeby
Ev.Č.: 228/20-12-2012_F
Původci: Zdeněk Macháček, Radim Hercík, Roman Slabý, Jiří Koziorek

Název: Souprava monitorovacích a transformačních modulů sériových komunikačních standardů
Ev.Č.: 227/20-12-2012_F
Původci: Zdeněk Macháček, Radim Hercík, Roman Slabý, Jiří Koziorek

Název: Laboratorní výukový modul pro naměření, záznam a zpracování obrazového signálu z kamerového systému

Ev.Č.: 112/13-12-2010_F

Původci: Zdeněk Macháček, Radim Hercík, Roman Slabý

Výzkumné aktivity

Název projektu: SCADA systém pro řízení a monitorování procesů v reálném čase
Číslo projektu: TACR TA1010632
Doba řešení: 1.1.2011 – 31.12.2013
Výzkumná funkce: Vývoj ovladačů Can, CanOpen pro RT QNX, programátorská činnost

Název projektu: Mikroprocesorové systémy pro měřicí a řídicí aplikace.
Číslo projektu: SGS_2014_156
Doba řešení: 1.1.2014 – 31.12.2014
Výzkumná funkce: Vývoj metod zpracování obrazu pro mikroprocesorové aplikace

Název projektu: Metody sběru a přenosu dat v distribuovaných systémech II.
Číslo projektu: SGS_2013_168
Doba řešení: 1.1.2013 – 31.12.2013
Výzkumná funkce: Vývoj metod zpracování obrazového signálu

Název projektu: Metody sběru a přenosu dat v distribuovaných systémech I.
Číslo projektu: SGS_2012_111
Doba řešení: 1.1.2012 – 31.12.2012
Výzkumná funkce: Vývoj metod zpracování obrazového signálu

Zahraniční působení a stáže:

University of Minho and Bosch, Portugal, Braga
ICCES 2013 – Innovation and Creativity for Complex Engineering System
ERASMUS IP, 17.6.2013 – 6.7.2013

University of Minho and Efacec, Portugal, Porto
ICCES 2013 – Innovation and Creativity for Complex Engineering System
ERASMUS IP, 30.1.2012 – 17.2.2012

Bang and Olufsen, Struer, Denmark
CDDIP 2010 – Conceptual Design and Development of Innovative Products
ERASMUS IP, 28.6.2010 – 16.7.2010

Pedagogická činnost

Výukové materiály a texty:

Tvorba výukových materiálů do předmětů „Modulované signály“, „Vestavěné řídicí systémy“, „Navrhování a realizace vestavěných řídicích systémů“ v rámci projektu Inovace oboru Měřicí a řídicí techniky na FEI - ESF CZ.1.07/2.2.00/15.0113

Projektová výuka, Zpracování obrazu, výukové podklady a návody pro řešení projektu. Radim Hercík, Zdeněk Macháček

Výuka:

Výuka – zimní semestr akademického roku 2012/2013, předmět Základy použití počítačů (ZPP3). Rozsah 4h/týden.

Výuka – letní semestr akademického roku 2012/2013, předmět Základy programování řídicích systémů (ZPRS). Rozsah 4h/týden.

Ostatní

- Vedení 3 bakalářských prací v akademickém roce 2013/2014
- Získání stipendia města Ostravy v akademickém roce 2009/2010, 2011/2012, 2012/2013 a 2013/2014
- Vedení studentů bakalářského studia v rámci soutěže Freescale Race Challenge 2011 až 2014, na které se umístili na 8 pozici ze 150 v rámci Evropy.
- 1.místo ve vědeckovýzkumné soutěži společnosti Freescale, zaměřené na autonomní řízení auta na autodráze ve školním kole VŠB-TU Ostrava, a 3. místo v mezinárodním kole v roce 2009 a 2011.
- Finalista národní univerzitní soutěže společnosti ABB v roce 2007 a 2008
- Členství v akademickém senátu Fakulty elektrotechniky a informatiky, VŠB – Technická univerzita Ostrava
- Členství v disciplinární komisi Fakulty elektrotechniky a informatiky, VŠB – Technická univerzita Ostrava

Seznam obrázků

Obr.1.	Metodika a struktura vyvíjeného systému.....	4
Obr.2.	Přehled segmentačních metod.....	7
Obr.3.	Princip segmentační metody Mean-shift.....	12
Obr.4.	Příklad aplikace K-means segmentační metody.....	13
Obr.5.	Segmentace pomocí algoritmu Záplava (funkce obrazu – vlevo, výsledná segmentace – vpravo.....	14
Obr.6.	Modul připojení 4 (vlevo), modul připojení 8 (vpravo).....	15
Obr.7.	Ukázka vstupní matice (vlevo) a výstupní matice (vpravo).....	15
Obr.8.	Logická funkce prvního cyklu „Two-pass“ algoritmu vyhledávání spojitostí.....	16
Obr.9.	Referenční tabulka.....	16
Obr.10.	Výsledek druhého průchodu cyklu „Two-pass“ algoritmu vyhledávání spojitostí.....	17
Obr.11.	Princip semínkového vyplňování.....	18
Obr.12.	Příklad implementace semínkového vyplňování pomocí rekurzivní funkce.....	19
Obr.13.	Řádková varianta semínkového vyplňování.....	20
Obr.14.	Princip optimalizovaného návrhu původního funkčního algoritmu pro vyhledávání spojitostí.....	21
Obr.15.	Obsah (bíle) a obvod (červeně) spojitě oblasti (vlevo), pozice spojitě oblasti (vlevo).....	23
Obr.16.	Paralelní výpočet parametrů objektů.....	24
Obr.17.	Výpočet obsahu objektů.....	24
Obr.18.	Výpočet obvodu objektů.....	25
Obr.19.	Výpočet pozice objektů.....	26
Obr.20.	Parametrický popis přímky.....	27
Obr.21.	Parametrický popis kružnice.....	28
Obr.22.	Popis skupinou vektorů.....	29
Obr.23.	Objekt a průběh křivosti po obvodě.....	30
Obr.24.	Kódování směrů ve Freemanově kódu(vlevo),Kódování tvaru křivky pomocí Freemanova kódu.....	31
Obr.25.	Princip tvarové kruhové transformace.....	33
Obr.26.	Amplitudové kmitočtové spektrum pro $\omega_v \geq 2\omega_m$	35
Obr.27.	Amplitudové kmitočtové spektrum pro $\omega_v < 2\omega_m$	35
Obr.28.	Vzorový signál.....	38
Obr.29.	Vzorový signál.....	40
Obr.30.	Grafická metoda pro určení koeficientů Fourierovy řady.....	40
Obr.31.	Posun segmentu do počátku souřadnicového systému X,Y.....	41
Obr.32.	Dopad posunu středu tvarové kruhové transformace na průběh funkce $f(\varphi)$	42
Obr.33.	Příklad rotace objektu jako vlastnost fázového posunu.....	45
Obr.34.	Projekce tvarové kruhové transformace do prostoru X, Y a r, φ pro vztah (53).....	46
Obr.35.	Projekce tvarové kruhové transformace do prostoru X, Y a r, φ pro vztah (54).....	46
Obr.36.	Projekce tvarové kruhové transformace do prostoru X, Y a r, φ pro vztah (55).....	47
Obr.37.	Projekce tvarové kruhové transformace do prostoru X, Y a r, φ pro vztah (56).....	47
Obr.38.	Projekce tvarové kruhové transformace do prostoru X, Y a r, φ pro vztah (57).....	47
Obr.39.	Projekce tvarové kruhové transformace do prostoru X, Y a r, φ pro vztah (58).....	48
Obr.40.	Projekce tvarové kruhové transformace do prostoru X, Y a r, φ pro vztah (60).....	48
Obr.41.	Projekce tvarové kruhové transformace do prostoru X, Y a r, φ pro vztah (61).....	49
Obr.42.	Projekce tvarové kruhové transformace do prostoru X, Y a r, φ pro vztah (62).....	49
Obr.43.	Projekce tvarové kruhové transformace do prostoru X, Y a r, φ pro vztah (63).....	49
Obr.44.	Projekce tvarové kruhové transformace do prostoru X, Y a r, φ pro vztah (64).....	50
Obr.45.	Projekce tvarové kruhové transformace do prostoru X, Y a r, φ pro vztah (65).....	50
Obr.46.	K rozdílu mezi teoretickou a skutečnou hranicí, Teoretická délka 5π , skutečná je 20.....	52
Obr.47.	Vzdálenost pixelu od hranice.....	53
Obr.48.	Třídění segmentů metodami parametrické analýzy.....	54
Obr.49.	Klasifikace segmentů s využitím parametrické analýzy.....	55

Obr.50. Princip převodu polárních souřadnic do systému XY.....	56
Obr.51. Ortogonální posunuté signály.....	58
Obr.52. Výpočet a průběh korelační funkce pro signály z Obr.50.....	59
Obr.53. Příklad korelačního koeficientu pro rozložení bodů v dvourozměrném prostoru.....	62
Obr.54. Přítomnost odlehlých hodnot (vlevo), podskupina objektů (vpravo).....	63
Obr.55. První testovací skupina bin. obr. pro ověření vlastností algoritmů v závislosti na plošné velikosti spojitosti....	66
Obr.56. Druhá testovací skupina bin. obr. pro ověření vlastností algoritmů v závislosti na počtu spojitých oblastí.....	67
Obr.57. Využití operační paměti funkcí během zpracování testovacího obrázku 4.....	69
Obr.58. Testovací originální segmenty obrazu.....	71
Obr.59. Kruhová tvarová transformace -aproximace kružnice Fourierovou řadou s 1 harm. sl.	71
Obr.60. Kruhová tvarová transformace -aproximace obecného segmentu Fourierovou řadou s 5-ti harm. sl.	72
Obr.61. Kruhová tvarová transformace -aproximace obecného segmentu Fourierovou řadou s 15-ti harm. sl.	72
Obr.62. Kruhová tvarová transformace -aproximace pětiúhelníku Fourierovou řadou s 5-ti harm. sl.	73
Obr.63. Kruhová tvarová transformace -aproximace pětiúhelníku Fourierovou řadou s 15-ti harm. sl.	74
Obr.64. Kruhová tvarová transformace -aproximace „srdce“ Fourierovou řadou s 5-ti harm. sl.	74
Obr.65. Kruhová tvarová transformace -aproximace „srdce“ Fourierovou řadou s 15-ti harm. sl.	75
Obr.66. Kruhová tvarová transformace -aproximace čtverce Fourierovou řadou s 5-ti harm. sl.	75
Obr.67. Kruhová tvarová transformace -aproximace čtverce Fourierovou řadou s 15-ti harm. sl.	76
Obr.68. Kruhová tvarová transformace -aproximace čtverce Fourierovou řadou s 150-ti harm. sl.	76
Obr.69. Kruhová tvarová transformace -aproximace čtverce Fourierovou řadou s 5-ti harm. sl.	77
Obr.70. Kruhová tvarová transformace -aproximace čtverce Fourierovou řadou s 15-ti harm. sl.	77
Obr.71. Kruhová tvarová transformace -aproximace čtverce Fourierovou řadou s 150-ti harm. sl.	77

Seznam tabulek

Tab.1. Příklad Numerické metody výpočtu koeficientů Fourierovy řady.....	39
Tab.2. Srovnání rychlosti běhu metod vyhledání spojitých oblastí v závislosti na změně plochy spojitosti.....	67
Tab.3. Využití operační paměti při zpracování metod vyhledání spojitých oblastí dle velikosti plochy spojitosti.....	67
Tab.4. Srovnání rychlosti běhu metod vyhledání spojitých oblastí v závislosti na počtu spojitostí.....	68
Tab.5. Srovnání využití operační paměti během vykonávání metod vyhledání spojitých oblastí dle počtu spojitostí....	68
Tab.6. Relativní zvýšení rychlosti autokorelační funkce $f(\varphi)$	79
Tab.7. Vzájemná korelační funkce diskretizovaného signálu s analytickým vyjádřením signálu Fourierovou řadou.....	80

Vyjádření spolupůvodců o předmětu průmyslového vlastnictví

Předmět průmyslového vlastnictví:

Podání přihlášky patentu s názvem „Distribuovaný autonomní mobilní rozpoznávací systém“ EV.č. PV 2012-616 k úřadu průmyslového vlastnictví ČR.

Vymezení podílu na řešení Ing. Radimem Hercíkem:

Podíl původce spočívá v návrhu dílčí části koncepce systému. Tím je specifikace funkční struktury metod sběru, přenosu, analýzy a zpracování obrazových dat. Návrh dílčí části databáze rozpoznávaných a systémových dat, návrh dílčí části databáze algoritmů a metod a specifikace některých základních funkčních požadavků. Původce se věnuje vývoji metod sběru, přenosu a zpracování dat z kamerových systémů a zároveň vývoji metod zpracování obrazového signálu se zaměřením na parametrickou analýzu a identifikaci segmentů obrazu.

Procentuální podíly původců:

Ing. Radim Hercík	30%
Ing. Vilém Srovnal, Ph.D.	30%
Ing. Roman Slabý	20%
Ing. Martin Stankuš	20%

V Ostravě dne 28.2.2014

Ing. Vilém Srovnal, Ph.D.

Ing. Roman Slabý

Ing. Martin Stankuš

Vyjádření spolupůvodců o předmětu průmyslového vlastnictví

Předmět průmyslového vlastnictví:

Zapsání užitého vzoru u úřadu průmyslového vlastnictví (UPV) s názvem „Zařízení pro distribuovaný autonomní mobilní rozpoznávací systém“ EV.č. PUV 2012-26830, číslo ochranného dokumentu 24601.

Vymezení podílu na řešení Ing. Radimem Hercíkem:

Podíl původce spočívá v návrhu dílčí části koncepce systému. Tím je specifikace funkční struktury metod sběru, přenosu, analýzy a zpracování obrazových dat a specifikace některých základních funkčních požadavků. Původce v rámci vývoje dílčí části systému proved implementaci a testování části metod sběru, přenosu, zpracování a analýzy obrazových dat, současně se podílí na vývoji nových metod zaměřených na segmentaci, parametrickou analýzu a identifikaci segmentů obrazu.

Procentuální podíly původců:

Ing. Radim Hercík	30%
Ing. Vilém Srovnal, Ph.D.	30%
Ing. Roman Slabý	20%
Ing. Martin Stankuš	20%

V Ostravě dne 28.2.2014

Ing. Vilém Srovnal, Ph.D.

Ing. Roman Slabý

Ing. Martin Stankuš