



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY

A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICINAL ENGINEERING

TVAROVÁ ANALÝZA OBRAZOVÝCH DAT

IMAGE DATA SHAPE ANALYSIS

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Jakub Kylián

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Jiří Chmelík

BRNO 2017

Bakalářská práce

bakalářský studijní obor **Biomedicínská technika a bioinformatika**

Ústav biomedicínského inženýrství

Student: Jakub Kylián

ID: 174509

Ročník: 3

Akademický rok: 2016/17

NÁZEV TÉMATU:

Tvarová analýza obrazových dat

POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s problematikou tvarové analýzy obrazových dat a proveďte literární rešerši dostupných metod. 2) Navrhněte vhodné metody pro určení tvarových vlastností objektů v obrazových datech. 3) Realizujte software pro výpočet tvarových příznaků ve zvoleném programovém prostředí a algoritmy otestujte na simulovaných datech. 4) Realizovaný software rozšiřte pro práci se 3D obrazy. 5) Navržené algoritmy otestujte na reálných medicínských datech. 6) Dosažené výsledky vyhodnoťte a diskutujte.

DOPORUČENÁ LITERATURA:

[1] COSTA, Luciano da Fontoura a Roberto Marcondes. CESAR. Shape analysis and classification: theory and practice. 1. Boca Raton: CRC Press, c2001. ISBN 08-493-3493-4.

[2] NEAL, F. Brent. a John C. RUSS. Measuring shape. 1. Boca Raton: CRC Press, c2012. ISBN 978-143-98-5-980.

Termín zadání: 6.2.2017

Termín odevzdání: 14.8.2017

Vedoucí práce: Ing. Jiří Chmelík

Konzultant:

prof. Ing. Ivo Provazník, Ph.D.
předseda oborové rady

UPOZORNĚNÍ:

Autor bakalářské práce nesmí při vytváření bakalářské práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

Abstrakt

Bakalářská práce se zabývá tvarovou analýzou obrazových dat, popisuje tedy metody, techniky a postupy, které k takové analýze vedou. Obsah práce je rozdělen do tří kapitol – Teoretická, řešení studentské práce a závěr.

V části teorie jsou popsány metody, které jsou následně využity v části řešení, ale i obecná teorie přímo související s tématem. Pravidlem je tedy, že použitá metoda v části řešení je popsána v části teoretické do detailů, nicméně tato skutečnost nemusí nutně platit i naopak.

V návaznosti na kapitolu teoretickou je řešení studentské práce. V kapitole řešení studentské práce je prezentován problém, který je, díky znalostem z teorie, vyřešen. Řešení sestává z více analytických procesů a patřičných příprav, které jsou v této části zcela jasně definovány.

Poslední část, závěr, slouží jako shrnutí přípravy, průběhu a zhodnocení řešení analýzy. Zároveň může posloužit jako prostor pro prezentaci nápadů, analogií, neprezentovaných metod a jiných postupů, které by mohly mít kladný či záporný vliv na výsledek práce, tedy i na její závěr.

Klíčová slova

analýza, tvar, obrys, obraz, deskriptor, generování

Abstract

Bachelor thesis is focused on shape analysis of image data. This thesis clarifies usage of methods, techniques and procedures that lead to such analysis. The content of this thesis is divided into three chapters – theory, analysis solution and conclusion.

In the chapter theory, methods and general theory of the topic are introduced. The rule is, that every method used in subsequent sections is explained in detail, but this doesn't necessarily mean that it applies in reverse.

Next chapter, following up the theory section is analysis solution. In this section, a problem is presented. This problem is then, with knowledge presented in chapter theory solved. The solution consists of many processes and preparations that are also explained in detail in this chapter.

Keywords

analysis, shape, contour, image, descriptor, generating

KYLIÁN, J. *Tvarová analýza obrazových dat*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2017. 44 s. Vedoucí bakalářské práce Ing. Jiří Chmelík.

Prohlášení

„Prohlašuji, že svou závěrečnou práci na téma Tvarová analýza obrazových dat jsem vypracoval samostatně pod vedením vedoucího bakalářské práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené závěrečné práce dále prohlašuji, že v souvislosti s vytvořením této závěrečné práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

V Brně dne **14. srpna 2017**

.....

podpis autora

Poděkování

Děkuji vedoucímu bakalářské práce Ing. Jiřímu Chmelíkovi za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé bakalářské práce.

V Brně dne **14. srpna 2017**

.....

podpis autora

Obsah

Úvod	1
1 TEORETICKÁ ČÁST	2
1.1 PŘÍPRAVA OBRAZOVÝCH DAT	2
1.1.1 MORFOLOGICKÉ ZPRACOVÁNÍ OBRAZU	3
1.1.2 ODSTRANĚNÍ ŠUMU	5
1.1.3 DETEKCE REGIONŮ	5
1.2 TVAROVÁ ANALÝZA	7
1.2.1 TVAROVÉ DESKRIPTORY 2D OBRAZOVÝCH DAT	7
1.2.2 TOPOLOGICKÉ PRVKY	9
1.2.3 POKROČILÉ METODY TVAROVÉ ANALÝZY	10
1.2.4 DESKRIPTORY 3D OBRAZOVÝCH DAT	13
1.3 KLASIFIKACE OBRAZOVÝCH DAT	15
2 ŘEŠENÍ STUDENTSKÉ PRÁCE	17
2.1 REALIZACE METOD TVAROVÉ ANALÝZY	17
2.1.1 DETEKCE REGIONŮ	18
2.1.2 ZÍSKÁNÍ DESKRIPTORŮ	19
2.2 GENEROVÁNÍ ZÁKLADNÍCH 2D OBRAZŮ	20
2.2.1 DISKUZE VÝSLEDKŮ GENEROVANÝCH TVARŮ	27
2.2.2 KLASIFIKACE SYNTETICKÝCH DAT	31
2.3 REÁLNÁ OBRAZOVÁ DATA	31
2.3.1 VÝSLEDKY ANALÝZY	31
2.3.2 KLASIFIKACE OBRATLŮ	33
2.3.3 DISKUZE VÝSLEDKŮ KLASIFIKACE	38
2.4 GENEROVÁNÍ ZÁKLADNÍCH 3D OBJEKTŮ	40
3 ZÁVĚR	44
Literatura	45
Seznam příloh	47

Seznam obrázků

Obr. 1: Zernikovy momenty pro různé tvary a jejich rotaci	13
Obr. 2: Kartézská soustava pro 3D prostor	14
Obr. 3: Hammingova síť	16
Obr. 4: Generovaný čtverec	21
Obr. 5: Obrys generovaného čtverce	21
Obr. 6: Vzdálenosti bodů obrysu od centroidu generovaného čtverce	21
Obr. 7: 1D-FD generovaného čtverce	21
Obr. 8: Generovaný obdélník	22
Obr. 9: Obrys generovaného obdélníku	22
Obr. 10: Vzdálenosti bodů obrysu od centroidu generovaného obdélníku	22
Obr. 11: 1D-FD generovaného generovaného obdélníku	22
Obr. 12: Generovaný kruh	23
Obr. 13: Obrys generovaného kruhu	23
Obr. 14: Vzdálenosti bodů obrysu od centroidu generovaného kruhu	23
Obr. 15: 1D-FD generovaného kruhu	23
Obr. 16: Generovaný trojúhelník	24
Obr. 17: Obrys generovaného trojúhelníku	24
Obr. 18: Vzdálenosti bodů obrysu od centroidu generovaného trojúhelníku	24
Obr. 19: 1D-FD generovaného trojúhelníku	24
Obr. 20: Generovaný kosočtverec	25
Obr. 21: Obrys generovaného kosočtverce	25
Obr. 22: Vzdálenosti bodů obrysu od centroidu generovaného kosočtverce	25
Obr. 23: 1D-FD generovaného kosočtverce	25
Obr. 24: Generovaný mnohoúhelník	26
Obr. 25: Obrys generovaného mnohoúhelníku	26
Obr. 26: Vzdálenosti bodů obrysu od centroidu generovaného mnohoúhelníku	26
Obr. 27: 1D-FD generovaného mnohoúhelníku	26
Obr. 28: Přední část obratle C3	32
Obr. 29: Zadní část obratle C3	32
Obr. 30: Obrys těla obratle z Obr. 28	32
Obr. 31: Obrys těla obratle z Obr. 29	32
Obr. 32: Vzdálenost bodů obrysu od centroidu pro P1C3* – přední část	32
Obr. 33: Vzdálenost bodů obrysu od centroidu pro P1C3* – zadní část	32
Obr. 34: 1D-FD P1C3* – přední část	32
Obr. 35: 1D-FD P1C3* – zadní část	32
Obr. 36: Hammingova síť, shluk s referenčním obrazem P1C3	34

Obr. 37: Hammingova síť, shluk s referenčním obrazem P1L3	34
Obr. 38: Hammingova síť, shluk s referenčním obrazem P1L5	35
Obr. 39: Hammingova síť, shluk s referenčním obrazem P1Th4	35
Obr. 40: Hammingova síť, shluk s referenčním obrazem P1Th10	36
Obr. 41: Stupně příslušnosti pro geometrické deskriptory	37
Obr. 42: Stupně příslušnosti pro 1D-FD	37
Obr. 43: Stupně příslušnosti pro Zernikovy momenty	38
Obr. 44: Generovaná koule	40
Obr. 45: Generovaná krychle	41
Obr. 46: Generovaný kvádr	41
Obr. 47: Generovaný jehlan	42
Obr. 48: Legenda pro Tab. 15.....	43

Seznam tabulek

Tab. 1: Pomocná matice	18
Tab. 2: Zernikovy momenty generovaného čtverce	21
Tab. 3: Zernikovy momenty generovaného obdélníku.....	22
Tab. 4: Zernikovy momenty generovaného kruhu.....	23
Tab. 5: Zernikovy momenty generovaného trojúhelníku.....	24
Tab. 6: Zernikovy momenty generovaného kosočtverce.....	25
Tab. 7: Zernikovy momenty generovaného mnohoúhelníku.....	26
Tab. 8: Přehled geometrických deskriptorů pro vygenerované 2D tvary.....	28
Tab. 9: Ukázka kruhu o velikosti $r=1px$	28
Tab. 10: Geometrické deskriptory P1C3	33
Tab. 11: Zernikovy momenty P1C3	33
Tab. 12: Zernikovy momenty P1C3-2.....	33
Tab. 13: Klasifikace obratlů – binární	36
Tab. 14: Úspěšnost klasifikace založené na srovnání deskriptorů	39
Tab. 15: Vzdálenosti bodů obrysu od centroidu pro generovanou kouli	42

ÚVOD

Tvarová analýza, jak již z názvu napovídá, je proces, jehož výsledkem je popis objektů (tvarů) nacházejících se v obrazových datech. Každý tvar je možné popsat pomocí mnoha deskriptorů, které mohou být založeny na matematické analýze, Fourierově transformaci, momentech nebo jiných metodách. Získaný popis je možné využít v odvětvích jako je archeologie, architektura, biomedicína, počítačové vědy a jiné.

V této práci je kladen důraz především na využití analýzy pro biomedicínu a biomedicínská data, kde tvarová analýza může sloužit např. jako prostředek pro detekci změn nebo nesrovnalostí při diagnostických vyšetřeních, které jsou založeny na hodnocení snímků pacienta. Sofistikovanějším využitím tvarové analýzy může být klasifikace objektů v obraze a srovnání s objekty referenčními.

Skrze tuto práci budou prezentovány, vysvětleny a v poslední kapitole i aplikovány jednotlivé metody a procesy, které vedou k tvarové analýze.

Pro názornost a jednoduchost je tvarová analýza nejprve aplikována na generovaná obrazová data, která jsou předem jasně definovaná a slouží jako kontrolní bod, který podává kvalitativní informace o správnosti použitých metod, respektive správnosti samotné analýzy. Reálná data, tedy biomedicínské snímky, podstupují stejnou analýzu a na základě hodnot, respektive rozdílů hodnot, odpovídajících deskriptorů je dosaženo objektivního porovnání tvarů.

1 TEORETICKÁ ČÁST

Teoretická část se skládá z podkapitol **příprava obrazových dat**, **tvárová analýza a klasifikace obrazových dat**. V každé ze zmíněných podkapitol jsou popsány metody a procesy, které jsou nezbytné pro provedení analýzy. Zároveň slouží tato kapitola jako předloha pro část řešení.

1.1 PŘÍPRAVA OBRAZOVÝCH DAT

Před samotnou tvarovou analýzou je nutné obraz zpracovat tak, aby bylo možné využít všechny metody popsané v následujících sekcích, které jsou závislé nebo alespoň významně benefitující právě ze správného předzpracování. Pokud by obraz zůstal nezpracován, metody by v mnoha případech nebyly spolehlivé a podávaly by zavádějící výsledky.

BINARIZACE

Pro tuto práci je uvažováno obrazových dat z biomedicínské oblasti, které jsou v původní formě v naprosté většině definovány v šedotónové reprezentaci. Metody použité pro tvarovou analýzu předpokládají obraz černobílý (binární), proto je nutné původní obrazová data příslušně zpracovat a převést do černobílého provedení. Při převodu je nutné brát v potaz atributy definující původní obraz, na kterých je kvalita převodu přímo závislá. Převodu lze docílit např. pomocí prahování, při kterém jsou jednotlivé pixely obrazu zařazeny do jedné ze dvou skupin – černá (hodnota pixelu 0) nebo bílá (hodnota pixelu 1). Vyhodnocení je založeno na jednoduchém posouzení, zda je hodnota pixelu vyšší nebo nižší, než je hodnota zadaného prahu a zařazení do příslušné skupiny.

Problém nastává v případě, kdy je práh nastaven nevhodně, například na velmi vysokou hodnotu (relativní k obrazu) a pixely, které nesou informaci tak mohou být zařazeny do skupiny černá (hodnota 0), čímž dojde k nevratné ztrátě užitečné informace. Hodnota prahu je definována ručně nebo automaticky s pomocí algoritmu, samotné prahování pak může být lokální, kdy je práh nastavován zvlášť pro každou oblast o určité velikosti či globální, kdy je práh pro celý obraz nastaven stejný. Pokud je již původní obraz v černobílém provedení, je možné tento krok ignorovat.

1.1.1 MORFOLOGICKÉ ZPRACOVÁNÍ OBRAZU

Výsledkem morfologického zpracování je změna obsahu binárních regionů v obraze na základě zvoleného strukturního elementu a hodnot v sousedících pixelech [11, 10]. Příslušná úprava je provedena v zadaném rozsahu, tedy lokálně nebo globálně.

Základními morfologickými operacemi jsou **eroze** a **dilatace**. Erozi rozumíme snižování obsahu regionů tak, že dochází ke změně stavů pixelů z hodnoty 1 na hodnotu 0. Změněny jsou pixely, které se nachází v místech přechodu mezi bílou a černou barvou (mezi hodnotami 1 a 0) pro daný region. Množství změn je dáno atributy strukturního elementu, který bude definován dále. Dilatace je proces opačný erozi, je tedy zvyšován obsah regionů podobným způsobem – dochází ke změně stavů pixelů z hodnot 0 na hodnoty 1 v místech přechodu definovaného výše. Množství je opět závislé na attributech strukturního elementu. Dilatace je zároveň jedním z procesů, který umožňují vyplnit díry (regiony s pixely hodnoty 0) uvnitř objektu. Tyto procesy jsou nejčastěji využívány v několika iteracích k docílení požadované úpravy obrazu, tzn. k redukci šumu, lokalizaci hran, tvorbě obrysů apod.

Dilatace a eroze nepatří pouze do morfologických operací, ale také do operací celulárních, které dosahují podobných výsledků, ale liší se použitými postupy. Jako jeden z rozdílů je možné uvést, že celulární zpracování má schopnost zachovat propojení objektů uvnitř obrazu [11]. Dalším rozdílem je schopnost morfologického zpracování volit velikost a tvar objektu, které budou procesy eroze a dilatace ovlivněny [11]. V této práci bude využito pouze morfologického zpracování obrazu.

EROZE A DILATACE

Operace morfologického zpracování jsou běžně využívány pro redukci šumu a detekci objektů v obraze. Šum by měl být potlačen co nejvíce, ale pouze do takové míry, aby procesy s tím spojené nedegradovaly samotný obraz.

Morfologické operace pracují se strukturními elementy. Základní strukturní element je možné si představit jako dvojrozměrnou matici $S(i, j)$ o velikosti $k_1 \times k_2$ [11]. Hodnoty v matici nabývají hodnot podle toho, jaký tvar má strukturní element představovat. Hodnoty nemusí být nastaveny symetricky, ale je nutné, aby byl explicitně nastaven počátek. Běžnými tvary strukturních elementů jsou: čtverec, kruh či orientovaná úsečka.

Každá morfologická operace probíhá tak, že je počátek strukturního elementu postupně aplikován na každý pixel a sousední pixely tak definuje jako $N_S(i_0, j_0)$, kde (i_0, j_0) jsou souřadnice počátku [11].

EROZE

Eroze je proces, při kterém dochází ke zmenšování regionu a tvorbě děr v místě, kde se nachází počátek strukturního elementu. Pokud je počátek aplikován na pixel, kde nedochází k překrytí všech hodnot 1 strukturního elementu okolními pixely, je hodnota takového pixelu nastavena na 0. To způsobí snížení počtu pixelů s hodnotou 1. Pokud je počátek aplikován na pixel s hodnotou 1 a zároveň zde dochází k překrytí, hodnota pixelu zůstává 1.

DILATACE

Dilatace je proces, při kterém dochází ke zvětšování regionu a tím také k plnění děr v místě, kde se nachází počátek strukturního elementu. Pokud je strukturní element překryt hodnotami 1, je hodnota počátku změněna nebo mu tato hodnota zůstává v případě, že již hodnotu 1 měl. Takto dochází ke zvyšování počtu pixelů ve stavu 1.

MORFOLOGICKÉ OTEVŘENÍ A ZAVŘENÍ

Základní morfologické transformace se skládají z kombinace eroze a dilatace. Proces otevření je zahájen erozí, která snižuje šum, vyhlazuje hrany a „rozpojuje“ úzká místa. Následuje dilatace, která vrací regiony přibližně do svých původních velikostí a vyplňuje vzniklé díry. Proces zavření je opakem otevření, dilatace tedy předchází erozi.

Výběr mezi těmito procesy je dán příznaky v obraze. Při velkém počtu menších objektů je výhodnější využít otevření z důvodu snížení šumu. Naopak, pokud v obraze došlo k nežádoucímu rozdělení regionů, ať už v důsledku eroze či jako chyba snímání, je vhodné použít zavření, aby bylo propojení obnoveno.

DALŠÍ MORFOLOGICKÉ ÚPRAVY

V kapitole řešení **studentské práce** jsou využity metody zpracování, které byly popsány výše, pro úplnost je ovšem nutné se zmínit i o dalších možnostech zpracování obrazu:

- Celulární zpracování
- Top-hat transformace
- Bottom-hat transformace
- Hit-and-Miss
- Skeletonizace
- Distanční mapa
- Komplement obrazu
- Binární sjednocení a průnik
- Šedotónová inkluse
- A další...

1.1.2 ODSTRANĚNÍ ŠUMU

Většina analytických metod je závislá nebo alespoň významně benefitující ze zlepšení poměru signál/šum. Obraz s nižším zastoupením šumu má tendenci být spolehlivější a robustnější pro další manipulaci [11]. Zároveň jsou z obrazu odstraněny přebytečné informace a obraz je proto menší z hlediska paměti.

V této sekci jsou popsány druhy šumu, s kterými je možné se v biomedicíně setkat. Těmi nejčastějšími jsou Gaussovský šum a impulsní šum [15]. Dále je nutné zmínit i druhy méně časté: „shot“ (Poissonův) šum, „rician“ šum. Tato práce ovšem není zaměřena na odstranění šumu, zmíněn bude tedy pouze šum impulsní, který je v medicínských obrazech nejběžnější [11, 10] a je nutné jej odfiltrovat, aby bylo možné použít metody obsažené v této práci.

IMPULSNÍ ŠUM

Impulsní šum, někdy nazývaný také šum typu sůl-pepř, je často následkem defektního snímače nebo neúměrně dlouhé expozici části snímaného tělesa [15]. Je definován jako rozlohou malý region (často pouze jeden pixel), který nabývá hodnot jiných, než mají okolní pixely [11]. Malý region musí být pro každý obraz definován zvlášť, aby nemohlo dojít k tomu, že bude odfiltrován relevantní objekt v obraze. Proces odstranění takových regionů je popsán níže.

MEDIÁNOVÝ FILTR, kFILL FILTR

Základní provedení mediánového i kFill filtru využívá masku o velikosti 3×3 , která je aplikována na každý pixel v obraze [11]. Při aplikaci dochází k vyplnění masky hodnotami sousedních pixelů, které jsou následně hodnoceny. V případě kFill filtru je na pozici centrálního pixelu vložena hodnota pixelů sousedních v určitých směrech [11, 10], čímž jsou filtrovány především regiony o velikosti 1px.

U mediánového filtru je opět využito zmíněné masky, kde jsou hodnoty seřazeny podle jejich velikosti a na centrální pixel je pak vložena hodnota, která odpovídá hodnotě prostředního prvku po jejich seřazení. Z principu mediánové filtrace vyplývá, že je tímto způsobem možné filtrovat i regiony s velikostí větší, než je 1 px.

1.1.3 DETEKCE REGIONŮ

Počítač vnímá binární obraz jako plochu pixelů, které jsou definovány hodnotami 1 pro bílou barvu a 0 pro barvu černou. Proces detekce regionů spočívá ve spojení pixelů se stejnými hodnotami do shluků na základě příslušnosti k těmto shlukům. Příslušnost je dána n-spojností či n-okolím, např. 4-spojnost považuje region za

spojený v případě, že se v ortogonálních směrech nachází stejné hodnoty pixelů, 8-spojitosť pak uvažuje stejné hodnoty i pro diagonální směry.

K detekci regionů jsou využívány dvě základní strategie. První z nich je založena na detekci obrysu, tedy pixelů ležících na přechodu mezi pixely s hodnotami 0 a 1. Druhá je založena na identifikaci sousedních pixelů pro každý pixel zvlášť a rozhodnutí, zda jsou pixely součástí stejného shluku. Stejně jako u většiny metod má každá strategie kladné a záporné projevy, je proto nutné strategie pochopit a použít je na příslušná data vhodně.

DETEKCE OBRYSU

Obrys objektu je definován pixely nacházející se na přechodu mezi bílou barvou, popisující součást regionu, a černou barvou popisující prostor, kde se nenachází žádný příznak obrazu. Jinak řečeno, pixel definující obrys je poslední pixel s hodnotou 1 v daném směru od centroidu objektu.

Detekce obrysu je jednou z esenciálních úprav obrazu, která je potřebná pro určení mnoha deskriptorů. V některých případech zároveň zajišťuje zvýšenou optickou přehlednost v obraze, např. v případě, kdy se v obraze s vysokým rozlišením nachází mnoho malých struktur, které jsou odděleny nepatrnými mezerami.

OBRYSOVÉ TRASOVÁNÍ

Je založeno na hledání pixelu s hodnotou 1, který leží těsně za pixelem s hodnotou 0 [\[11, 10\]](#). Pro tuto metodu je nutné předpokládat, že hledání začíná na pixelu s hodnotou 0. Na první nalezený pixel, tedy na první pixel obrysu, je aplikována maska o velikosti 3×3, přičemž centrální pixel masky je umístěn právě na tento pixel. V masce jsou následně zanalyzovány okolní pixely po směru hodinových ručiček a je vybrán první pixel s hodnotou 1, který je následován pixelem 0 [\[11, 10\]](#). Ten se stává součástí obrysu a zároveň je na něj přesunut centrální pixel masky. Tento postup je opakován v několika dalších iteracích potřebných pro jasnou definici obrysu objektu a je zastaven až v případě, kdy se centrální pixel masky ocitne na pozici, kde byl nalezen první pixel obrysu.

Samotný proces obrysového trasování ovšem tímto nekončí a pokračuje dál, dokud stejným způsobem neobsáhne všechny objekty nacházející se v obrazových datech. Výsledkem jsou tedy jasně definované objekty, respektive jejich obrys, které byly nalezeny pomocí popsání postupu.

Případ, kdy jeden objekt obklopuje objekt další, tedy např. terč, jehož střed je obklopen několika kruhy, je nazýván hnízdění. V takových případech je nutné určit, zda je hnízdění žádoucí či nežádoucí efekt v rámci analýzy a upravit podle něj proces obrysového trasování.

1.2 TVAROVÁ ANALÝZA

V posledních několika letech bylo vytvořeno mnoho algoritmů popisujících objekty v obraze. Ve specializovaných oborech existují velmi sofistikované nástroje pro identifikaci abecedních písmen, číslic, znaků a jiných symbolů [11]. Experti jednotlivých oborů se setkávají s tvary, které jejich oboru přísluší, v naprosté většině případů lze ovšem konstatovat, že jde o kombinaci modifikovaných či nemodifikovaných tvarů základnějších, do kterých je možné zařadit kruh, čtverec, trojúhelník a další.

Pro následující text je nutné zavést termín deskriptor. Deskriptor je prvek popisující objekt na základě jeho vlastností, do kterých patří např. obsah (rozloha), obvod, kompaktnost, kulatost, hranatost, úhlovitost a mnohé další [1, 3]. Neméně důležité jsou Fourierovy deskriptory a jiné pokročilé deskriptory popisující tvar v obrazových datech. V této sekci jsou některé deskriptory popsány a je vysvětlena jejich funkce při tvarové analýze.

1.2.1 TVAROVÉ DESKRIPTORY 2D OBRAZOVÝCH DAT

Jakýkoli prvek vyskytující se v objektu může rozhodovat o odlišnosti od objektu jiného, proto je nutné každý takový prvek najít a jasně popsat právě pomocí tvarového deskriptoru. Tvarový deskriptor tedy popisuje prvky vlastní pro jednotlivé objekty, které jej odlišují od objektů jiných.

Kterýkoliv z příznaků objektu (tvaru) může rozhodovat o jeho odlišnosti od objektu jiného, proto je nutné každý takový příznak najít a jasně popsat právě pomocí tvarového deskriptoru. Tvarový deskriptor tedy popisuje příznaky vlastní pro jednotlivé objekty, které ho odlišují od objektů jiných.

GEOMETRICKÉ DESKRIPTORY

Jedním z nejjednodušších popisů tvarů je za pomoci geometrických deskriptorů. Například obsah (rozloha) je definován počtem pixelů hodnoty 1 v objektu. Hodnota obsahu může posloužit jako ukazatel při určení velikosti objektu [1].

Další z geometrických deskriptorů, kterým je možné do jisté míry odhadnout velikost objektu je obvod. Obvod je suma vzdáleností mezi pixely obrysu, tuto vzdálenost lze spočítat např. pomocí euklidovské vzdálenosti nebo pouhou sumou pixelů s hodnotou 1 nacházejících se v obrysu. Jak již bylo zmíněno, deskriptor obvodu odhaduje velikost objektu pouze do jisté míry – vysoká hodnota obvodu nemusí být nutně spjata s velkou velikostí objektu a naopak [1, 3].

Deskriptor kombinující obvod a obsah je kompaktnost. Je-li dán obvod O a obsah S , je kompaktnost definována jako $C = O^2/4\pi S$ [11]. Nejkompaktnější tvar je kruh, pro který vychází kompaktnost $C = 1$. Vyšší hodnota popisuje méně kompaktní tvary [1].

Do geometrických deskriptorů dále patří kulatost, která je definována za pomoci vzdálenosti obrysových bodů od centroidu objektu. Pro lepší porovnatelnost s ostatními tvary jsou vzdálenosti počítány v jednotlivých úhlech. Kulatost je popsána rovnicí (1): [\[1\]](#)

$$Kulatost = \sum_{\theta=0}^{\theta=359} \frac{|R_{\theta} - R_p|}{R_p} \quad (1)$$

kde θ popisuje směrový úhel, R_{θ} vzdálenost bodu obrysu od centroidu pro daný úhel a R_p průměrnou vzdálenost bodů obrysu od centroidu. Pokud je objekt přesně kruhového tvaru, vychází $kulatost = 0$. Vzdálenosti pixelů obrysu od centroidu jsou velmi užitečné i pro výpočet dalších statistických hodnot, mezi které je možné zařadit modus, který je určen nejčastější hodnotou vzdálenosti, dále medián a průměr, které mohou být využity pro určení extrémů v podobě směrodatné odchylky, respektive rozptylu. Všechny zmíněné statistické nástroje mohou přispívat ke správné klasifikaci tvaru.

Poměr stran je dalším z deskriptorů popisujícím rozměry objektu. Ve 2D prostoru je pro stanovení poměru stran nejprve nutné zjistit délku hlavní a vedlejší osy pro příslušný objekt. Poměr stran je pak dán rovnicí (2): [\[1\]](#)

$$Poměr\ stran = \frac{Délka\ hlavní\ osy}{Délka\ vedlejší\ osy} \quad (2)$$

výsledkem je vždy hodnota vyšší nebo rovna 1.

Úhlovitost je definována jako rozdíl mezi poloměrem objektu v určitém směru a poloměrem odpovídající elipse. Pro správnou interpretaci deskriptoru úhlovitosti je nutné předpokládat elipsu o stejném poměru stran, jako má analyzovaný objekt. Jiný poměr by výrazně znehodnocoval výsledky. Úhlovitost je dána rovnicí (3): [\[3\]](#)

$$Úhlovitost = \sum_{\theta=0}^{\theta=359} \frac{|R_{p\theta} - R_{EE\theta}|}{R_{EE\theta}} \quad (3)$$

kde θ představuje směrový úhel, $R_{p\theta}$ poloměr objektu ve směru pod úhlem θ a $R_{EE\theta}$ poloměr odpovídající elipse ve směru pod úhlem θ .

Dále je možné popisovat hranatost objektu, která uvádí, jaký je poměr mezi obsahem daného objektu s obsahem nejmenšího možného obdélníku nebo čtverce, který obklopuje zmíněný objekt. Hranatost je popsána pomocí rovnice (4): [\[2\]](#)

$$Hranatost = \frac{S_{obj}}{S_{nmo}} \quad (4)$$

kde S_{obj} představuje obsah analyzovaného objektu a S_{nmo} obsah nejmenšího možného obdélníku nebo čtverce, který takový objekt celý obklopí, tzv. opsaný čtverec/obdélník.

1.2.2 TOPOLOGICKÉ PRVKY

Tvary mohou být charakterizovány pomocí topologických prvků, tedy prvků, které se nemění při elastické deformaci nebo separaci různých regionů v obraze. Pro binární regiony je do topologických prvků možné zařadit: počet děr, popis výčnělků či odsazení [\[11, 10\]](#).

ANALÝZA MOMENTU

Analýza momentu představuje systematickou metodu tvarové analýzy. Nejčastěji užívané atributy regionů jsou počítány ze tří momentů s nejnižším řádem. Obsah (rozloha) je dán momentem nultého řádu a reprezentuje počet vnitřních pixelů regionu. Centroid je dán momentem prvního řádu a je umístěn v těžišti daného regionu. Orientace nekulatého regionu je reprezentována hlavními osami, které jsou dány momentem druhého řádu [\[11\]](#).

Informace získané z takové analýzy je možné využít k vyhodnocení centrálních momentů, normalizovaných centrálních momentů a momentových invariant. Těmi je následně možné vyjádřit tvarové příznaky, které jsou nezávislé na poloze regionu, jeho velikosti či orientaci a jsou proto užitečné pro objektové rozpoznávání a klasifikování objektů, u kterých jsou pozice, obsah a orientace irelevantní [\[11\]](#).

Analýzu momentu je možné provádět na základě vnitřních pixelů regionu, kdy je nutné nejdříve provést procedury upravující vnitřek regionu zmíněné v sekci 1.1.3. Další možností je analýzu provádět na základě obrysu, které musí opět předcházet techniky zmíněné ve stejné sekci.

GEOMETRICKÉ MOMENTY

Analýza geometrických momentů patří mezi nejpoužívanější a jejich principy jsou často využity k tvarové analýze. Důvodem je snadnější implementace a provedení, než je tomu u jiných, komplexnějších metod.

Geometrické momenty lze definovat jako součin souřadnic pixelů $x^p y^q$. Dvoudimenzionální moment řádu $(p + q)$ pro obraz o velikosti $N \times M$ je dán rovnicí (5): [\[7\]](#)

$$m_{pq} = \sum_{y=1}^M \sum_{x=1}^N x^p y^q f(x, y) \quad p, q = 0, 1, 2, 3, \dots \quad (5)$$

DESKRIPTORY VYUŽÍVAJÍCÍ GEOMETRICKÝCH MOMENTŮ

Nejnižší řád momentu m_{00} prezentuje počet pixelů v regionu, udává tedy jeho obsah (rozlohu). Obsah (rozloha) je deskriptor, který lze využít k porovnání velikostí objektů v obraze, je nutné mít ovšem na paměti, že deskriptor neuvažuje velikost samotného obrazu. Velikost je tedy vždy relativní.

První řád momentu v souřadnicích x a y , normalizován podle obsahu, udává přibližné umístění regionu v obraze. Centroidy x_c a y_c jsou vypočítány pomocí rovnice (6): [\[11\]](#)

$$x_c = \frac{m_{10}}{m_{00}} \quad y_c = \frac{m_{01}}{m_{00}} \quad (6)$$

, kde m_{xy} představuje moment řádu xy . Centrální moment μ_{pq} pak reprezentuje deskriptor regionu, který je normalizován s přihlédnutím k jeho umístění, toho je dosaženo pomocí rovnice (7): [\[11\]](#)

$$\mu_{pq} = \sum_R (x - x_c)^p (y - y_c)^q \quad (7)$$

1.2.3 POKROČILÉ METODY TVAROVÉ ANALÝZY

V této sekci budou rozebrány některé z metod tvarové analýzy obrazu využívajících Fourierovu transformaci (FT). Výsledky takové analýzy, která je založena na kvantitativním hodnocení tvarových zkreslení, mohou obsahovat velmi detailní popis tvaru vedoucí k jeho klasifikaci. Fourierovy deskriptory lze rozdělit na deskriptory, které jsou tvořeny pomocí obrysových bodů objektu a na deskriptory, které popisují tvar nejen na základě obrysu, ale i na pixelech, které se nacházejí uvnitř objektu. Je zřejmé, že deskriptory vycházející z obrysu trpí vážným

nedostatkem, a to neschopností popsat právě vnitřek objektu. V další části je kladen důraz na dva, asi nejběžnější, deskriptory, kde každý z nich patří do jedné ze zmíněných skupin [9].

JEDNODIMENZIONÁLNÍ FOURIERŮV DESKRIPTOR

Jedno-dimenzionální Fourierův deskriptor (dále jen 1D-FD) je základní deskriptor využívající Fourierovu transformaci (dále jen FT). Jak již bylo zmíněno výše, jeho nedostatkem je základní princip metody, která využívá pouze bodů z obrysu objektu. I přes to je 1D-FD oblíbený a používaný deskriptor [12, 13]. Výhody 1D-FD metody tkví v možnosti snadné derivace, normalizace, odolnosti proti šumu, snadné charakterizaci (přiřazování výsledků ke známým datům) a mnoha dalších [12, 13, 14]. Pro realizaci 1D-FD je využito znalosti vzdálenosti obrysových bodů od centroidu x_c, y_c objektu.

Vzdálenost bodu od centroidu r_t je možné vypočítat pomocí rovnice (8): [14]

$$r_t = \sqrt{(x(t) - x_c)^2 + (y(t) - y_c)^2} \quad (8)$$

Kde jsou centroidy se souřadnicemi x_c, y_c popsány pomocí rovnic (9): [14]

$$x_c = \frac{1}{2} \sum_{t=0}^{N-1} x(t) \quad y_c = \frac{1}{2} \sum_{t=0}^{N-1} y(t) \quad (9)$$

, kde $x(t), y(t)$ představují souřadnice obrysového bodu v horizontálním, respektive vertikálním směru, N je celkový počet bodů. 1D-FD je poté aplikována na vzdálenost $r(t)$ k získání 1D-FD, výsledná rovnice (10):

$$1D - FD_t = FFT(r(t)) \quad (10)$$

, kde t představuje index obrysového bodu, pro který je 1D-FD počítán, výsledkem je tedy řada hodnot. Takto získaný deskriptor často popisuje tvary lépe než jiné deskriptory vycházející z obrysových bodů [14]. Dále je nutné zmínit, že k provedení takových výpočtů je nutná znalost obrysových bodů, které je, v některých případech, složité nebo zcela nemožné definovat.

Naopak, pokud je obrys jasně definován, je možné 1D-FD použít a získat tak cenný deskriptor. Je vhodné zmínit, že je Fourierova transformace při správném použití reverzibilní – ze získaného deskriptoru lze inverzní Fourierovou transformací získat původní obraz. 1D-FD je demonstrována v kapitole řešení studentské práce.

ZERNIKŮV MOMENTOVÝ DESKRIPTOR

Problémy, s nimiž se potýká *1D-FD* (viz. výše) řeší *Zernikovy momentové deskriptory* (dále pouze *ZMD*). *ZMD* je počítán z hodnot všech pixelů objektu, nejen z jeho obrysu. Pro tuto práci byl *ZMD* vybrán také z důvodu, že je považován za jeden z nejkvalitnějších deskriptorů v rámci celkových výsledků v porovnání s deskriptory jinými, např. Legendrovy momenty, pseudo-Zernikovy momenty a další [4]. Výborné výsledky *ZMD* pochází z jeho vlastností, mezi které je možné zařadit: rotační invariance, odolnost proti šumu, rychlá realizace metody a další. S použitím správné normalizační metody je možné dosáhnout také škálovatelnosti [5].

ZMD je získán pomocí Zernikových polynomů. V polárním prostoru (ρ, θ) jsou polynomy $R_{nm}(\rho)$ definovány rovnicí (11): [14]

$$R_{nm}(\rho) = \sum_{s=0}^{(n-|m|)/2} (-1)^s \frac{(n-s)!}{s! \left(\frac{n+|m|}{2} - s\right)! \left(\frac{n+|m|}{2} - s\right)!} \rho^{n-2s} \quad (11)$$

Kde ρ je vzdálenost bodu od ceontroidu, θ úhel rotace, n je kladné číslo a m nenulové číslo. Tyto čísla dále podléhají následujícím podmínkám: $n - |m| = \text{sudé číslo}$ a $|m| \ll n$. Řád (n, m) základní Zernikovy funkce $V_{nm}(\rho, \theta)$ je dán rovnicí (12): [14]

$$V_{nm}(\rho, \theta) = R_{nm}(\rho) \exp(jm\theta), \quad \rho \ll 1 \quad (12)$$

Konečně, Zernikův moment je definován rovnicí (13): [14]

$$Z_{nm} = \frac{n+1}{\pi} \int \int V_{nm}^*(\rho, \theta) f(\rho, \theta) \quad (13)$$

kde V_{nm}^* je V_{nm} v komplexní rovině. Příklad výsledků *ZMD* řádu $n = 4$, $m = 2$ je znázorněn na Obr. 1:

Horizontal oval  $z = 0.092942$ $f_i = -179.92$	-45° oval  $z = 0.090255$ $f_i = -89.9094$	Vertical oval  $z = 0.092942$ $f_i = 0.079697$
Horizontal shape  $z = 0.06855$ $f_i = 110.4494$	Vertical shape  $z = 0.06885$ $f_i = -69.5508$	Horizontal oval  $z = 0.14797$ $f_i = -179.9256$

Obr. 1: Zernikovy momenty pro různé tvary a jejich rotaci, $n = 4$, $m = 2$, zdroj: [13]

DALŠÍ TVAROVÉ DESKRIPTORY

Tato práce se zaměřuje na deskriptory, které byly popsány výše, nicméně je pro úplnost nutné zmínit, že tvarových deskriptorů je celá řada. Mezi ty nejpoužívanější, které zmíněny nebyly, patří:

- Deskriptory založené na hraničním zakřivení
- Deskriptory vycházející z fraktální analýzy
- Vlnkové deskriptory
- Deskriptory založené na tzv. korespondenci

1.2.4 DESKRIPTORY 3D OBRAZOVÝCH DAT


V dnešní době jsou běžně využívány diagnostické metody, které poskytují obraz ve 3D, kde třetí dimenze představuje hloubku obrazu a čtvrtou může být čas. Je ovšem vhodné si uvědomit, že trojrozměrný obraz je v naprosté většině získáván pomocí zpracování jednotlivých řezů snímaného tělesa. Jako příklad může posloužit výpočetní tomografie (dále jen CT). Jedná se o metodu, která využívá více než sto let známé Roentgenovo záření, ale změnil se přístup k pořizování snímků. CT pořizuje snímky v různých rovinách a krocích, které se následně zpracují tak, aby byl vytvořen 3D obraz. Je tedy zřejmé, že deskriptory, které byly využity pro 2D obrazy lze, při správné aplikaci, použít i na obrazy ve 3D provedení.

Jako deskriptor popisující obraz ve třech dimenzích je možné uvést objem. Objem je možné definovat jako sumu všech hodnot 1 uvnitř daného objektu, jedná se tedy o sumu obsahů pro každý řez. Rovnice pro výpočet objemu je pak zřejmě (14):

$$Objem = \sum_0^M Obsah \quad (14)$$

kde M je počet řezů.

Dále, stejně jako u 2D obrazů, lze počítat vzdálenost jednotlivých bodů obrysu od centroidu. V případě 2D obrazů je optimální, aby byly zmíněné vzdálenosti počítány pro jednotlivé úhly, viz sekce 1.2.1. Pro 3D obrazy lze využít stejné myšlenky. Rozdíl je v tom, že tato myšlenka musí být aplikována dvakrát, poprvé pro vzdálenost v rovině XY a podruhé v rovině v XZ. Prostor 3D je znázorněn na Obr. 2:



Obr. 2: Kartézská soustava pro 3D prostor

OBRYŠ 3D OBJEKTŮ

U tvorby obrysů 3D objektů bylo využito znalosti, která byla popsána výše, a tedy, že 3D obraz je tvořen jednotlivými řezy tvořenými 2D obrazy. Na každý z řezů je aplikován proces obrysového trasování ze sekce 1.1.3 a získán tak jejich obrys. V případě prvního a posledního řezu je nutné vyplnit vnitřky obrysu hodnotou 1, aby byl 3D objekt uzavřen ze všech stran.

VZDÁLENOSTI BODŮ OD OBRYSU

Stejně jako u 2D obrazových dat je možné vypočítat vzdálenost jednotlivých bodů obrysu od centroidu. V případě 3D je ovšem proces složitější a je nutné brát v úvahu dva úhly – úhel φ a elevační úhel θ , které jsou počítány pomocí rovnic (15,16): [\[18, 19\]](#)

$$\varphi = \arctan \frac{y}{x} \quad (15)$$

$$\theta = \arccos \frac{z}{\sqrt{x^2 + y^2 + z^2}} \quad (16)$$

kde x, y, z představují pozici pixelu v dané rovině. Elevační úhel θ nabývá hodnot $(-89, 90)$, zatímco úhel φ nabývá hodnot $(0, 359)$. Výsledek se tedy dá interpretovat maticí (tabulkou) o velikosti 180×360 , která obsahuje vzdálenosti bodů obrysu v daných úhlech.

1.3 KLASIFIKACE OBRAZOVÝCH DAT

Tvarová analýza vede, v optimálním případě, ke klasifikaci obrazových dat ve stejné kvalitě, jako by analýzu provedl expert v daném oboru. Je nutné si uvědomit, že analýza prováděná expertem se ve většině případech nezakládá na různých deskriptorech, ale spíše na jeho zkušenostech s klasifikovaným objektem.

Naopak, zautomatizovaná klasifikace obrazových dat je založena právě na deskriptorech, které byly popsány skrze tuto práci a mnoha dalších metodách, které jsou pro člověka těžko definované od pohledu. Příkladem klasifikace obrazových dat může být Hammingova síť, která může využívat binární logiku nebo fuzzy logiku [\[6\]](#).

HAMMINGOVA SÍŤ

Pro tuto práci uvažujeme, že do Hammingovy sítě vstupují hodnoty pixelů již zbinarizovaného obrazu. Jedná se o umělou neuronovou síť, která není založena na deskriptorech zmíněných v předchozích sekcích, nýbrž na podobnosti analyzovaných objektů s objekty referenčními. K určení podobnosti je využito tzv. Hammingovy vzdálenosti, která je založena na znalosti hodnoty daného pixelu $x(i, j)$ u obrazu referenčního a porovnání této hodnoty s pixelem analyzovaným $x_2(i, j)$.


Tento postup je aplikován na celý obraz a je definován rovnicí (17):

$$\text{Hammingova vzdálenost} = \sum_i^N \sum_j^M |x(i, j) - x_2(i, j)| \quad (17)$$

kde M označuje velikost obrazu v horizontálním směru, N pak velikost ve vertikálním směru, $x(i, j)$ značí pixel se souřadnicemi (i, j) referenčního obrazu, a $x_2(i, j)$ značí pixel se souřadnicemi (i, j) obrazu analyzovaného. Výsledkem je tedy hodnota rozdílu, která popisuje podobu obou tvarů. Čím vyšší rozdíl, tím samozřejmě nižší podobnost obrazů. Samotnou klasifikaci je možné dělit na binární a fuzzy.

Binární klasifikace je jednoduché zařazení analyzovaného objektu do skupiny (shluku), která jej nejvýstižněji popisuje, rozdíl je tedy v rámci analýzy nejmenší a podobnost největší. Fuzzy logika řadí objekty do skupin (shluků) podle hodnot podobnosti analyzovaného objektu, které jsou dány jejich poměrem.

Při pohledu na výpočet je zřejmé, že Hammingova síť předpokládá dva stejně velké obrazy, což může být v mnoha případech výrazná nevýhoda, která by se dala řešit zmenšením, respektive zvětšením, jednoho z obrazů, tím ovšem dochází ke ztrátě kvality jednoho z obrazů. Schéma Hammingovy sítě je na Obr. 3:



Obr. 3: Hammingova síť, x – vstupy, y – výstupy, w – váhy, zdroj: [6]

2 ŘEŠENÍ STUDENTSKÉ PRÁCE

V kapitole řešení studentské práce jsou navrženy postupy, které využívají znalostí z kapitoly teorie a které vedou k tvarové analýze obrazových dat. Pro výpočty samotných deskriptorů byly vytvořeny funkce v jazyce MATLAB, který byl zvolen hlavně z důvodu jeho nativní podpory pro zpracování obrazových dat a z důvodu široké komunity, která jazyk MATLAB využívá pro práci s biomedicínskými daty.

V první sekci této kapitoly budou prezentovány postupy vedoucí k tvarové analýze založené na znalostech z kapitoly teorie. Metody jsou následně aplikovány na generovaná data v sekci druhé. V třetí sekci této kapitoly jsou metody použity i na reálná data. V poslední sekci je prezentováno generování 3D obrazů, které jsou opět popsány deskriptory, které byly definovány v kapitole teorie v sekci 1.2.4.

2.1 REALIZACE METOD TVAROVÉ ANALÝZY

Příprava obrazu postupuje podle metod popsaných v části teorie, dochází tedy k převodu z šedotónové reprezentace do černobílé (binární) reprezentace obrazu pomocí prahování – původní šedotónový obraz je procházen pixel po pixelu, kdy v každém daném pixelu je jeho hodnota porovnávána s hodnotou nastaveného prahu. Pokud je hodnota pixelu vyšší, než je hodnota prahu, je daný pixel klasifikován jako bílý – má hodnotu 1 v binárním obraze. V opačném případě je pixel černý a jeho hodnota je 0.

Je nutné dodat, že je v případě této práce využito globálního prahování, které s sebou nese mnohé nevýhody. Pravděpodobně největší nevýhodou je neschopnost použité metody binarizovat více úrovní šedotónového obrazu. Úroveň je v tomto kontextu definována jako rozsah hodnot, které definují objekty v obrazových datech. Pokud se v obraze nachází více takových úrovní, např. při zvýšené expozici části obrazu, je zcela možné, že budou některé důležité prvky obrazu zcela ignorovány. V takových případech je výhodnější využít prahování lokálního, které je, jak z názvu vyplývá, ovlivňováno pouze hodnotami pixelů v zadaném rozsahu okolo centrálního pixelu. Tato práce ovšem není zaměřena na úpravu samotného obrazu a využívá proto již zmíněného, mnohem jednoduššího, globálního prahování, které je zprostředkováno nativní funkcí MATLABU – *graythresh*.

ODSTRANĚNÍ ŠUMU A MALÝCH OBJEKTŮ

Jak bylo zmíněno v části teoretické, práce se zabývá odstraněním pouze šumu impulsního. K tomu je využit následující postup. Odstranění impulsního šumu využívá funkce *bwareaopen* z toolboxu image processing [17], která využívá principů kFill filtru, který je popsán v kapitole 1.1.2. Jedná se tedy o postup, který je zaměřen čistě na náhodný impulsní šum. Pro odstranění malých objektů se využívá

informací, které byly zjištěny pomocí funkce *bwconncomp(binární_obraz)*, které se bude blíže věnovat další sekce. Nicméně, princip je možné vysvětlit ihned, pokud je nalezený region pomocí zmíněné funkce větší než nastavitelný práh, je region považován za objekt vhodný pro analýzu/klasifikaci, v opačném případě je region odfiltrován. Práh je v případě této práce nastaven automaticky pomocí funkce *graythresh(šedotónový_obraz)* [17].

2.1.1 DETEKCE REGIONŮ

K detekci regionů je využito funkce *bwconncomp(binární_obraz)* z toolboxu *image processing* [17]. Funkce rozdělí pixely v obraze do jednotlivých shluků (regionů) na základě jejich propojenosti se sousedními pixely. Výstup funkce pak představuje počet regionů v obraze a souřadnice pixelů, které do nich patří – toho je využito v tvorbě zdroj. kódu u výše zmíněného postupu odstranění šumu.

ZÍSKÁNÍ OBRYSU

K získání obrysu bylo využito postupu popsáno v teoretické části v kapitole 1.1.4. Vlastnosti obrysu jsou velmi důležité pro tvarovou analýzu obrazových dat, protože jsou na něm založeny mnohé deskriptory. Zároveň je obrys relativně dobrým prostředkem pro zvýšení přehlednosti v některých typech obrazů – převážně tedy obrazy s velkým rozlišením, ve kterých jsou některé regiony rozděleny jen nepatrnými mezerami.

OBRYS A VEKTOR OBRYSU

Termín vektor obrysu je v práci použit jako definice směru sousedních pixelů v obrysu. Pro nalezení obrysu byla využita alternace metody obrysového trasování popsáno v kapitole 1.1.4. Masky se tedy nepohybuje pouze po obrysových bodech, ale dochází zároveň k zaznamenávání směru pohybu. K tomu je využita pomocná matice.

Při pohybu masky po jednotlivých pixelech obrysu je směr zapsán pomocí pomocné matice, která má rozložení z Tab. 1:

Tab. 1: Pomocná matice

1	4	7
2	5	8
3	6	9

Při každém pohybu je nastavena priorita směrů, s jakým se má matice dále přemísťovat. Priorita je určena podle posledního pohybu matice a faktem, že jde o obrysové trasování po směru hodinových ručiček.

DETEKCE HRAN

Pro tuto práci byla vytvořena funkce *hrany(obrys, vektor_obrysu)*, která je schopná detekovat jednotlivé hrany a určit jejich délku. K tomu jsou využity znalosti o obrysu a vektoru obrysu zmíněného výše, které jsou zároveň vstupními hodnotami funkce.

Algoritmus pracuje tak, že je vytvořena maska o rozměrech 1×7 , která je naplněna hodnotami vektorů obrysu. Rozměry masky jsou zvoleny po dostatečném otestování funkčnosti. Dále je určen modus hodnot v masce, to z důvodu, že v mnoha případech je hrana orientovaná pod úhlem α , což způsobí, že je hrana tvořena více než jednou hodnotou vektoru obrysu. Modus tedy vezme nejčastější hodnotu v masce a dále s ní pracuje.

Dále je nastaven práh, který definuje minimální velikost hrany, ten může být pro každý obraz, potažmo objekt nastaven zvlášť. Pokud je velikost hrany větší než práh, hrana je registrována a její velikost je uložena do proměnné.

PŘIZPŮSOBENÍ OBRAZŮ KE KLASIFIKACI

Jednotlivé biomedicínské obrazy byly poskytnuty v rozdílných rozlišeních, což by znamenalo významný problém v sekci 1.2.1. Proto je potřeba obrazy přizpůsobit zvolené velikosti, v případě této práce velikosti největšího z analyzovaných obrazů.

Toho bylo docíleno tak, že se obraz nejdříve vycentroval na analyzovaný objekt, který byl následně vyříznut z obrazu. K vyříznutému obrazu byly po všech jeho stranách vloženy dostatečně velké matice s hodnotami 0 tak, aby měl obraz ve výsledku stejné rozměry jako největší analyzovaný obraz.

2.1.2 ZÍSKÁNÍ DESKRIPTORŮ

V této sekci jsou popsány procesy a algoritmy, které vedou k určení vybraných deskriptorů.

GEOMETRICKÉ DESKRIPTORY

Část geometrických deskriptorů je získaných pomocí funkce *regionprops(binární_obraz, [vlastnosti])*, která je součástí toolboxu image processing [\[17\]](#), další část deskriptorů je popsána pomocí vlastních funkcí. Do deskriptorů získaných za pomoci *regionprops* patří: obvod, orientace, délky hlavních a vedlejších os. Do deskriptorů získaných pomocí vlastních funkcí, které vycházejí z rovnic a popisů z kapitoly Teoretická část, patří: kulovitost, hranatost, kompaktnost, obsah, centroidy, vektorové směry hran a minimální, maximální a průměrná vzdálenost obrysových bodů od centroidu. Pro výpočet vlastních deskriptorů byly využity vzorce popsané v kapitole teorie v sekci 1.2. Samotný algoritmus je uveden v příloze. (soubor *main2D.m*)

FOURIEROVY DESKRIPTORY

Pro popis tvarů pomocí metod využívající FT bylo zapotřebí správné znalosti obrysu a vzdáleností mezi jednotlivými body obrysu a centroidem objektu. Pro objektivní porovnání těchto vzdáleností mezi jednotlivými objekty je zároveň nutné vzdálenosti vypočítat ne pro jednotlivé body, ale spíše pro úhel. K tomu byla vytvořena funkce *vzdalenostOdCentroidu(obrys, centroidy)*, která má na vstupu obrys a centroidy objektu. Na výstup této funkce je poté aplikována FT, jejímž výsledkem je 1D-FD. Další z deskriptorů popsanych v sekci 1.2.3 byly Zernikovy momenty. Pro výpočet těchto momentů bylo využito funkce *ZernikeMoments(obj)*, která byla naprogramována panem Amir Tahmasbiem [\[10\]](#).

2.2 GENEROVÁNÍ ZÁKLADNÍCH 2D OBRAZŮ

Do základních 2D tvarů tato práce zařazuje čtverec, trojúhelník, obdélník, kosočtverec a mnohoúhelník. Ke generování těchto tvarů byly vytvořeny funkce, které mají na vstupu rozměry zvoleného tvaru. Nejjednodušším příkladem je čtverec, který na vstupu bere velikost hrany a . Protože generované objekty slouží jako kontrolní bod analýzy, byly funkce navrženy tak, aby byly jednotlivé objekty škálovatelné podle potřeb, aby bylo možné vytvořit mnoho testovacích dat. Speciální případ představuje mnohoúhelník.


Za mnohoúhelník by se daly považovat všechny zmíněné tvary, i jakékoliv jiné tvary v 2D prostoru, proto byla navržena funkce, která generuje uživatelem zadaný tvar přesně podle jeho potřeb. Vstup funkce bere počet vrcholů mnohoúhelníku a velikost obrazu, tedy jeho rozlišení v pixelech. Uživatel pak myší definuje body ve vygenerovaném okně, které se nakonec propojí a vytvoří tak mnohoúhelník.

V každé podsekci, která je věnovaná každému tvaru, je možné vidět: vygenerovaný objekt pomocí vlastních funkcí, obrys generovaného tvaru, kde jsou barevně znázorněny vektory hran a bodem vyznačen centroid objektu, graf popisující vzdálenosti bodů obrysu od centroidu vygenerovaného objektu a 1D-FD popsany v sekci 1.2.4. Dále je u každého tvaru pro jednu z prezentací daného objektu vytvořena tabulka Zernikových momentů. Pro každý tvar byly vygenerovány dvě jejich prezentace tak, aby bylo možné je v další sekci porovnat na základě znalostí jednotlivých deskriptorů.


Tato sekce může zároveň sloužit jako mechanismus ke zjištění různých nepřesností nebo chyb v použitých procesech získávání deskriptorů, protože vygenerované tvary jsou jasně definovány a jejich deskriptory jsou předem známé.

ČTVEREC


Mezi nejjednodušší tvary patří bezesporu čtverec. Generování čtverce je v práci realizováno funkcí $VytvorCtverec(a)$, která má na vstupu velikost hrany a . Základní data o vygenerovaném čtverci jsou znázorněna v Obr.: 4-7 a ZM následně v Tab. 2.




Obr. 4: Čtverec generovaný pomocí funkce $aVytvorCtverec(200)$



Obr. 5: Obrys generovaného čtverce s barevně vyznačenými směry hran



Obr. 6: Vzdálenosti bodů obrysu od centroidu generovaného čtverce



Obr. 7: 1D-FD generovaného čtverce

Tab. 2: Zernikovy momenty pro čtverec(234)


m,n	0	1	2	3	4	5	6	7	8	9	10
0	1,25	-	-	-	-	-	-	-	-	-	-
1	-	7,43	-	-	-	-	-	-	-	-	-
2	0,76	-	1,46	-	-	-	-	-	-	-	-
3	-	2,20	-	3,58	-	-	-	-	-	-	-
4	1,25	-	2,09	-	0,00	-	-	-	-	-	-
5	-	4,62	-	6,17	-	1,05	-	-	-	-	-
6	1,78	-	4,20	-	0,00	-	1,04	-	-	-	-
7	-	2,20	-	2,98	-	5,84	-	1,34	-	-	-
8	2,26	-	2,12	-	0,01	-	1,44	-	0,01	-	-
9	-	2,54	-	5,29	-	6,17	-	1,57	-	4,12	-
10	2,80	-	1,01	-	0,01	-	3,26	-	0,01	-	4,58

OBDÉLNÍK


Další ze základních tvarů je obdélník. Pro jeho generování byla vytvořena funkce *VytvorObdelnik(a,b)*, která bere jako vstupní hodnoty výšku *a* a šířku *b*. Základní data o vygenerovaném obdélníku jsou znázorněna v Obr.: 8-11 a ZM následně v Tab. 3.




Obr. 8: Obdélník generovaný pomocí funkce *aVytvorObdelnik(100,400)*



Obr. 9: Obrys generovaného obdélníku s barevně vyznačenými směry hran



Obr. 10: Vzdálenosti bodů obrysu od centroidu generovaného obdélníku




Obr. 11: 1D-FD generovaného generovaného obdélníku

Tab. 3: Zernikovy momenty pro obdélník(100,400)


m,n	0	1	2	3	4	5	6	7	8	9	10
0	1,23	-	-	-	-	-	-	-	-	-	-
1	-	0,00	-	-	-	-	-	-	-	-	-
2	0,73	-	0,00	-	-	-	-	-	-	-	-
3	-	0,01	-	0,01	-	-	-	-	-	-	-
4	1,18	-	0,01	-	0,02	-	-	-	-	-	-
5	-	0,01	-	0,01	-	0,01	-	-	-	-	-
6	1,69	-	0,01	-	0,03	-	0,01	-	-	-	-
7	-	0,01	-	0,01	-	0,01	-	0,01	-	-	-
8	2,13	-	0,01	-	0,04	-	0,01	-	0,03	-	-
9	-	0,01	-	0,01	-	0,01	-	0,01	-	0,01	-
10	2,65	-	0,01	-	0,04	-	0,01	-	0,04	-	0,01

KRUH


Pro generování kruhu byla vytvořena funkce *VytvorKruh(d)*. Do funkce vstupuje hodnota d reprezentující průměr kruhu. Algoritmus je založen na výpočtu euklidovských vzdáleností od středu kruhu. Pokud je eukl. vzdálenost menší než $d/2$, pak je pixel součástí kruhu a vyznačen hodnotou 1, v opačném případě je hodnota pixelu 0. Základní data o vygenerovaném kruhu jsou znázorněny v Obr.: 12-15 a ZM následně v Tab. 4.




Obr. 12: Kruh generovaný pomocí funkce aVytvorKruh(201)



Obr. 13: Obrys generovaného kruhu s barevně vyznačenými směry hran



Obr. 14: Vzdálenosti bodů obrysu od centroidu generovaného kruhu




Obr. 15: 1D-FD generovaného kruhu

Tab. 4: Zernikovy momenty pro kruh(201)


m,n	0	1	2	3	4	5	6	7	8	9	10
0	0,98	-	-	-	-	-	-	-	-	-	-
1	-	0,01	-	-	-	-	-	-	-	-	-
2	0,06	-	0,00	-	-	-	-	-	-	-	-
3	-	0,03	-	0,00	-	-	-	-	-	-	-
4	0,09	-	0,00	-	0,00	-	-	-	-	-	-
5	-	0,03	-	0,00	-	0,00	-	-	-	-	-
6	0,12	-	0,00	-	0,00	-	0,00	-	-	-	-
7	-	0,04	-	0,00	-	0,00	-	0,00	-	-	-
8	0,14	-	0,00	-	0,00	-	0,00	-	0,01	-	-
9	-	0,04	-	0,00	-	0,00	-	0,00	-	0,00	-
10	0,15	-	0,01	-	0,00	-	0,00	-	0,01	-	0,00

TROJÚHELNÍK


Trojúhelník je generován funkcí *VytvorTrojuhelnik([rozmetry])*, která má jako vstupní hodnoty velikost podstavy a ramen ve formátu *[podstava rameno1 rameno2]*. Generování využívá velmi podobného principu jako kruh, tedy vzdáleností pixelů od bodů, kde body (vrcholy) podstavy jsou známy a třetí bod (vrchol) je místo, kde se protínají kruhy o velikosti ramen. Zákl. data o vygen. trojúhelníku jsou znázorněna v Obr.: 16-19 a ZM následně v Tab. 5.




Obr. 16: Trojúhelník generovaný pomocí funkce *aVytvorTrojuhelnik([200 224 224])*



Obr. 17: Obrys generovaného trojúhelníku s barevně vyznačenými směry hran



Obr. 18: Vzdálenosti bodů obrysu od centroidu generovaného trojúhelníku




Obr. 19: 1D-FD generovaného trojúhelníku

Tab. 5: Zernikovy momenty pro trojúhelník(200 224 224)


m,n	0	1	2	3	4	5	6	7	8	9	10
0	0,63	-	-	-	-	-	-	-	-	-	-
1	-	0,27	-	-	-	-	-	-	-	-	-
2	0,65	-	0,24	-	-	-	-	-	-	-	-
3	-	0,02	-	0,05	-	-	-	-	-	-	-
4	0,59	-	0,12	-	0,06	-	-	-	-	-	-
5	-	0,08	-	0,17	-	0,13	-	-	-	-	-
6	0,57	-	0,01	-	0,00	-	0,00	-	-	-	-
7	-	0,05	-	0,13	-	0,09	-	0,01	-	-	-
8	0,61	-	0,06	-	0,03	-	0,10	-	0,08	-	-
9	-	0,01	-	0,01	-	0,02	-	0,01	-	0,01	-
10	0,79	-	0,06	-	0,03	-	0,09	-	0,09	-	0,00

KOSOČTVEREC


Pro generování kosočtverce byla vytvořena funkce $VytvorKosoctverec(hrana, uhel)$, kde vstupní hodnoty představují velikost hrany a směrový úhel kosočtverce. Kosočtverec je tvar, který je tvořen dvěma stejnými, pravoúhlými trojúhelníky a obdélníkem. S takovou znalostí bylo také přistupováno k samotné tvorbě algoritmu generování kosočtverce. Základní data o vygenerovaném obdélníku jsou znázorněna v Obr.: 20-23 a ZM následně v Tab. 6.




Obr. 20: Kosočtverec generovaný pomocí funkce aVytvorKosoctverec(200,60)



Obr. 21: Obrys generovaného kosočtverce s barevně vyznačenými směry hran



Obr. 22: Vzdálenosti bodů obrysu od centroidu generovaného kosočtverce




Obr. 23: 1D-FD generovaného kosočtverce

Tab. 6: Zernikovy momenty pro kosočtverec(200,60)


m,n	0	1	2	3	4	5	6	7	8	9	10
0	0.837	-	-	-	-	-	-	-	-	-	-
1	-	0.120	-	-	-	-	-	-	-	-	-
2	0.451	-	0.076	-	-	-	-	-	-	-	-
3	-	0.087	-	0.032	-	-	-	-	-	-	-
4	0.209	-	0.027	-	0.060	-	-	-	-	-	-
5	-	0.046	-	0.038	-	0.199	-	-	-	-	-
6	0.221	-	0.070	-	0.098	-	0.045	-	-	-	-
7	-	0.104	-	0.041	-	0.033	-	0.067	-	-	-
8	0.230	-	0.054	-	0.051	-	0.071	-	0.030	-	-
9	-	0.036	-	0.030	-	0.048	-	0.033	-	0.031	-
10	0.154	-	0.053	-	0.051	-	0.021	-	0.035	-	0.040

MNOHOÚHELNÍK


Jak již bylo zmíněné v úvodu této sekce, do mnohoúhelníku je možné zařadit všechny zmíněné i další 2D tvary. Byla vytvořena funkce *VytvorMnolehelnik(n,m)*, která má na vstupu hodnotu n pro počet vrcholů (úhlů) a hodnotu m pro velikost čtvercového okna, do kterého pak uživatel zadá body, které se následně propojí a vytvoří tak mnohoúhelník. Základní data o vygenerovaném obdélníku jsou znázorněna v Obr.: 24-24 a ZM následně v Tab. 7.




Obr. 24: Mnohoúhelník generovaný pomocí funkce aVytvorMnolehelnik(5,300)



Obr. 25: Obrys generov. mnohoúhelníku s barevně vyznačenými směry hran



Obr. 26: Vzdálenosti bodů obrysu od centroidu generovaného mnohoúhelníku



Obr. 27: 1D-FD generovaného mnohoúhelníku

Tab. 7: Zernikovy momenty pro mnohoúhelník(5, 300)

m,n	0	1	2	3	4	5	6	7	8	9	10
0	0.783	-	-	-	-	-	-	-	-	-	-
1	-	0.168	-	-	-	-	-	-	-	-	-
2	0.494	-	0.122	-	-	-	-	-	-	-	-
3	-	0.078	-	0.091	-	-	-	-	-	-	-
4	0.134	-	0.134	-	0.051	-	-	-	-	-	-
5	-	0.098	-	0.081	-	0.086	-	-	-	-	-
6	0.135	-	0.105	-	0.060	-	0.130	-	-	-	-
7	-	0.049	-	0.035	-	0.014	-	0.046	-	-	-
8	0.225	-	0.082	-	0.012	-	0.025	-	0.035	-	-
9	-	0.056	-	0.067	-	0.016	-	0.106	-	0.030	-
10	0.165	-	0.120	-	0.023	-	0.069	-	0.048	-	0.029

2.2.1 DISKUZE VÝSLEDKŮ GENEROVANÝCH TVARŮ

Jak bylo zmíněno v sekci 2.2, generování základních tvarů funguje jako mechanismus, kterým je možné ohodnotit získané deskriptory z kvalitativního hlediska, protože jsou deskriptory předem známe a tímto způsobem je možné zjistit, zda výsledné deskriptory odpovídají realitě. Generování je realizováno tak, že jsou vygenerovány vždy dvě reprezentace stejného tvaru, kde první z nich má rozlišení obrazu $200 \times 200 \text{ px}$ a druhá, která má hodnotu obsahu 40000 px .

Je zřejmé, že tvary čtverce, obdélníku a kosočtverce mají při stejném rozlišení obrazu identické geometrické deskriptory, protože k vytvoření kosočtverce se zmíněným rozlišením obrazu je nutné použít hodnotu úhlu 90° , jedná se tedy o čtverec. Pro vytvoření obdélníku je v tomto případě nutné použít stejných velikostí hran, jedná se opět o čtverec.

Tvary vytvořené pro porovnání na základě obsahu jsou čistě orientační a slouží pouze jako přehled, jakých hodnot deskriptory mohou nabývat.

Jak již bylo zmíněno v předchozí sekci, základní tvary slouží k tomu, aby bylo možné jasně určit funkční a správné deskriptory, protože jsou výsledky takové analýzy předem známe.

Deskriptor vzdálenosti od centroidu a na něm založený 1D-FD jsou znázorněné pro každý vygenerovaný tvar zvlášť, aby bylo možné provést alespoň vizuální analýzu výsledků a definovat jasně viditelné rozdíly mezi tvary. U grafů vzdáleností jsou zřetelné píky znázorňující vrcholy tvaru, z toho vyplývá, že je kruh v takovém grafu definován vodorovnou úsečkou, protože „nemá“ vrcholy. 1D-FD je následně tvořen pomocí FT použité na zmíněnou vzdálenost. Kvalita a funkčnost 1D-FD se následně významně projeví při klasifikaci, která je založená právě na tomto deskriptoru, proto bude kvalita tohoto deskriptoru diskutována až v následujících částech práce.

Zernikovy momenty popisují složitost tvarů pomocí Zernikových polynomů. Z výsledků ZM vyplývá, že nejjednodušším tvarem kruh, který je definován nízkými hodnotami jednotlivých ZM. Naopak, nejsložitějším tvarem je podle výpočtů prezentovaný obdélník o rozměrech 100×400 . Kvalitu a funkčnost ZM je možné určit z klasifikace založené na ZM, která je samozřejmě na kvalitě ZM naprosto závislá.

Přehled geometrických deskriptorů je uveden v Tab. 8:

Tab. 8: Přehled geometrických deskriptorů pro vygenerované 2D tvary

Tvar	GM tvarů s rozlišením 200px						GM tvarů s obsahem 40000px					
	Čtve.	Ob.	Kruh	Troj.	Kos.	Mno.	Čtve.	Ob.	Kruh	Troj.	Kos.	Mno.
Obsah	40000	40000	31415	20100	40000	31490	40000	40000	40087	40127	40288	40275
Obvod	779,72	779,72	625,71	633,53	779,72	647,38	779,72	975,72	706,99	897,73	937,32	768,13
Orientace	0	0	45	-90	0	20,2	0	0	45	1,5	22,2	-74,3
Délka hl. osy	230,9	230,9	200	189	230,9	209,3	230,9	461,9	225,9	248,7	360,4	250,7
Délka ve. osy	230,9	230,9	200	163,7	230,9	193,3	230,9	115,5	225,9	248,4	149	208,9
Centroidy	102,50	102,50	102,00	102,25	102,50	102,39	102,50	202,5	115,00	154,10	206,00	119,62
	102,50	102,50	102,00	135,67	102,50	96,1	102,50	52,5	115,00	177,67	86,50	121,65
Kulatost	18,4	18,4	0,3	42,4	18,4	14,1	18,4	146	0,2	41,1	54,7	26
Hranatost	1	1	0,8	0,5	1	0,8	1	1	0,8	0,5	0,6	0,7
Kompaktnost	1,2	1,2	1	1,6	1,2	1,1	1,2	1,9	1	1,6	1,7	1,2
Počet hran	4	4	9	3	4	7	4	4	9	3	4	5
Délky hran	199	199	64	201	199	81	199	99	70	304	238	190
	199	199	73	282	199	95	199	399	84	370	238	132
	199	199	90	194	199	136	199	99	100	367	238	191
	199	199	...	...	199	87	199	399	...	...	238	156
Min. vzd. od C	99,5	99,5	99	59,1	99,5	87,2	99,5	49,5	112	87,1	83,5	93,4
Max vzd. od C	121,9	121,9	99,3	100,1	121,9	103,6	121,9	199,5	112,2	136,6	155,4	122,4
Pr. vzd. od C	104,9	104,9	99,1	69,9	104,9	96,4	104,9	80,7	112,1	99,2	96,7	106,8

Je nutné poznamenat, že algoritmus rozeznávající hrany a jejich velikosti je v případě kruhu nefunkční. Není to ovšem tak úplně chybný výsledek – u kruhu je zcela nelogické určovat počet a délku hran. Hrana je v geometrii označována jako úsečka spojující dva vrcholy. Z toho vyplývá, že kruh v obrazu může být definován 0 hranami nebo X hranami, kde X označuje číslo, které je nižší, než suma pixelů obrysu kruhu a vyšší nebo rovno 4. Při běžném pohledu na kruh není nesprávné uvažovat, že má kruh 0 hran, protože by se v takovém tvaru teoreticky neměly vyskytovat žádné vrcholy. V případě počítačového vidění a definice obrazu v rastrovém formátu je situace ovšem zcela odlišná.

Je nutné si uvědomit, že právě MATLAB, ve kterém je kruh vytvořen, využívá rastrový formát obrazu, to znamená, že při dostatečném poloměru (průměru) kruhu se v obrysu objevuje dostatečně dlouhá série pixelů o stejném směru, která spojuje „vrcholy“ a je následně klasifikována jako hrana. Z toho také vyplývá, že se zvyšujícím se poloměrem (průměrem) kruhu se bude zvyšovat i počet nesprávně detekovaných hran. Jako příklad nejlépe poslouží následující Tab 9. reprezentující nejmenší možný kruh v rastrovém formátu:

Tab. 9: Ukázka kruhu o velikosti $r=1px$

0	1	0
1	0	1
0	1	0

V rastrovém formátu by objekt definovaný v tabulce výše mohl být považován za kruh se 4 hranami, protože hodnoty 1 v Tab. 9 představují „vrcholy“ kruhu.

Dále je nutné poznamenat, že výpočet orientace kruhu je opět "nefunkční" a stejně tak je nelogické u kruhu orientaci určovat. Vzdálenost obrysových pixelů od středu ideálního kruhu je vždy stejná, orientaci je tedy nemožné určit. Hodnoty, které jsou zapsané v tabulce v podsekcí Kruh, jsou výsledkem nedokonalostí použitého rastrového formátu obrazu.

Problémy s určením délky hran, který vychází právě z detekce hran, je dalším problematickým deskriptorem, který se jeví jako velmi nespolehlivý. Použitý algoritmus, který byl popsán v sekci 2.3.4, má problém se směry pod různými úhly, které jsou tvořeny dvěma vektory. Pro představu je možné uvést úsečku, která vede z pravého dolního rohu obrazovky počítače do jeho levého horního rohu.

Při předpokladu, že obrazovka nemá poměr stran 1:1 (PC obrazovky mívají nejčastěji poměr stran 16:9), bude tato úsečka vedena pod úhlem, který je jiný než 45 stupňů. Taková úsečka je v rastrovém formátu provedena pomocí dvou vektorů obrysu (viz. sekce 1.1.3) - nahoru a doleva, které nakonec po jejich vzájemné kombinaci dovedou úsečku až do levého horního rohu. Použitý algoritmus detekce využívá matematické funkce modus, která určí nejčastější hodnotu v detekované hraně, a pokud je "celkový" vektor hrany diagonální, je tato hrana vynásobena hodnotou $\sqrt{2}$ ze zřejmých důvodů. Problém tedy nastává ve zmíněném případě, kdy je úsečka (hrana) vedena pod úhlem jiným než 45 stupňů – hodnota modusu takové hrany je rovna vektoru jinému než diagonálnímu, tím pádem je výsledný deskriptor chybný.

Další záležitostí, která negativně ovlivňuje výsledky deskriptorů je určení centroidu nepravidelného, nekonvexního tvaru. Centroid se často v takových případech nachází mimo samotný objekt, následkem jsou pak neúplné výpočty vzdáleností od centroidu, které z principu použité metody neobsahují informace o vzdálenosti obrysu od centroidu definované ve směru, ve kterém se nenachází obrysový bod. Hodnoty těchto výsledků jsou nahrazeny nulami, aby bylo alespoň dosaženo 360-ti prvků, které jsou potřebné pro klasifikaci objektu.

Na generovaných tvarech lze s největší jistotou určit, jestli jsou použité metody smysluplné, respektive jestli jsou dosažené výsledky správné. Jak již bylo popsáno na začátku této kapitoly, u některých tvarů se nepodařilo jasně určit některé z geometrických deskriptorů a sloužily pouze jako orientační hodnoty. Naopak, správně určené deskriptory posloužily jako zdroj informací, na jejichž základě je možné jednotlivé tvary popsat a porovnat.

Informace o jednotlivých deskriptorech uvedené v této sekci jsou zhodnoceny tak, že byly zavedeny tzv. „vypovídající deskriptory“, které jsou dále použity pro klasifikaci. „Vypovídající deskriptory“ jsou deskriptory pouze takové,

kteře mohou reálně přispět k analýze tvaru v případě zvolených obratlů. Počet a délky hran jsou při složitějších tvarech nepoužitelné z důvodů zmíněných výše. Minimální, maximální a průměrné vzdálenosti od centroidu jsou nahrazeny vzdálenostmi pod jednotlivými úhly a byly by tak redundantní. Délky hlavních a vedlejších os jsou pak zastoupeny kompaktností, která kombinuje tyto dva deskriptory.

Z výše zmíněného vyplývá, že „vypovídající deskriptory“ popisují:

- Obsah – byl určen zcela správně pro všechny generované tvary, jako příklad může posloužit obsah čtverce, který vyšel 40000px, což odpovídá hodnotě vycházející ze známého vzorce $S = a^2$
- Obvod – hodnoty vycházely velmi podobně hodnotám známým, opět může čtverec posloužit jako příklad, pro který vyšel obvod 779,72px, zatímco podle známého vzorce $O = 2 * (a + b)$ vychází hodnota 800px
- Centroidy – byly určeny zcela správně pro všechny generované tvary
- Kulatost – byla určena správně pro všechny tvary, jako důkaz může posloužit fakt, že pokud byly vytvořeny dva čtverce o jiném obsahu, kulatost vyšla s velmi malými rozdíly prakticky identická. Zároveň byla hodnota kulatosti podle očekávání (viz. sekce 1.2.1) nejnížší pro kruh, nevyšla ovšem nulová, protože byl použit rastrový obraz.
- Hranatost – byla určena správně pro všechny generované tvary, jako důkaz může posloužit fakt, že se při různých velikostech stejného tvaru deskriptor nemění a nejvyšší možná hodnota, tedy hodnota 1 (viz. sekce 1.2.1) vycházela správně pro čtverec a obdélník.
- Kompaktnost – byla určena správně pro všechny generované tvary, jako důkaz může posloužit fakt, že se při různých velikostech stejného tvaru deskriptor nemění a kompaktnost vychází podle předpokladu (viz. sekce 1.2.1) nejnížší pro kruh.
- Počet hran – i přes zřejmou nespolehlivost určení přesného počtu hran popsanou výše byl deskriptor počtu hran využit pro klasifikaci. Důvodem je fakt, že i když počet hran nebyl v případě kruhu správný, podával identické výsledky pro různé rozměry (obsah/rozlišení obrazu) pro stejný generovaný tvar. A protože je klasifikace založená pouze na rozdílu těchto hodnot, mohlo být tohoto deskriptoru využito.

Deskriptory obsahu, obvodu a centroidů je v případě této práce možné využít, ale je nutné si uvědomit, že pokud by reálná data (viz. další sekce) byla získávána pomocí různých přístrojů, jejichž výsledkem by byl obraz o různých rozlišeních, byly by zmíněné deskriptory nepoužitelné.

2.2.2 KLASIFIKACE SYNTETICKÝCH DAT

K otestování správné funkčnosti klasifikace bylo využito generování základních 2D tvarů. Byla navržena jednoduchá neuronová síť pomocí funkce *patternnet(počet_skrytých_vrstev,[trénovací funkce])*, která byla naučená deskriptory z výsledků analýzy patnácti náhodných reprezentací pro každý tvar, celkem tedy 75 obrazů. Počet skrytých vrstev neuronové sítě byl zvolen tři, počet neuronů v každé vrstvě odpovídá počtu deskriptorů, trénovací funkce byla použita *trainscg (BP síť)*, aktivací funkce byla skoková sigmoida, počet epoch učení se pohyboval kolem třiceti pěti [17].

Následně byl vygenerován další set obrazů podle stejných pravidel a ve stejném množství jako učební set, testovací set byl poté oklasifikován naučenou neuronovou sítí. Protože se úspěšnost klasifikace pohybovala kolem 90-100%, je možné s klidem konstatovat, že „vypovídající“ deskriptory byly zvoleny správně a je možné je využít i pro klasifikaci reálných dat.

Je ovšem nutné zmínit, že byly tvary generované náhodně, proto byly různě velké a obsah, obvod a centroidy nebylo možné využít a byly proto vyjmuty z klasifikace, viz. předchozí sekce. Klasifikaci syntetických dat je možné najít v příloze. (soubor *klasifikace_synteticka_data.m*)

2.3 REÁLNÁ OBRAZOVÁ DATA

Reálná obrazová data jsou data, která jsou tvořena jinak než algoritmem. Může se tedy jednat o obrazová data získaná z nemocničních nebo z veřejně přístupných databází. Předmětem tvarové analýzy této práce jsou obratle. Páteř je tvořena 33-34 obratli, které se mohou lišit svým tvarem. Na základě znalostí, které by poskytla vhodná analýza, je možné jednotlivé obratle separovat a mohla je tak umožněna například pohodlnější diagnostika z pohledu vyšetřujícího. Bylo vybráno pět obratlů - C3, L3, L5, Th4 a Th10, na které byly aplikovány metody a procesy popsány skrze tuto práci.

2.3.1 VÝSLEDKY ANALÝZY

V této podsekci jsou prezentovány výsledky analýzy vybraných obratlů od tří pacientů. Je nutné uvést, že obratle jsou reprezentovány po řezech a tvoří tak 3D obraz, autor práce se tedy snažil najít řez, který popisuje daný obratel co nejlépe. S přístupem k silnějším výpočetním možnostem by se dala analýza vytvářet pro každý řez. V Tab. 10 jsou pak prezentovány pouze „vypovídající“ geometrické deskriptory, tedy deskriptory, které podávaly správné hodnoty, viz. 2.2.1.


Jako příklad navržené tvarové analýzy poslouží obratel C3 prvního pacienta znázorněný na Obr.: 28-35. Tab.: 10-12. pak popisují obratel navrženými deskriptory.




Obr. 28: Přední vyseparovaná část obratle C3 prvního pacienta




Obr. 29: Zadní vyseparovaná část obratle C3 prvního pacienta




Obr. 30: Obrys těla obratle z Obr. 28




Obr. 31: Obrys těla obratle z Obr. 29




Obr. 32: Vzhládnost bodů obrysu od centroidu pro P1C3* - přední část



Obr. 33: Vzhládnost bodů obrysu od centroidu pro P1C3* - zadní část



Obr. 34: 1D-FD P1C3* - přední část



Obr. 35: 1D-FD P1C3* - zadní část

*P1C3 = Obratel C3 prvního pacienta

Tab. 10: Geometrické deskriptory P1C3

Obratle	C3	
Pacient	P1	
Obsah	1140,00	646,00
Obvod	302,08	94,88
Orientace	12,20	11,80
Délka hl. osy	97,50	34,10
Délka Vedl. osy	48,60	24,50
Centroidy	42,65 30,09	20,38 16,62
Kulatost	167,20	34,20
Hranatost	0,30	0,70
Kompaktnost	6,40	1,10
Počet hran	10,00	3,00

Tab. 11: Zernikovy momenty P1C3

m,n	0	1	2	3	4	5	6	7	8	9	10
0	0,28	-	-	-	-	-	-	-	-	-	-
1	-	0,14	-	-	-	-	-	-	-	-	-
2	0,02	-	0,21	-	-	-	-	-	-	-	-
3	-	0,19	-	0,21	-	-	-	-	-	-	-
4	0,08	-	0,07	-	0,04	-	-	-	-	-	-
5	-	0,07	-	0,19	-	0,08	-	-	-	-	-
6	0,03	-	0,14	-	0,02	-	0,14	-	-	-	-
7	-	0,07	-	0,06	-	0,10	-	0,06	-	-	-
8	0,02	-	0,12	-	0,11	-	0,03	-	0,09	-	-
9	-	0,08	-	0,04	-	0,06	-	0,06	-	0,02	-
10	0,15	-	0,10	-	0,08	-	0,07	-	0,05	-	0,03

Tab. 12: Zernikovy momenty P1C3-2

m,n	0	1	2	3	4	5	6	7	8	9	10
0	0,83	-	-	-	-	-	-	-	-	-	-
1	-	0,21	-	-	-	-	-	-	-	-	-
2	0,44	-	0,12	-	-	-	-	-	-	-	-
3	-	0,14	-	0,13	-	-	-	-	-	-	-
4	0,06	-	0,10	-	0,06	-	-	-	-	-	-
5	-	0,10	-	0,05	-	0,05	-	-	-	-	-
6	0,21	-	0,11	-	0,08	-	0,06	-	-	-	-
7	-	0,04	-	0,05	-	0,03	-	0,05	-	-	-
8	0,34	-	0,04	-	0,03	-	0,04	-	0,06	-	-
9	-	0,08	-	0,03	-	0,09	-	0,07	-	0,03	-
10	0,41	-	0,08	-	0,03	-	0,03	-	0,05	-	0,01

Výsledky analýzy pro všechny ostatní obratle jsou uvedeny v příloze.
(soubor *analysis_data_all_slices.mat*)

2.3.2 KLASIFIKACE OBRATLŮ

Celá myšlenka tvarové analýzy nakonec vede k automatizaci klasifikace tvarů v kvalitě podobné, jako analýza provedená expertem. Deskriptory, které jsou základem tvarové analýzy, by měly poskytovat takové informace o obrazových datech, aby na jejich základě mohla být provedena klasifikace.

Klasifikaci obratlů lze provádět na základě porovnání deskriptorů jednotlivých obratlů s deskriptory získané z referenčních tvarů. K určení referenčních dat lze přistupovat více způsoby, jako dva základní je možné uvést:

- Referenční data jsou tvořena analýzou takového objektu, který je expertem ohodnocen jako dostatečně vypovídající o dané problematice.
- Referenční data jsou tvořena všemi tvary, kdy je analyzovaný objekt srovnán s každým jiným tvarem a na základě rozdílů je pak objekt zařazen do třídy.

Pro klasifikaci pomocí Hammingovy sítě byl v práci využit první přístup, ale protože byly analyzovány pouze obratle nemocných pacientů, nebylo možné jasně určit referenční tvar, kterým byl po pečlivém zvážení manuálně zvolen vždy obratel prvního pacienta pro každý typ obratle. Klasifikace založená na získaných deskriptorech využívá druhý přístup.

Hammingova síť

Princip Hammingovy sítě byl popsán v kapitole teorie v sekci 1.3. Pro výpočet Hammingových vzdáleností a klasifikaci obratlů byla vytvořena funkce *Hamming_obratle*, která má na vstupu obrazová data všech obratlů. Výsledkem je pět shluků, do kterých byly jednotlivé obratle zařazeny.

1. shluk



P1C3

Obr. 36: Hammingova síť, shluk s referenčním obrazem P1C3

2. shluk



P3C3




P1L3



P3L3


Obr. 37: Hammingova síť, shluk s referenčním obrazem P1L3

3. shluk



Obr. 38: Hammingova síť, shluk s referenčním obrazem P1L5

4. shluk



Obr. 39: Hammingova síť, shluk s referenčním obrazem P1Th4

5. shluk



Obr. 40: Hammingova síť, shluk s referenčním obrazem P1Th10

Obr.: 36-40 jsou výsledkem shlukové analýzy založené na Hammingově síti. Výsledky klasifikace na základě Hammingovy sítě jsou diskutovány dále.

KLASIFIKACE NA ZÁKLADĚ HODNOT DESKRIPTORŮ

V této sekci je provedeno porovnání deskriptorů, které posloužilo jako vstupní data pro klasifikaci obratlů. Nejprve byly porovnány některé geometrické deskriptory, poté 1D-FD a nakonec Zernikovy momenty jednotlivých obratlů.

K samotné klasifikaci bylo využito matlabovských funkcí *kMeans(vstupy, počet tříd)* a *fcm(vstupy, počet tříd)*, které zařazují objekty do jednotlivých skupin užitím binární klasifikace a klasifikace pomocí fuzzy logiky v tomto pořadí. Pro obě funkce jsou vstupy rovny vybraným deskriptorům a počet tříd je rovno pěti.

Binární klasifikace je provedena pomocí Tab. 13. Názvy v tabulce odpovídají:


- GM = geometrické deskriptory
- FD = 1D-FD
- ZM = Zernikovy momenty

Tab. 13: Klasifikace obratlů – binární


Id	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Pacient	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3
Obratel	C3	C3	C3	L3	L3	L3	L5	L5	L5	Th4	Th4	Th4	Th10	Th10	Th10
GM	1	1	5	3	2	2	3	3	3	1	4	4	5	5	5
FD	2	3	5	2	2	2	3	3	3	4	4	4	5	4	5
ZM	1	1	5	2	2	1	4	2	2	5	4	4	3	5	5

Hodnoty a barva pole v tabulce značí shluk, do kterého byl obratel zařazen. Stejně hodnoty tedy představují objekty, které byly na základě deskriptorů zařazeny do stejného shluku.


Výsledek klasifikace s užitím fuzzy logiky je realizován pomocí grafů v Obr.: 41-43. Obratlů bylo celkem patnáct – pět druhů obratlů, každý od tří pacientů. V grafu jsou na ose x vyneseny jednotlivé obratle, kdy první tři odpovídají jednomu druhu obratle pro každého pacienta, další tři pak dalšímu druhu obratle pro všechny pacienty. Tímto způsobem jsou obsaženy všechny objekty. Na ose y jsou znázorněny stupně příslušnosti objektu do shluku.



Obr. 41: Stupně příslušnosti pro geometrické deskriptory



Obr. 42: Stupně příslušnosti pro 1D-FD



Obr. 43: Stupně příslušnosti pro Zernikovy momenty

2.3.3 DISKUZE VÝSLEDKŮ KLASIFIKACE

I přes to, že byly pro závěrečnou klasifikaci použity pouze „vypovídající deskriptory“, které podávaly kvalitní výsledky analýzy, je nutné konstatovat, že byla klasifikace úspěšná pouze z části. V sekci 2.3.2 je pro klasifikaci nejprve využita Hammingova síť a následně metody *kMeans*(*vstupy, počet tříd*) a *fcm*(*vstupy, počet tříd*) pro binární i fuzzy klasifikaci tomto pořadí, která byla založená na získaných deskriptorech GM, 1D-FD a ZM.

Výsledky dosažené pomocí Hammingovy sítě jsou velmi zavádějící, protože byly jako referenční obrazy vybrány vždy obratle daného typu prvního pacienta. Jak je možné vidět na obrázcích v sekci 2.3.2. Hammingova síť v případě prvního shluku prvního shluku klasifikovala správně jeden objekt ze tří možných, v druhém pak dva objekty ze tří, ve třetím případě zařadila všechny objekty správně. Nicméně, do stejné skupiny byly zařazeny i další dva objekty, do čtvrté skupiny byly zařazeny všechny objekty správně, ale opět došlo k špatnému zařazení jednoho objektu do této skupiny a do poslední skupiny byl zařazen pouze jeden objekt správně.

Na základě porovnání deskriptorů byla provedena klasifikace, jejíž výsledky jsou zaznamenány v tabulce a grafech v sekci 2.3.2. Z výsledků v tabulce jasně vyplývá, že pro:

- Geometrické deskriptory – byly do shluků reprezentující obratle C3, L3 a Th4 zařazeny správně vždy dva ze tří objektů, obratle L5 a Th10 byly zařazeny zcela správně. Zároveň je nutné poznamenat, že z výsledků fuzzy metod

vyplývá, že byly obratle zařazeny do shluků zcela jednoznačně až na výjimku v podobě P1-L3.

- 1D-FD – byly zcela správně zařazeny objekty reprezentující obratle L3, L5 a Th4, dva ze tří objektů byly správně zařazeny pro obratel Th10 a obratel C3 byl zařazen zcela nesprávně. Zde je nutné poznamenat, že z fuzzy výsledků klasifikace vyplývá, že jsou si některé výsledky velmi významně podobné, a i přes to, že byly tři obratle zcela správně zařazeny, není vhodné se na takovou klasifikaci příliš spoléhat.
- Zernikovy momenty – byly do shluků reprezentující obratle C3, L3, Th4 a Th10 správně zařazeny vždy dva ze tří objektů. Shluk reprezentující obratel L5 byl klasifikován zcela nesprávně.

Fuzzy klasifikace na základě porovnání deskriptorů poskytuje detailnější popis řazení objektů, protože je určena stupněm příslušnosti k danému shluku. Výsledky jsou ovšem logicky stejné, jako je tomu v tabulce popisující binární klasifikaci, platí proto stejný závěr, který byl popsán výše. Je tedy zřejmé, že klasifikace, která je založena na porovnání deskriptorů jednotlivých obratlů, je pro různé metody různě účinná.

Úspěšnost klasifikace je možné vyjádřit pomocí senzitivity – schopnosti klasifikace zařadit objekt do správného shluku, a specifity – schopnosti klasifikace zařadit objekt, který do daného shluku nepatří. Specifita a senzitivita jsou uvedeny v Tab. 14.

Tab. 14: Úspěšnost klasifikace založené na srovnání deskriptorů

Obratel	Specifita			Senzitivita		
	GM	1D-FD	ZM	GM	1D-FD	ZM
C3	0.92	0.92	0.92	0.67	0.00	0.67
L3	1.00	0.92	0.83	0.67	1.00	0.67
L5	0.92	0.92	0.92	1.00	1.00	0.00
Th4	1.00	1.00	0.92	0.67	1.00	0.67
Th10	0.92	0.92	0.83	1.00	0.67	0.67
Průměr	0.95	0.93	0.88	0.80	0.73	0.53


Z výsledků v Tab. 14 je zřejmé, že nejlepší výsledky klasifikace obecně podávaly geometrické deskriptory (GM), jejichž specifita vyšla 0,95 a senzitivita 0,8. O poznání horší výsledky podávaly metody založené na rozdílu 1D-FD a Zernikových momentů. Zde je opět nutné dodat, že při pohledu na Tab. 14 je kvalita 1D-FD porovnatelná s GM, ale výsledky z fuzzy klasifikace jsou velmi podobné a proto zavádějící.

2.4 GENEROVÁNÍ ZÁKLADNÍCH 3D OBJEKTŮ

Do základních 3D objektů tato práce řadí koule, krychli, kvádr a jehlan. Stejně jako u generování 2D objektů, i u 3D byly objekty vygenerovány pomocí funkcí, která mají na vstupu rozměry objektu. Jsou tedy stejně jako 2D úplně škálovatelné a dají se proto využít jako referenční tvary. Pro zobrazení vygenerovaných objektů byl použit program ImageJ.

KOULE

Ke generování koule byla vytvořena funkce *VytvorKouli(d)*, která vychází ze stejného principu, kterého bylo využito u generování kruhu, je tedy vypočítána vzdálenost jednotlivých bodů od centroidu v matici o zadaném rozměru, která je následně vyhodnocena. Pokud je vzdálenost nižší nebo rovna vstupu $d/2$, je do matice vepsána hodnota 1, v opačném případě je vepsána hodnota 0. Příklad generování koule je znázorněn v Obr. 44.



Obr. 44: Koule vygenerovaná pomocí funkce *aVytvorKouli(51)*

KRYCHLE


Krychli lze definovat jako čtverec, který je promítnut do prostoru. S takovouto znalostí bylo přistupováno k tvorbě funkce *VytvorKrychli(a)*, která má na vstupu velikost hrany a . Příklad generování krychle je znázorněn v Obr. 45.



Obr. 45: Krychle vygenerovaná pomocí funkce `aVytvorKrychli(20)`

KVÁDR


Krychli lze definovat jako obdélník, který je promítnut do prostoru. S takovou znalostí bylo přístupováno k tvorbě funkce `VytvorKvadr(a,b,c)`, která má na vstupu šířku a , výšku b a hloubku c . Příklad generování kvádru je znázorněn v Obr. 46.



Obr. 46: Kvádr vygenerovaný pomocí funkce `aVytvorKvadr(20,20,40)`

JEHLAN

V případě této práce se jedná o generování jehlanu se středem, který svými souřadnicemi v rovině XY odpovídá souřadnicím středu podstavy v rovině XY . Generování probíhá pomocí tvorby jednotlivých "vrstevnic" při pohybu zdola nahoru. Popsaný proces je proveden ve vytvořené funkci `VytvorJehlan(a,b,c)`, která na svém vstupu bere rozměry jehlanu – šířku podstavy a , výšku podstavy b a výšku jehlanu c . Příklad generování jehlanu je znázorněn v Obr. 47.



Obr. 47: Jehlan vygenerovaný pomocí funkce aVytvorJehlan(30,30,40)


VÝSLEDKY ANALÝZY 3D OBRAZOVÝCH DAT

Jak již bylo popsáno v kapitole teorie, v sekci 1.2.4, některé diagnostické metody jsou schopné vytvářet 3D obrazy. V této práci bylo pro zpracování reálných dat využito 2D deskriptorů, kterých je možné využít iteračně pro všechny řezy 3D obrazu. Jako příklad deskriptoru specifického pro 3D obraz jsou vypočítány vzdálenosti bodů obrysu od centroidu pro úhel ϕ a elevační úhel θ pro vygenerovanou kouli. Takový deskriptor pro kvádr s hranami $a = 31px, b = 41px, c = 51px$ je zobrazen pomocí Tab. 15 s legendou v Obr. 48.

Tab. 15: Vzdálenosti bodů obrysu od centroidu pro generovanou kouli

Vzdálenosti	Úhel ϕ												
Úhel θ	-179	-149	-119	-89	-59	-29	0	30	60	90	120	150	180
-85	22,69	17,81	18,93	21,34	17,88	18,86	17,15	18,62	18,07	18,32	18,68	18,01	17,15
-75	22,69	17,81	18,93	21,34	17,88	18,86	15,87	18,62	18,07	16,17	18,68	18,01	15,87
-65	22,69	18,41	18,93	21,34	18,44	18,86	16,28	18,62	18,07	16,31	18,68	18,01	16,28
-55	22,69	18,41	19,24	21,34	18,44	19,20	18,07	19,53	19,26	18,08	19,56	19,23	18,07
-45	22,69	20,72	21,47	21,34	20,74	21,45	20,55	20,78	20,64	20,55	20,79	20,63	20,55
-35	22,69	23,30	25,39	21,34	23,31	25,39	24,32	24,68	24,65	25,82	24,69	24,65	24,32
-25	22,69	26,08	31,35	21,34	31,79	25,29	22,37	25,64	30,32	27,67	30,32	25,62	22,37
-15	22,69	24,38	29,77	21,34	30,52	23,91	20,92	25,64	30,32	25,99	30,32	25,62	20,92
-5	22,69	23,56	28,84	21,34	29,34	23,06	20,15	25,64	30,32	25,22	30,32	25,62	20,15
5	22,69	23,39	28,76	21,34	29,26	22,89	20,07	25,64	30,32	25,06	30,32	25,62	20,07
15	22,69	24,12	29,53	21,34	30,02	23,41	20,66	25,64	30,32	25,75	30,32	25,62	20,66
25	22,69	25,41	31,49	21,34	31,95	24,96	21,97	25,64	30,32	27,35	30,32	25,62	21,97
35	22,69	26,56	27,11	21,34	27,53	26,14	23,89	25,21	26,38	26,55	26,38	25,20	23,89
45	22,69	21,90	22,48	21,34	22,14	22,23	21,91	22,03	22,32	21,95	22,32	22,03	21,91

55	22,69	19,00	20,33	21,34	19,12	20,21	18,63	19,53	19,68	18,63	19,68	19,53	18,63
65	22,69	19,00	20,69	21,34	19,12	20,63	17,04	17,81	18,93	17,04	17,88	18,86	17,04
75	22,69	18,36	20,69	21,34	18,42	20,63	15,86	17,81	18,93	15,86	17,88	18,86	15,86
85	22,69	18,36	20,69	21,34	18,42	20,63	15,19	17,81	18,93	15,19	17,88	18,86	15,19



Obr. 48: Legenda pro Tab. 15

Příklady deskriptorů, který jsou rozšířen z 2D reprezentace, jsou objem a centroidy znázorněné v Tab. 16.

Tab. 16: Vzdálenosti bodů obrysu od centroidu pro generovanou kouli

Deskriptor	Kvádr(31, 41, 51)
Objem	64821
Centroidy	16 20 25

3 ZÁVĚR

Práce obsahuje v teoretické části detailní popis základních i pokročilejších metod tvarové analýzy obrazových dat. V prostředí MATLAB se podařilo vytvořit dílčí procesy analýzy tak, jak byly popsány v rámci **teorie**. Takové procesy se skládají z přípravy obrazu - transformace obrazu, filtrace, morfologických úprav a tvorby obrysu, dále ze samotného popisu tvarů, čehož bylo dosaženo pomocí geometrických deskriptorů a deskriptorů založených na Fourierově transformaci.

Metody analýzy byly nejprve aplikovány na syntetická data, jejichž deskriptory byly předem známe a bylo na nich možné ověřit jejich funkčnost a správnost. Mnohé deskriptory byly tímto způsobem ohodnoceny jako „vypovídající“, hodnoty takových deskriptorů následně sloužily ke klasifikaci obrazu.

Reálná data bylo nejprve nutné upravit a připravit tak na analýzu. Dostupné obrazy nebyly svou strukturou konzistentní – obrazové informace se v jednotlivých řezech nacházely na jiných pozicích, což vedlo k několika kompromisům (např. manuální určení „správného“ řezu) a spoustám dalších úprav obrazu. I přes to, že byly použity pouze „vypovídající deskriptory“ (funkční), byla klasifikace z těchto důvodů úspěšná pouze částečně.

Klasifikace podávající nejlepší výsledky byla založena na GM, která překonala Hammingovu síť. Klasifikace založené na 1D-FD a ZM podávaly o poznání horší výsledky. Je ovšem zcela možné, že zmíněné kompromisy a úpravy původního obrazu vedly ke snížení kvality analýzy a na ní závislé klasifikaci.

Je nutné konstatovat, že úspěšnost klasifikace nebyla na takové úrovni, aby na jejím základě mohl být navrhnut samostatný expertní systém, nicméně může posloužit jako systém podpůrný při diagnostice obrazových dat.

LITERATURA

- [1] AL-ROUSAN, Taleb, Eyad MASAD, Erol TUTUMLUER a Tongyan PAN. Evaluation of image analysis techniques for quantifying aggregate shape characteristics. *Construction and Building Materials* [online]. 2007, **21**(5), 978-990 [cit. 2017-08-03]. DOI: 10.1016/j.conbuildmat.2006.03.005. ISSN 09500618. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0950061806000377>
- [2] COSTA, Luciano da Fontoura a Roberto Marcondes CESAR. *Shape classification and analysis: theory and practice*. 2nd ed. Boca Raton: CRC Press, c2009. Image processing series. ISBN 0849379296.
- [3] DALLAS, Little, Joe BUTTON, Priyantha JAYAWICKRAMA a Barry HUDSON. *Quantify Shape, Angularity and Surface Texture of Aggregates Using Image Analysis and Study Their Effect on Performance* [online]. In: . [cit. 2017-08-03]. Dostupné z: https://www.researchgate.net/publication/35715088_Quantify_shape_angularity_and_surface_texture_of_aggregates_using_image_analysis_and_study_their_effect_on_performance
- [4] GRANLUND, G. H. Fourier Preprocessing for Hand Print Character Recognition. *IEEE Transactions on Computers* [online]. 1972, **C-21**(2), 195-201 [cit. 2017-08-03]. DOI: 10.1109/TC.1972.5008926. ISSN 00189340. Dostupné z: <http://ieeexplore.ieee.org/document/5008926/>
- [5] KIM, Whoi-Yul a Yong-Sung KIM. A region-based shape descriptor using Zernike moments. *Signal Processing: Image Communication* [online]. 2000, **16**(1-2), 95-102 [cit. 2017-08-03]. DOI: 10.1016/S0923-5965(00)00019-9. ISSN 09235965. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0923596500000199>
- [6] KOZUMPLÍK, Jiří a Ivo PROVAZNÍK. *Umělá inteligence v medicíně* [online]. VUT FEKT, 2007 [cit. 2017-08-03]. Dostupné z: <https://moodle.vutbr.cz/mod/resource/view.php?id=98718>. Skripta. VUT.
- [7] MD GHANI, Nor Azura, Choong-Yeun LIONG a Abdul Aziz JEMAIN. Analysis of geometric moments as features for firearm identification. *Forensic Science International* [online]. 2010, **198**(1-3), 143-149 [cit. 2017-08-03]. DOI: 10.1016/j.forsciint.2010.02.011. ISSN 03790738. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0379073810000630>
- [8] MIKŠÍK, Ondřej. *Praktické využití metod digitálního zpracování obrazu*. Gymnázium Kroměříž, 2007. Dostupné také z: <http://soc.nidv.cz/data/2007/01-2.pdf>
- [9] MING-KUEI HU. Visual pattern recognition by moment invariants. *IEEE Transactions on Information Theory* [online]. 1962, **8**(2), 179-187 [cit. 2017-08-03]. DOI: 10.1109/TIT.1962.1057692. ISSN 00189448. Dostupné z: <http://ieeexplore.ieee.org/document/1057692/>
- [10] NEAL, F. Brent. a John C. RUSS. *Measuring shape*. Boca Raton: CRC Press, c2012. ISBN 9781439855980.
- [11] O'GORMAN, Lawrence., Michael J. SAMMON a Michael. SEUL. *Practical algorithms for image analysis: description, examples, programs, and projects*. 2nd ed. New York: Cambridge University Press, 2008. ISBN 9780521884112.
- [12] PERSOON, Eric a King-Sun FU. Shape Discrimination Using Fourier Descriptors. *IEEE Transactions on Pattern Analysis and Machine Intelligence* [online]. 1986, **PAMI-8**(3), 388-

- 397 [cit. 2017-08-03]. DOI: 10.1109/TPAMI.1986.4767799. ISSN 01628828. Dostupné z: <http://ieeexplore.ieee.org/document/4767799/>
- [13] TAHMASBI, Amir. Zernike Moments. In: *Mathworks* [online]. [cit. 2017-08-03]. Dostupné z: <https://www.mathworks.com/matlabcentral/fileexchange/38900-zernike-moments?requestedDomain=www.mathworks.com>
- [14] ZHANG, Dengsheng a Guojun LU. *Shape-based image retrieval using generic Fourier descriptor* [online]. , 2-4 [cit. 2017-08-03]. DOI: 10.1016/S0923-5965(02). Dostupné z: [https://doi.org/10.1016/S0923-5965\(02\)00084-X](https://doi.org/10.1016/S0923-5965(02)00084-X)
- [15] Image Noise and Filtering. In: *The University of Utah* [online]. [cit. 2017-08-03]. Dostupné z: <http://www.coe.utah.edu/~cs4640/slides/Lecture6.pdf>
- [16] Matematická morfologie. In: *People CVUT* [online]. Praha: CVUT, 2009 [cit. 2017-08-03]. Dostupné z: <http://people.ciirc.cvut.cz/~hlavac/TeachPresCz/11DigZprObr/71-3MatMorpholBinCz.pdf>
- [17] Image Processing Toolbox. *Mathworks* [online]. Praha: Humusoft s.r.o, 2012 [cit. 2017-08-03]. Dostupné z: <https://www.mathworks.com/products/image.html>
- [18] *Cylindrical and Spherical Coordinates* [online]. USA, 2009 [cit. 2017-08-07]. Dostupné z: <https://www.math.utah.edu/lectures/math2210/9PostNotes.pdf>. Utah University.
- [19] *Spherical polar coordinates* [online]. University of Sheffield, 2011 [cit. 2017-08-03]. Dostupné z: <https://neil-strickland.staff.shef.ac.uk/courses/MAS243/lectures/lecture10.pdf>

Seznam příloh

Příloha 1. CD obsahující všechny výsledky tvarové analýzy a zdrojové kódy k ní vedoucí