



# VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

## FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

## ÚSTAV TELEKOMUNIKACÍ

DEPARTMENT OF TELECOMMUNICATIONS

# AUTOMATIZACE EXOSKOPICKÉ ANALÝZY POMOCÍ ZPRACOVÁNÍ OBRAZŮ SEDIMENTÁRNÍCH ZRN POŘÍZENÝCH ELEKTRONOVÝM MIKROSKOPEM

AUTOMATION OF EXOSCOPIC ANALYSIS USING IMAGE PROCESSING OF SEDIMENTARY GRAINS  
ACQUIRED BY ELECTRON MICROSCOPE

## DIZERTAČNÍ PRÁCE

DOCTORAL THESIS

## AUTOR PRÁCE

AUTHOR

Ing. Aleš Křupka

## ŠKOLITEL

SUPERVISOR

doc. Ing. Kamil Říha, Ph.D.

BRNO 2016

# Abstrakt

Práce se zabývá výzkumem metod analýzy obrazu za účelem využití při exoskopické analýze sedimentárních zrn, konkrétně při rozlišování mezi jednotlivými geomorfologickými genezemi, kterými byla tato zrna formována. Obrazy zrn jsou pořízeny pomocí rastrového elektronového mikroskopu. Hlavním přínosem je návrh metodiky, pomocí které je možné exoskopickou analýzu do značné míry automatizovat. Tato metodika pokrývá automatickou segmentaci zrn v obraze, automatickou analýzu zaoblenosti 2D průmětu zrn a rozlišitelnost geomorfologických genezí podle struktury povrchu zrn.

V části zabývající se automatickou segmentací byla navržena metoda, která následně umožňuje snadnou manuální korekci výsledků segmentace. Tato metoda je založena na rozdělení a slučování regionů v obraze. Jednotlivé kroky této procedury byly navrženy tak, aby bylo co nejvíce využito specifických vlastností snímků zachycujících zrna a následně dosaženo co nejlepších výsledků segmentace.

V části automatické analýzy zaoblenosti 2D průmětu sedimentárních zrn byl vyhodnocen vliv obrazového rozlišení na výslednou hodnotu zaoblenosti. Dále zde bylo zkoumáno minimální množství sedimentárních zrn, které je nutné analyzovat pro spolehlivé porovnání dvojice geomorfologických genezí na základě míry zaoblenosti. Pro určení tohoto množství byla navržena metoda, která byla experimentálně ověřena.

V části automatické analýzy povrchové struktury sedimentárních zrn byla navržena metoda pro rozlišování geomorfologických genezí. Tato metoda využívá nízkoúrovňové texturní příznaky, pomocí kterých lze popsat jednotlivé obrazy sedimentárních zrn. Modely jednotlivých geomorfologických genezí jsou pak tvořeny souborem histogramů reprezentujících četnosti zastoupení různých konfigurací nízkoúrovňových texturních příznaků.

Metody navržené v jednotlivých částech práce byly otestovány a vyhodnoceny na základě databáze, která obsahuje vzorky sedimentárních zrn pocházejících z celkem 4 různých geomorfologických genezí (eolická, glaciální, svahová a vulkanická).

## Klíčová slova:

Exoskopická analýza, rastrový elektronový mikroskop, sedimentární zrna, zpracování obrazu, segmentace, analýza tvaru, analýza textury, klasifikace

KŘUPKA, Aleš *Automatizace exoskopické analýzy pomocí zpracování obrazů sedimentárních zrn pořízených elektronovým mikroskopem*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav telekomunikací, 2016.

Vedoucí dizertační práce: doc. Ing. Kamil Říha, Ph.D

## Abstract

This thesis deals with image analysis methods which can be exploited in exoscopic analysis of sedimentary grains, specifically for the purpose of distinguishing between geomorphologic geneses which influenced a form of sedimentary grains. The images of sedimentary grains were acquired by a scanning electron microscope. The main contribution is the proposal of multiple methods that can significantly automate the exoscopic analysis. These methods cover the automatic segmentation of grains in image, the automatic analysis of roundness of 2D grain projection and the classification of geomorphologic geneses according to the grain surface structure.

In the section concerning the automatic segmentation, a segmentation method enabling an easy subsequent manual result correction was proposed. This method is based on the split-and-merge approach. The individual steps the procedure were designed to exploit specific properties of sedimentary grain images in order to obtain the best segmentation results.

In the section concerning the automatic roundness analysis of 2D projection of sedimentary grains, an influence of pixel resolution on a result roundness value was evaluated. Further, a minimal number of grains, which is necessary to analyze in order to reliably compare a pair of geomorphological geneses, was investigated. For the determination of this number, a method was proposed and experimentally verified.

In the section of automatic analysis of sedimentary grain surface structure, a method for classification of geomorphologic geneses was proposed. The method utilizes low-level texture features which describes individual images of sedimentary grains. A model of geomorphological genesis is constituted of a set of histograms representing occurrences of different configurations of low-level texture features.

The methods proposed in the thesis were tested and evaluated based on a database, which consists of sedimentary grain samples from 4 different geomorphological geneses (eolic, glacial, slope and volcanic).

### Keywords:

Exoscopic analysis, scanning electron microscope, sedimentary grains, image processing, segmentation, shape analysis, texture analysis, classification.

KŘUPKA, Aleš *Automation of exoscopic analysis using image processing of sedimentary grains acquired by electron microscope*. Brno: Brno University of Technology, Faculty of Electrical Engineering and Communication, Department of Telecommunications, 2016.

Supervised by doc. Ing. Kamil Říha, Ph.D

## Prohlášení

Prohlašuji, že svou doktorskou práci na téma „Automatizace exoskopické analýzy pomocí zpracování obrazů sedimentárních zrn pořízených elektronovým mikroskopem“ jsem vypracoval samostatně pod vedením vedoucího doktorské 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 doktorské práce dále prohlašuji, že v souvislosti s vytvořením této doktorské 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 S 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení S 152 trestního zákona č. 140/1961 Sb.

Brno .....

.....

(podpis autora)

VEDOUCÍ PRÁCE  
SUPERVISOR

doc. Ing. Kamil Říha, Ph.D.

ŠKOLITEL SPECIALISTA  
CO-SUPERVISOR

prof. Marcos Faundez-Zanuy, Ph.D.  
Escuela Superior Politécnica, Mataró, Spain

## PODĚKOVÁNÍ

Rád bych poděkoval vedoucímu dizertační práce panu doc. Ing. Kamilovi Říhovi, Ph.D. za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci.

Dále bych chtěl poděkovat svým nejbližším, především mé ženě, za podporu a porozumění při mém doktorském studiu.

Výzkum popsaný v této dizertační práci byl realizovaný v laboratořích podpořených projektem Centrum senzorických, informačních a komunikačních systémů (SIX); registrační číslo CZ.1.05/2.1.00/03.0072, operačního programu Výzkum a vývoj pro inovace.

# Obsah

1. Úvod.....	14
2. Dosavadní vývoj v oblasti automatické analýzy geologických objektů v kontextu využití v exoskopické analýze .....	17
2.1. Metody segmentace obrazu .....	17
2.2. Analýza 2D tvaru sedimentárních zrn .....	19
2.2.1. Metody analýzy zaoblenosti.....	19
2.2.2. Určování velikosti vzorku pro odlišení tříd .....	26
2.3. Analýza povrchu sedimentárních zrn .....	26
2.3.1. Analýza textury.....	26
2.3.2. Využití analýzy textury v oblasti rozpoznávání sedimentárních zrn.....	27
3. Cíle dizertační práce .....	29
4. Experimentální databáze .....	30
5. Segmentace.....	33
5.1. Fáze rozdělení do regionů .....	33
5.2. Ohodnocení grafu přilehlých regionů.....	35
5.3. Fáze slučování regionů.....	36
5.4. Fáze vyhodnocení množin regionů.....	37
5.5. Fáze výběru segmentu .....	38
5.6. Zpřesnění hranic .....	40
5.7. Experimentální výsledky .....	40
5.7.1. Optimální rozdělení do regionů.....	40
5.7.2. Vyhodnocení výsledků segmentace .....	42
5.7.3. Srovnání s metodou aktivních kontur.....	44
5.7.4. Diskuze výsledků .....	45
6. Porovnání geomorfologických genezí podle tvaru 2D kontury sedimentárních zrn .....	47
6.1. Určení minimálního rozlišení pro analýzu zaoblenosti.....	47
6.2. Porovnávání genezí na základě hodnot zaoblenosti.....	49
6.3. Určení minimálního počtu projekcí zrn .....	53
6.3.1. Princip určení minimálního počtu projekcí zrn .....	53
6.3.2. Ověření metody pro určení minimálního počtu projekcí.....	54
6.4. Diskuze experimentálních výsledků na dostupné databázi .....	57



7.	Klasifikace podle texturních vlastností .....	59
7.1.	Blokový popis vytvoření modelů geomorfologických genezí.....	59
7.1.1.	Vytvoření texton slovníku.....	59
7.1.2.	Vytvoření modelu geomorfologických genezí .....	61
7.1.3.	Klasifikace neznámého vzorku.....	62
7.2.	Detailní popis procedury vytvoření modelů geomorfologických genezí .....	62
7.2.1.	Použité obrazové příznaky.....	62
7.2.2.	Sestavení texton slovníku .....	65
7.2.3.	Vytvoření modelu geomorfologické geneze .....	66
7.2.4.	Klasifikace geneze neznámého vzorku metodou k-NN.....	66
7.3.	Experimentální výsledky .....	67
7.3.1.	Výsledky určování tříd genezí .....	71
7.3.2.	Srovnání s metodou analýzy povrchu zrn dle Newella .....	73
7.3.3.	Vliv nepřesnosti segmentace na výsledek klasifikace .....	74
7.4.	Diskuze experimentálních výsledků na dostupné databázi .....	76
8.	Závěr .....	78
	Literatura .....	80
	Publikace autora .....	84
	Seznam zkratk.....	85
	Přílohy.....	86

## Seznam obrázků

Obr. 1:	Příklad snímků sedimentárních zrn s různými exoskopickými vlastnostmi .....	15
Obr. 2:	Ukázky strukturních charakteristik používaných v exoskopii – a) lasturnaté lomy, b) obloukové stupně, c) V-jamky, d) paralelní rýhy [1].....	16
Obr. 3:	Ukázka výsledků aplikace metod prahování a detekce hran [7].....	18
Obr. 4:	Vliv natočení průmětné roviny na výslednou podobu 2D průmětu .....	20
Obr. 5:	Princip využití přístupu založeného na disktrétní geometrii [23] .....	21
Obr. 6:	Princip využití přístupu založeného na Fourierově analýze [35] .....	22
Obr. 7:	Princip využití přístupu založeného na faktoru angularity .....	23
Obr. 8:	Princip využití přístupu založeného na matematické morfologii [40] .....	25
Obr. 9:	Princip využití přístupu založeného na fraktálech [41].....	25
Obr. 10:	Konvoluční jádra filtrů pro extrakci BIF [51].....	28
Obr. 11:	Schéma segmentační metody .....	33
Obr. 12:	Příklady říditelných filtrů pro natočení $\alpha \in \{0, 45, 90, 135, 180, 225, 270, 315\}^\circ$ .....	34
Obr. 13:	Fáze rozdělení do regionů – a) původní obraz, b) gradientní obraz – reliéf, c) značky, d) rozdělení do regionů.....	34
Obr. 14:	Graf přilehlých regionů RAG.....	35
Obr. 15:	Obraz filtrovaný říditelnými filtry pro směry $\alpha \in \{0, 45, 90, 135, 180, 225, 270, 315\}^\circ$ .....	36
Obr. 16:	Vizualizace matic, (a) <b>M</b> , (b) <b>S</b> , (c) <b>C</b> , (d) maska určující potenciálně správné množiny regionů.....	38
Obr. 17:	(a) Množina regionů po proceduře slučování (b) Výsledný segment po proceduře slučování (c) Obraz s inicializačními body (d) Výsledná maska po proceduře zpřesnění hranic.....	39
Obr. 18:	Vliv prahu $t_{\text{mark}}$ na průměrný počet protnutí (společně se směrodatnou odchylkou) a průměrný počet regionů. Práh $t_{\text{mark}}$ je daný jako $x$ -tý percentil histogramu obrazu $\text{grd}_{\text{abs}}(x, y)$ .....	41
Obr. 19:	Rozdělení do regionů na základě prahu $t_{\text{mark}}$ , (a) příliš vysoký $t_{\text{mark}}$ , (b) příliš nízký $t_{\text{mark}}$ , (c) optimální $t_{\text{mark}}$ .....	41
Obr. 20:	Příklady výsledků segmentace, (a) $\text{pph} = 90 \%$ , (b) $\text{pph} = 95 \%$ , (c) $\text{senzitivita} = 90 \%$ , (d) $\text{senzitivita} = 95 \%$ .....	42
Obr. 21:	Výsledky po proceduře slučování regionů. Vertikální osy představují podíl obrazů z testovací sady, které byly správně segmentovány $\text{pph}$ resp. $\text{senzitivitou}$ na horizontální ose. Pravá strana zobrazuje detail grafu. ....	43
Obr. 22:	Výsledky po proceduře zpřesnění hranic. Vertikální osy představují podíl obrazů z testovací sady, které byly správně segmentovány s $\text{pph}$ resp. $\text{senzitivitou}$ na horizontální ose. Pravá strana zobrazuje detail grafu. ....	44

Obr. 23: Příklady výsledků segmentace metodou aktivních kontur, (a) správný výsledek segmentace, (b) část pozadí špatně označená jako zrno, (c) část zrna špatně označená jako pozadí .....	46
Obr. 24: Závislost korelačního koeficientu $c$ na průměrné délce kontury $\bar{l}$ .....	49
Obr. 25: Příklad histogramu zaoblenosti měřené metodou M1 pro svahovou genezi .....	50
Obr. 26: Histogramy zaoblenosti zrn měřené pro různé geneze metodami M1-M2.....	50
Obr. 27: Histogramy zaoblenosti zrn měřené pro různé geneze metodami M3-M4.....	51
Obr. 28: Histogramy zaoblenosti zrn měřené pro různé geneze metodami M5-M6.....	52
Obr. 29: Překryv rozložení dvojice tříd .....	54
Obr. 30: Použitá sada částic pro generování průmětů .....	55
Obr. 31: Procedura vytvoření texton slovníku. ....	60
Obr. 32: Vytvoření modelu geomorfologických genezí .....	61
Obr. 33: Klasifikace vzorku do geomorfologické geneze .....	62
Obr. 34: Příklad sestavení kookurenční matice pro posun $(1, 1)$ se zvýrazněným vznikem prvku $(i, j) = (1, 0)$ , tedy jeho trojnásobného výskytu.....	64
Obr. 35: Získání lokálních příznakových vektorů .....	65
Obr. 36: Reprezentace obrazu histogramem .....	66
Obr. 37: Schéma křížové validace použité v experimentu .....	70

## Seznam tabulek

Tab. 1: Vzorky eolické geneze .....	31
Tab. 2: Vzorky glaciální geneze .....	31
Tab. 3: Vzorky svahové geneze .....	32
Tab. 4: Vzorky vulkanické geneze .....	32
Tab. 5: Výsledky po proceduře slučování regionů.....	43
Tab. 6: Výsledky po proceduře zpřesnění hranic .....	44
Tab. 7: Výsledky po aplikaci metody aktivních kontur .....	45
Tab. 8: Použité parametry implementovaných metod měření zaoblenosti .....	49
Tab. 9: Střední hodnoty a směrodatné odchylky zaoblenosti zrn měřené různými metodami pro jednotlivé geneze .....	52
Tab. 10: Popis použité sady objektů .....	55
Tab. 11: Vztažné MNP určené pro dvojice tříd $C1C2$ , $C2C3$ a $C3C4$ a pro metody měření zaoblenosti M1-M6.....	56
Tab. 12: Srovnání MNP určeného na základě odhadů statistických momentů a vztažného MNP pro dvojici tříd $C1C2$ .....	57
Tab. 13: Srovnání MNP určeného na základě odhadů statistických momentů a vztažného MNP pro dvojici tříd $C2C3$ .....	57
Tab. 14: Srovnání MNP určeného na základě odhadů statistických momentů a vztažného MNP pro dvojici tříd $C3C4$ .....	57
Tab. 15: Minimální počty průmětů pro dvojice tříd při použití metod měření zaoblenosti M1-M6 a při různých hodnotách přesnosti $f$ .....	58
Tab. 16: Šablona kontingenční tabulky v kontextu senzitivity (celkové výsledky pro všechna opakování a iterace křížové validace) .....	71
Tab. 17: Šablona kontingenční tabulky v kontextu pozitivní prediktivní hodnoty (celkové výsledky pro všechna opakování a iterace křížové validace).....	71
Tab. 18 Průměrné výsledky klasifikace na úrovni jednotlivých zrn v kontextu senzitivity .....	71
Tab. 19: Průměrné výsledky klasifikace na úrovni celých vzorků v kontextu senzitivity .....	71
Tab. 20: Průměrné výsledky klasifikace na úrovni jednotlivých zrn v kontextu pozitivní prediktivní hodnoty.....	72
Tab. 21: Průměrné výsledky klasifikace na úrovni celých vzorků v kontextu pozitivní prediktivní hodnoty.....	72
Tab. 22: Průměrné výsledky klasifikace na úrovni celých vzorků v kontextu senzitivity při použití BIF .....	74

Tab. 23: Průměrné výsledky klasifikace na úrovni celých vzorků v kontextu pozitivní prediktivní hodnoty při použití BIF .....	74
Tab. 24: Srovnání výsledků klasifikace na úrovni celých vzorků při použití texton slovníku a při použití BIF .....	74
Tab. 25: Průměrné výsledky klasifikace na úrovni jednotlivých zrn v kontextu senzitivity při použití automatické segmentace pro vymezení plochy zrna .....	75
Tab. 26: Průměrné výsledky klasifikace na úrovni celých vzorků v kontextu senzitivity při použití automatické segmentace pro vymezení plochy zrna .....	75
Tab. 27: Průměrné výsledky klasifikace na úrovni jednotlivých zrn v kontextu pozitivní prediktivní hodnoty při použití automatické segmentace pro vymezení plochy zrna .....	75
Tab. 28: Průměrné výsledky klasifikace na úrovni celých vzorků v kontextu pozitivní prediktivní hodnoty při použití automatické segmentace pro vymezení plochy zrna .....	76
Tab. 29: Srovnání výsledků klasifikace na úrovni celých vzorků při použití manuálně a automaticky získané masky vymežující zrna .....	76

# 1. Úvod

Tato dizertační práce si klade za cíl návrh nových metod automatické analýzy povrchových vlastností sedimentárních zrn. Analýzu povrchových vlastností částic obsažených v horninách lze využít pro studium geomorfologických pochodů, které formovaly zemský povrch. Jedním z postupů geomorfologie je analýza vlastností těchto nezpevněných sedimentárních částic z různých hornin. Tyto částice bývají nazývány zrna a většinou nabývají miniaturních rozměrů. Z důvodu jejich malých rozměrů bývá pro jejich snímání použit rastrový elektronový mikroskop SEM (Scanning Electron Microscope) a nasnímané obrazy jednotlivých zrn jsou digitalizovány, viz příklad na obrázku 1. Obvykle bývá zkoumán vzorek odebraný v určité lokalitě (v kontextu geomorfologie se vzorkem rozumí soubor řádově několika desítek kusů zrn). Takový vzorek je při analýze reprezentován sadou obrazů jednotlivě nasnímaných zrn. Tato sada je pak podrobena tzv. exoskopické analýze. Exoskopie je technika analýzy, při které jsou vyšetřovány povrchové vlastnosti nezpevněných sedimentárních zrn. Exoskopická analýza je v současné praxi manuální procedurou a je prováděna zkušeným odborníkem, který na základě svých znalostí a zkušeností detekuje a kvantifikuje u zkoumaných vzorků typické povrchové struktury, které jsou na povrchu zrn hledány. V terminologii exoskopie jsou tyto struktury označovány jako textury (přesto budou v dalším textu dále nazývány jako strukturní charakteristiky z důvodu odlišení od pojmu textura používaného v oblasti počítačového zpracování obrazu a počítačové grafiky). Jako typické strukturní charakteristiky lze jmenovat například lasturnatý lom, obloukový stupeň, V-jamka aj, [1], viz obrázek 2. Dále jsou sledovány i tvarové charakteristiky jako zaoblenost či kruhovost. Pro daný vzorek jsou během exoskopické analýzy shromažďovány statistiky o výskytech jednotlivých strukturních charakteristik (tj. jaký počet zrn obsažených v jednom odebraném vzorku obsahuje danou strukturní charakteristiku). Na základě těchto statistik lze vyvozovat různé závěry. Např. v [1][2] jsou tyto statistiky používány pro rozlišování geomorfologických genezí určitých geografických oblastí, v [3] jsou využity pro určení místa původu zkoumaného sedimentu.

Právě v oblasti exoskopické analýzy se nabízí prostor pro výzkum nových metod zpracování obrazu. Hlavní motivací je především odstranění zdoluhavé manuální práce odborníka. Části exoskopické procedury je možné z hlediska její automatizace rozdělit do několika základních částí.


První základní částí je tzv. segmentace obrazu. Segmentace je prováděna za účelem označení oblasti náležící zrně ve snímku. Vymezení oblasti zájmu je základním předpokladem pro následující zpracování. Proto, aby zpracování obrazů počítačem bylo přínosné, je vhodné, aby byl tento proces automatizován při dosažení vysoké míry přesnosti. Provedení automatické segmentace sedimentárních zrn v obraze není triviální, což je způsobeno komplexním charakterem snímků. Z tohoto důvodu je důležité vyvinout takovou segmentační metodu, která bude dostatečně robustní vzhledem ke komplexnímu charakteru snímku a umožní co nejpřesnější vymezení objektu zájmu v obraze.

Druhou základní částí je analýza 2D tvaru zrn. Často sledovaným parametrem je zde zaoblenost, vyjadřující míru zakulacení hran zkoumaného zrna. Tento parametr může poskytovat při exoskopické analýze evidenci o přírodních pochodech, které na zrno působily (vliv větru, kapalin atd.), a může tedy být použit při vyhodnocování geomorfologické geneze. Tyto parametry jsou často vyhodnocovány subjektivně, např. klasifikací zrna do dané třídy zaoblenosti podle srovnávací tabulky, což může mít za následek různé výsledky při hodnocení různými osobami. Jako vhodná se tedy jeví automatizace analýzy zaoblenosti a zhodnocení použitelnosti automatizovaných metod při exoskopické analýze.


Třetí základní částí je pak analýza samotného povrchu sedimentárních zrn, tedy sledování výskytu různých strukturních charakteristik na povrchu zrn.

- V této části je tedy první logickou cestou návrh metod zpracování obrazu, které budou schopny rozeznat a kvantifikovat různé druhy strukturních charakteristik. Na základě četnosti jejich výskytu pak bude možné vyhodnocovat pravděpodobné geomorfologické geneze. Záměrem je zachování stávajících principů procedury exoskopické analýzy, přičemž její část, spočívající ve sledování četností výskytu strukturních charakteristik, by byla automatizována. Vzhledem k různorodosti obrazů zachycujících zrna i samotných strukturních charakteristik se jedná o netriviální problém.
- Druhá možná cesta zahrnuje přímou klasifikaci zkoumaného vzorku do některé z definovaných tříd. V případě exoskopické analýzy se bude třídou rozumět některá z geomorfologických genezí (např. eolická, glaciální, svahová či vulkanická geneze). Klasifikace by probíhala s využitím v současné době velmi perspektivních technik rozpoznání vzoru, kdy je na základě dostupných dat (tzv. trénovací databáze) vytvořen model, pomocí kterého jsou klasifikovány nové vzorky. Jako příznaky pro klasifikaci je možné použít vhodných charakteristik extrahovaných z povrchu zrn.

Kapitoly této dizertace tedy pokrývají jednotlivé, výše uvedené aspekty, které je nutné brát v potaz při automatizaci analýzy obrazu pro účely exoskopické analýzy. Nejprve je představen současný stav poznání relevantní k řešené problematice. Poté jsou vytyčeny cíle práce, konkrétně se jedná o navržení automatické metody pro segmentaci sedimentárních zrn v obraze, dále pak metody pro odlišení geomorfologických genezí na základě analýzy obrazu. Další kapitoly pak detailně popisují řešení jednotlivých cílů a poslední kapitola shrnuje výsledky práce.



Obr. 1: Příklad snímků sedimentárních zrn s různými exoskopickými vlastnostmi



Obr. 2: Ukázky strukturních charakteristik používaných v exoskopii – a) lasturnaté lomy, b) obloukové stupně, c) V-jamky, d) paralelní rýhy [1]



## 2. Dosavadní vývoj v oblasti automatické analýzy geologických objektů v kontextu využití v exoskopické analýze

V této kapitole je popsán současný stav problematiky v oblasti automatické analýzy obrazu, který je relevantní vzhledem k jejímu zamýšlenému využití pro účely exoskopické analýzy.


### 2.1. Metody segmentace obrazu

Jak bylo popsáno v úvodu práce, důvodem k zahrnutí segmentace do řešení této práce je potřeba určení oblasti, ve které se nachází objekt zájmu, tedy zrno. Tato oblast pak může být analyzována z hlediska tvaru, či může být využita pro analýzu strukturních charakteristik. Obecně je segmentace velice rozsáhlá oblast zpracování obrazu, proto jsou v této části uvedeny pouze ty metody, které určitým způsobem souvisí s řešeným problémem.

Jako nejjednodušší metodu segmentace lze uvést prahování, které klasifikuje pixely obrazu podle hodnoty jejich intenzity. Na základě prahů lze definovat rozsahy hodnot, které náležejí objektům v obraze (např. zrno a pozadí). Existují různé techniky pro určení optimálních prahových hodnot [4][5][6]. Při aplikaci prahování na obrazy sedimentárních zrn se objevují problémy s překrývajícím se rozsahem hodnot jasů pixelů zrna s rozsahem hodnot jasů pixelů pozadí, především, je-li zrno hladké, a tudíž podobné pozadí, viz obrázek 3. Další možností je segmentace založená na detekci hran, kdy jsou hledány výrazné jasové změny v obraze. Jako příklad lze uvést metody [7] či metodu relaxace hran [8]. Detekce hran sama o sobě ještě není výsledkem segmentace, následující krok oddělení objektu od pozadí vychází z předpokladu, že objekty v obraze jsou po celém obvodu ohraničeny hranami. Je zřejmé, že hrana jednoho objektu by měla být uzavřená. Taková uzavřená hrana ohraničující jeden objekt bývá označována jako kontura. V reálných situacích proces detekce hran zřídka produkuje ideálně uzavřené hrany. Výsledný obraz často obsahuje množství nerelevantních hran, proto je třeba aplikovat další metody zpracování, viz obrázek 3.

Watershed segmentace je velmi rozšířená segmentační metoda [9][10][11]. Je založena na principu zaplávání reliéfu. Reliéf je dán obsahem konkrétního obrazu, kdy výška reliéfu je přímo úměrná intenzitě obrazu. Výsledné segmenty jsou získány po proceduře zaplávání reliéfu. V daném reliéfu jsou určena tzv. regionální minima, tj. místa, jejichž okolí má výhradně vyšší reliéf. Počet těchto minim určuje počet výsledných segmentů. Z těchto míst je zahájeno zaplávání reliéfu, kdy je v každém kroku zvyšována výška fiktivní hladiny, a tím dochází k většímu „zaplavení“ reliéfu. Hranice jednotlivých regionů je stanovena v místě, kde se setkají povodí z různých regionálních minim. Jelikož jsou hranice objektů obvykle doprovázeny výraznými jasovými přechody, jako reliéf je obvykle použit gradientní obraz. Nedostatkem této metody je často velmi přesegmentovaný obraz. Eliminaci přesegmentování lze provést úpravou gradientního obrazu, v případě, že jsou známy body, ve kterých začíná zaplávání, tzv. watershed segmentace založená na inicializačních bodech [12].

Obecně lze přesegmentování obrazu také řešit metodikou slučování regionů, kdy jsou malé regiony slučovány za účelem vymezení celistvých objektů. Toto slučování je často prováděno, dokud je splněno určité definované kritérium rozdílnosti [13][14][15]. Příležitost regionů je často reprezentována pomocí grafu přilehlých regionů (Region Adjacency Graph [16]), kdy uzly grafu představují regiony a hrany grafu pak společné hranice přilehlých regionů. Hranám jsou obvykle



Obr. 3: Ukázka výsledků aplikace metod prahování a detekce hran [7]

přiřazeny váhy vyjadřující rozdílnost přilehlých regionů a tyto váhy pak ovlivňují proces slučování. V [17] je navržena obecná metoda slučování, kdy je slučování řízeno kritériem založeným na průměrné intenzitě regionů. V [18] je topografický reliéf proložen rovinou za použití metody nejmenších čtverců, rozdíl mezi rovinami přilehlých regionů je použit jako kritérium rozdílnosti. Kritérium může být také uzpůsobené dané úloze, v [19] je slučování ovlivněno kritériem vyhodnocujícím obdélníkový tvar při segmentaci domů z obrazů dálkového průzkumu. V [20] jsou zachyceny obrazy mramoru při různých polarizacích, což přináší přídavnou informaci pro definici speciálního slučovacího kritéria. Slučování může být ovlivněno i předpokládaným tvarem výsledného segmentu [21]. Je také možné slučování řídit na základě texturních vlastností slučovaných regionů [22].

Pro konkrétní typ obrazů sedimentárních zrn pořízených elektronovým mikroskopem (viz obrázek 1) nebyla dosud navržena žádná segmentační technika. Ačkoliv lze v oblasti geologie nalézt různé segmentační metody hornin [23][24][25][26], povaha obrazů je zcela odlišná od obrazů sedimentárních zrn pořízených elektronovým mikroskopem, a proto metody nelze aplikovat na daný problém.

V [26] je prováděna segmentace horniny z povrchu Marsu. Pro prvotní segmentaci je zde použita analýza textury, pro jemné doladění hranic je použita metoda aktivních kontur [27]. Metoda aktivních kontur je založena na definici deformovatelné křivky, která je inicializovaná do určitého výchozího tvaru a polohy v analyzovaném obraze (může být provedeno například interakcí s uživatelem). Informace obsažená v obraze představuje rozložení vnějších sil, které na deformovatelnou křivku působí. Parametry křivky pak určují vnitřní síly, které působí proti vnějším silám. Proces hledání hranice mezi objekty v obraze je založen na deformaci křivky, kdy dojde k vyrovnání vnitřních a vnějších sil a tedy minimalizaci energie.

## 2.2. Analýza 2D tvaru sedimentárních zrn

Jak bylo uvedeno, důležitým parametrem vyhodnocovaným při exoskopické analýze je tvar zrna. Jako příklad, kdy je využito tvarových vlastností pro rozlišování různých tříd objektů, lze uvést práce [28][29][30]. Pro analýzu tvaru jsou nejčastěji užívány následující charakteristiky [31]:

- Forma - tato charakteristika je určena rozměry zkoumaného zrna v jednotlivých dimenzích. Z jejich poměrů lze odvozovat další charakteristiky jako např. míra protáhlosti objektu.
- Sféricita - tato charakteristika určuje, do jaké míry se zkoumané zrně podobá kouli o stejném objemu.
- Zaoblenost - tato charakteristika určuje míru obroušení povrchu zrna, tj. jak jsou hrany na jeho povrchu ostré.

Je-li uvažována analýza tvarových vlastností zrn z obrazu SEM elektronového mikroskopu, bude hodnocení tvaru probíhat na základě 2D obrazu zrna, tj. dochází zde k zachycení průmětu reálného 3D tělesa. Je zřejmé, že při projekci ze 3D → 2D dojde k jisté ztrátě informace o analyzovaném zrně.

Formu lze u 3D tělesa určit změřením jeho rozměrů (nejčastěji v navzájem kolmých směrech). Na obrázku 4 je pak vidět, jak je forma měřená ve 2D ovlivněna natočením zrna vzhledem k průmětné rovině. V závislosti na orientaci zrna lze tedy získat různé hodnoty formy. Snímky z elektronového mikroskopu obsažené v databázi, která byla použita pro tento výzkum (viz kapitola 4), byly pořizovány pro nekontrolovanou polohu zrna vzhledem k průmětné rovině, proto tedy forma není ze statistického hlediska vhodnou charakteristikou pro porovnávání tříd geomorfologických genézí (jelikož je forma přímo ovlivněna orientací zrna) a není v této práci dále uvažována.


Sféricita, určující míru podobnosti objektu kouli, může být definována např. jako poměr plochy analyzovaného zrna k ploše jemu ekvivalentní koule [32]. Ve 2D prostoru pak sféricitě odpovídá tzv. cirkularita, tj. do jaké míry se analyzované zrně podobá ideálnímu kruhu. Sféricita, potažmo cirkularita, je závislá na formě [31], což je i zřejmé z obrázku 4. Proto v této práci není uvažována.

Zaoblenost je na rozdíl od sféricity na formě nezávislá [31]. Při zkoumání 2D průmětu zrna pro různé úhly natočení průmětné roviny by měla být teoreticky získána stejná hodnota zaoblenosti (při předpokladu rovnoměrného opracování zrna). Z tohoto důvodu se míra zaoblenosti jeví jako nejvhodnější charakteristika pro popis tvaru 2D kontury zrn pořízených elektronovým mikroskopem, a proto je v dalším textu detailně popsán dosavadní vývoj v této oblasti.

### 2.2.1. Metody analýzy zaoblenosti

Patrně nejznámější definice zaoblenosti je uvedena ve [32], kde je dána jako průměrný poloměr zakřivení jednotlivých rohů částice, který je normalizovaný poloměrem vepsané kružnice částice. Jelikož má být podle originální metody měření zaoblenosti prováděno manuálně, jednalo se o časově velmi náročnou proceduru. Z tohoto důvodu byly vytvořeny různé vzorové tabulky pro vizuální srovnávání a následnou klasifikaci částic do definovaných tříd zaoblenosti [33][34]. Problémem vizuálního určení zaoblenosti je především velká subjektivita takového měření a s tím i související špatná reprodukovatelnost měření.

S rozvojem počítačového zpracování obrazu byly navrženy automatizované metody, kde výsledkem hodnocení zaoblenosti již není několik diskrétních hodnot, ale číselná hodnota ze spojitého rozsahu. Pro automatickou analýzu zaoblenosti z 2D průmětu bylo publikováno několik



Obr. 4: Vliv natočení průmětné roviny na výslednou podobu 2D průmětu

základních přístupů. Některé z nich využívají prostředků Fourierovy analýzy. V práci [35] je využito Fourierovy řady, kdy je analyzována funkce poloměru částice v závislosti na polárních souřadnicích. Součet určitých koeficientů Fourierovy řady pak udává míru zaoblenosti. Další experimenty s tímto přístupem byly provedeny v práci [36]. Podobný přístup je využit také v práci [37], kde je analýza prováděna pomocí tzv. Fourierových deskriptorů. V práci [23] je automatizována původní metoda dle Wadella, tento přístup využívá postupů diskrétní geometrie. V práci [38] je publikována automatická metoda pro určení úzce souvisejícího parametru: angularity. Angularita je u této metody určena na základě rozdílu úhlů polygonu odpovídajícího dané částici a polygonu odpovídajícího kruhu. Angularitu je pak možné považovat za obrácenou reciproční vlastnost k zaoblenosti, tj. že se zvyšující se zaobleností se snižuje angularita a naopak. Další přístup pro určení zaoblenosti nabízí využití matematické morfologie, kdy lze na základě kombinace operací morfologické eroze a dilatace sledovat změny tvaru zkoumané částice a z těchto změn odvodit míru zaoblenosti. Tento přístup byl publikován v pracích [39] a [40], obě dvě publikované metody využívají v podstatě stejného přístupu. Zaoblenost lze také určovat pomocí fraktálů [41].

Dále existují metody, které jsou schopny určit zaoblenost částice z jeho 3D modelu. V [42] je využita tzv. spherical harmonic representation pro popis 3D tvaru částice. Pomocí této reprezentace je možné určit 3D zakřivení v jednotlivých bodech povrchu a využít tuto informaci v rozšířeném Wadellově vztahu pro výpočet zaoblenosti celé prostorové částice. Dále je zde navržena i druhá metoda, která stanovuje zaoblenost jako hodnotu úměrnou průměrnému úhlu mezi dvěma vektory. První vektor vede od středu částice k určitému bodu povrchu, druhý vektor je v tomto bodě kolmý k povrchu. V [43] je snímána vždy polovina povrchu částice, která je pak morfologicky zpracována podobným způsobem jako u 2D metod, které využívají principů matematické morfologie s tím rozdílem, že v tomto případě je použit 3D strukturální element eliptického tvaru.

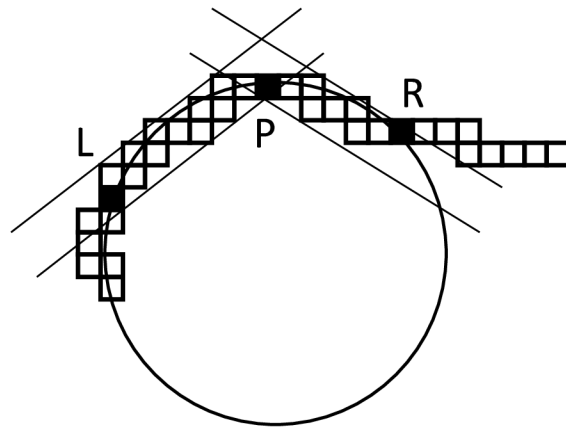
Vzhledem k povaze obrazů ze skenovacího elektronového mikroskopu jsou použitelné pouze metody analyzující 2D průmět zrna. Z výše uvedeného výčtu jsou blíže specifikovány jednotlivé přístupy k analýze 2D průmětu zrna.

- **Analýza zaoblenosti s užitím technik disktrétní geometrie (M1)**

Tato metoda vychází z definice zaoblenosti podle Wadellova vztahu [32], ve kterém je zaoblenost  $r_{MI}$  určena jako

$$r_{MI} = \frac{1}{N} \sum_{i=1}^N r_i, \quad (1)$$

kde  $r_i$  je lokální poloměr zaoblenosti a  $R_{in}$  je poloměr kružnice, která je vepsaná analyzované kontuře. Výsledná celková zaoblenost je tedy stanovena jako průměrná hodnota ze sady  $N$  lokálních poloměrů zaoblenosti  $r_i$ . Praktický automatizovaný odhad lokálního poloměru zakřivení vychází z [23] a je znázorněn na obrázku 5. Aktuální pixel kontury průmětu je označen jako P a poloměr zakřivení určuje kružnice proložená pixely LPR. Pro tuto kružnici je tedy nutné stanovit ještě pixely L a R. Ty jsou stanoveny jako koncové pixely v nejdelší možné posloupnosti pixelů vycházející z pixelu P. Tato posloupnost musí splňovat podmínku, že všechny její pixely nesahají mimo oblast vymezenou vždy dvěma rovnoběžnými přímkami o definované vzájemné vzdálenosti. Lokální poloměr zakřivení  $r_i$  je zde spočítán pro každý pixel kontury analyzovaného průmětu. Ty poloměry zakřivení, které nepřesahují poloměr  $R_{in}$  vepsané kružnice, jsou podle původního postupu v [32] dosazeny do sumy ve vztahu (1).



Obr. 5: Princip využití přístupu založeného na disktrétní geometrii [23]

- **Analýza zaoblenosti s užitím Fourierovy transformace (M2)**

Tato metoda patří do rodiny metod využívajících Fourierovy analýzy [35]. Také v této metodě jsou využity pixely kontury průmětu. Průměrováním souřadnic kontury na horizontální a vertikální ose je získán středový bod. Tento bod se stane středem pro určení polárních souřadnic  $(\rho, \theta)$  pixelů kontury, kde  $\rho$  je vzdálenost od středu souřadnic a  $\theta$  je úhel, který svírá přímka procházející středem a aktuálním bodem kontury s osou x. Příklady průběhu vzdálenosti  $\rho$  pro různé tvary průmětů jsou


zobrazeny na obrázku 6. Je vidět, že pro různá zaoblení zrn má i průběh vzdálenosti  $\rho$  různý charakter. Na tento průběh, kdy je kontura průmětu vzorkována s krokem  $360^\circ/N$ , je pak aplikována diskrétní Fourierova transformace, kde  $N$  určuje vzorkovací krok. Dále jsou pak využívány její absolutní koeficienty  $C_p(i)$ , pro  $i = 0, 1, \dots, N-1$ . Pro kompenzaci vlivu velikosti zrna jsou koeficienty poděleny velikostí stejnosměrné složky. Podle [35] je dále pro omezení vlivu cirkularity nutné spočítat Fourierovy koeficienty  $C_{el}(i)$  ekvivalentní elipsy, které jsou odečteny od koeficientů spektra průmětu. Jednotlivé koeficienty jsou dále váhovány funkcí, jejíž parametry autoři experimentálně zjistili. Hodnota korelující se zaobleností průmětu je pak získána podle vztahu

$$P = \sum_{i=3}^n c_i (C_p(i) - C_{el}(i)), \quad (2)$$

kde  $c_i = 0.56e^{0.2i}$  představuje váhovací funkci a  $n$  značí počet použitých koeficientů. Rozsah hodnot  $P$  je poté transformován a je získána výsledná hodnota zaoblenosti

$$r_{M2} = e^{-1,25P}. \quad (3)$$

Další experimenty s tímto přístupem byly provedeny v práci [36]. Podobný přístup je využit také v práci [37], kde je analýza prováděna pomocí tzv. Fourierových deskriptorů.



Obr. 6: Princip využití přístupu založeného na Fourierově analýze [35]

- **Analýza zaoblenosti s užitím faktoru angularity**


Tato metoda slouží k určování míry zaoblenosti využitím faktoru angularity. Angularitu je možné považovat za převrácenou hodnotu zaoblenosti, čehož je také využito v této studii. Základní princip metody je popsán v [38] a demonstrován na obrázku 7. Daný průmět je rovnoměrně rozdělen s daným úhlovým krokem, průsečíky obvodu částice s dělicími paprsky pak tvoří  $N$ -úhelník. Na základě rozdílu mezi úhly  $\beta_i$   $N$ -úhelníku částice a úhly  $N$ -úhelníku odpovídající kružnice, je pak určen tzv. *angularity factor* ( $AF$ ) podle vztahu

$$AF = \frac{\sum_{i=1}^N (\beta_i - 180)^2 - \frac{360^2}{N}}{3 \cdot (180^2) - \frac{360^2}{N}}. \quad (4)$$

Princip je založen na tom, že při dostatečně jemném vzorkování jsou úhly v odpovídající kružnici rovny téměř  $180^\circ$ , zatímco úhly v částici mohou být obecné. Se vzrůstající angularitou částice, tedy s jeho snižující se zaobleností, se pak zvětšuje průměrný kvadrát rozdílu mezi úhlem  $\beta_i$  a úhlem  $180^\circ$ .

Míra zaoblenosti pak může být určena jako

$$r_{M3} = \frac{1}{AF}. \quad (5)$$



Obr. 7: Princip využití přístupu založeného na faktoru angularity

- **Analýza zaoblenosti s užitím jednoduchého vztahu (M4)**

Často se lze v oblasti analýzy 2D tvaru, např. [30][44], setkat se zaobleností definovanou jednoduše jako

$$r_{M4} = \frac{4\pi A}{p^2}, \quad (6)$$

kde  $A$  je obsah plochy průřezu částice, tj. počet pixelů průřezu, a  $p$  je obvod průřezu částice, tj. počet pixelů jeho kontury.

- **Analýza s využitím matematické morfologie (M5)**

Tato metoda využívá postupů matematické morfologie, konkrétně metody pracující s tzv. tvarovými spektry (pattern spectra)[40]. Tvarové spektrum je číselná posloupnost získaná pomocí opakované operace morfologického otevření. Morfologické otevření je tvořeno po sobě jdoucími morfologickou erozí a dilatací. Morfologické otevření je prováděno pomocí strukturního prvku kruhového tvaru. V každém kroku je poloměr strukturního prvku zvětšen. Plocha  $A_i$ , která je pomocí otevření strukturním prvkem o poloměru  $R_i$  odstraněna oproti předchozímu kroku, je zapsána na příslušnou pozici  $i$  tvarového spektra  $P(i)$ , tedy  $P(i) = A_i$ . Hodnota  $i$  je dána pořadovým číslem morfologické iterace. Zvětšování poloměru  $R_i$  strukturního prvku je prováděno až do hodnoty iterace  $I$ , dokud průmět částice vlivem morfologických operací se strukturním prvkem o poloměru  $R_I$  zcela nezmizí (poloměr  $R_I$  je větší než vepsaná kružnice průřezu). Pro lepší znázornění vlivu tvaru analyzované částice na tvarové spektrum bývá počítána kumulativní suma tvarového spektra

$$C(i) = \sum_1^i P(i), \quad (7)$$

viz obrázek 8. Podle [40] pak hodnota  $C(i)$  koreluje se zaobleností pro podíl  $i/I$  o hodnotě mezi 0,2 a 0,4. Hodnota zaoblenosti je u této metody určena jako

$$r_{M5} = C(i) \quad \text{pro } i/I \in (0,2; 0,4). \quad (8)$$

V podstatě na stejném principu je založena i analýza zaoblenosti publikovaná v [39].

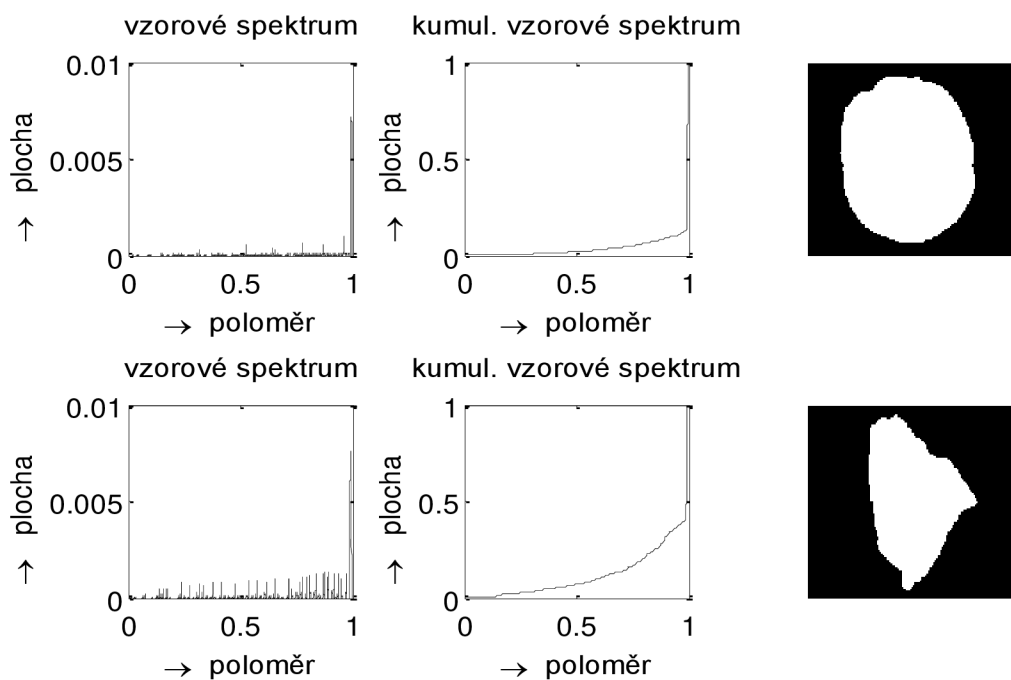
- **Analýza pomocí fraktálů (M6)**

Tato metoda vychází z prostředků fraktální geometrie. Metoda se nazývá divider method a lze pomocí ní určit tzv. roughness částice [41]. Tato roughness je dle autorů taktéž korelována se zkoumanou vlastností zaoblenosti. Určení této vlastnosti vychází ze vztahu

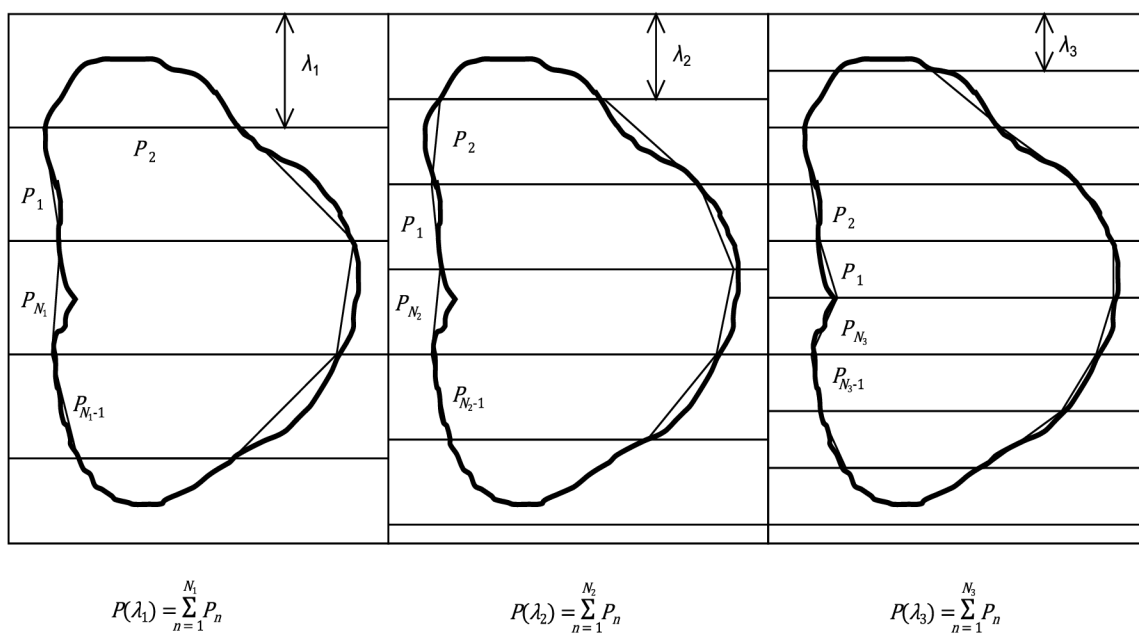
$$P(\lambda) = n\lambda^{1-D_R}, \quad (9)$$

kde  $D_R$  je fraktální dimenze, zde představující roughness,  $n$  je konstanta úměrnosti a  $P(\lambda)$  je obvod polygonu v závislosti na zvolené délce  $\lambda$ , viz obrázek 9.





Obr. 8: Princip využití přístupu založeného na matematické morfologii [40]



Obr. 9: Princip využití přístupu založeného na fraktálech [41]

Paralelní úsečky se vzdáleností  $\lambda$  protínají konturu průmětu, tyto průsečíky pak tvoří polygon, jehož obvod je označen  $P(\lambda)$ . Pro jednotlivé hodnoty  $\lambda$  jsou pak získány odpovídající hodnoty  $P(\lambda)$ . Zlogaritmováním vztahu (9) lze určit směrnici  $m = 1 - D_R$  přímky, která je proložena metodou nejmenších čtverců pro hodnoty  $P(\lambda)$  závislé na  $\lambda$ . Ze směrnice  $m$  lze pak určit hodnotu  $D_R$ , která kvalitativně souvisí se zkoumanou zaobleností, lze tedy napsat, že

$$r_{M6} = D_R. \tag{10}$$

## 2.2.2. Určování velikosti vzorku pro odlišení tříd

Ačkoliv bylo v předchozí kapitole uvedeno, že hodnota zaoblenosti není teoreticky závislá na formě (tedy na úhlu natočení průměrné roviny), úhel pohledu na jedno a totéž zrno při použití automatizovaných metod také do jisté míry ovlivňuje výslednou hodnotu zaoblenosti a přispívá tak k rozptylu hodnot uvnitř třídy. Je-li třeba porovnat za účelem odlišení dvě třídy pouze na základě hodnoty jednoho příznaku (v kontextu práce se jedná o odlišení na základě hodnoty zaoblenosti), je třeba mít k dispozici určitý statistický vzorek zrn, tedy jejich určitý počet. Důvodem je rozptyl hodnoty zaoblenosti uvnitř jednotlivých tříd, jelikož se hodnoty zaoblenosti pro dvojici různých tříd mohou překrývat. O určení minimálního počtu projekcí MNP (Minimal Number of Particle Projections) pojednává práce [30], ve které jsou vyhodnoceny dvě metody pro určení MNP: metoda stabilizace hodnoty a Chí-kvadrát test. V závislosti na metodě vybrané z uvedené dvojice nabývá získaná hodnota MNP dosti odlišných hodnot. Např. dle [30], při použití metody stabilizace hodnoty pro testovanou třídu byla získána hodnota MNP 1100 a při použití metody Chí-kvadrát hodnota MNP 200. Hodnota MNP byla v [30] určena nezávisle vždy pro jednu tvarovou třídu. V kontextu porovnávání a odlišování geomorfologických genezí je však výhodnější určovat MNP ne pro každou třídu zvlášť, ale pro konkrétní porovnanou dvojici geomorfologických tříd. MNP musí být určeno tak, aby bylo dostatečné vzhledem k rozdílu středních hodnot dané dvojice tříd a také vzhledem k rozptylu hodnot uvnitř těchto tříd. Znalost MNP může znamenat výhodu v tom, že není třeba snímat nadbytečné množství zrn, jsou-li porovnané třídy dostatečně odlišné, což může ušetřit prostředky vynaložené na snímání (např. v případě snímání elektronovým mikroskopem). Určení MNP pro dvojici tříd je proto předmětem zkoumání kapitoly 6.

## 2.3. Analýza povrchu sedimentárních zrn

### 2.3.1. Analýza textury

Pro klasifikaci geomorfologické geneze sedimentárních zrn pořízených elektronovým mikroskopem se nabízí možnost využití informace získané z povrchu zrn. Pro účely rozpoznávání nepravidelného a rozmanitého povrchu zachyceného v obraze se v praxi hojně používá analýza textury. Pro automatizaci takové procedury existuje požadavek na kvantifikaci vlastností dané textury. Za tímto účelem lze použít tzv. lokálních texturních příznaků. Pojem lokální příznak značí hodnotu, která je platná pro pozici určitého pixelu v obraze a je spočítána z jeho okolí o definované velikosti.

Příznaky mohou být založeny na různých předpokladech. Následují příklady příznaků, které jsou používány pro analýzu textury:

- Četnost hran - je zde analyzována míra gradientu v analyzované oblasti [27].
- Délka primitiv - primitivum je definováno jako množina pixelů o stejném jasu v určitém směru [45]. Pro analyzovanou oblast je určena matice počtů primitiv, přičemž pozice v matici určuje parametry primitiva - délka a hodnota jasu.
- Kookurenční matice - podobně jako matice délky primitiv, je i zde vytvořena matice počtů, přičemž pozice v matici určuje jasové hladiny dvojice pixelů o definované vzdálenosti [46]. Taktéž jsou z této matice na základě definovaných vztahů počítány různé charakteristiky.

- Odezvy 2D filtrů - hodnota příznaku je dána hodnotou odezvy filtru na analyzovanou oblast. V praxi se pro tyto účely používají např. řiditelné filtry [47].
- Lokální binární vzory LBP (Local Binary Patterns) - jedná se o vytvoření binárního řetězce, který vznikne odprahováním sousedních pixelů vzhledem k hodnotě centrálního pixelu analyzované oblasti [48]. Binární řetězec pak reprezentuje určité číslo. Takovou reprezentaci pak lze použít pro rozlišování textur.

### 2.3.2. Využití analýzy textury v oblasti rozpoznávání sedimentárních zrn

V části týkající se automatické analýzy povrchu sedimentárních zrn pro účely exoskopické analýzy lze v dostupné literatuře nalézt málo relevantních pramenů. Je možné zmínit práci [49][50], kde je využita analýza obrazu pro zkoumání povrchu křemenných zrn taktéž snímaných rastrovým elektronovým mikroskopem (SEM). V této práci byly rozlišovány tzv. štěpné plátky (upturned plates) na povrchu zrn. Pro tento účel byly využity tzv. základní obrazové příznaky BIF (Basic Image Features)[51]. BIF příznak představuje klasifikaci jednotlivých pixelů do jedné ze 7 tříd. Třída je určena na základě odezvy sady filtrů na okolí daného pixelu. Konvoluční jádra použitých filtrů jsou tvořena různými variantami derivace dvojrozměrné Gaussovy funkce, jejich vizualizaci a označení lze vidět na obrázku 10. Jsou-li odezvy filtrů pro daný pixel a jeho okolí označeny podle obrázku 10, tj.  $\{c_{00}, c_{10}, c_{01}, c_{20}, c_{11}, c_{02}\}$ , je klasifikace pixelu určena tímto postupem [51]:

1. Jsou spočítány odezvy filtrů  $\{c_{00}, c_{10}, c_{01}, c_{20}, c_{11}, c_{02}\}$  pro daný pixel a jeho okolí.
2. Na základě hodnot odezev jsou určeny členy  $\lambda$  a  $\gamma$  jako

$$\lambda = \sigma^2(c_{20} + c_{02}) \quad (11)$$

a

$$\gamma = \sigma^2 \sqrt{(c_{20} - c_{02})^2 + 4c_{11}^2}, \quad (12)$$

kde  $\sigma$  je parametr upravující odezvu sady filtrů z obrázku 10.

3. Třída, do které je daný pixel klasifikován, je určena podle největšího členu z následující množiny

$$\left\{ \varepsilon c_{00}, 2\sigma \sqrt{c_{10}^2 + c_{01}^2}, +\lambda, -\lambda, 2^{-\frac{1}{2}}(\gamma + \lambda), 2^{-\frac{1}{2}}(\gamma - \lambda), \gamma \right\}. \quad (13)$$


Postup klasifikace snímku jako snímek obsahující či neobsahující štěpné plátky je pak následující:

1. Ve snímku určeném ke klasifikaci jsou nejprve popsány jednotlivé pixely pomocí BIF příznaků, jsou tedy klasifikovány pomocí výše uvedené procedury. Extrakce BIF příznaků je provedena pro 4 různá rozlišení analyzovaného snímku (prakticky je tedy každý pixel obrazu klasifikován na základě odezvy filtrů, která je spočítána z různě velkého okolí daného pixelu).
2. Ze snímku je spočítán histogram výskytu hodnot BIF příznaků.
3. Vektor představující histogram výskytu hodnot BIF příznaků je pak klasifikován metodou  $k$ -NN ( $k$ -Nearest Neighbors -  $k$ -nejbližších sousedů) jako obsahující či neobsahující štěpné plátky.  $k$ -NN klasifikátor je vytvořen sadou vzorových vektorů (trénovací množina) představující pozitivní a negativní příklady (tj. snímky obsahující resp. neobsahující štěpné plátky).

Pro experiment popsaný v [50] byla použita množina pozitivních a množina negativních zrn, přičemž pozitivní množina byla vytvořena umělým opracováním zrn v laboratorních podmínkách vzájemnými nárazy tak, aby na jejich povrchu došlo k vytvoření štěpných plátek. Z obou množin zrn pak byla nasnímána sada pozitivních a sada negativních snímků, tj. snímky obsahující a neobsahující

štěpné plátky (obdélníkové snímky zachycující část povrchu zrna). Z celkem 47 pozitivních zrn bylo získáno 266 snímků, ze 41 negativních zrn pak 237 snímků. Na této databázi byly prováděny experimenty. Autoři uvádí, že při použití schématu tzv. leave-one-out křížové validace bylo dosaženo přesnosti klasifikace 98,8%.

Lze konstatovat, že uvedená metoda by odpovídala prvnímu možnému přístupu k využití metod analýzy obrazu v exoskopické analýze (kapitola 1), kdy by bylo možné sledovat četnost výskytu konkrétní strukturní charakteristiky (zde štěpné plátky) a na základě těchto výskytů pak určovat geomorfologickou genezi. Na základě dostupné literatury, je výše uvedená studie ojedinělým pramenem, který se zabývá klasifikací povrchu geologických zrn na základě snímků, které jsou pořízené elektronovým mikroskopem. Metoda je relevantní k obsahu této dizertační práce a je tedy dále použita pro porovnání s metodou navrženou pro klasifikaci sedimentárních zrn podle geomorfologických genezí.



Obr. 10: Konvoluční jádra filtrů pro extrakci BIF [51]

### 3. Cíle dizertační práce

Tato dizertační práce si klade za obecný cíl výzkum nových automatických metod analýzy obrazu pro určení exoskopických parametrů sedimentárních zrn. Hlavními přínosy je po dosažení cíle zlepšení současného stavu v následujících aspektech:

- snížení manuální rutinní činnosti geomorfologa,
- eliminace subjektivní chyby při analýze stejných vzorků různými experty,
- rozšíření exoskopické analýzy o kvalitativně nový přístup pro rozlišení různých geomorfologických genezí.

Na základě povahy exoskopické analýzy jsou z hlediska aplikovatelnosti automatických metod analýzy obrazu vytyčeny 2 hlavní praktické cíle dizertační práce:

#### 1. Návrh metody pro automatickou segmentaci sedimentárních zrn v obraze z elektronového mikroskopu

Konkrétně se jedná o získání metody detekující oblast zrna, což je prvním logickým krokem při řešení problému automatizované exoskopické analýzy zrna v obraze. Z detekované oblasti mohou být následně získávány různé charakteristiky. Přesnost segmentační metody tedy může mít zásadní vliv na kvalitu finálních výsledků. V detekované oblasti se mohou pouze v minimální míře vyskytnout části, které nezachycují povrch zkoumaného zrna a které by mohly do následující analýzy zanechat nepřesnosti. V kapitole 2.1 jsou uvedeny práce, které se zabývají segmentací obrazu v oblasti geologických věd, avšak žádná z těchto metod není přímo aplikovatelná na obrazy zrn pořízených pomocí elektronového mikroskopu, jelikož charakter obrazů, pro které byly tyto metody navrženy, je odlišný. Proto je zde hlavním cílem návrh takové segmentační metody, která co nejpřesněji vymezí hledanou oblast zájmu v obraze.

#### 2. Návrh metod pro analýzu vlastností vzorků sedimentárních zrn za účelem klasifikace jejich geomorfologické geneze

Zde je hlavním cílem návrh automatizovaných metod analýzy zrn, které budou využitelné pro rozlišování mezi různými geomorfologickými genezemi. Na základě popisu v kapitole 1 je tento cíl rozdělen do dvou dílčích částí:

##### a) Porovnání podle tvaru 2D kontury

Cílem této části je výzkum metod analýzy zaoblenosti 2D tvaru zrn, pomocí kterých bude možné porovnávat jednotlivé geomorfologické geneze. Jelikož je zde porovnávání genezí prováděno pouze na základě jednoho deskriptoru (zaoblenosti), je cílem této části i návrh metodiky pro zhodnocení, zda-li je velikost dostupných vzorků (tj. počet zrn ve vzorku) dostatečná pro spolehlivé odlišení dvojice geomorfologických genezí.

##### b) Klasifikace podle texturních vlastností

Cílem této části je výzkum metod analýzy povrchové struktury zrn, pomocí kterých bude možné odlišovat jednotlivé geomorfologické geneze. Konkrétně se jedná o návrh metod texturní analýzy založené na extrakci sady tzv. nízkourovňových obrazových příznaků, na jejichž základě bude možné vytvořit klasifikační model pro třídění vzorků sedimentárních zrn podle geomorfologických genezí, které se podílely na jejich vzniku. Tento model bude vytvořen na základě dostupných vzorků, tzv. trénovací databáze.

## 4. Experimentální databáze

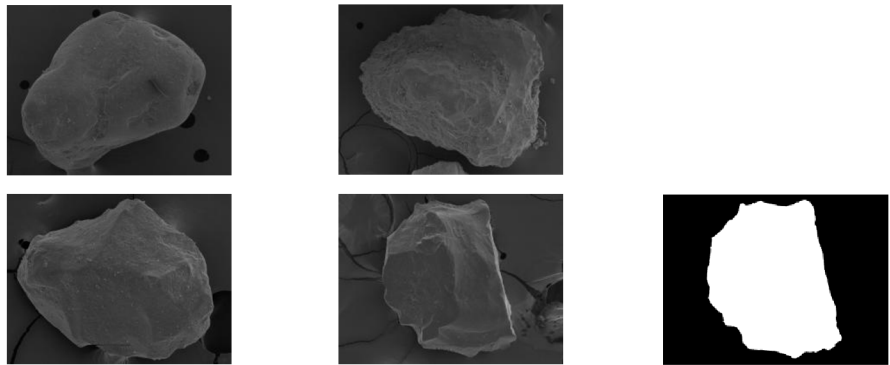
Pro dosažení cílů dizertace byla u jednotlivých experimentů použita databáze křemenných zrn. Tuto databázi pro účely experimentů poskytli geomorfologové RnDr. Lenka Kášová a RNDr. Marek Křížek, Ph.D.<sup>1</sup> Postup vytvoření databáze spočíval v očištění zkoumaných sedimentů, jejich pozlacení a následném nasnímání jejich obrazů pomocí rastrovacího elektronového mikroskopu (SEM) Cameca SX 100.

Snímaná zrna dosahují velikosti 250-1000  $\mu\text{m}$ . V databázi se nachází vzorky z celkem 4 různých tříd lišících se geomorfologickou genezí. Popis vzorků eolické, glaciální, svahové a vulkanické geneze lze vidět ve stejném pořadí v tabulkách 1, 2, 3 a 4. U každého vzorku je uveden počet dostupných snímků a místo jeho původu. Taktéž jsou zde zobrazeny i ukázky snímků pro danou genezi. Celou databázi lze vidět v příloze A. Jak je vidět, na první pohled mezi genezemi není žádný zřetelný znak, podle kterého by se daly jednotlivé třídy od sebe jednoduše rozeznat. Pro každé zrno byla manuálním způsobem získána maska zrna, viz spodní část tabulek 1-4, která slouží k vymezení oblasti zrna v obraze, což lze využít například pro vyhodnocení přesnosti segmentace.

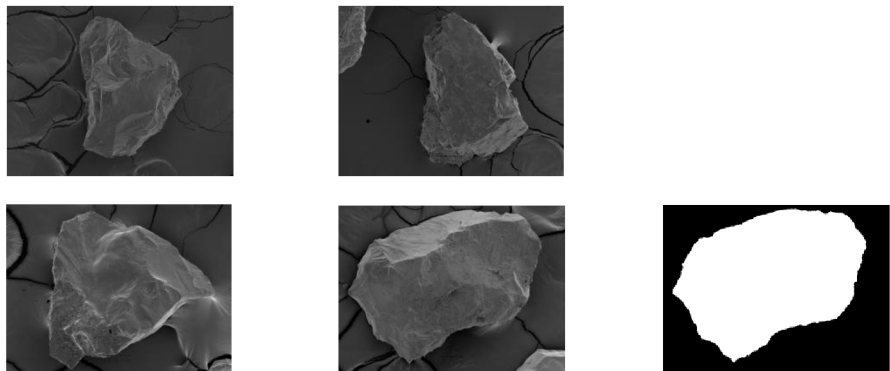
---

<sup>1</sup> Univerzita Karlova v Praze, Přírodovědecká fakulta, Katedra fyzické geografie a geoekologie, Albertov 6, 128 43 Praha 2

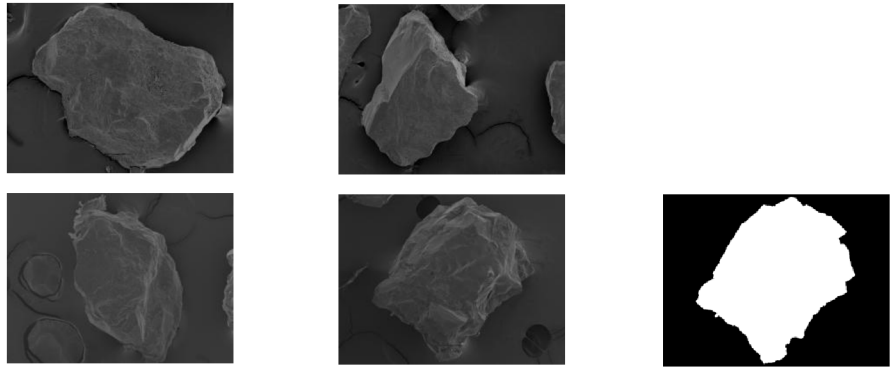
Tab. 1: Vzorok eolické geneze

	Geneze	Název	Popis	Počet zrn
Vzorek #1	Eolická	BPX1	Letenské souvrství, Praha - Klárov	19
Vzorek #2	Eolická	BPX6	Mrazový hrnec, Jankovická brázda, Holešov	17
Vzorek #3	Eolická	HJ6	Hrubý Jeseník	48
Celkem:				84
Příklady:				

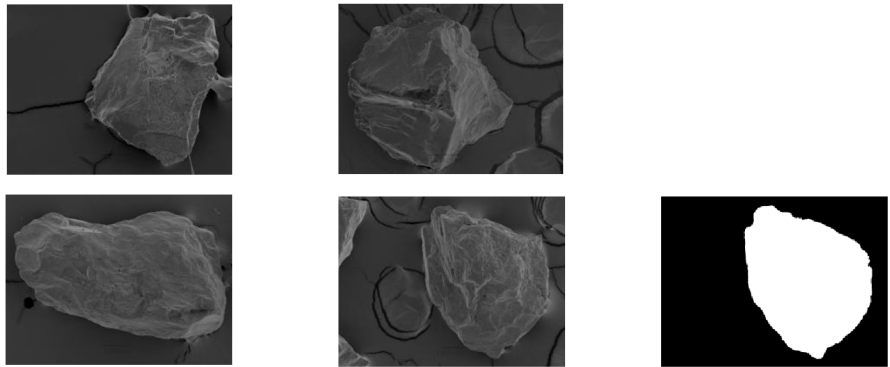
Tab. 2: Vzorok glaciální geneze

	Geneze	Název	Popis	Počet zrn
Vzorek #1	Glaciální	A1	Střední moréna, Aletchský ledovec v Bernských Alpách	48
Vzorek #2	Glaciální	A2	Bočně čelní moréna, Aletchský ledovec v Bernských Alpách	52
Vzorek #3	Glaciální	KHA1	Čelní moréna, Kyrgyzský hřbet: Adygine	49
Celkem:				149
Příklady:				

Tab. 3: Vzorčky svahové geneze

	Geneze	Název	Popis	Počet zrn
Vzorek #1	Svahová	S14	Mura, boční val, Šumava, Černé jezero	49
Vzorek #2	Svahová	S15	Mura, Šumava, Černé jezero	50
Vzorek #3	Svahová	KHA8	Mura, Kyrgyzský hřbet, Adygine	49
Celkem:				148
Příklady:				

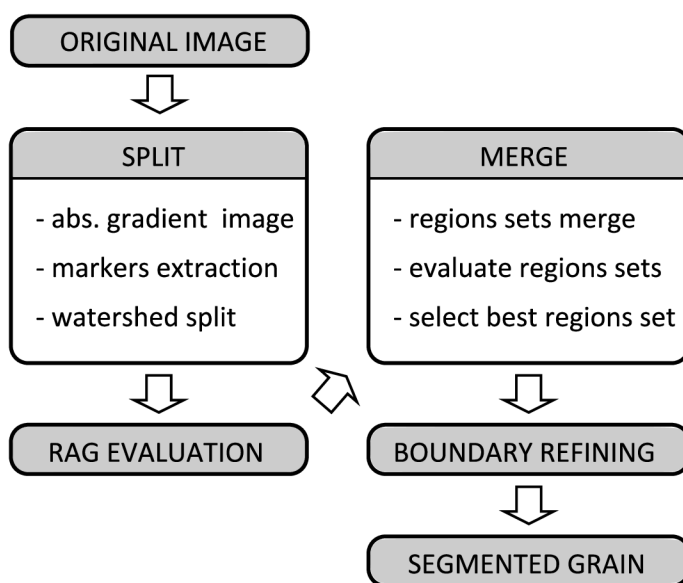
Tab. 4: Vzorčky vulkanické geneze

	Geneze	Název	Popis	Počet zrn
Vzorek #1	Vulkanická	VI1	Čerstvý nezvětralý sediment, jemnější složka, Stromboli	29
Vzorek #2	Vulkanická	VI2	Původní pláž, jemnější složka, Volcano	49
Vzorek #3	Vulkanická	VI3	Dno erozní rýhy, naplavený sediment, Stromboli	14
Celkem:				92
Příklady:				



## 5. Segmentace

V oblasti segmentace zrn je nutné vytvořit metodu, která bude co nejpřesněji vymezovat oblast zájmu. V dostupné literatuře nebyla nalezena metoda, která by segmentovala obrazy mající charakter zrn nasnímaných pomocí elektronového mikroskopu, viz obrázek 1. Z hlediska charakteru obrazů se jako vhodná výchozí metoda jeví watershed segmentace, která dobře vymezuje objekty, pokud jsou jejich hranice doprovázeny výraznými jasovými přechody. Oproti segmentačním metodám založeným na detekci hran má tu výhodu, že zde není problém s vymezováním uzavřené hrany (kontury) vytvářející segment. Ačkoliv, i při využití modifikace watershed segmentace využívající inicializačních bodů [12] se přesegmentování stále objevuje. Proto byla pro segmentaci zrn v práci [60] navržena metoda, jejíž procedura je zobrazena na obrázku 11. Celkové schéma metody je založeno na rozdělení obrazu do regionů a jejich následném slučováním. Pro dělení do regionů je použita již zmíněná watershed segmentace s inicializačními body. Inicializační body jsou získány pomocí prahování gradientního obrazu. Obraz rozdělený do regionů je reprezentován pomocí grafu přílehlých regionů RAG, regiony jsou potom slučovány na základě speciálně navrženého kritéria pro získání výsledného segmentu zrna. Jednotlivé části procedury jsou detailně popsány v následujících kapitolách.



Obr. 11: Schéma segmentační metody


### 5.1. Fáze rozdělení do regionů

Jak bylo uvedeno, vstupem watershed segmentace je gradientní obraz tvořící reliéf. Pro výpočet gradientního obrazu lze použít různé lineární filtry, v tomto případě jsou použity filtry ve formě směrových 1. derivací 2D Gaussových funkcí. Směr derivace je volitelný, proto filtry bývají označovány jako říditelné filtry [47], viz obrázek 12. Liší-li se směrový vektor derivace vzhledem


k ose  $x$  o úhel  $\alpha$  pak je filtrovaný výstupní obraz označen jako  $\text{grd}_\alpha(x, y)$ . Důvodem použití říditelných filtrů je zvýraznění důležitých jasových změn v daném směru při současném potlačení nevýrazných chaotických změn způsobených texturou či šumem. Vstupem watershed segmentace je obraz reliéfu

$$\text{grd}_{\text{abs}}(x, y) = |\text{grd}_{45}(x, y)| + |\text{grd}_{135}(x, y)|, \quad (14)$$

tedy součet absolutních hodnot původního obrazu, filtrovaného ve dvou na sebe kolmých směrech, viz obrázek 13b. Jelikož by přímá aplikace watershed segmentace způsobila přesegmentování, je obraz  $\text{grd}_{\text{abs}}(x, y)$  odprahován prahem  $t_{\text{mark}}$ . Výsledkem prahování je binární obraz, viz obrázek 13c, jehož propojené komponenty jsou použity jako inicializační body pro watershed segmentaci. Výsledkem této operace je obraz rozdělený do regionů, jednotlivé regiony jsou očíslovány, viz obrázek 13d.



Obr. 12: Příklady říditelných filtrů pro natočení  $\alpha \in \{0, 45, 90, 135, 180, 225, 270, 315\}^\circ$




Obr. 13: Fáze rozdělení do regionů – a) původní obraz, b) gradientní obraz – reliéf, c) značky, d) rozdělení do regionů

## 5.2. Ohodnocení grafu přilehlých regionů


Po rozdělení do dílčích regionů je dále vytvořen graf přilehlých regionů RAG (Region Adjacency Graph) [16], který logicky reprezentuje sousednost mezi vytvořenými regiony, viz obrázek 14. Region je zde představován uzlem, společná hranice se sousedním regionem tvoří v grafu hranu. Těmto hranám je přiřazena určitá váha, na základě které je prováděno slučování. Navržené ohodnocení hran grafu vychází z následujícího předpokladu, který je splněn pro většinu obrazů. Tímto předpokladem je, že změna jasu při přechodu ve směru od pozadí k zrnům má charakter změny jasu z tmavší na světlejší hodnoty. Proto je pro účel ohodnocení hran prováděna filtrace pomocí říditelných filtrů. Parametrem říditelných filtrů je směr, ve kterém dochází ke zvýrazňování jasových změn. Vstupní obraz je filtrován říditelnými filtry pro směry  $\alpha \in \{0, 45, 90, 135, 180, 225, 270, 315\}^\circ$ , viz obrázek 15. Výsledný obraz filtrovaný ve směru  $\alpha$  je označen jako  $\text{grd}_\alpha(x, y)$ . Souřadnice pixelů na hranici mezi regiony  $R_i$  a  $R_j$  jsou označeny  $(x, y) = a_{R_i R_j}(p)$ , kde  $p = 1, 2, \dots, N_{R_i R_j}$  jsou indexy pixelů společné hranice mezi regiony a  $N_{R_i R_j}$  značí počet pixelů společné hranice. V každém pixelu společné hranice je třeba určit k ní kolmý směr  $\alpha$ , který je orientovaný ve směru od pozadí k zrnům. Tento směr je pro jednotlivé pixely hranice označen  $\alpha = b_{R_i R_j}(p)$  a může nabývat některé z výše uvedených 8 hodnot. Hraně v grafu, orientované z regionu  $R_i$  do  $R_j$ , je pak přidělena váha dle vztahu

$$w_{R_i R_j} = \frac{\sum_{p=1}^{N_{R_i R_j}} \text{grd}_{b_{R_i R_j}(p)}(a_{R_i R_j}(p))}{N_{R_i R_j}}. \quad (15)$$

Tato váha vyjadřuje průměrnou hodnotu gradientu hraničního pixelu mezi dvěma regiony. Tímto způsobem je celý RAG ohodnocen vahami. Hranice mezi regiony, které jsou současně hranicí skutečného segmentu, mají hodnoty vah nižší v porovnání s hranicemi, které skutečný segment neohraničují, a to v případě, kdy je splněn výše uvedený předpoklad o změně jasu.



Obr. 14: Graf přilehlých regionů RAG



Obr. 15: Obrázek filtrovaný říditelnými filtry pro směry  $\alpha \in \{0, 45, 90, 135, 180, 225, 270, 315\}^\circ$

### 5.3. Fáze slučování regionů

Po ohodnocení hranic mezi sousedními regiony je provedeno slučování regionů. Cílem je získat množinu regionů, jejichž spojením vznikne segment vymezující oblast zrna. Slučování regionů probíhá po jednotlivých krocích, kdy je v každém kroku ke stávající množině regionů přidán nový region. Je-li celkový počet regionů v obraze  $K$ , pak slučování probíhá v celkem  $K$  krocích. Množina  $k$  regionů představující aktuální segment po  $k$  krocích slučování ( $k \in \langle 1; K \rangle$ ), u které slučování bylo započato od regionu  $R_i$ , bude označována jako  $R_{ik}$ . Aktuální množina regionů  $R_{ik}$  po  $k$ -tém kroku je tedy tvořena předchozí množinou regionů  $R_{i(k-1)}$  a novým regionem  $R_j$ . Na konci slučování při počátečním regionu  $R_i$  je tedy k dispozici  $K$  množin  $R_{ik}$ . Jelikož počáteční region  $R_i$ , od kterého má slučování začít, není znám, je proces slučování opakován pro všechny možné varianty počátečního regionu  $R_i$ , kde  $i \in \langle 1; K \rangle$ . Nejlepší množinu regionů odpovídající segmentu zrna je nutné vybrat podle metrik uvedených dále. Při vytváření množin sloučených regionů je klíčové pořadí, ve kterém je v jednotlivých krocích přidáván nový region  $R_j$  k předchozí množině  $R_{i(k-1)}$ . Sjednocení množiny regionů  $R_{ik}$  sloučených v kroku  $k$  představuje aktuální segment sousedící s okolními regiony, které lze označit jako množinu  $V_{ik}$ . V kroku  $k + 1$  bude k množině  $R_{ik}$  přidán takový region  $R_j$  z množiny  $V_{ik}$ , aby platilo

$$w_{R_{ik}R_j} = \max_{R_m \in V_{ik}} w_{R_{ik}R_m}, \quad (16)$$

tj. ze sousedních regionů  $V_{ik}$  aktuálního segmentu  $R_{ik}$  je vybrán ten, u kterého má hrana grafu ve směru od  $R_{ik}$  k  $R_j$  maximální váhu. Uvedené pravidlo pořadí slučování vychází z dříve uvedeného předpokladu, že na hranicích zrna nabývá gradient ve směru  $\alpha$  kolmém k tečně směřujícím do zrna relativně nízkých záporných hodnot. Reprezentuje-li tedy množina regionů  $R_{ik}$  segment vymezující zrna v obraze, pak váhy hran směřujících z regionů  $R_{ik}$  do sousedních regionů  $V_{ik}$  budou také nabývat nízkých záporných hodnot. Proto je při slučování žádoucí směřovat k nízkému průměru vah hran vystupujících z aktuální množiny  $R_{ik}$ , a tudíž je v kroku  $k + 1$  přidán k aktuální množině ten region  $R_j$ , u kterého má hrana grafu ve směru od  $R_{ik}$  k  $R_j$  maximální váhu, čímž jsou zachovávány hrany o nízkých hodnotách a potenciálně jsou tak skutečné hranice zrna zachovávány v co největším počtu kroků.

## 5.4. Fáze vyhodnocení množin regionů

Po skončení slučování je třeba vybrat množinu sloučených regionů  $R_{ik}$ , která nejvíce odpovídá ploše zrna. Pro nalezení nejslibnější množiny sloučených regionů  $R_{ik}$  byly navrženy následující metriky, kterými jsou jednotlivé množiny  $R_{ik}$  charakterizovány. První metrika vychází přímo z pravidla pro pořadí slučování a vyjadřuje průměrnou váhu hran vystupujících z množiny regionů  $R_{ik}$  a je rovna

$$m_{R_{ik}} = \frac{\sum_{R_j \in V_{ik}} w_{R_{ik}R_j} N_{R_{ik}R_j}}{\sum_{R_j \in V_{ik}} N_{R_{ik}R_j}}, \quad (17)$$

kde  $N_{R_{ik}R_j}$  je počet pixelů společné hranice mezi množinou regionů  $R_{ik}$  a regionem  $R_j$ . Tato metrika by pro množinu regionů  $R_{ik}$  odpovídající oblasti zrna měla být minimální. Další metrikou je směrodatná odchylka vah hran vystupujících z množiny  $R_{ik}$

$$s_{R_{ik}} = \text{stddev}_{R_j \in V_{ik}} w_{R_{ik}R_j}. \quad (18)$$

Tato metrika by měla mít minimální hodnotu pro množinu regionů odpovídající segmentu zrna. Třetí metrika zavádí poměr obsahu plochy sloučených regionů  $R_{ik}$  ku jejímu obvodu. Jelikož tento poměr s rostoucí plochou sloučených regionů roste lineárně, je tento poměr normalizován poměrem obsahu plochy a obvodu kruhu o poloměru  $r$ , který má stejný obsah, jako zkoumané sloučené regiony. Je-li obsah plochy regionu  $R_j$  označen jako  $F_{R_j}$ , potom třetí metrika je dána vztahem


$$c_{R_{ik}} = \frac{\frac{\sum_{R_j \in R_{ik}} F_{R_j}}{\sum_{R_j \in V_{ik}} N_{R_{ik}R_j}}}{\frac{\pi r^2}{2\pi r}} = \frac{2 \sqrt{\pi} \sum_{R_j \in R_{ik}} F_{R_j}}{\sum_{R_j \in V_{ik}} N_{R_{ik}R_j}} \quad (19)$$

kde obvod  $r$  byl nahrazen

$$r = \sqrt{\frac{\sum_{R_j \in R_{ik}} F_{R_j}}{\pi}}. \quad (20)$$

Maximální poměr plochy ku obvodu je dán pro případ kruhu. Maximální hodnota metriky  $c_{R_{ik}}$  může tudíž nabývat hodnoty 1 v případě, že aktuální množina regionů  $R_{ik}$  bude utvářet kruhový segment. Jelikož obvyklý tvar zrn představuje kompaktní geometrické útvary, bude mít ohodnocení množiny regionů  $R_{ik}$  tvořící segment zrna touto metrikou vyšší hodnotu než ostatní množiny regionů.

Jak bylo řečeno v kapitole 5.3, proces slučování je opakován a začíná vždy od jiného regionu  $R_{ik}$ , je tedy proveden  $K$ -krát. Výsledný počet množin regionů  $R_{ik}$  je potom  $K^2$ . Získané množiny regionů  $R_{ik}$  lze ohodnotit podle výše uvedených metrik. Jelikož  $i \in \langle 1; K \rangle$  a  $k \in \langle 1; K \rangle$ , pro lepší vizuální interpretaci lze hodnoty metrik pro různé hodnoty  $i$  a  $k$  zapsat do matice. Jsou vytvořeny matice  $\mathbf{M}(i, k) = m_{R_{ik}}$ ,  $\mathbf{S}(i, k) = s_{R_{ik}}$  a  $\mathbf{C}(i, k) = c_{R_{ik}}$ . Vizualizace těchto matic pro obrázek 13a) je zobrazena na obrázku 16. Je zde vidět, že lze vybrat určité charakteristické množiny  $R_{ik}$ , jejichž hodnoty metrik naznačují, že spojením množiny regionů vznikne segment vymezující zrno v obraze. Pro matice  $\mathbf{M}$  a  $\mathbf{S}$  jsou to nízké hodnoty, u matice  $\mathbf{C}$  naopak vysoké. Jak je vidět, tyto nízké resp. vysoké hodnoty metrik se však mohou objevovat i u množin  $R_{ik}$ , které neodpovídají segmentu



Obr. 16: Vizualizace matic, (a)  $\mathbf{M}$ , (b)  $\mathbf{S}$ , (c)  $\mathbf{C}$ , (d) maska určující potenciálně správné množiny regionů

zrna, např. poslední sloupce matic. Vhodným algoritmem kombinujícím uvedené metriky s doplňkovými omezeními však lze dosáhnout správného výběru množiny  $R_{ik}$ .

## 5.5. Fáze výběru segmentu

Výběr nejvhodnější množiny  $R_{ik}$  je prováděn ve dvou krocích. V první kroku dojde k odstranění množin  $R_{ik}$ , které přesahují následující stanovené meze:

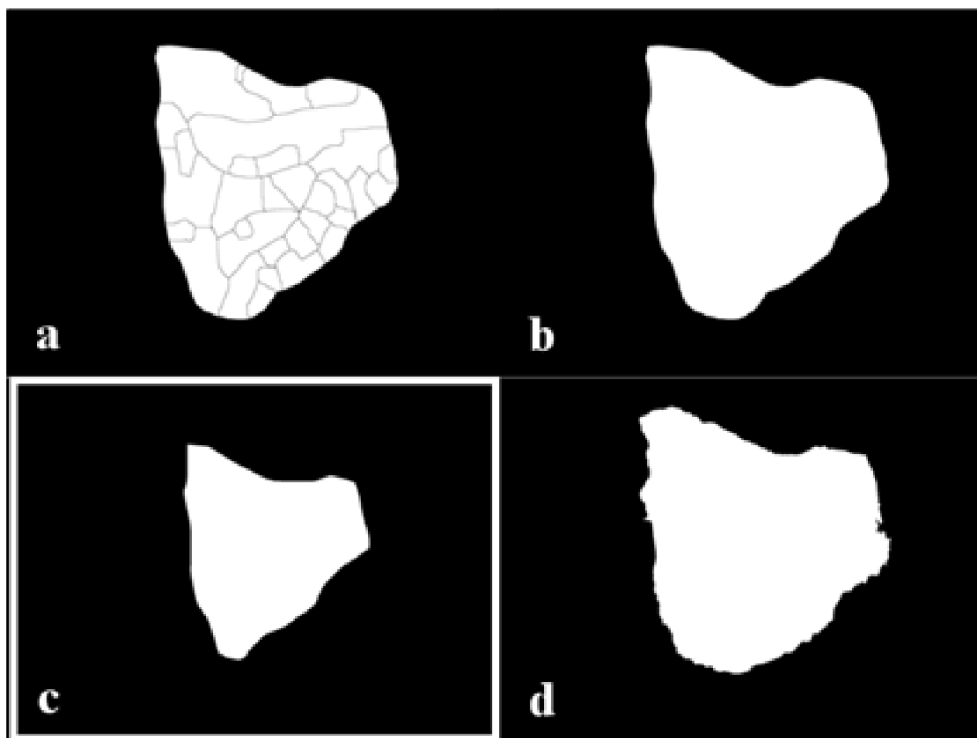
- Segment složený z množiny  $R_{ik}$  je menší než stanovená mez (tj. minimální velikost segmentu).
- Segment složený z množiny  $R_{ik}$  obsahuje díry (tj. vnitřní regiony, které k němu nebyly připojeny).
- Množina  $R_{ik}$  má metriku  $c_{R_{ik}}$  větší než 1.
- Množina  $R_{ik}$  má metriku  $m_{R_{ik}}$  větší než 0.

Důvod pro odstraňování množin  $R_{ik}$  obsahujících díry je ten, aby hrana segmentu sousedící s regionem tvořícím díru nezkrusovala použité metriky. Množiny  $R_{ik}$  s metrikou  $c_{R_{ik}}$  větší než 1 jsou odstraňovány, protože u celistvých segmentů tato hodnota nemůže přesáhnout 1. Je-li množina  $R_{ik}$  ohodnocena metrikou  $c_{R_{ik}}$  větší než 1, pak je to způsobeno tím, že došlo ke sloučení mnoha regionů, které jsou v kontaktu s okraji obrazu, což je nežádoucí stav (je předpokládáno, že snímky byly pořízeny tak, aby se hrana daného zrna nedotýkala okraje). Nakonec množiny  $R_{ik}$  s metrikou  $m_{R_{ik}}$

větší než nula jsou odstraněny, jelikož metrika  $m_{R_{ik}}$  koresponduje s hodnotou gradientu na okrajích segmentu a tato hodnota je z důvodu předpokládaného směru přechodu požadována záporná. Výsledná maska matice obsahující vyhovující množiny  $R_{ik}$  (bíle) je znázorněna na obrázku 16(d). Jak je vidět, převážná většina nevhodných regionů je vyřazena. Dále je třeba zdůraznit fakt, že množiny  $R_{ik}$  mohou být pro různá  $i$  shodné, což si lze všimnout i na obrázku 16(a-c), kde jiný počáteční region generuje stejnou skupinu regionů (což vyplývá ze stejné hodnoty metrik v kroku  $k$ ). V této fázi jsou tedy duplicitní regiony  $R_{ik}$  odstraněny a je vytvořen seznam zbývajících unikátních množin regionů  $R_{ik}$ . V postupných krocích je počet množin v tomto seznamu redukován následovně:

- Ze seznamu je odstraněno 50 % množin  $R_{ik}$  s nejvyšší hodnotou  $s_{R_{ik}}$ .
- Ze seznamu zbývajících po předchozím kroku je odstraněno 50% množin  $R_{ik}$  s nejnižší hodnotou  $c_{R_{ik}}$ .
- Ze seznamu zbývajících po předchozím kroku je odstraněno 50% množin  $R_{ik}$  s nejvyšší hodnotou  $m_{R_{ik}}$ .
- Ze seznamu zbývajících po předchozím kroku je vybrána množina  $R_{ik}$  s maximální hodnotou  $c_{R_{ik}}$ .

Tímto postupem je získána výsledná množina regionů  $R_{ik}$  tvořící výsledný segment, viz obrázek 17a. Jednotlivé regiony jsou pak již jednoduše spojeny, např. pomocí morfologického uzavření, viz obrázek 17b. V této fázi je tedy z regionů watershed segmentace získána oblast definující hledaný objekt – zrno.



Obr. 17: (a) Množina regionů po proceduře slučování (b) Výsledný segment po proceduře slučování (c) Obraz s inicializačními body (d) Výsledná maska po proceduře

## 5.6. Zpřesnění hranic

Jak bylo uvedeno, říditelné filtry jsou použity z důvodu extrakce důležitých jasových přechodů a potlačení texturních a jasových změn. Tento postup však může mít za následek vychýlení pozice hrany a tím ve výsledku i vychýlené hranice výsledného segmentu. Pro extrakci přesnější masky lze opět provést watershed segmentaci nad gradientním obrazem získaným filtrací ve dvou na sebe kolmých směrech. Tentokrát však pro filtraci není použit říditelný filtr, ale Sobelův filtr, který je taktéž využíván pro detekci hran, není však upraven proti redukci šumu, jako je tomu u říditelných filtrů, proto dává detailnější výsledky. Rozdíl oproti watershed segmentaci prováděné v úvodu je ten, že nyní před watershed segmentací nad gradientním obrazem již poměrně dobře známe velikost a polohu zrna, což můžeme využít pro definici inicializačních oblastí watershed segmentace. Nad gradientním obrazem je s pomocí inicializačních oblastí provedena morfologická rekonstrukce pro stanovení minim, v nynějším případě jsou použity pouze 2 inicializační oblasti pro získání 2 segmentů, jeden odpovídající zrnu a jeden pozadí. Obraz s inicializačními oblastmi použitými při morfologické rekonstrukci je zobrazen na obrázku 17c. Jedna inicializační oblast je tvořena hranicemi obrazu (představuje pozadí) a jedna je tvořena mírně ztenčeným výstupem předchozího slučování (s využitím morfologické eroze). Tímto je poměrně přesně určeno, z jakých míst má probíhat zaplavování, což na počátku nebylo známo a představovalo tak základní problém jednoduchého použití watershed segmentace. Nad upraveným gradientním obrazem je pak provedena watershed segmentace a je tak získán výsledný segment zrna, viz obrázek 17d.


## 5.7. Experimentální výsledky

Navržený algoritmus byl testován na 341 obrazech z dostupné databáze (viz kapitola 4), kde pro vyhodnocování úspěšnosti byly k dispozici již zmiňované manuálně vytvořené vztažné masky vymezující oblast zrna. Rozlišení obrázků bylo ponecháno na původní hodnotě 1280x960 pixelů.

### 5.7.1. Optimální rozdělení do regionů

Jako první byla vyhodnocena úspěšnost watershed segmentace při rozdělování do regionů, přičemž bylo hledáno optimální nastavení metody. Důležitý požadavek při segmentaci byl, aby hranice referenčních masek byly přibližně lemovány hranicemi regionů vzniklých po watershed segmentaci. Bylo proto zkoumáno, kolik procent pixelů hranice vztažné masky se protíná s některou z hranic regionů, z čehož lze posuzovat úspěšnost uvedeného postupu. Pro zavedení určité tolerance byly hranice regionů rozšířeny operací dilatace, aby nebyly pixely hranice zrna ležící v bezprostřední blízkosti označeny jako neprotnuté. Znázornění výsledků pro různé nastavení parametrů segmentace je vidět na obrázku 19. Na počet regionů má vliv velikost prahu  $t_{\text{mark}}$  (viz kapitola 5.1), kdy propojené komponenty v odprahovaném obrazu  $\text{gr}_{\text{abs}}(x, y)$  definují inicializační oblast, viz obrázek 13c. Je-li práh příliš vysoký, pak obraz obsahuje méně větších markerů, což může způsobit, že pomocí výsledných regionů nelze dobře sestavit výsledný segment, viz obrázek 19a. Příliš velký práh naopak způsobuje zbytečně velké přesegmentování, viz obrázek 19c. Aby byla brána v úvahu různá rozložení hodnot gradientu  $\text{gr}_{\text{abs}}(x, y)$  pro různé obrazy, je jako práh použit  $x$ -percentil histogramu gradientního obrazu  $\text{gr}_{\text{abs}}(x, y)$ . Pro jeden práh a pro různé obrazy je tedy odprahována vždy stejná plocha. Na obrázku 18 je vynesena průměrná přesnost rozdělení do regionů (průměrný počet





Obr. 18: Vliv prahu  $t_{\text{mark}}$  na průměrný počet protnutí (společně se směrodatnou odchylkou) a průměrný počet regionů. Práh  $t_{\text{mark}}$  je daný jako  $x$ -tý percentil histogramu obrazu  $\text{grd}_{\text{abs}}(x, y)$



Obr. 19: Rozdělení do regionů na základě prahu  $t_{\text{mark}}$ , (a) příliš vysoký  $t_{\text{mark}}$ , (b) příliš nízký  $t_{\text{mark}}$ , (c) optimální  $t_{\text{mark}}$

protnutí) a průměrný počet regionů v závislosti na parametru  $x$ . Jak je vidět z výsledků, jako optimální práh  $t_{\text{mark}}$  byl stanoven 35. percentil z histogramu obrazu  $\text{grd}_{\text{abs}}(x, y)$ , kdy při nižších hodnotách  $x$  již nedochází k růstu průměrné přesnosti dělení ani poklesu její odchylky, ale nadále roste počet segmentů vzniklých dělením.

### 5.7.2. Vyhodnocení výsledků segmentace


Vyhodnocení celkových výsledků metody probíhalo porovnáním výsledného segmentu získaného automatickou segmentací s manuálně extrahovanou maskou zrna. Masky je s výsledným segmentem překryta a poté jednotlivé pixely výsledného obrazu označeny jako  $TP$  (správně pozitivní),  $FP$  (falešně pozitivní),  $FN$  (falešně negativní),  $TN$  (správně negativní). Z těchto počtů jsou potom určeny míry: senzitivita (recall)

$$\text{senzitivita} = \frac{TP}{TP + FN} \quad (21)$$

a pozitivní prediktivní hodnota (precision, Positive Predictive Value) [52]


$$pph = \frac{TP}{TP + FP} \quad (22)$$

Je-li *senzitivita* menší než 100 %, pak to představuje případ, kdy výsledný segment zcela nevykazuje skutečnou oblast zrna (viz obrázek 20c,d). Je-li *pph* menší než 100 %, pak výsledný segment zahrnuje i část obrazu, která nepatří do oblasti zrna (viz obrázek 20a,b)).



Obr. 20: Příklady výsledků segmentace, (a)  $pph = 90 \%$ , (b)  $pph = 95 \%$ , (c)  $\text{senzitivita} = 90 \%$ , (d)  $\text{senzitivita} = 95 \%$

Na obrázku 21 je uvedeno zhodnocení výsledků po fázi slučování regionů, kdy je výsledný segment určen sloučením vybrané množiny  $R_{ik}$ , před provedením etapy zpřesnění hranice. Na grafech y-ová souřadnice vyjadřuje procenta z počtu testovacích snímků, u kterého *senzitivita* či *pph* dosahuje alespoň hodnoty procent uvedené na ose x. Hodnoty z grafu jsou přepsány i do tabulky 5. Jak je z grafů vidět, algoritmus produkuje dobré výsledky. Např. připustíme-li 95 % hodnotu *pph* či *senzitivity*, pak jsou tyto požadavky splněny pro 86 % resp. 71 % všech testovacích snímků, v případě tolerance 90 % *pph* či *senzitivity* jsou požadavky splněny pro 96 % resp. 82 % všech testovacích snímků. Jak je vidět z výsledků, metoda vykazuje lepší *pph* než *senzitivitu*. Tato vlastnost byla v průběhu návrhu cíleně implementována tak, aby byl častější případ chyby, kdy k výslednému segmentu nejsou přidány všechny potřebné regiony, a naopak případ, kdy jsou k segmentu přidány i regiony pozadí, byl méně častý. Toto je v souladu se zamýšleným využitím, jelikož pro analýzu texturních vlastností zrn je důležitější, aby nebyla analyzována textura pozadí, naopak případ, kdy není vyhodnocena pouze část textury daného zrna, je z hlediska statistického vlivu na výsledky analýzy přijatelný.

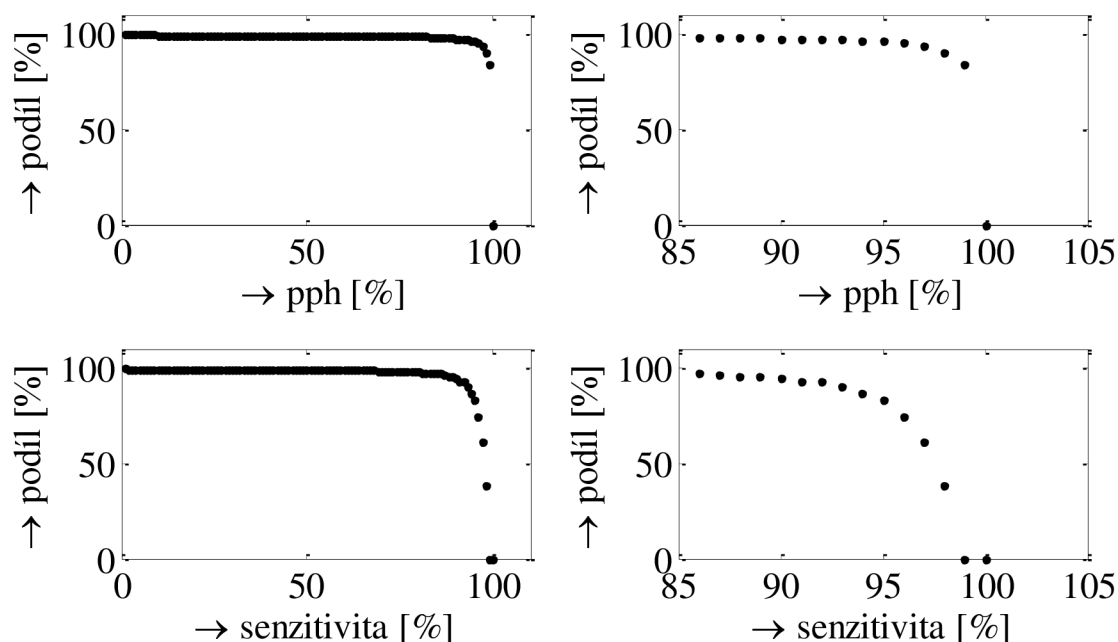


Obr. 21: Výsledky po proceduře slučování regionů. Vertikální osy představují podíl obrazů z testovací sady, které byly správně segmentovány *pph* resp. *senzitivitou* na horizontální ose. Pravá strana zobrazuje detail grafu.

Tab. 5: Výsledky po proceduře slučování regionů

<i>pph</i> [%]	<i>podíl</i> [%]	<i>pph</i> [%]	<i>podíl</i> [%]	<i>senz.</i> [%]	<i>podíl</i> [%]	<i>senz.</i> [%]	<i>podíl</i> [%]
100	0	93	93,2	100	0	93	76,8
99	8,8	92	94,1	99	1,2	92	80
98	48,8	91	95	98	37,6	91	81,2
97	68,5	90	96,2	97	56,2	90	82,1
96	79,1	85	97,9	96	66,2	85	86,2
95	86,2	80	98,8	95	71,2	80	88,8
94	89,1	75	98,8	94	74,1	75	91,2

Díky zpřesnění hranic, kdy je opět provedena segmentace pomocí watershed segmentace, ovšem s použitím přesnějšího výpočtu gradientu s pomocí Sobelových operátorů (viz kapitola 5.6), jsou výsledky segmentace výrazně lepší. Jejich shrnutí je uvedeno na obrázku 22 a v tabulce 6. Postačuje-li 95 % *pph* či *senzitivita*, pak je tato podmínka splněna pro 96 %, resp. 82 % všech testovacích snímků, postačuje-li 90 % *pph* či *senzitivita*, pak je tato podmínka splněna pro 97 %, resp. 95 % všech testovacích snímků. Průměrná *pph* a *senzitivita* pak je 98,5 % resp. 96,1 %.



Obr. 22: Výsledky po proceduře zpřesnění hranic. Vertikální osy představují podíl obrazů z testovací sady, které byly správně segmentovány s *pph* resp. *senzitivitou* na horizontální ose. Pravá strana zobrazuje detail grafu.

Tab. 6: Výsledky po proceduře zpřesnění hranic

<i>pph</i> [%]	<i>podíl</i> [%]	<i>pph</i> [%]	<i>podíl</i> [%]	<i>senz.</i> [%]	<i>podíl</i> [%]	<i>senz.</i> [%]	<i>podíl</i> [%]
100	0	93	97,1	100	0	93	90,6
99	83,8	92	97,1	99	0	92	92,6
98	90,6	91	97,1	98	38,5	91	92,9
97	93,8	90	97,6	97	61,5	90	95
96	95,3	85	98,2	96	74,4	85	97,4
95	96,2	80	98,8	95	82,9	80	97,9
94	96,8	75	99,1	94	86,8	75	97,9

### 5.7.3. Srovnání s metodou aktivních kontur

Jak bylo uvedeno v přehledu současného stavu poznání v oblasti segmentace geologických objektů, metoda v [26] využívala přístupu určení hranic objektu pomocí metody aktivních kontur. Pro využití této metody je třeba znát přibližné hranice objektu pro zahájení procesu vymezení

objektu zrna. Segmentační metoda navržená v předchozích částech kapitoly 5 využívala předpokladu, že zpracovávaný obraz zachycuje jedno zrno zabírající velkou část obrazu. Tohoto předpokladu je využito i zde při nastavení pozice aktivní kontury. Aktivní kontura je inicializovaná na okraje obrazu (podobě jako na obrázku 17c). Dále je pak počítáno s tím, že kontura v obraze je zdeformována tak, aby její výsledný tvar vymezoval plochu zrna. Pro experiment byla použita implementace [53], u které byly nastavitelné různé parametry, viz [27][53]. Experimentálně byly jako optimální parametry segmentace použity výchozí hodnoty v dané implementaci, pouze následující parametry byly pozměněny za účelem dosažení lepších výsledků segmentace:

- Elasticita aktivní kontury - hodnota 0,2.
- Tuhost aktivní kontury - hodnota 0,05.
- Váha obrazových externích sil - hodnota 10.
- Počet iterací při procesu adaptace aktivní kontury - 300.
- Krok při procesu adaptace aktivní kontury - 0,025.

Segmentace byla aplikována na stejnou sadu 341 obrazů, na které byla testována i metoda navržená v předchozích částech kapitoly 5. Na obrázku 23 lze vidět různé výsledky segmentace při využití metody aktivních kontur. Kvantifikace výsledků byla provedena stejným způsobem jako v předchozích částech a hodnoty jsou zobrazeny v tabulce 7. Postačuje-li 95 % *pph* či *senzitivity*, pak je tato podmínka splněna pro 72 %, resp. 26 % všech testovacích snímků, postačuje-li 90 % *pph* či *senzitivity*, pak je tato podmínka splněna pro 79 %, resp. 55 % všech testovacích snímků. Průměrná *pph* a *senzitivity* pak činí 93,3 % resp. 88,5 %. V porovnání s navrženou metodou nebylo dosaženo tak vysoké úspěšnosti, jelikož aktivní kontura při procesu své adaptace často uvízla na artefaktech pozadí, viz obrázek 23b, nebo hranice zrna nebyly natolik výrazné, aby při adaptaci aktivní konturu zafixovaly na jejich pozici, viz obrázek 23c.


Tab. 7: Výsledky po aplikaci metody aktivních kontur

<i>pph</i> . [%]	<i>podíl</i> [%]	<i>pph</i> . [%]	<i>podíl</i> [%]	<i>senz.</i> [%]	<i>podíl</i> [%]	<i>senz.</i> [%]	<i>podíl</i> [%]
100	0,0	93	75,9	100	0,0	93	39,1
99	34,4	92	77,4	99	0,0	92	43,8
98	61,8	91	78,5	98	0,6	91	49,7
97	65,6	90	79,4	97	8,5	90	55,0
96	70,6	85	82,4	96	17,4	85	70,6
95	72,4	80	85,0	95	25,9	80	82,9
94	73,8	75	88,2	94	33,5	75	90,6

#### 5.7.4. Diskuze výsledků

Z výsledků vyplývá, že segmentační metoda podává lepší výsledky z hlediska pozitivní prediktivní hodnoty, to znamená, že méně častým jevem je případ, kdy je pozadí označeno jako objekt zájmu (průměrná pozitivní prediktivní hodnota činí 98,5 %, senzitivity pak 96,1 %). Tato situace je z pohledu následující analýzy příznivá, jelikož méně často bude docházet k situaci, kdy část pozadí bude analyzována jako oblast zájmu, což by mohlo zkreslit výsledky následující analýzy. Naopak případ, kdy část skutečné oblasti zájmu není vinou nepřesnosti algoritmu zahrnuta do následující analýzy, není kritický, protože podle dosažených výsledků tato malá část oblasti zájmu nemusí výrazně ovlivnit

výsledky následující analýzy. Je však nutné zdůraznit, že i přes nízkou chybovost vymezení zrna metoda není vhodná pro analýzu 2D tvaru kontury zrna. Jak je vidět z obrázku 20, případné nezahrnutí regionu do množiny regionů tvořící segment zrna může značně zkreslit výslednou konturu zrna, což zcela zkreslí skutečné tvarové charakteristiky zkoumaného zrna. Jak však bylo uvedeno v kapitole 3, jedním z cílů výzkumu je snížení manuální činnosti geomorfologa, rutinní a rychlá kontrola segmentačních výsledků však nemusí výrazně zvýšit časovou náročnost. Vzhledem k povaze segmentace tak lze výsledek segmentace použít jako prvotní návrh segmentace a dále již případně manuálně provést korekci přidáním či odebráním chybějících resp. přebývajících regionů pro vytvoření přesného segmentu, jelikož v drtivé většině případů jsou hranice segmentu zrna lemovány hranicemi regionů. Jako příklad praktické segmentace sedimentárních zrn založené na manuálním výběru regionů lze uvést aplikaci [67].



Obr. 23: Příklady výsledků segmentace metodou aktivních kontur, (a) správný výsledek segmentace, (b) část pozadí špatně označená jako zrno, (c) část zrna špatně označená jako pozadí

## **6. Porovnání geomorfologických genezí podle tvaru 2D kontury sedimentárních zrn**

Jedním z nejvýznamnějších a relativně snadno strojově měřitelných parametrů je zaoblenost zrn. Proto byly jednotlivé geomorfologické geneze porovnány právě na základě strojově měřené zaoblenosti 2D průmětů jednotlivých zrn. Výstupem automatizovaného určování zaoblenosti je jedno reálné číslo z určitého rozsahu. Rozlišení genezí s pomocí hodnoty zaoblenosti je tedy možné provádět užitím experimentálně stanovené prahové hodnoty zaoblenosti. Tuto prahovou hodnotu je nutné určit na základě statistického vzorku, jelikož zaoblenost při snímání zrn ve 2D v rámci třídy nabývá určitého rozptylu. Vedle samotného porovnávání vzorků podle zaoblenosti byl v této části práce řešen také vliv rozlišení zpracovávaných snímků (resp. byla hledána minimální hodnota rozlišení pro dosažení spolehlivých výsledků). Bylo také zkoumáno, jaký počet 2D kontur musí být k dispozici, aby bylo (vzhledem k rozptylu hodnot zaoblenosti uvnitř dané třídy vzorků) možné porovnání na základě hodnoty zaoblenosti považovat za spolehlivé

### **6.1. Určení minimálního rozlišení pro analýzu zaoblenosti**

Ještě před vlastním porovnáváním genezí podle zaoblenosti byl vyhodnocen vliv rozlišení obrazu na výsledky automatického měření zaoblenosti. Jak je uvedeno v [54], rozlišení obrazu při analýze tvaru 2D průmětu může mít významný vliv na výslednou hodnotu zaoblenosti. Konkrétně uvedená studie představovala návrh metody pro určení minimálního rozlišení zrn pro spolehlivé měření následujících tvarových vlastností: cirkularita, sféricita a protáhlost. Princip byl založen na sestavení teoretické křivky závislosti cirkularita-protáhlost, či sféricita-protáhlost pro základní tvary jako jsou elipsy a obdélníky. Analýzou reálných dat pak bylo určeno minimální rozlišení, kdy spočítané tvarové míry neodporují předpokladům daným teoretickou křivkou. Ačkoliv v [54] byla zmíněna i míra zaoblenosti (která je předmětem této dizertace), možnost určení minimálního rozlišení byla založena pouze pro základní tvary, tj. elipsy a čtverce. Tyto základní tvary však reprezentují extrémní případy tvarů, zatímco reálné tvary zrn se od těchto extrémů často liší a proto závěry publikované v [54] nejsou dostatečné.

Z tohoto důvodu byla v rámci této práce provedena statistická analýza na reálných tvarech zrn pro určení minimálního rozlišení obrazu [61], při kterém může být zaoblenost měřena s dostatečnou citlivostí. Tato analýza je založena na měření korelace s Krumbeinovou tabulkou [33]. Tato srovnávací tabulka obsahuje reálné, běžně se vyskytující tvary zrn. Kritérium korelace s Krumbeinovou tabulkou bylo použito v publikacích [35][40][23]. Konkrétně jsou 2D průměty zrn z Krumbeinovy tabulky při daném obrazovém rozlišení analyzovány zvolenou metodou měření zaoblenosti a je vyhodnoceno, jak takto změřená zaoblenost koreluje s referenční hodnotou zaoblenosti, která je v Krumbeinově tabulce pro každý v ní obsažený tvar udána. Krumbeinova tabulka obsahuje celkem 81 2D průmětů zrn pro 9 různých tříd, které se liší hodnotou zaoblenosti. Korelace mezi hodnotou zaoblenosti změřenou pomocí zvolené metody a referenční hodnotou z Krumbeinovy tabulky, je pak dána jako

$$c = \frac{\sum_{i=1}^{81} (r(i) - \bar{r})(r_T(i) - \bar{r}_T)}{\sqrt{\sum_{i=1}^{81} (r(i) - \bar{r})^2} \sqrt{\sum_{i=1}^{81} (r_T(i) - \bar{r}_T)^2}}, \quad (23)$$

kde  $r(i)$  představuje změřenou zaoblenost  $i$ -tého 2D průmětu zrna Krumbeinovy tabulky,  $r_T(i)$  představuje referenční hodnotu zaoblenosti danou Krumbeinovou tabulkou,  $\bar{r}$  a  $\bar{r}_T$  jsou průměrné hodnoty zaoblenosti spočítané jako

$$\bar{r} = \frac{1}{81} \sum_{i=1}^{81} r(i) \quad (24)$$

a

$$\bar{r}_T = \frac{1}{81} \sum_{i=1}^{81} r_T(i). \quad (25)$$


Minimální rozlišení je pak určeno následovně: každý 2D průmět zrna z Krumbeinovy tabulky je pro dané rozlišení analyzován zvolenou metodou měření zaoblenosti. Jelikož jsou pro jednotlivé 2D průměty známy referenční hodnoty, je spočítán korelační koeficient ze vztahu (23). Míra rozlišení je zde reprezentována ve formě délky kontury 2D průmětu, jelikož lépe vystihuje skutečné rozlišení 2D průmětu nežli míra rozlišení reprezentovaná rozměry obrazu. Konturou 2D průmětu se myslí uzavřená posloupnost pixelů ve 4 propojení a její délka je dána počtem pixelů, které konturu tvoří. Ze všech 81 průmětů v Krumbeinově tabulce je pak pro dané rozlišení určena průměrná délka kontury  $\bar{l}$ . Korelační koeficient  $c$  a délka kontury  $\bar{l}$  jsou pak spočítány pro různá rozlišení a závislost korelačního koeficientu na průměrné délce kontury je vynesena do grafu. Z grafu pak lze určit průměrnou délku kontury, při které korelační koeficient dosáhne saturované hodnoty, kdy další zvyšování délky kontury (a tedy i rozlišení obrazu) významně neovlivňuje hodnotu korelačního koeficientu. Taková průměrná délka kontury (a tedy i její přibližně odpovídající rozlišení obrazu) pak určuje minimální rozlišení obrazu nutné při použití zvolené metody měření zaoblenosti.

Výše uvedeným postupem byly analyzovány metody měření zaoblenosti M1-M6. Závislost korelačního koeficientu  $c$  na průměrné délce kontury  $\bar{l}$  je vidět na obrázku 24. Jak je vidět, nízká hodnota korelačního koeficientu odpovídá nízké hodnotě průměrné délky kontury. U jednotlivých metod pak lze určit takovou délku kontury, kdy hodnota korelačního koeficientu dosahuje saturované hodnoty. Další zvyšování délky kontury již způsobuje pouze nevýznamný nárůst korelačního koeficientu nebo jeho fluktuaci v úzkém rozmezí. Lze tedy konstatovat, že pro dané rozlišení je již dosaženo maximální shody s Krumbeinovou tabulkou a další zvyšování rozlišení již míru shody neovlivňuje. V grafu na obrázku 24 lze vidět, že u jednotlivých metod se průměrná délka kontury, při které dojde k saturaci korelačního koeficientu, mírně liší. Má-li však být určeno rozlišení dostatečné pro analýzu zaoblenosti všemi metodami M1-M6, pak se jako dostatečná jeví délka kontury přibližně 450 pixelů. V následujících experimentech bylo tedy z důvodu rezervy voleno rozlišení 2D průmětu zrn tak, aby délka jejich kontury byla v průměru 600 pixelů ve 4-propojení. Parametry implementovaných metod M1-M6 jsou popsány v tabulce 8. Tyto parametry byly empiricky stanoveny tak, aby bylo pro jednotlivé metody dosaženo nejvyšší hodnoty korelace s Krumbeinovou tabulkou.



Tab. 8: Použité parametry implementovaných metod měření zaoblenosti


Metoda	Parametry
M1	U této metody je parametrem vzdálenost použitých paralelních přímek, konkrétně nastavená na hodnotu 2 pixely.
M2	Na základě popisu v literatuře [35] byla délka analyzované posloupnosti zvolena $N = 64$ , počet použitých koeficientů byl $n = 24$ .
M3	Na základě popisu v literatuře [38] byl parametr $N$ -úhelníku zvolen $N = 40$ .
M4	Tato metoda nemá žádný specifický parametr.
M5	Na základě hodnoty korelace s Krumbeinovou tabulkou byla zvolena hodnota $i = 0,3$ .
M6	Hodnota vzdálenosti protínajících úseček byla stanovena na $\lambda = H/5$ , kde $H$ odpovídá výšce použitého obrazu. Postupně je vzdálenost $\lambda$ snižována až na hodnotu 1 pixelu.




Obr. 24: Závislost korelačního koeficientu  $c$  na průměrné délce kontury  $\bar{l}$

## 6.2. Porovnávání genezí na základě hodnot zaoblenosti


Na obrázku 25 je zobrazen příklad rozložení hodnot zaoblenosti pro konkrétní třídu (svahová geneze). Na obr. 26, 27 a 28 jsou histogramy reprezentující rozložení hodnot zaoblenosti u zrn obsažených v databázi popsané v kap. 4. Pro výpočet hodnot zaoblenosti byly použity automatizované metody M1-M6 uvedené v kapitole 2.2.1. Histogramy ve sloupcích odpovídají výsledkům při použití jednotlivých metod analýzy zaoblenosti M1-M6, v jednotlivých řádcích pak histogramy odpovídají jednotlivým třídám geneze.




Obr. 25: Příklad histogramu zaoblenosti měřené metodou M1 pro svahovou genezi



Obr. 26: Histogramy zaoblenosti zrn měřené pro různé geneze metodami M1-M2



Obr. 27: Histogramy zaoblenosti zrn měřené pro různé geneze metodami M3-M4



Obr. 28: Histogramy zaoblenosti zrn měřené pro různé geneze metodami M5-M6

Z obrázků 26, 27 a 28 je vidět, že rozložení hodnot jednotlivých tříd genezí se značně překrývá. V tabulce 9 jsou vyčísleny střední hodnoty a rozptyly těchto rozložení. Je zřejmé, že třídy od sebe nelze odlišovat na základě hodnoty zaoblenosti jednotlivých zrn (kvůli značnému překryvu hodnot různých tříd), ale na základě statistických momentů hodnot zaoblenosti určených přes celý vzorek - především střední hodnoty. Porovnání tedy bude provedeno na základě statisticky významnějšího souboru. Proto je zkoumáno, jak velký musí být vzorek (sada zrn), aby bylo možné rozdíl ve středních hodnotách mezi třídami geneze považovat za dostatečný pro jejich vzájemné odlišení.

Tab. 9: Střední hodnoty a směrodatné odchylky zaoblenosti zrn měřené různými metodami pro jednotlivé geneze

	M1	M2	M3	M4	M5	M6
Eolická	0,55±0,20	0,42±0,26	0,80±0,14	0,67±0,18	0,78±0,15	0,72±0,15
Glaciální	0,38±0,15	0,16±0,09	0,61±0,15	0,53±0,20	0,61±0,16	0,55±0,14
Vulkanická	0,32±0,15	0,15±0,08	0,59±0,14	0,56±0,19	0,56±0,16	0,51±0,15
Svahová	0,39±0,16	0,15±0,10	0,60±0,16	0,56±0,22	0,59±0,18	0,52±0,17

### 6.3. Určení minimálního počtu projekcí zrn

V této práci je určována hodnota MNP v kontextu odlišení dvojice tříd na základě hodnoty jednoho příznaku, konkrétně zaoblenosti. Následuje popis pro určení nezbytné velikosti vzorku (MNP - Minimal Number of Particle projections) uvedený v [61]. Jelikož dochází k porovnávání tříd na základě jedné střední hodnoty zaoblenosti, je MNP platné vždy pro určitou dvojici porovnávaných tříd. MNP musí být určeno tak, aby bylo dostatečné vzhledem k rozdílu středních hodnot dvojice tříd a také vzhledem k rozptylu jejich hodnot. V případě, že je rozdíl středních hodnot zaoblenosti vzhledem k rozptylu hodnot velký (nízká vzájemná podobnost tříd), bude hodnota MNP nižší než v případě, že je rozdíl středních hodnot zaoblenosti vzhledem k rozptylu hodnot nízký (vysoká vzájemná podobnost tříd). Cílem je tedy určit MNP v závislosti na vlastnostech porovnávaných tříd tak, aby střední hodnoty tříd byly dostatečně vypovídající pro vzájemné rozlišení. Tímto se tedy daný přístup liší od přístupu v [30], kde je MNP určováno absolutně pro každý typ materiálu zvlášť. Výhodou přístupu určování MNP na základě podobnosti dvojice tříd je, že při velké rozdílnosti tříd je možné použít menší velikost vzorku a tím šetřit prostředky na pořizování snímků zrn.

#### 6.3.1. Princip určení minimálního počtu projekcí zrn

MNP tedy závisí na podobnosti /odlišnosti dvojice tříd. Teoreticky, má-li dvojice tříd  $C_A$  a  $C_B$  obecné rozložení hodnot se středními hodnotami zaoblenosti  $\mu_A$  resp.  $\mu_B$ , existuje pak požadavek, aby odebrané vzorky zrn z daných rozložení měly své výběrové průměry  $\bar{r}_A$  a  $\bar{r}_B$  s velkou mírou pravděpodobnosti v určitém intervalu  $h$  okolo skutečných středních hodnot  $\mu_A$  resp.  $\mu_B$ , viz obrázek 29. Tento interval je definován úměrně k rozdílu středních hodnot

$$h = f |\mu_{C_A} - \mu_{C_B}|, \quad (26)$$

kde hodnota  $f$  závisí na požadované přesnosti, která se volí jako vstupní parametr v rozmezí (0;0.5). Tento interval lze vidět na obrázku 29. Podle [55] lze odhad intervalu střední hodnoty zaoblenosti  $\mu$  populace, kde je směrodatná odchylka dané populace neznámá, vyjádřit jako

$$\mu_A = \bar{r}_A \pm h_A \quad (27)$$

a

$$\mu_B = \bar{r}_B \pm h_B \quad (28)$$


pro třídy  $C_A$  resp.  $C_B$ , kde  $h_A$  a  $h_B$  určují velikost intervalu kolem středních hodnot  $\mu_A$  resp.  $\mu_B$ . Tato velikost intervalu závisí na velikosti vzorku  $n$  a lze ji určit jako

$$h_A = t_{n-1,0.025} \frac{s_A}{\sqrt{n}} \quad (29)$$

a

$$h_B = t_{n-1,0.025} \frac{s_B}{\sqrt{n}}, \quad (30)$$

kde  $s_A$  a  $s_B$  představují směrodatnou odchylku třídy  $C_A$  resp.  $C_B$ . Člen  $t_{n-1,0.025}$  značí kvantil Studentova rozložení s  $n - 1$  stupni volnosti odpovídající hladině významnosti 95 %. Takto spočítaný odhad intervalu by měl poskytnout dobré výsledky i pro populace mající jiné než normální rozložení v případě, že  $n$  je dostatečně velké [55].



Obr. 29: Překryv rozložení dvojice tříd

Je-li tedy k dispozici dvojice vzorků o velikosti  $n$ , lze odhadnout velikosti intervalu  $h_A$  a  $h_B$ . Pokud  $h_A \leq h$  a  $h_B \leq h$ , tj. odhadnuté intervaly jsou menší než definovaná velikost intervalu  $h$ , může být velikost vzorku  $n$  považována za dostačující. V opačném případě není považována za dostačující.

Jelikož nejsou střední hodnoty  $\mu_A$  a  $\mu_B$  v praktických podmínkách známe, jsou nahrazeny odpovídajícími výběrovými průměry  $\bar{r}_A$  a  $\bar{r}_B$  a definovaný interval je spočítán jako

$$\hat{h} = f |\bar{r}_A - \bar{r}_B|. \quad (31)$$

Minimální počty jsou pak určeny dosažením  $\hat{h}$  za  $h_A$  a  $\hat{h}$  za  $h_B$  ve vztahu (29) resp.(30) a následnou úpravou jako

$$\hat{n}_A = \left( t_{n-1,0.025} \frac{S_A}{\hat{h}} \right)^2 \quad (32)$$

a

$$\hat{n}_B = \left( t_{n-1,0.025} \frac{S_B}{\hat{h}} \right)^2. \quad (33)$$

Z důvodu zjednodušení lze MNP nutné pro spolehlivé odlišení dvojice tříd získat jako

$$\hat{n}_{AB} = \max(\hat{n}_A, \hat{n}_B), \quad (34)$$

tedy takový počet, pro který bude požadovaná podmínka splněna pro obě třídy.

Jelikož při odvozování došlo k nahrazení  $\hat{h}$  za  $h$ , nelze tvrdit, že s hladinou významnosti 95 % se při daném MNP budou výběrové průměry nacházet v definovaném okolí středních hodnot, nicméně i přesto takový výsledek poskytuje jistou evidenci, jak přibližně musí být vzorek velký. Pokud bude pro požadovanou přesnost (parametr  $f$ ) určené MNP větší než velikosti dvojice vzorků, na základě kterých bylo MNP spočítáno, nelze pak výběrové průměry dostupných vzorků považovat za dostatečně vypovídající pro rozlišení zkoumané dvojice tříd.

### 6.3.2. Ověření metody pro určení minimálního počtu projekcí

Správnost v předchozí části odvozeného postupu byla ověřena na velké množině vygenerovaných dat 2D průmětů z množiny skutečných 3D geologických částic. Na základě jejich nasnímaných prostorových modelů byly pomocí prostorového natočení průmětné roviny získány různé 2D průměty. Tímto postupem byl tedy nejen získán velký počet 2D průmětů, ale bylo možné simulovat také vliv natočení průmětné roviny při snímání jedné konkrétní částice. Výsledná variabilita

v experimentálních datech je pak kombinací variability mezi jednotlivými částicemi a variability dané různými pohledy na částici. Pro účely generování databáze bylo proto nasnímáno několik sad skutečných geologických částic pomocí 3D skeneru HandySCAN 3D™ EXAscan, který byl použit pro snímání prostorových modelů částic s přesností 0,5 mm. Pro experimenty byly sestaveny a nasnímány celkem čtyři vzorky reprezentující čtyři třídy zaoblenosti. Samotný počet částic byl pro každou třídu roven 10, celkem tedy bylo k dispozici 40 reálných částic a jejich 3D modelů. Třídy částic byly vybrány cíleně tak, aby reprezentovaly rovnoměrně každá jinou zaoblenost ze škály jejich možných hodnot. Kompletní sada použitých částic je vidět na obrázku 30 a jejich popis je také uveden v tabulce 10. Kvůli zajištění dostatečné přesnosti 3D modelu byla velikost těchto pokusných objektů volena mezi 5 a 10 cm. Při volbě menších částic by mohly vzniknout potíže s mezním limitem přesnosti použitého skeneru, nehledě na potíže při samotném procesu skenování. Zaoblenost prostorových částic však je možné hodnotit poměrově, tedy nezávisle na skutečné velikosti a proto mohou být získané výsledky považovány za obecně platné pro různá měřítka (tedy i pro sedimentární zrna o velikostech v řádech stovek  $\mu\text{m}$ ).



Obr. 30: Použitá sada částic pro generování průmětů

Tab. 10: Popis použité sady objektů

	Vzorek	Subjektivní zaoblenost	Počet částic ve vzorku
$C_1$	Uměle zaoblený mramor	Zaoblený R1	10
$C_2$	Přírodně zaoblený křemen	Polozaoblený R2	10
$C_3$	Drcený mramor	Poloangulární R3	10
$C_4$	Přírodní lánaný pískovec	Angulární R4	10

Z nasnímaných 3D modelů byly poté vygenerovány 2D průměty pro různé úhly natočení průmětné roviny. Střed 3D modelu byl vždy umístěn v počátku 3D souřadnicového systému. Natočení průmětné roviny je realizováno různým umístěním kamery na povrchu pomyslné koule se středem v počátku, přičemž kamera je vždy taktéž namířena do počátku. Pro generování průmětů bylo použito paralelní promítání, tedy promítání bez perspektivního zkreslení. Pozice kamery byly rovnoměrně rozmístěny na povrchu polokoule, což zajistilo získání různých průmětů téže 3D částice. Tímto

způsobem bylo z každé 3D částice získáno 3843 snímků o rozlišení 540x540. Jelikož je při tomto promítání ve dvou přesně opačných směrech dosaženo stejného tvaru průmětu, je dostačující použít jen jednu polovinu koule. Ukázky vygenerovaných průmětů z jedné 3D částice lze vidět na obrázku 4 v kapitole 2.2, celou databázi lze vidět v příloze A.

Postup ověření odvozeného určení MNP pak obnášel nejprve získání vztažných MNP vždy pro sousední dvojice tříd zaoblenosti ve vygenerované ověřovací sadě. Dvojice tříd tedy byly  $C_1C_2$ ,  $C_2C_3$  a  $C_3C_4$  a jim odpovídající MNP byly označeny postupně jako  $n_{12}$ ,  $n_{23}$  a  $n_{34}$ . Tyto počty byly určeny na základě vztahu (34), přičemž statistické momenty  $\bar{r}_A$ ,  $\bar{r}_B$ ,  $s_A$  a  $s_B$  jsou spočítány na celé dostupné sadě 10·3843 2D průmětů u odpovídající třídy, jedná se tedy o skutečné hodnoty těchto statistik a ne jejich odhady (je-li celá sada tříd o 10·3843 průmětech považována za celou populaci). Při výpočtu byl použit parametr  $f = 0.1$ . Tyto vztažné hodnoty MNP jsou uvedeny v tabulce 11.

Tab. 11: Vztažné MNP určené pro dvojice tříd  $C_1C_2$ ,  $C_2C_3$  a  $C_3C_4$  a pro metody měření zaoblenosti M1-M6

	$n_{12}$	$n_{23}$	$n_{34}$
M <sub>1</sub>	90	272	2,208
M <sub>2</sub>	54	106	762
M <sub>3</sub>	183	97	767
M <sub>4</sub>	787	11,223	5,352
M <sub>5</sub>	113	128	934
M <sub>6</sub>	2,265	239	2,644

Poté byla pro ověření použita procedura určení MNP, která byla založena na odhadech statistických momentů  $\bar{r}_A$ ,  $\bar{r}_B$ ,  $s_A$  a  $s_B$ . Tato procedura je následující:

- $n$  2D projekcí je vybráno z obou tříd porovnávaného páru a hodnoty  $\hat{h}$  a  $\hat{n}_{AB}$  jsou spočítány s použitím rovnic (31) a (34) na základě aktuálního vzorku.
- Pokud je  $n < \hat{n}_{AB}$ , je aktuální velikost vzorku nedostatečná a další 2D projekce je vybrána a přidána k aktuálnímu vzorku, tedy jeho velikost je zvětšena na hodnotu  $n + 1$ .
- Postupné zvětšování dvojice vzorků je prováděno tak dlouho, dokud není dosaženo  $n \geq \hat{n}_{AB}$ . Hodnota  $n$  pak určuje hodnotu MNP.

Jelikož výběr 2D projekcí probíhal náhodně, výše uvedená procedura určení MNP byla celkem 1000-krát zopakována pokaždé s jinak sestavenou dvojicí náhodných vzorků. MNP určené v  $i$ -tém opakování bylo označeno jako  $\hat{n}_{ABi}$ . Po všech opakováních byl určen průměrný odhad MNP označený jako  $\bar{\hat{n}}_{AB}$  a tato hodnota byla porovnána se vztažnými hodnotami MNP  $n_{AB}$ . Výsledky lze vidět v tabulkách 12, 13 a 14, kde jsou postupně vyhodnoceny dvojice tříd  $C_1C_2$ ,  $C_2C_3$  a  $C_3C_4$ . V každé z tabulek je vedle průměrného odhadu určena i směrodatná odchylka ze všech opakování označená jako  $\text{std}(\hat{n}_{AB})$  a relativní směrodatná odchylka označena jako  $\text{rel. std}(\hat{n}_{AB})$ .

Jak lze vidět v tabulkách 12, 13 a 14, průměrná hodnota  $\bar{\hat{n}}_{AB}$  experimentálně určeného MNP odpovídá vztažným hodnotám  $n_{AB}$  pro všechny metody měření zaoblenosti M1-M6. V průměru činí relativní směrodatná odchylka odhadu MNP  $\hat{n}_{AB}$  od správné hodnoty MNP 15%. Proto lze tvrdit, že použitím dané procedury odhadu MNP pro dvojici tříd lze získat řádově přesnou hodnotu MNP.



Tab. 12: Srovnání MNP určeného na základě odhadů statistických momentů a vztažného MNP pro dvojici tříd  $C_1C_2$

	$n_{12}$	$\bar{\hat{n}}_{12}$	$\text{std}(\hat{n}_{12})$	$\text{rel. std}(\hat{n}_{12})[\%]$
M1	90	95	17	18
M2	54	56	11	20
M3	183	186	25	14
M4	787	792	123	15
M5	113	113	19	17
M6	2,265	2279	204	9

Tab. 13: Srovnání MNP určeného na základě odhadů statistických momentů a vztažného MNP pro dvojici tříd  $C_2C_3$

	$n_{23}$	$\bar{\hat{n}}_{23}$	$\text{std}(\hat{n}_{23})$	$\text{rel. std}(\hat{n}_{23})[\%]$
M1	272	274	45	16
M2	106	105	20	19
M3	97	98	18	18
M4	11,223	11192	1182	11
M5	128	130	21	16
M6	239	248	45	18

Tab. 14: Srovnání MNP určeného na základě odhadů statistických momentů a vztažného MNP pro dvojici tříd  $C_3C_4$

	$n_{34}$	$\bar{\hat{n}}_{34}$	$\text{std}(\hat{n}_{34})$	$\text{rel. std}(\hat{n}_{34})[\%]$
M1	2,208	2211	332	15
M2	762	769	110	14
M3	767	766	100	13
M4	5,352	5402	652	12
M5	934	933	117	13
M6	2,644	2668	331	12

## 6.4. Diskuze experimentálních výsledků na dostupné databázi

Z dostupných vzorků, které jsou obsaženy v databázi popsané v kapitole 4, byly sestaveny různé kombinace dvojic tříd geomorfologických genezí a pro tyto dvojice byly spočítány MNP. Každé MNP pro danou kombinaci tříd bylo spočítáno na základě všech zrn obsažených v dvojici vzorků. MNP bylo spočítáno na základě rovnic (32)(33) a (34). Je-li určené MNP větší než velikost dostupných vzorků, nelze danou dvojici tříd geomorfologických genezí odlišit s danou přesností  $f$  podle míry zaoblenosti.

Výsledky pro různé metody měření zaoblenosti M1-M6 a pro různé hodnoty přesnosti  $f$  lze vidět v tabulce 15. Pozice v tabulce určuje kombinaci tříd, pro které byl MNP určen. Jak vyplývá ze vztahů (31), (32) a (33), určený MNP je nepřímo úměrný kvadrátu vstupního parametru  $f$ . Tento parametr je nutné zvolit podle požadované přesnosti. Jak je vidět z výsledků, rozlišování geomorfologických genezí na základě zaoblenosti je aplikovatelné pouze na odlišení eolické geneze od ostatních genezí.

V případě přesnosti  $f = 0,1$  jsou spočítané MNP hodnoty větší, než velikosti vzorků, ze kterých byly spočítány. Pro danou přesnost lze tvrdit, že hodnota zaoblenosti neposkytuje dostatečnou informaci pro rozlišení genezí.

Bude-li snížena požadovaná přesnost na hodnotu  $f = 0,2$ , pak hodnoty MNP platné pro dvojice tříd, v nichž je zahrnuta eolická geneze, přibližně odpovídají velikostem vzorků v dostupné databázi, ze kterých byly hodnoty MNP spočítány (platí pro všechny metody určování zaoblenosti kromě metody M4). Lze tedy konstatovat, že rozsah hodnot zaoblenosti třídy eolické geneze (a s ním související i jeho střední hodnota) je dostatečně odlišný od rozsahů hodnot zaoblenosti ostatních tříd a je tedy možné míru zaoblenosti využít pro rozlišení eolické geneze od ostatních. Pro zbývající geneze (glaciální, svahová a vulkanická) lze konstatovat, že míra zaoblenosti není vhodným ukazatelem (na základě velikosti vzorků, které byly v dané databázi k dispozici) k jejich vzájemnému odlišení. Určené MNP mnohonásobně převyšují velikost vzorku, na základě kterých byly spočítány.

Při snížení přesnosti na  $f=0,5$  je vidět, že pro různé kombinace dvojic genezí (glaciální, svahová a vulkanická) hodnoty MNP stále převyšují velikost použitých vzorků (kromě kombinace glaciální-svahová u metody M1). Při dalším snižování přesnosti (nad 0,5) by už došlo k překrytí tolerančních intervalů. Byla-li by pro odlišení genezí použita prahová hodnota stanovená jako polovina vzdálenosti mezi středními hodnotami zaoblenosti dané dvojice genezí, zvyšovala by se pravděpodobnost nesprávné klasifikace na základě této prahové hodnoty.

Z výsledků lze tedy soudit, že pro dané geneze hodnota zaoblenosti neposkytuje dostatečnou evidenci pro spolehlivou separaci genezí (kromě odlišení eolické geneze od ostatních). Přesto je však navržená metoda pro určení MNP užitečnou pomůckou, kterou lze použít jako vodítko, zda-li jsou dvě geneze separovatelné na základě dostupných vzorků o dané velikosti. Z důvodu rozpoznání i geneze jiné než eolické byla dále zkoumána možnost klasifikace vzorků na základě texturních vlastností povrchu sedimentárních zrn.

Tab. 15: Minimální počty průmětů pro dvojice tříd při použití metod měření zaoblenosti M1-M6 a při různých hodnotách přesnosti  $f$

		$f = 0,1$			$f = 0,2$			$f = 0,5$		
		glac.	svah.	vulk.	glac.	svah.	vulk.	glac.	svah.	vulk.
M1	eol.	520	281	537	130	70	134	21	11	21
	glac.		2169	1255016		542	313754		87	50201
	svah.			2263			566			91
M2	eol.	357	343	339	89	86	85	14	14	14
	glac.		127563	81961		31891	20490		5103	3278
	svah.			1577902			394476			63116
M3	eol.	238	166	248	60	41	62	10	7	10
	glac.		12555	83205		3139	20801		502	3328
	svah.			43198			10800			1728
M4	eol.	880	1133	1492	220	283	373	35	45	60
	glac.		35570	33775		8892	8444		1423	1351
	svah.			3797450			949362			151898
M5	eol.	324	203	319	81	51	80	13	8	13
	glac.		4320	24923		1080	6231		173	997
	svah.			18276			4569			731
M6	eol.	277	180	265	69	45	66	11	7	11
	glac.		4117	14910		1029	3728		165	596
	svah.			28827			7207			1153

## 7. Klasifikace podle texturních vlastností

V této části je popsána metoda analýzy povrchu sedimentárních zrn pomocí automatizovaných technik zpracování obrazu. Tato analýza je prováděna za účelem rozlišení různých geomorfologických genezí. Jak již bylo uvedeno, postup používaný geomorfology při exoskopické analýze spočívá ve sledování četnosti výskytu definovaných strukturních charakteristik na povrchu sedimentárních zrn (např. lasturnatý lom, obloukový stupeň, V-jamka). Na základě těchto četností pak lze rozlišovat geomorfologické geneze [1]. Do tohoto schématu lze zařadit přístup [50] již zmiňovaný v kapitole 2.3.2, kde byla představena automatická metoda pro detekci štěpných plátků. V tomto případě měli autoři pro vytvoření modelu velký počet exemplárních případů štěpných plátků, které byly na povrchu zrn uměle vytvořeny v laboratorních podmínkách a poté nasnímány pomocí SEM elektronového mikroskopu. V dostupné databázi uvedené v kapitole 4 jsou však nasnímány reálné vzorky odebrané z vybraných lokalit, kde výskyt exemplárních příkladů strukturních charakteristik není dostatečný pro vytvoření jejich modelu. Dalším problémem může být i subjektivita posouzení výskytu dané strukturní charakteristiky na povrchu zrna různými lidmi. Proto, jak bylo uvedeno v cílech dizertace, byla pro rozlišení genezí navržena metoda přímé klasifikace do skupin podle geomorfologických genezí na základě nízkourovňových obrazových příznaků.

### 7.1. Blokový popis vytvoření modelů geomorfologických genezí

Základní princip metodiky pro rozlišení genezí je inspirován schématem pro rozlišování textury v [56]. Princip schématu je založen na předpokladu, že celkovou texturu (texturu na úrovni části obrazu) lze reprezentovat množinou lokálních textur (textury na úrovni pixelu a jeho blízkého okolí). Schéma vytvoření modelu textury se skládá ze dvou částí:

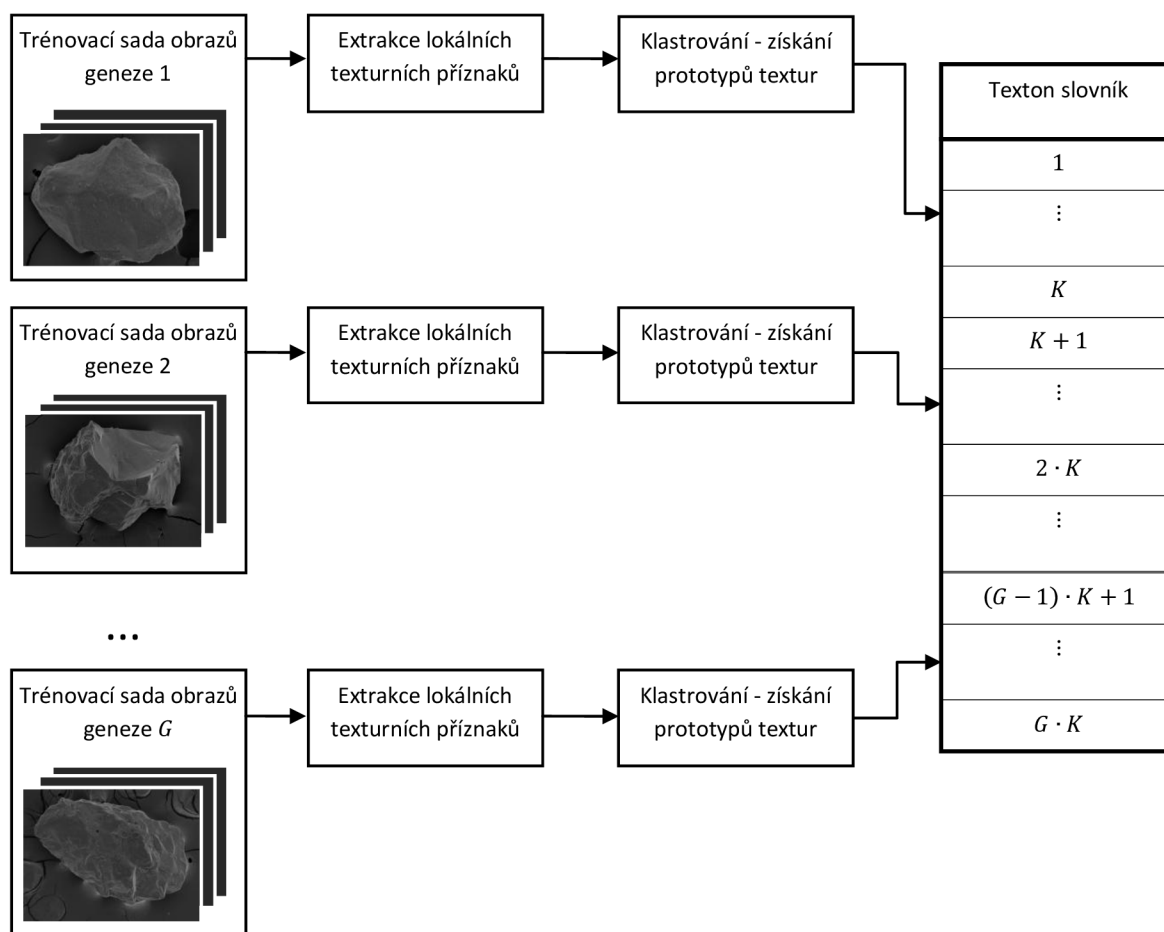
- Vytvoření texton slovníku, kde texton představuje prototyp tzv. lokální textury, tedy textury na úrovni pixelu a jeho blízkého okolí. Texton slovník tedy představuje soubor prototypů lokálních textur, podle nichž je pak možné klasifikovat typ lokální textury.
- Vytvoření modelu celkové textury, který je vytvořen na základě četnosti zastoupení jednotlivých prototypů lokálních textur v celkové textuře. Na základě tohoto modelu pak lze klasifikovat typ celkové textury.

Obě části budou nyní podrobněji popsány v kontextu rozlišování geomorfologických genezí, což je hlavním cílem této kapitoly. Pro přehlednost budou v popisu rozlišování geomorfologických genezí používány tyto dva pojmy:

- **třída lokální textury**, tj. typ lokální textury určený na základě texton slovníku
- **třída geomorfologické geneze**, tj. třída geneze specifikovaná texturou povrchu zrn (tato textura povrchu zrn tedy odpovídá celkové textuře ve výše popsaném schématu)

#### 7.1.1. Vytvoření texton slovníku

Schéma procedury vytvoření texton slovníku je na obrázku 31. Princip je takový, že ze sady obrazů zrn, náležících do třídy určité geneze, jsou vyextrahovány lokální texturní příznakové vektory. Pojem lokální příznak značí hodnotu, která je platná pro určitou pozici pixelu v obraze  $I(x, y)$  a je spočítána z jeho okolí o definované velikosti. Toto okolí bude dále označeno jako  $I_R(x, y)$ . Pro pozici



Obr. 31: Procedura vytvoření texton slovníku.


daného pixelu lze spočítat různé typy příznaků (viz kapitola 2.3.1), taktéž lze měnit velikost okolí pixelu, ze které jsou tyto příznaky počítány. Tímto způsobem je tedy vytvořen příznakový vektor platný pro určitou pozici obrazového pixelu, tj. pixel v obraze je reprezentován příznakovým vektorem, který popisuje lokální texturu. Tyto příznakové vektory jsou spočítány pro různé pozice v obraze a zároveň pro všechny obrazy ze sady dané geneze. Všechny takto získané příznakové vektory jsou uspořádány do tabulky. Na tuto tabulku je aplikováno klastrování. Klastrování podle rozložení hodnot vektorů v příznakovém prostoru vytvoří model definující  $K$  tříd lokální textury. Tento model pak umožňuje klasifikaci určitého příznakového vektoru (příslušejícího k určitému pixelu v obraze) do určité třídy lokální textury na základě jeho pozice v příznakovém prostoru. Vytvořený model prototypů lokálních textur pak představuje již zmíněný texton slovník. Jako vhodný algoritmus použitelný ke tvorbě texton slovníku lze zmínit  $K$ -means metodu [57]. Jak je vidět na obrázku 31, pro každou sadu obrazů pocházející z určité geomorfologické geneze je vytvořen model prototypů textur, které jsou sloučeny do jednoho texton slovníku. Je-li počet tříd geomorfologických genezí  $G$ , sestává výsledný texton slovník z celkem  $K \cdot G$  prototypů lokální textury.

Metoda klasifikace jednotlivých pixelů podle typu lokální textury je do značné míry podobná schématu podle Newella [50] uvedeném v kapitole 2.3.2. U tohoto schématu jsou taktéž jednotlivé pixely klasifikovány do několika různých tříd lokální textury na základě porovnání hodnot odezev sady filtrů (viz obrázek 10). Rozdíl zde spočívá především ve způsobu klasifikace jednotlivých pixelů. Zatímco v [50] je klasifikační schéma pevně dané, u metody využívající textonů je slovník vytvořen na základě trénovacích dat patřících různým třídám, v našem případě třídám geomorfologických

genezí. Způsob klasifikace jednotlivých pixelů do tříd lokální textury je tedy více přizpůsoben konkrétní povaze analyzované textury.

### 7.1.2. Vytvoření modelu geomorfologických genezí

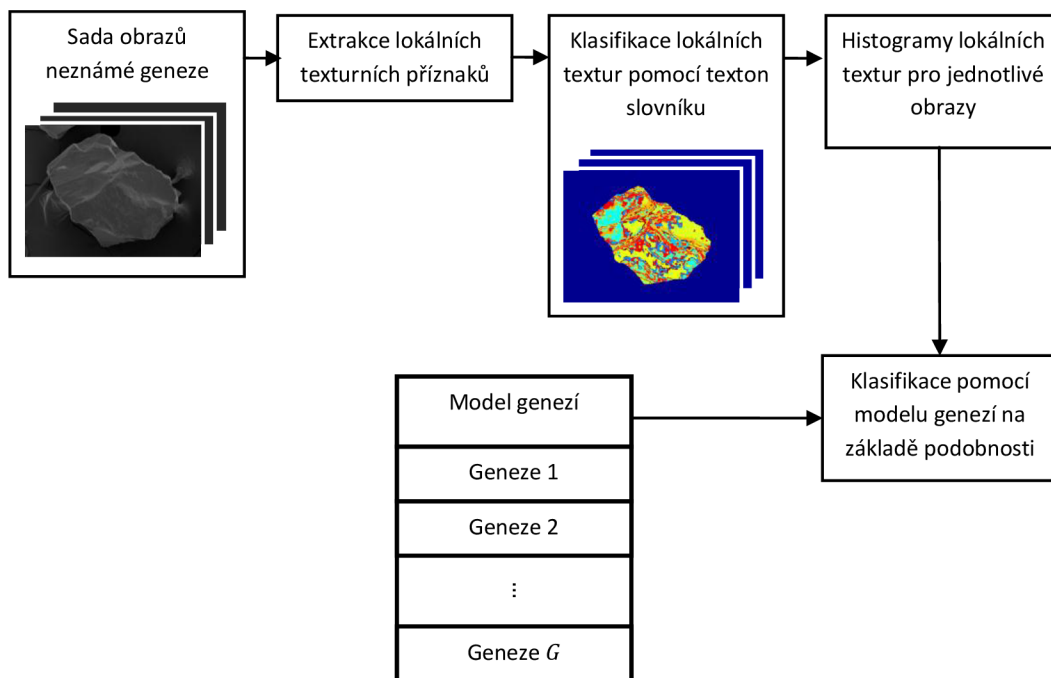
Model geomorfologické geneze je pak vytvořen postupem zobrazeným na obrázku 32. Opět je zde použita sada obrazů zrn náležících do třídy určité geneze. Z každého zrna jsou vyextrahovány lokální texturní příznakové vektory. Pomocí texton slovníku je každý vektor přiřazen k určité třídě lokální textury (přiřazení k třídám lokální textury je barevně vizualizováno na obrázku 32). Dané zrna je pak reprezentováno histogramem v něm obsažených lokálních textur. Textura povrchu zrna (jakožto celková textura) je tedy charakterizována četností zastoupení jednotlivých prototypů lokální textury. Ze sady sedimentárních zrn náležících dané geomorfologické genezi je tak získána sada histogramů, která tvoří model dané geomorfologické geneze.



Obr. 32: Vytvoření modelu geomorfologických genezí

### 7.1.3. Klasifikace neznámého vzorku

Klasifikace neznámého vzorku sedimentárních zrn je provedena podobně jako při vytváření modelu (viz obrázek 33). Z každého zrna jsou vyextrahovány lokální texturní příznakové vektory a pomocí texton slovníku je každý vektor přiřazen k určité třídě lokální textury. Histogram lokálních textur, získaný ze zrna neznámého vzorku, je porovnán s jednotlivými sadami vztažných histogramů, kde každá sada vztažných histogramů představuje model určité geomorfologické geneze. Dané zrno je pak klasifikováno podle podobnosti se sadami vztažných histogramů do jedné ze tříd geomorfologických genezí. Tímto postupem jsou klasifikována všechna zrna neznámého vzorku a na základě nejčastěji se vyskytující geneze je pak klasifikován celý vzorek. Podrobněji je tento postup popsán v následujících kapitolách.



Obr. 33: Klasifikace vzorku do geomorfologické geneze

## 7.2. Detailní popis procedury vytvoření modelů geomorfologických genezí

### 7.2.1. Použité obrazové příznaky

Základní informace, která slouží pro klasifikaci jednotlivých vzorků do tříd, je extrahována z obrazů ve formě lokálních texturních příznaků. V případě sedimentárních zrn byly pro popis textury využity příznaky založené na kookurenční matici a říditelných filtrech. Následuje tedy podrobný popis obou použitých typů příznaků.

### 7.2.1.1. Příznaky založené na kookurenční matici

Kookurenční matice je vhodným nástrojem pro extrakci příznaků, jelikož se tyto příznaky ve studii [62] na základě experimentů ukázaly jako vhodné pro rozlišení různých textur povrchu sedimentárních zrn. Konkrétně bylo zjištěno, že lze pomocí těchto příznaků odlišovat tři základní typy povrchů - hladký povrch, hrubý povrch a zlomy (hrany). Vyšlo se zde tedy z předpokladu, že budou příznaky založené na kookurenční matici taktéž vhodné k popisu a odlišení jednotlivých tříd lokální textury.

Kookurenční matice [46] zachycuje počty (četnosti) různých kombinací pixelových intenzit. Oblast v obraze  $I(x, y)$ , ze které má být spočítána kookurenční matice a z ní následně odvozené lokální texturní příznaky, je označena  $I_R(x, y)$ . Pro definovaný posun  $m, n$  je pak kookurenční matice  $P(i, j)$  definována jako

$$P(i, j) = \sum_{x=1}^U \sum_{y=1}^V \begin{cases} 1, & \text{pro } I_R(x, y) = i \wedge I_R(x + m, y + n) = j, \\ 0, & \text{pro ostatní} \end{cases}, \quad (35)$$

kde  $U, V$  představují rozměry oblasti  $I_R(x, y)$ . Pro definovaný posun  $(m, n)$  lze tedy pro konkrétní pozici  $(x, y)$  určit dvojici pixelových intenzit  $(i, j)$  tak, že  $i = I_R(x, y)$  a  $j = I_R(x + m, y + n)$ . Tímto způsobem jsou pro všechny pozice  $(x, y)$  v oblasti  $I_R(x, y)$  určeny dvojice intenzit  $(i, j)$  a na základě jejich hodnot je sestavena kookurenční matice  $P(i, j)$ , což je v podstatě dvojrozměrný histogram vyjadřující četnosti výskytu jednotlivých dvojic intenzit. Dvojice intenzit  $(i, j)$  jsou určeny pouze pro pozice, kdy hodnoty  $(x, y)$  a  $(x + m, y + n)$  nepřekračují hranice obrazu  $I(x, y)$ . Kookurenční matice  $P(i, j)$  normalizovaná počtem dvojic pixelových intenzit je pak označena  $p(i, j)$ , v tomto tvaru tedy reprezentuje rozložení pravděpodobnosti výskytu různých dvojic intenzit  $(i, j)$ . Příklad sestavení kookurenční matice pro posun  $(1, 1)$  dle předchozího postupu je ilustrován na obrázku 34. Obecně je kookurenční matice čtvercová a její velikost je rovna počtu jasových hodnot, kterých mohou pixely obrazu  $I_R(x, y)$  nabývat. Velikost matice tak lze snížit kvantováním obrazu do méně úrovní. Přesto je kookurenční matice příliš hrubou reprezentací textury, proto jsou z ní dále počítány různé příznaky. Následují nejčastěji používané definice různých příznaků:

$$\text{kontrast} = \sum_{i,j} |i - j|^2 p(i, j), \quad (36)$$

$$\text{korelace} = \sum_{i,j} \frac{(i - \mu_i)(j - \mu_j)p(i, j)}{\sigma_i \sigma_j}, \quad (37)$$

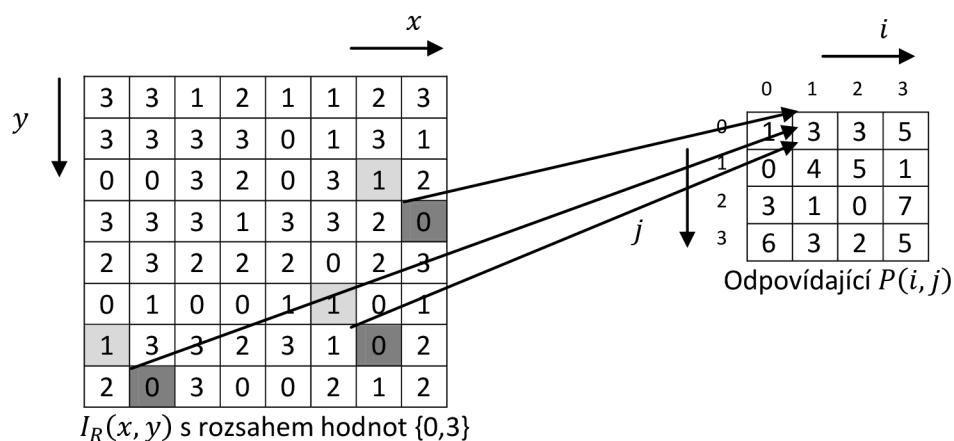
$$\text{energie} = \sum_{i,j} p(i, j)^2, \quad (38)$$

$$\text{korelace} = \sum_{i,j} \frac{p(i, j)}{1 + |i - j|}, \quad (39)$$

kde rozsah  $i$  a  $j$  je dán počtem jasových úrovní,  $\mu_i, \mu_j$  jsou marginální střední hodnoty rozložení  $p(i, j)$ ,  $\sigma_i$  a  $\sigma_j$  jsou marginální směrodatné odchylky rozložení  $p(i, j)$ . Pomocí kookurenční matice lze tedy pro lokální oblast  $I_R(x, y)$  spočítat celkem čtyři lokální jednočíselné příznaky.

Ze skupiny kookurenčních příznaků byly při provádění experimentů spočítány výše uvedené typy - homogenita, korelace, kontrast a energie. Tyto příznaky byly spočítány pro skupiny posunů  $(m, n) = \{(1,0), (1,1), (0,1), (-1,1), (-1,0), (-1,-1), (0,-1), (1,-1)\}$  a  $(m, n) = \{(5,0), (5,5), (0,5), (-5,5), (-5,0), (-5,-5)\}$ .

(0,-5), (5,-5)}. Tyto posuny byly zvoleny za účelem získání informace o vzájemných konfiguracích dvojic intenzit jak pro malý, tak i větší posun. Zároveň se také jedná o posuny v různých směrech. Z každé osmice posunů pak byla u každého typu příznaku vybrána vždy jeho nejvyšší hodnota. Cílem výběru nejvyšší hodnoty z posunů v různých směrech je dosažení podobných hodnot příznaků v případě analýzy jednoho typu různě natočené textury. Při výpočtu příznaků byla použita trojice velikostí analyzované lokální oblasti  $I_R(x, y)$ , konkrétně velikost 15, 30 a 60 pixelů. Celkem tedy byly získány čtyři typy příznaků pro dvě velikosti posunů a tři velikosti analyzované lokální oblasti, tj. 24 hodnot.



Obr. 34: Příklad sestavení kookurenční matice pro posun (1, 1) se zvýrazněným vznikem prvku  $(i, j) = (1, 0)$ , tedy jeho trojnásobného výskytu

### 7.2.1.2. Příznaky založené na říditelných filtrech

Tento typ příznaků je vhodný pro zpracování snímků sedimentárních zrn, protože tyto obrazy obsahují velké množství hran a zlomů, které lze pomocí říditelných filtrů efektivně zachytit. Konvoluční jádro říditelných filtrů je tvořeno derivací dvojrozměrné Gaussovy funkce, přičemž směr derivace lze parametricky měnit (tento typ filtrů byl již popsán v kapitole 5.1, viz obrázek 12). Oproti klasickému Sobelovu filtru pro detekci hran je u říditelných filtrů uvažováno okolí větší než  $3 \times 3$  pixely, takže zde dochází k většímu potlačení šumových složek v obraze. Hodnota lokálního příznaku je pak určena odezvou říditelného filtru na oblast  $I_R(x, y)$ .

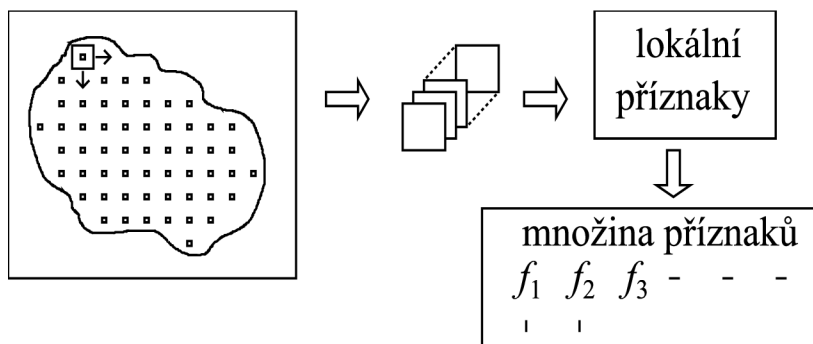
Ze skupiny příznaků založených na říditelných filtrech bylo spočítáno vždy celkem 8 odezev pro různá natočení říditelného filtru (krok rotace  $45^\circ$ ), viz obrázek 12, a z těchto odezev byla vždy vybrána maximální hodnota. Cílem výběru nejvyšší hodnoty odezvy pro různá natočení filtrů je dosažení podobných hodnot příznaků v případě analýzy jednoho typu různě natočené textury. Při výpočtu příznaků byla taktéž použita trojice velikostí analyzované lokální oblasti  $I_R(x, y)$ , konkrétně velikost 15, 31 a 61 pixelů. Celkem tedy byly získány příznaky pro tři velikosti analyzované lokální oblasti, tj. 3 hodnoty.

Při použití příznaků založených na kookurenční matici a říditelných filtrech byl pro jednu pozici v obraze pak vždy určen lokální příznakový vektor o délce  $24+3=27$ .



## 7.2.2. Sestavení texton slovníku

Pro sestavení texton slovníku je použita trénovací sada sestavená z databáze popsané v kapitole 4, která slouží k vytvoření modelu, viz obrázky 31, 32. Vytvoření trénovací sady je blíže specifikováno v kapitole 7.3. Trénovací sada obsahuje několik tříd geomorfologických genezí, přičemž vzorek každé třídy obsahuje přibližně stejný počet obrazů jednotlivě nasnímaných sedimentárních zrn. Z každého zrna jsou extrahovány lokální příznakové vektory z různých oblastí obrazu zachycujícího povrch zrna, konkrétně pozice lokálních příznakových vektorů tvořily čtvercový rastr, kde vzájemná vzdálenost mezi pozicemi byla 4 pixely, viz obrázek 35. Rozlišení obrazů bylo ponecháno původní, tedy 1280x960 pixelů. Z jednoho zrna tedy bylo získáno 20000-35000 příznakových vektorů. Skupiny příznakových vektorů náležející zrnům ze stejné geneze byly shromážděny do jedné množiny. Na každou takovou množinu reprezentující jednu geomorfologickou genezi pak bylo aplikováno klustrování  $K$ -means.



Obr. 35: Získání lokálních příznakových vektorů

Klastrovací metoda  $K$ -means [57] umožňuje sdružovat do klastrů množinu  $D$ -rozměrných příznakových vektorů  $\{\mathbf{x}_s\}$ , kde  $s = 1, \dots, S$ .  $S$  tedy představuje počet vektorů v množině. Metoda spočívá v určení množiny středových vektorů  $\{\boldsymbol{\mu}_k\}$ , kde  $k = 1, \dots, K$ . Potom středový vektor  $\boldsymbol{\mu}_k$  určuje  $k$ -tý klaster. Vektor  $x_n$  je pak přiřazen ke klasteru, jehož středový vektor  $\boldsymbol{\mu}_k$  je mu nejbližší. Pro určení vzdálenosti mezi vzorky a středovými body je obvykle používána euklidovská metrika, tedy  $\|\mathbf{x}_s - \boldsymbol{\mu}_k\|$ . Určení optimálních středových bodů  $\{\boldsymbol{\mu}_k\}$  je založeno na minimalizaci kritéria

$$J = \sum_{s,k} r_{sk} \|\mathbf{x}_s - \boldsymbol{\mu}_k\|^2, \quad (40)$$

kde  $r_{sk} = 1$ , pokud je vektor  $\mathbf{x}_s$  přiřazen ke  $k$ -tému klasteru, v opačném případě  $r_{sk} = 0$ . Kritérium  $J$  tedy představuje součet čtverců vzdáleností mezi vzorky  $\mathbf{x}_s$  a jim odpovídajícími klastery se středovým vektorem  $\boldsymbol{\mu}_k$ . Minimalizace  $J$  spočívá v nalezení optimálních  $\{r_{sk}\}$  a  $\{\boldsymbol{\mu}_k\}$ . Toho je docíleno pomocí iterativní optimalizační procedury, kdy se každá iterace skládá ze dvou kroků. V prvním kroku je optimalizace prováděna vzhledem k  $\{r_{sk}\}$ , což představuje přiřazení vektorů  $\mathbf{x}_s$  k jim nejbližším středovým vektorům  $\boldsymbol{\mu}_k$ . V druhém kroku dochází k aktualizaci  $\{\boldsymbol{\mu}_k\}$ , jednotlivé hodnoty středových vektorů  $\boldsymbol{\mu}_k$  jsou spočítány jako průměr z jim přiřazených vzorků. Optimalizační procedura je prováděna, dokud nedojde ke konvergenci kritéria  $J$ , tj. pokles jeho hodnoty je již s dalšími iteracemi nevýznamný. Na začátku optimalizace je třeba inicializovat středové body  $\{\boldsymbol{\mu}_k\}$ , obvykle jim


bývají přiřazeny náhodné hodnoty. Optimalizační procedura nezaručuje dosažení globálního optima, proto lze použít způsob, kdy je opakovaně provedena optimalizační procedura pro různé inicializace středových bodů. Jako výsledek je pak použit případ s nejnižší dosaženou hodnotou  $J$ .

Pomocí  $K$ -means klastrování je každý lokální příznakový vektor ze skupiny náležící dané třídě geneze přiřazen k jednomu z  $K$  klastrů. Vizualizace přiřazení příznakových vektorů odpovídajících různým klastrům je vidět na obrázku 36. Jak vyplývá z předchozího popisu, každý klaster je reprezentován středovým vektorem  $\mu_k$ .  $K$ -means procedura je aplikována na skupiny příznakových vektorů všech tříd a získaných  $K$  klastrů od každé třídy je pak sjednoceno, čímž vznikne  $K \cdot G$  klastrů, kde  $G$  představuje počet tříd genezí. Toto sjednocení tvoří již zmiňovaný texton slovník. Pro experimenty byl použit počet klastrů na třídu  $K = 20$ , a jelikož byl počet rozlišovaných geomorfologických tříd  $G = 4$ , byl počet tříd lokální textury obsažených v texton slovníku  $K \cdot G = 80$ .

### 7.2.3. Vytvoření modelu geomorfologické geneze

Pro vytvoření modelu byla použita stejná trénovací sada, která byla použita pro vytvoření texton slovníku, procedura je vidět na obrázku 32. Stejně jako u sestavování texton slovníku jsou z jednotlivých zrn extrahovány lokální příznakové vektory, přičemž každý z nich je pak přiřazen jednomu z  $K \cdot G$  klastrů texton slovníku na základě nejmenší euklidovské vzdálenosti.

Každý obraz zrna lze pak reprezentovat  $K \cdot G$  prvkovým histogramem vyjadřujícím zastoupení jednotlivých klastrů z texton slovníku v daném zrně, tj. zastoupení tříd lokální textury, viz obrázek 36. Vzorek  $H$  trénovacích zrn určité geneze je tvořen množinou  $H$  histogramů o  $K \cdot G$  prvcích. Tato množina pak reprezentuje model dané geomorfologické geneze.



Obr. 36: Reprezentace obrazu histogramem

### 7.2.4. Klasifikace geneze neznámého vzorku metodou k-NN

Při klasifikaci neznámého vzorku zrn (viz obrázek 33) jsou z obrazů jednotlivých zrn spočítány histogramy, jak bylo popsáno v části 7.2.3. Klasifikace jednotlivých zrn do genezí pak probíhá metodou  $k$ -NN, tedy  $k$  nejbližších sousedů.

U metody  $k$ -NN [57] je model tvořen vlastní trénovací množinou příznakových vektorů - v případě modelování geomorfologických genezí je model geneze tvořen množinou histogramů o  $K \cdot G$  prvcích. Klasifikace nového příznakového vektoru (histogramu)  $x$  je pak provedena tak, že je v příznakovém

prostoru nalezeno  $k$  nejbližších vektorů z trénovací množiny k aktuálnímu vektoru  $\mathbf{x}$ . Jako míra vzdálenosti je zde použita  $\chi^2$  vzdálenost definovaná jako

$$\chi^2 = \sum_{i=0}^{K.G} \frac{(m_i - x_i)^2}{(m_i + x_i)}, \quad (41)$$

kde  $m_i$  a  $x_i$  jsou prvky porovnávaných příznakových vektorů (histogramů). Tato metrika se často používá pro porovnávání histogramů pro lepší zachycení podobnosti jejich tvarů [56]. Vektor  $\mathbf{x}$  je pak klasifikován do třídy, která se s nejvyšší četností vyskytuje mezi  $k$  nalezenými nejbližšími vektory.

Důvodem použití  $k$ -NN je předpoklad, že vzorek zrn určité třídy geomorfologické geneze, který bude použit k vytvoření modelu, může obsahovat i zrna, která svými vlastnostmi nebudou typickými představiteli dané třídy. Předpokládá se však, že tato zrna budou v minoritě a ve vzorku budou převažovat zrna s typickými charakteristikami dané třídy. Na rozdíl od jiných klasifikačních metod (např. logistická regrese, SVM) je model u  $k$ -NN tvořen přímo trénovací databází a není zde tedy prováděna procedura trénování sloužící k vytvoření generalizujícího modelu, který by mohl být zkrácen zrn, která nejsou pro danou třídu typická.

Je-li pak klasifikován vzorek zrn neznámé třídy geneze, předpokládá se, že při porovnávání s trénovací databází bude největší část zrn ve vzorku klasifikována na základě podobnosti do správné třídy a na základě této největší části pak bude celý vzorek klasifikován do správné geneze. Pro experimenty byl při klasifikaci použit parametr  $k = 5$ .

### 7.3. Experimentální výsledky

Pro vyhodnocení navrženého postupu rozlišování mezi různými geomorfologickými genezemi byly provedeny experimenty nad databází uvedenou v kapitole 4. Konkrétně byla pro vyhodnocení použita  $L$ -průběhová křížová validace.

Křížová validace slouží k vyhodnocení úspěšnosti určité klasifikační procedury, především v případě, kdy je k dispozici omezený vzorek dat, na základě kterého jsou sestavovány klasifikační modely [58]. Princip spočívá v rozdělení dostupné množiny dat náhodně na  $L$  stejných částí, přičemž  $L-1$  částí je použito pro sestavení modelu (trénovací část) a zbývající část je použita pro vyhodnocení modelu (validační část). Procedura sestavení a vyhodnocení modelu je celkem  $L$  krát zopakována, přičemž v každém průběhu křížové validace je vždy použita jiná část pro validaci. Tímto způsobem se celkem  $L$  krát vyhodnotí úspěšnost klasifikace a jako výsledná hodnota je použit průměr. Podle [59] se dále doporučuje celý proces křížové validace několikrát zopakovat, jelikož často vyhodnocení klasifikace v jednotlivých průchodech validace může nabývat dosti variabilních hodnot. Několikerým zopakováním křížové validace, přičemž rozdělení na  $L$  částí je s každým opakováním jiné (z důvodu náhodného rozdělení), je získán vyšší počet vyhodnocení úspěšnosti klasifikační procedury, což má z hlediska statistiky i vyšší vypovídající hodnotu. Tento přístup byl tedy aplikován i v tomto experimentu.

V použité databázi (viz kapitola 4) jsou pro různé třídy k dispozici různé počty obrazů sedimentárních zrn. Aby nebylo vyhodnocení zkráceno nevyváženou reprezentací jednotlivých geomorfologických tříd, byl počet obrazů vstupující do křížové validace u každé třídy omezen na hodnotu 84, tj. počet nejméně obsáhlé třídy geneze (eolická). Omezení na tento počet proběhlo pomocí náhodného výběru. Jak bylo však zmíněno, proces křížové validace byl několikrát opakován, a proto je výsledné zhodnocení platné pro celou databázi (jelikož při každém opakování byla

podmnožina 84 obrazů náhodně vybrána – postupně tedy byla s velkou pravděpodobností využita celá databáze, případně její naprostá většina).

Jak již bylo uvedeno, z principu určování genezí při exoskopické analýze se předpokládá, že některá zrna ve vzorku dané geneze mohou mít podobné charakteristiky jako zrna jiné geneze. Přesto se předpokládá, že daný vzorek bude obsahovat větší počet zrn s charakteristikami, na jejichž základě bude možné daný vzorek přiřadit k určité genezi a odlišit tak od vzorků jiných genezí. Z tohoto důvodu je použit poměrně jednoduchý klasifikátor  $k$ -NN, kdy klasifikace neznámého zrna proběhne na základě nalezení jemu nejpodobnějších zrn majících informaci o genezi.

V experimentu je vyhodnocení úspěšnosti klasifikace do tříd geomorfologických genezí provedeno na úrovni: A) jednotlivých zrn ve vzorku a B) celého vzorku.

U neznámého vzorku je tedy za účelem jeho klasifikace provedena následující procedura (v prováděných experimentech je neznámý vzorek představován validační částí dat použitých při křížové validaci):

1) Pomocí  $k$ -NN klasifikátoru je provedena klasifikace všech jednotlivých zrn obsažených v neznámém vzorku, tj. pro každé zrno ve vzorku je určena jeho geneze - odpovídá klasifikaci na úrovni A.

2) Na základě klasifikace jednotlivých zrn v neznámém vzorku je určena nejčetnější ve vzorku vyskytující se geneze. Na základě této nejčetnější geneze je pak stanovena geneze celého neznámého vzorku - odpovídá klasifikaci na úrovni B.

Z důvodu klasifikace na úrovni B, tj. klasifikace celého vzorku na základě nejvíce se vyskytující geneze ve vzorku, byl stanoven parametr křížové validace  $L = 4$ , tj. každá část dat použitých pro vyhodnocení obsahuje 21 zrn. Určování nejčetnější geneze tak probíhá z poměrně velkého vzorku. Jak bylo uvedeno, celý proces křížové validace se doporučuje zopakovat, proto byla křížová validace provedena pro celkem  $O = 30$  opakování.

Experiment a následné vyhodnocení pak probíhaly následovně:

- Křížová validace byla provedena celkem  $O$ -krát.
  1. Pro dané opakování  $o$  křížové validace ( $o = 1, 2, \dots, O$ ) byla od každé geneze vybrána skupina 84 zrn.
  2. Pro každou genezi byla vybraná skupina zrn náhodně rozdělena do  $L = 4$  částí o 21 zrnech. Každá část je pak považována za vzorek dané geneze.
  3. V celkem  $L = 4$  iteracích byl z každé geneze použit jeden vzorek jako validační část a zbývající vzorky jako trénovací část, viz obrázek 37.
    - V rámci  $l$ -té iterace je tedy na základě 12 vzorků (3 vzorky od každé geneze - na obrázku 37 znázorněno písmenem T) vytvořen dle popisu v kapitole 7.2.3 model. Zbývající 4 vzorky (1 vzorek od každé geneze - na obrázku 37 znázorněno písmenem V) byly pak pomocí vytvořeného modelu klasifikovány, tj. nejprve byla pomocí modelu klasifikována jednotlivá zrna ve vzorku (klasifikace na úrovni A), poté byl celý vzorek klasifikován na základě nejčetnější, v něm vyskytující se geneze (klasifikace na úrovni B).
    - Výsledky klasifikace byly zaznamenány do kontingenční tabulky, jejíž šablony jsou v tabulkách 16 a 17, ve kterých vertikální pozice značí skutečnou genezi a horizontální pozice genezi určenou klasifikací. Jednotlivá pole tabulek pak značí normalizované výsledky klasifikace obdržené pro různé kombinace skutečné/určené geneze. Způsob normalizace je popsán vztahy uvedenými níže v textu. Vyhodnocení

tabulky může být provedeno buď v kontextu senzitivity, nebo pozitivní prediktivní hodnoty.

- Vyhodnocení v kontextu senzitivity spočívá v porovnání počtů správně a špatně klasifikovaných A) zrn resp. B) vzorků stejné třídy  $x$ . Je-li klasifikovaná geneze  $x$  a skutečná geneze také  $x$ , pak je počet takových klasifikací v  $l$ -té iteraci při  $o$ -tém opakování označen jako  $TP_x^{o,l}$  (správně pozitivní). Je-li klasifikovaná geneze  $y$ , ale skutečná geneze  $x$ , pak je počet označen jako  $FN_{x/y}^{o,l}$  (falešně negativní).
- Vyhodnocení v kontextu pozitivní prediktivní hodnoty spočívá ve vyhodnocení, jaká část ze A) zrn nebo B) vzorků klasifikovaných do určité třídy  $x$  skutečně do této třídy náleží. Je-li klasifikovaná geneze  $x$  a skutečná geneze také  $x$ , pak je počet takových klasifikací v  $l$ -té iteraci při  $o$ -tém opakování označen jako  $TP_x^{o,l}$  (správně pozitivní). Je-li klasifikovaná geneze  $x$ , ale skutečná geneze je  $y$ , pak je počet takových klasifikací označen jako  $FP_{y/x}^{o,l}$  (falešně pozitivní).

4. Pro dané opakování  $o$  jsou po každé křížové validaci spočítány souhrnné počty klasifikací v kontextu senzitivity jako

$$TP_x^o = \sum_{l=1}^L TP_x^{o,l}, \quad (42)$$

$$FN_{x/y}^o = \sum_{l=1}^L FN_{x/y}^{o,l} \quad (43)$$

a

$$M_x^o = TP_x^o + \sum_{i \neq x} FN_{x/i}^o \quad (44)$$

a v kontextu pozitivní prediktivní hodnoty jako

$$TP_x^o = \sum_{l=1}^L TP_x^{o,l}, \quad (45)$$

$$FP_{x/y}^o = \sum_{l=1}^L FP_{x/y}^{o,l} \quad (46)$$

a

$$N_x^o = TP_x^o + \sum_{i \neq x} FP_{i/x}^o. \quad (47)$$

Hodnoty  $M_x^o$  resp.  $N_x^o$  slouží k normalizaci hodnot (42)(43) resp. (45)(46) pro získání procentuálního vyjádření v kontextu senzitivity resp. pozitivní prediktivní hodnoty.

Senzitivitu pro konkrétní třídu  $x$  (tj. kolik procent zrn nebo vzorků stejné třídy  $x$  je správně klasifikovaných) lze spočítat jako

$$\text{senzitivita}^o = \frac{TP_x^o}{M_x^o}. \quad (48)$$

Pozitivní prediktivní hodnotu pro konkrétní třídu  $x$  (tj. kolik procent ze zrn nebo vzorků klasifikovaných do třídy  $x$  skutečně do této třídy náleží) lze spočítat jako

$$pph^o = \frac{TP_x^o}{N_x^o}. \quad (49)$$

Celkovou přesnost klasifikace přes množinu všech genezí  $X = \{x_1, x_2, \dots, x_G\}$  lze spočítat jako

$$\text{přesnost}^o = \sum_{x \in X} TP_x^o / \sum_{x \in X} M_x^o. \quad (50)$$

- Po provedení všech opakování byly výsledky jednotlivých křížových validací zprůměrovány a zaznamenány do kontingenčních tabulek. Jednotlivé procentuální hodnoty kontingenční tabulky lze pro kontext senzitivity spočítat dle vztahu

$$f_s(x, y) = \begin{cases} \frac{1}{O} \sum_{o=1}^O \frac{TP_x^o}{M_x^o} & \text{pro } x = y \\ \frac{1}{O} \sum_{o=1}^O \frac{FN_{x/y}^o}{M_x^o} & \text{pro } x \neq y \end{cases} \quad (51)$$

a pro kontext pozitivní prediktivní hodnoty dle vztahu

$$f_p(x, y) = \begin{cases} \frac{1}{O} \sum_{o=1}^O \frac{TP_x^o}{N_x^o} & \text{pro } x = y \\ \frac{1}{O} \sum_{o=1}^O \frac{FP_{x/y}^o}{N_x^o} & \text{pro } x \neq y \end{cases}. \quad (52)$$

Použití těchto vztahů při sestavování kontingenční tabulky je pak vidět v tabulce 16 pro kontext senzitivity a v tabulce 17 pro kontext pozitivní prediktivní hodnoty. Hodnoty v hlavní diagonále tabulky 16 a 17 (vyznačeno šedě) pak určují senzitivitu resp. pozitivní prediktivní hodnotu pro konkrétní třídu danou podle vztahu (48) a (49). Výpočet celkové přesnosti udává vztah (53).

	eol.	glac.	svah.	vulk.	iterace 1. 2. 3. 4.
1. část					<b>V</b> T T T
2. část					T <b>V</b> T T
3. část					T T <b>V</b> T
4. část					T T T <b>V</b>

Obr. 37: Schéma křížové validace použité v experimentu

Tab. 16: Šablona kontingenční tabulky v kontextu senzitivity (celkové výsledky pro všechna opakování a iterace křížové validace)

		Geneze určená klasifikací			
		Eolický	Glaciální	Svahový	Vulkanický
Skutečná geneze	Eolický	$f_s(\text{eol.}, \text{eol.})$	$f_s(\text{eol.}, \text{glac.})$	$f_s(\text{eol.}, \text{svah.})$	$f_s(\text{eol.}, \text{vulk.})$
	Glaciální	$f_s(\text{glac.}, \text{eol.})$	$f_s(\text{glac.}, \text{glac.})$	$f_s(\text{glac.}, \text{svah.})$	$f_s(\text{glac.}, \text{vulk.})$
	Svahový	$f_s(\text{svah.}, \text{eol.})$	$f_s(\text{svah.}, \text{glac.})$	$f_s(\text{svah.}, \text{svah.})$	$f_s(\text{svah.}, \text{vulk.})$
	Vulkanický	$f_s(\text{vulk.}, \text{eol.})$	$f_s(\text{vulk.}, \text{glac.})$	$f_s(\text{vulk.}, \text{svah.})$	$f_s(\text{vulk.}, \text{vulk.})$

Tab. 17: Šablona kontingenční tabulky v kontextu pozitivní prediktivní hodnoty (celkové výsledky pro všechna opakování a iterace křížové validace)

		Geneze určená klasifikací			
		Eolický	Glaciální	Svahový	Vulkanický
Skutečná geneze	Eolický	$f_p(\text{eol.}, \text{eol.})$	$f_p(\text{eol.}, \text{glac.})$	$f_p(\text{eol.}, \text{svah.})$	$f_p(\text{eol.}, \text{vulk.})$
	Glaciální	$f_p(\text{glac.}, \text{eol.})$	$f_p(\text{glac.}, \text{glac.})$	$f_p(\text{glac.}, \text{svah.})$	$f_p(\text{glac.}, \text{vulk.})$
	Svahový	$f_p(\text{svah.}, \text{eol.})$	$f_p(\text{svah.}, \text{glac.})$	$f_p(\text{svah.}, \text{svah.})$	$f_p(\text{svah.}, \text{vulk.})$
	Vulkanický	$f_p(\text{vulk.}, \text{eol.})$	$f_p(\text{vulk.}, \text{glac.})$	$f_p(\text{vulk.}, \text{svah.})$	$f_p(\text{vulk.}, \text{vulk.})$

$$\text{přesnost} = \frac{1}{O} \sum_{o=1}^O \frac{TP_{\text{eol.}}^o + TP_{\text{glac.}}^o + TP_{\text{svah.}}^o + TP_{\text{vulk.}}^o}{M_{\text{eol.}}^o + M_{\text{glac.}}^o + M_{\text{svah.}}^o + M_{\text{vulk.}}^o} \quad (53)$$

### 7.3.1. Výsledky určování tříd genezí

Výsledky křížové validace, které byly získány na základě výše popsané procedury, jsou v kontextu senzitivity pro klasifikaci na úrovni zrn a pro klasifikaci na úrovni celého vzorku znázorněny v tabulce 18 resp. v tabulce 19 formou kontingenční tabulky. Podobně v kontextu pozitivní prediktivní hodnoty pak v tabulce 20 resp. tabulce 21.

Tab. 18 Průměrné výsledky klasifikace na úrovni jednotlivých zrn v kontextu senzitivity

		Geneze určená klasifikací			
		Eolický	Glaciální	Svahový	Vulkanický
Skutečná geneze	Eolický	68,8 %	8,9 %	16,8 %	5,5 %
	Glaciální	8,3 %	42,9 %	18,9 %	30,0 %
	Svahový	17,7 %	23,6 %	44,2 %	14,5 %
	Vulkanický	8,6 %	35,9 %	18,4 %	37,1 %

Tab. 19: Průměrné výsledky klasifikace na úrovni celých vzorků v kontextu senzitivity

		Geneze určená klasifikací			
		Eolický	Glaciální	Svahový	Vulkanický
Skutečná geneze	Eolický	100,0 %	0,0 %	0,0 %	0,0 %
	Glaciální	0,0 %	77,5 %	3,3 %	19,2 %
	Svahový	6,7 %	13,3 %	80,0 %	0,0 %
	Vulkanický	0,0 %	50,0 %	3,3 %	46,7 %

Tab. 20: Průměrné výsledky klasifikace na úrovni jednotlivých zrn v kontextu pozitivní prediktivní hodnoty

		Geneze určená klasifikací			
		Eolický	Glaciální	Svahový	Vulkanický
Skutečná geneze	Eolický	66,7 %	8,0 %	17,1 %	6,3 %
	Glaciální	7,9 %	38,5 %	19,3 %	34,4 %
	Svahový	17,1 %	21,3 %	45,0 %	16,6 %
	Vulkanický	8,2 %	32,2 %	18,6 %	42,6 %

Tab. 21: Průměrné výsledky klasifikace na úrovni celých vzorků v kontextu pozitivní prediktivní hodnoty

		Geneze určená klasifikací			
		Eolický	Glaciální.	Svahový	Vulkanický
Skutečná geneze	Eolický	95,2 %	0,0 %	0,0 %	0,0 %
	Glaciální	0,0 %	56,4 %	3,7 %	28,6 %
	Svahový	4,8 %	9,9 %	93,0 %	0,0 %
	Vulkanický	0,0 %	33,7 %	3,3 %	71,4 %

Z tabulek 18 až 21 je možné usuzovat, že klasifikace na základě povrchových vlastností zrn poskytuje vyšší schopnost separovat od sebe různé typy geomorfologické geneze než u porovnávání založeného pouze na základě tvaru 2D kontury zrna z kapitoly 6. Je-li uvažována klasifikace na úrovni jednotlivých zrn (tabulka 18 a 20) v kontextu senzitivity i pozitivní prediktivní hodnoty, je úspěšnost klasifikace poměrně nízká. Avšak je třeba vzít v úvahu již zmiňovaný předpoklad, že se očekává, že ne všechna zrna ve vzorku musí mít typické vlastnosti dané geneze.

Máme-li k dispozici vzorek o určitém počtu zrn, je třeba vyhodnotit, kolik procent z nich je klasifikováno do správné třídy. Nejdříve tedy bylo provedeno vyhodnocení v kontextu senzitivity (kolik procent ze skutečné třídy  $x$ , je jako třída  $x$  klasifikováno). Jak je vidět z tabulky 18, nejvyšší senzitivity je dosaženo u eolických zrn, celkem 68,8 %. Oproti ostatním genezím je zde tedy dosaženo nejvyšší úspěšnosti, což koresponduje i s nejlepší separovatelností eolické geneze na základě hodnoty zaoblenosti z kapitoly 6. U glaciální a svahové geneze pak senzitivita nabývá hodnot 42,9 % resp. 44,2 %. Naproti tomu u vulkanické geneze je úspěšnosti nižší: 37,1 %. V odpovídajících řádcích kontingenční tabulky jsou však vždy příslušné geneze klasifikovány s významně vyšší četností, což se pak projevuje u klasifikace na úrovni celých vzorků. U vulkanické geneze je nejnižší úspěšnost dána zejména faktem, že je jako vulkanická nesprávně klasifikována velká část glaciálních zrn. Celková přesnost klasifikace dle vztahu (53) je 48,2 %.

Lze konstatovat, že u klasifikace na úrovni zrn je úspěšnost stále poměrně nízká, na druhou stranu, jedná-li se o klasifikaci do 4 tříd, je tato senzitivita (přibližně 69 %, 43 %, 44 % a 37 %) stále výrazně vyšší než senzitivita 25 %, což je hodnota, které by bylo dosaženo náhodnou klasifikací, byla-li by pravděpodobnost výběru jednotlivých tříd rovnoměrná. Dále je významným faktorem ovlivňujícím výsledky fakt, že kromě nepřesnosti klasifikátoru se zde projevuje také výskyt netypických vlastností v rámci jednoho vzorku dané geneze, což může mít právě za následek klasifikaci určitého zrna do jiné geneze než té, již odpovídají procesy, které podle předpokladu místa odběru vzorku dané zrno geologicky utvářely. Z tohoto důvodu byla klasifikace prováděna také na úrovni celého vzorku na základě nejčastěji klasifikované geneze. Tyto výsledky jsou ve smyslu senzitivity uvedeny v tabulce 19. Jak je zde vidět, při klasifikaci na úrovni celých vzorků je u eolické geneze dosaženo 100% senzitivity. U glaciální a svahové geneze byla senzitivita 77,5 % resp. 80 %. Nejnižší senzitivity je



opět dosaženo u vulkanické geneze: 46,7 %. Celková přesnost klasifikace dle vztahu (53) je 76,0 %. Klasifikace na úrovni vzorků (souborů mnoha jednotlivých zrn), tedy tak, jak je prováděna v současné praxi exoskopické analýzy, je výrazně úspěšnější.

V kontextu pozitivní prediktivní hodnoty (tedy kolik procent z klasifikací do třídy  $x$  patří skutečně do třídy  $x$ ) lze vidět u klasifikace na úrovni jednotlivých zrn (tabulka 20) podobné procentuální rozložení, jaké bylo vidět u senzitivity. Na úrovni klasifikace celých vzorků (tabulka 21) je nejnižší pozitivní prediktivní hodnoty dosaženo u glaciální geneze, konkrétně 56,4 %, tj. největší poměr klasifikací (43,6 %) do této třídy byl vyhodnocen jako nesprávný. Z tabulky lze vidět, že klasifikátor zaměňoval nejvíce vulkanickou genezi s glaciální a naopak.

### 7.3.2. Srovnání s metodou analýzy povrchu zrn dle Newella

Výsledky experimentu při použití navržené analýzy povrchu zrn s použitím texton slovníku byly srovnány s výsledky analýzy povrchu zrn s použitím BIF příznaků (metoda dle Newella - pro popis viz kapitola 2.3.2). Metoda s použitím BIF příznaků [50] byla v původní práci použita pouze pro rozpoznání přítomnosti štěpných plátků v analyzovaném obraze (lokální obdélníkové oblasti zachycující část povrchu zrna). Textura popsána pomocí BIF je však podobně jako u metody využívající textonů reprezentována histogramy vyjadřujícími zastoupení jednotlivých typů BIF. Určení typu BIF určité lokální oblasti zde odpovídá určení třídy lokální textury. Tento typ popisu textury lze tedy použít pro charakteristiku povrchu celých zrn, a proto lze danou metodu aplikovat i v experimentu rozlišování geomorfologických genezí. Princip původní metody s použitím BIF příznaků byl popsán v kapitole 2.3.2. Hlavní rozdíl oproti novému přístupu využívajícímu texton slovníku (viz kapitola 7.2) spočívá v pevně daném způsobu určování BIF příznaků, tedy klasifikace lokálních oblastí do tříd lokální textury. Naproti tomu u nové metody je klasifikace lokální textury založená na texton slovníku, který je vytvořen až na základě dostupné trénovací sady textur. Takto vytvořené prototypy textur jsou schopny lépe zachytit povahu textur vyskytujících se v dané úloze.

Implementace metody s použitím BIF příznaků zahrnovala klasifikaci tříd lokální textury na základě odezvy filtrů z obrázku 10, které byly popsány v kapitole 2.3.2. Množina vztahů, ze kterých jsou BIF příznaky určovány, je uvedena v (13). Určení BIF příznaku (tedy určení třídy lokální textury) proběhlo na základě volby největšího členu z množiny  $\{2\sigma\sqrt{c_{10}^2 + c_{01}^2} + \lambda, -\lambda, 2^{-\frac{1}{2}}(\gamma + \lambda), 2^{-\frac{1}{2}}(\gamma - \lambda), \gamma\}$ . Příznak  $\varepsilon_{c_{00}}$ , uvedený v (13), nebyl na základě analýzy v [50] používán. BIF příznak tedy může nabývat celkem 6 různých hodnot (6 tříd lokální textury). Jak bylo uvedeno v kapitole 2.3.2, analýza textury má být provedena pro 4 rozlišení. Toto bylo v experimentu zohledněno určováním lokální textury z lokálních oblastí o velikostech 9, 17, 33 a 65 pixelů. Obraz zrna je pak popsán histogramem o velikosti 24 prvků (6 typů lokální textury určené z lokálních oblastí o 4 různých velikostech). Podobně jako v kapitole 7.2.3 je tedy obraz zrna také reprezentován histogramem. Další postup experimentu byl již shodný s postupem uvedeným v 7.2.3, tj. z množiny trénovacích zrn (množina histogramů) je sestaven model určité geomorfologické geneze. Na základě popisu v kapitole 7.2.4 pak probíhá klasifikace neznámého vzorku.

Při klasifikaci na úrovni celých vzorků v kontextu senzitivity (viz tabulka 22) je eolická geneze opět velmi dobře separovatelná od ostatních genezí. U ostatních genezí je však vidět, že metoda s použitím BIF příznaků dosahuje nižší senzitivity než nová metoda využívající texton slovníku, konkrétně je nižší úspěšnost klasifikace patrná ze srovnání v tabulce 24. Podobný závěr vyplývá i z výsledků klasifikace na úrovni celých vzorků v kontextu pozitivní prediktivní hodnoty,

viz tabulka 23. I zde při srovnání s novou metodou využívající texton slovníku dosahuje metoda s použitím BIF příznaků nižší úspěšnosti klasifikace. Srovnání pozitivních prediktivních hodnot pro jednotlivé geomorfologické geneze je uvedeno v tabulce 24. Celková přesnost klasifikace dle vztahu (53) pro metodu s použitím BIF příznaků na úrovni celých vzorků je 66,7 %, což potvrzuje její nižší úspěšnost ve srovnání s celkovou přesností 76,0 % u metody využívající texton slovníku.

Z výsledků na dostupné databázi je zřejmé, že navržená metoda využívající texton slovníku popsaná v kapitolách 7.1 a 7.2 dosahuje vyšší úspěšnosti klasifikace geomorfologických genezí na základě texturních vlastností. Díky propracovanější metodě klasifikace lokální textury s využitím texton slovníku, který je získán jako výsledek klastrování příznakových vektorů trénovací množiny, je textura jednotlivých zrn lépe charakterizována, nežli je tomu u klasifikace lokální textury s využitím BIF příznaků dle Newella [50], kde je použito pevně dané schéma klasifikace lokální textury.

Tab. 22: Průměrné výsledky klasifikace na úrovni celých vzorků v kontextu senzitivity při použití BIF

		Geneze určená klasifikací			
		Eolický	Glaciální	Svahový	Vulkanický
Skutečná geneze	Eolický	100,0 %	0,0 %	0,0 %	0,0 %
	Glaciální	6,7 %	65,0 %	11,7 %	16,7 %
	Svahový	4,2 %	34,2 %	57,5 %	4,2 %
	Vulkanický	0,8 %	48,3 %	6,7 %	44,2 %

Tab. 23: Průměrné výsledky klasifikace na úrovni celých vzorků v kontextu pozitivní prediktivní hodnoty při použití BIF

		Geneze určená klasifikací			
		Eolický	Glaciální	Svahový	Vulkanický
Skutečná geneze	Eolický	91,8 %	0,0 %	0,0 %	0,0 %
	Glaciální	4,5 %	44,6 %	18,3 %	26,8 %
	Svahový	2,9 %	23,9 %	73,1 %	5,6 %
	Vulkanický	0,8 %	31,5 %	8,6 %	67,6 %

Tab. 24: Srovnání výsledků klasifikace na úrovni celých vzorků při použití texton slovníku a při použití BIF

		Senzitivita		PPH	
		Texton slovník	BIF	Texton slovník	BIF
Geneze	Eolický	100,0 %	100,0 %	95,2 %	91,8 %
	Glaciální	77,5 %	65,0 %	56,4 %	44,6 %
	Svahový	80,0 %	57,5 %	93,0 %	73,1 %
	Vulkanický	46,7 %	44,2 %	71,4 %	67,6 %

### 7.3.3. Vliv nepřesnosti segmentace na výsledek klasifikace

V dosud uvedených experimentech bylo rozlišování genezí založeno na pixelech obrazu, které odpovídaly oblastem zachycujícím zrno. Tyto oblasti byly určeny na základě manuálně získaných masek, viz kapitola 4. V kapitole 5 byla navržena a testována segmentační metoda pro automatickou extrakci těchto masek. Tato metoda dosahovala jisté chybovosti, která byla vyhodnocena. Určená

chybovost je považována za poměrně nízkou, navíc případ, kdy je nesprávně označena oblast pozadí jako část zrna, je méně častý než případ, kdy není zrno zcela označeno. Přesto je na místě vyhodnotit, jak velký vliv může mít tato chybovost na klasifikaci genezí vzorků sedimentárních zrn (v případě, že by při segmentaci nebyla provedena manuální korekce).

V následujícím experimentu tedy bylo opět provedeno vyhodnocení úspěšnosti klasifikace pomocí křížové validace stejným způsobem jako v kapitole 7.3.1, rozdíl byl jen v oblasti, ve které byla provedena extrakce lokálních texturních příznaků. Tyto příznaky nebyly extrahovány z oblastí daných manuálně získanou maskou, ale z oblastí daných maskami, které byly získány pomocí plně automatické segmentační metody představené v kapitole 5, kdy masky vymezovaly korektní oblast sedimentárních zrn v obraze se senzitivitou segmentace 95,6 % a s pozitivní prediktivní hodnotou segmentace 97,9 % (viz kapitola 5.7.2).

Pro plně automaticky segmentované obrazy sedimentárních zrn jsou tedy v tabulkách 25 a 26 vyhodnoceny klasifikace zrn do jednotlivých tříd genezí v kontextu senzitivity na úrovni jednotlivých zrn resp. celých vzorků, v tabulkách 27 a 28 pak také v kontextu pozitivní prediktivní hodnoty. Celková přesnost klasifikace dle vztahu (53) na úrovni celých vzorků při použití automaticky získané masky zrna je 75,4 %, což je velmi podobná hodnota jako celková přesnost klasifikace 76,0 % při použití manuálně získané masky zrna. Srovnání na úrovni celých vzorků, kdy jsou porovnány výsledky při použití manuálně a automaticky získané masky vymezující zrno, lze vidět v tabulce 29.

Tab. 25: Průměrné výsledky klasifikace na úrovni jednotlivých zrn v kontextu senzitivity při použití automatické segmentace pro vymezení plochy zrna

		Geneze určená klasifikací			
		Eolický	Glaciální	Svahový	Vulkanický
Skutečná geneze	Eolický	70,8 %	9,0 %	15,3 %	4,8 %
	Glaciální	8,5 %	42,2 %	19,0 %	30,3 %
	Svahový	17,9 %	23,8 %	43,5 %	14,8 %
	Vulkanický	10,0 %	34,3 %	17,8 %	37,9 %

Tab. 26: Průměrné výsledky klasifikace na úrovni celých vzorků v kontextu senzitivity při použití automatické segmentace pro vymezení plochy zrna

		Geneze určená klasifikací			
		Eolický	Glaciální	Svahový	Vulkanický
Skutečná geneze	Eolický	100,0 %	0,0 %	0,0 %	0,0 %
	Glaciální	0,0 %	72,5 %	3,3 %	24,2 %
	Svahový	1,7 %	19,2 %	78,3 %	0,8 %
	Vulkanický	0,8 %	45,8 %	2,5 %	50,8 %

Tab. 27: Průměrné výsledky klasifikace na úrovni jednotlivých zrn v kontextu pozitivní prediktivní hodnoty při použití automatické segmentace pro vymezení plochy zrna

		Geneze určená klasifikací			
		Eolický	Glaciální	Svahový	Vulkanický
Skutečná geneze	Eolický	66,2 %	8,3 %	16,1 %	5,5 %
	Glaciální	7,8 %	38,4 %	19,7 %	34,4 %
	Svahový	16,7 %	21,8 %	45,6 %	16,9 %
	Vulkanický	9,3 %	31,5 %	18,6 %	43,3 %

Tab. 28: Průměrné výsledky klasifikace na úrovni celých vzorků v kontextu pozitivní prediktivní hodnoty při použití automatické segmentace pro vymezení plochy zrna

		Geneze určená klasifikací			
		Eolický	Glaciální	Svahový	Vulkanický
Skutečná geneze	Eolický	98,0 %	0,0 %	0,0 %	0,0 %
	Glaciální	0,0 %	53,7 %	3,4 %	32,0 %
	Svahový	1,3 %	12,7 %	93,9 %	0,7 %
	Vulkanický	0,7 %	33,5 %	2,6 %	67,3 %

Tab. 29: Srovnání výsledků klasifikace na úrovni celých vzorků při použití manuálně a automaticky získané masky vymežující zrna

		Senzitivita		PPH	
		Man. maska	Aut. maska	Man. maska	Aut. maska
Geneze	Eolický	100,0 %	100,0 %	95,2 %	98,0 %
	Glaciální	77,5 %	72,5 %	56,4 %	53,7 %
	Svahový	80,0 %	78,3 %	93,0 %	93,9 %
	Vulkanický	46,7 %	50,8 %	71,4 %	67,3 %

Z tabulky 29 vyplývá, že při analýze obrazů zrn zatížených segmentační chybou dojde při klasifikaci pomocí texton slovníku v průměru ke zhoršení výsledků oproti zpracování přesně ručně segmentovaných dat, v případě klasifikace některých genezí je patrné i zlepšení. Celkově se však jedná vždy o změny maximálně v jednotkách procent. Největší rozdíl byl u senzitivity v případě klasifikace glaciálních zrn, konkrétně 5 %. Je tedy možné konstatovat, že úspěšnost klasifikace jednotlivých geomorfologických genezí s využitím automatické segmentační metody je velice podobná s úspěšností klasifikace s využitím přesných, manuálně získaných masek a nepřesnost navržené segmentační metody nemá zásadní vliv na přesnost navržené metody klasifikace geomorfologických genezí.

## 7.4. Diskuze experimentálních výsledků na dostupné databázi

V kapitole 7 byla představena nová metoda, pomocí které lze klasifikovat skupiny sedimentárních zrn do tříd podle geomorfologických genezí. Stejně jako u rozlišování genezí na základě hodnoty zaoblenosti z kapitoly 6 je eolická geneze nejlépe separovatelná od ostatních. Na úrovni vzorků v kontextu senzitivity byla správně klasifikována ve všech případech. V kontextu pozitivní prediktivní hodnoty pak byla malá část (4,8 %) svahových vzorků nesprávně klasifikována jako vzorky eolické.

Z hlediska přesnosti klasifikace je jako další nejlépe rozlišitelná svahová geneze. Na úrovni vzorků v kontextu senzitivity byla správně klasifikována v 80 % případů, klasifikátorem byla nejčastěji zaměňována s glaciální genezí (13,3 % případů.) V kontextu pozitivní prediktivní hodnoty pak byla malá část glaciálních a vulkanických vzorků (7,0 % celkově) nesprávně klasifikována jako vzorky svahové.

Geneze glaciální a vulkanická byly klasifikátorem nejčastěji nesprávně zaměňovány. Na úrovni vzorků v kontextu senzitivity bylo 50 % všech vzorků vulkanické geneze nesprávně klasifikováno jako geneze glaciální. Toto se pak u glaciálních zrn projevilo v kontextu pozitivní prediktivní hodnoty

nižší hodnotou 56,4 %. Lze si tedy všimnout, že klasifikátor měl v případě glaciálních a vulkanických zrn větší tendenci hodnotit zrna jako glaciální.

Ačkoliv chybovost klasifikace při využití přístupu založeného na texton slovníku není zanedbatelná, dosahuje tento přístup vyšší úspěšnosti než je tomu při použití stávajících metod pro vyhodnocování povrchových vlastností křemenných zrn založených na BIF příznacích [50].

## 8. Závěr

Tato práce se zabývala návrhem nových metod automatizované analýzy obrazu za účelem provádění exoskopické analýzy sedimentárních zrn, které byly zachyceny pomocí SEM mikroskopu. Hlavním přínosem práce je navržení metodiky pro zpracování těchto snímků. Mezi výhody této metodiky patří snížení manuální rutinní činnosti geomorfologa a rozšíření exoskopické analýzy o kvalitativně nový přístup pro rozlišení různých geomorfologických genezí. Konkrétně byla navržena segmentační metoda pro vymezení zrna v obraze, metoda pro porovnávání geomorfologických genezí na základě jednoho tvarového příznaku (zaoblenosti) a metoda pro rozlišování geomorfologických genezí na základě povrchové struktury zrn, která je analyzována pomocí nízkoúrovňových texturních příznaků.

V části zabývající se segmentací byla navržena a otestována metoda pro vymezení plochy zrna v obraze, konkrétně pro případ, že je v každém obraze zachyceno pouze jedno zrno. Z hlediska použitých hodnotících metrik, které procentuálně vyčíslují správné označení plochy zrna v obraze, dosahuje navržená segmentační metoda vysoké přesnosti, konkrétně pozitivní prediktivní hodnoty 98,5 % a senzitivity 96,1 %. Vysegmentovaná oblast zrna je díky vysoké přesnosti segmentace použitelná pro další zpracování analyzující texturu povrchu zachyceného zrna. Při analýze tvaru kontury zrna (i přes velkou přesnost vymezení plochy zrna) může z principu segmentační metody, při které je využito slučování regionů, i malá chyba v segmentaci výrazně zkreslit konturu skutečného zrna v obraze. Z tohoto důvodu je možné provést manuální korekci, u níž je podle potřeby provedeno přidání či odebrání chybějících resp. přebývajících regionů pro vytvoření přesného segmentu. Tato korekce však již nepředstavuje časově náročnou operaci.

V části zabývající se tvarovou analýzou byla použita pro porovnávání geomorfologických genezí míra zaoblenosti z důvodu její teoretické nezávislosti na úhlu pohledu při snímání analyzovaného zrna. Pro rozlišování genezí na základě jednoho příznaku (zaoblenosti) byla navržena metoda, pomocí které lze pro stanovenou přesnost vyhodnotit, zda jsou dostupné velikosti vzorků dostačující pro vzájemné odlišení tříd. Porovnání tříd je provedeno na základě střední hodnoty daného příznaku. Správnost této metody byla experimentálně ověřena. Dále bylo pomocí navržené metody vyhodnoceno, zda jsou počty obrazů zrn v dostupné databázi dostatečné pro vzájemné odlišení jednotlivých genezí. Výsledkem bylo, že pomocí automatických metod měření zaoblenosti lze odlišit pouze eolickou genuzi od ostatních.

V části rozlišování genezí na základě povrchové struktury zrn bylo navrženo klasifikační schéma, které slouží k určování genezí vzorků sedimentárních zrn. Na rozdíl od současných metod přístupu k exoskopické analýze, kdy jsou manuálně sledovány četnosti výskytu definovaných strukturních charakteristik, je zde zkoumána možnost automatického rozlišování přímo na základě nízkoúrovňových texturních příznaků. Metodika byla navržena s ohledem na předpokládanou situaci, kdy je klasifikace prováděna na úrovni vzorků obsahujících několik desítek snímků sedimentárních zrn z jedné třídy geomorfologické geneze. Nejprve jsou pomocí klasifikačního schématu určeny geneze jednotlivých zrn a výsledná geneze vzorku je určena podle nejčetněji se vyskytující geneze ve vzorku. Z experimentů vyplynulo, že analýza povrchu zrn poskytuje mnohem vyšší rozlišitelnost genezí než v případě analýzy tvaru 2D průmětu zrna. Taktéž je u navržené metody dosaženo lepších výsledků než v případě analýzy textury dle Newella, kde je využito BIF příznaků. Z hlediska klasifikace je největší rozlišitelnosti dosaženo opět u eolické geneze, poměrně dobře je také rozlišitelná geneze svahová. K chybným klasifikacím docházelo nejčastěji záměnou vulkanické geneze za glaciální.

Obecně je možné na základě experimentálních výsledků konstatovat, že nově navržená metodika pro analýzu sedimentárních zrn pomocí automatických metod zpracování obrazu je z hlediska jejího využití v geomorfologické praxi perspektivní.

## Literatura

- [1] Křížová, L., Křížek, M., Lisá, L., Applicability of Quartz Grains Surface Analysis to The Study of the Genesis of Unlithified Sediments, *Geografie*, roč. 116, č. 1, 2011, s. 59–78.
- [2] Costa, P. J. M., Andrade, C., Dawson, A.G., Mahaney, W.C., Freitas, M.C., Paris, R., Taborda, R., Microtextural Characteristics of Quartz Grains Transported and Deposited by Tsunamis and Storms, *Sedimentary Geology*, roč. 275-276, 2012, s. 55-69.
- [3] Moral Cardona, J. P., Gutiérrez Mas, J. M., Sánchez Bellón, A., Domínguez-Bella, S., Martínez López, J., Surface Textures of Heavy-mineral Grains: A New Contribution to Provenance Studies, *Sedimentary Geology*, roč. 174, 2005, s. 223-235.
- [4] Weszka, J.S., A survey of threshold selection techniques, *Computer Graphics and Image Processing*, roč. 7, č. 1, 1978, s. 259–265.
- [5] Otsu, N., A threshold selection method from gray-level histograms, *IEEE Transactions on Systems, Man and Cybernetics*, roč. 9, č. 1, 1979, s. 62-66.
- [6] Riddler, T. W., Calvard, S. Picture thresholding using an iterative selection method, *IEEE Transactions on Systems, Man and Cybernetics*, roč. 8, č. 8, 1978, s. 630–632.
- [7] Canny, J., A computational approach to edge detection. *IEEE Transactions Pattern Analysis and Machine Intelligence*, roč. 8, č. 6, 1986, s. 679–698.
- [8] Prager, J., Extracting and labeling boundary segments in natural scenes. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, roč. 2, č. 1, 1980, s. 16–27.
- [9] Beucher, S., Lantuejoul, C., Use of watersheds in contour detection, *International Workshop on Image Processing, Real-Time Edge and Motion Detection*, 1979.
- [10] Vincent, L., Soille, P., Watersheds in digital spaces: an efficient algorithm based on immersion simulations, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, roč. 13, č. 6, 1991, s. 583–598.
- [11] Meyer, F., Topographic distance and watershed lines, *Signal Processing*, roč. 38, č. 1, 1994, s. 113–125.
- [12] Vincent, L., Morphological grayscale reconstruction in image analysis: Applications and efficient algorithms. *IEEE Transactions on Image Processing*, roč. 2, č. 2, 1993, s. 176–201.
- [13] Brice, C. R., Fennema, C. L. Scene analysis using regions. *Artificial Intelligence*, roč. 1, č. 3-4, 1970, s. 205–226.
- [14] Chang, Y., Li, X., Adaptive image region-growing, *IEEE Transactions on Image Processing*, roč. 3, č. 6, 1994, s. 868-872.
- [15] Nock, R., Nielsen, F., Statistical region merging, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, roč. 26, č. 11, 2004, s. 1452–1458.
- [16] Horowitz, S. L., Pavlidis, T., Picture segmentation by a tree traversal algorithm, *Journal of the Association for Computing Machinery*, roč. 23, č. 2, 1976, s. 368–388.



- [17] Haris, K., Efstratiadis, S. N., Maglaveras, N., Katsaggelos, K., Hybrid image segmentation using watersheds and fast region merging, *IEEE Transactions on Image Processing*, roč. 7, č. 12, 1998, s. 1684–1699.
- [18] Beil, M., Irinopoulou, T., Vassy, J., Wolf, G., A dual approach to structural texture analysis in microscopic cell images, *Computer Methods and Programs in Biomedicine*, roč. 48, č. 3, 1995, s. 211–219.
- [19] Korting, T. S., Dutra, L. V., Fonseca, L. M. G., A resegmentation approach for detecting rectangular objects in highresolution highresolution imagery, *IEEE Geoscience and Remote Sensing Letters*, roč. 8, č. 4, 2011, s. 621–625.
- [20] Lumbresas, F., Serrat, J., Segmentation of petrographical images of marbles, *Computers & Geosciences*, roč. 22, č. 5, 1996, s. 547–558.
- [21] Hamarneh, G., Li, X., Watershed segmentation using prior shape and appearance knowledge, *Image and Vision Computing*, roč. 27, č. 1-2, 2009, s. 59–68.
- [22] Chevrefils, C., Cheriet, F., Aubin, C. E., Grimard, G., Texture analysis for automatic segmentation of intervertebral disks of scoliotic spines from MR images, *IEEE Transactions on Information Technology in Biomedicine*, roč. 13, č. 4, 2009, s. 608–620.
- [23] Roussillon, T., Piégay, H., Sivignon, I., Tougne, L., Lavigne, F. Automatic computation of pebble roundness using digital imagery and discrete geometry. *Computers & Geosciences*, roč. 35, č. 10, 2009, s. 1992–2000.
- [24] Lu, B., Cui, M., Liu, Q., Wang, Y. Automated grain boundary detection using the level set method. *Computers & Geosciences*, roč. 35, č. 2, 2009, s. 267–275.
- [25] Barraud, J. The use of watershed segmentation and GIS software for textural analysis of thin sections. *Computers & Geosciences*, roč. 154, č. 1-2, 2006, s. 17–33.
- [26] Song, Y., Automated Rock Segmentation for Mars Exploration Rover Imagery, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Beijing (China), roč. 37, 2008, s. 1017-1023.
- [27] Sonka, M., Hlavac, V., Boyle, R., *Image Processing, Analysis, and Machine Vision*, International Student Edition, Thomson Learning, 2008, s. 257-320.
- [28] Cox, M.R., Budhu, M., A practical approach to grain shape quantification, *Engineering Geology*, roč. 96, 2008, s. 1–16.
- [29] Bouwman, A.M., Bosma, J.C., Vonk, P., Wesselingh, J.A., Frijlink, H.W., Which shape factor(s) best describe granules?, *Powder Technology*, roč. 146, 2004, s. 66–72.
- [30] Souza, D.O.C., Menegalli, F.C., Image analysis: Statistical study of particle size distribution and shape characterization, *Powder Technology*, roč. 214, 2011, s. 57–63.
- [31] Blott, S.J., Pye K., Particle shape: a review and new methods of characterization and classification, *Sedimentology*, roč. 55, 2008, s. 31-63.
- [32] Wadell, H., Volume, shape and roundness of rock particles, *Journal of Geology*, roč. 40, 1932, s. 443–451.

- [33] Krumbein, W.C., Measurement and geological significance of shape and roundness of sedimentary particles, *Journal of Sedimentary Petrology*, roč. 11, č. 2, 1941, s. 64–72.
- [34] Powers, M.C., A new roundness scale for sedimentary particles, *Journal of Sedimentary Petrology* roč. 23, 1953, s. 117–119.
- [35] Diepenbroek, M., Bartholomä, A., Ibbeken, H., How round is round? A new approach to the topic 'roundness' by Fourier grain shape analysis, *Sedimentology* roč. 39, 1992, s. 411-422.
- [36] Drevin, G.R., Computational Methods for the Determination of Roundness of Sedimentary Particles, *Mathematical Geology*, roč. 38, č. 7, 2006, s. 871-890.
- [37] Bowman, E.T., Soga, K., Drummond, T.W., Particle Shape Characterisation using Fourier Analysis, CUED/D-Soils/TR315, 2000.
- [38] Sukumaran B., Ashmawy, A.K., Quantitative characterization of the geometry of discrete particles, *Géotechnique*, roč. 51, 2001, s. 1-9.
- [39] Masad, E., Unified Imaging Approach for Measuring Aggregate Angularity and Texture, *Computer-Aided Civil and Infrastructure Engineering*, roč. 15, 2000, s. 273-280.
- [40] Drevin, G.R., Vincent, L., Granulometric determination of sedimentary rock particle roundness, In: *Proceedings of International Symposium on Mathematical Morphology*, Sydney, Australia, 2002, s. 315–325.
- [41] Hyslip, J.P., Vallejo, L.E., Fractal analysis of the roughness and size distribution of granular materials, *Engineering Geology*, roč. 48, 1997, s. 231-244.
- [42] Bullard, J.W., Garboczi, E.J., Defining shape measures for 3D star-shaped particles: Sphericity, roundness, and dimensions, *Powder Technology*, roč. 249, 2013, s. 241-252.
- [43] Lee, J.R.J., Smith, M.L., Smith, L.N., P.S. Midha, A mathematical morphology approach to image based 3D particle shape analysis, *Machine Vision and Applications*, roč. 16, č. 5, 2005, s. 282-288.
- [44] Pohlman, N.A., Roberts, J.A., Gonser, M.J., Characterization of titanium powder: microscopic view and macroscopic flow, *Powder Technology*, roč. 228, 2012, s. 141-148.
- [45] Jan, J., *Medical Image Processing, Reconstruction and Restoration*, Taylor & Francis, 2006, s. 610-611.
- [46] Haralick, R.M., Shanmugam, K., Dinstein, I., Textural Features for Image Classification, *IEEE Transactions on Systems, Man and Cybernetics*, roč. 3, č. 6, 1973, s. 610-621.
- [47] Freeman, W. T., Adelson, E. H., The design and use of steerable filters, *IEEE Transactions Pattern Analysis and Machine Intelligence*, roč. 13, č. 9, 1991, s. 891-906.
- [48] Ojala, T., Pietikäinen, M., and T. Mäenpää, Multiresolution gray-scale and rotation invariant texture classification with local binary patterns, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, roč. 24, 2002, s. 971–987.

- [49] Newell, A.J., Morgan, R.M., Griffin, L.D., Bull, P.A., Marshall, J.R., Graham, G., Automated Texture Recognition of Quartz Sand Grains for Forensic Applications, *Journal of Forensic Sciences*, roč. 57, č. 5, 2012, s. 1285-1289.
- [50] Newell, A.J., Griffin, L.D., Morgan, R.M., Bull, P.A., Texture-based Estimation of Physical Characteristics of Sand Grains, *Digital Image Computing*, 2010, s. 504-509.
- [51] Crosier, M., Griffin, L.D., Texture Classification with a Dictionary of Basic Image Features, *IEEE Conference on Computer Vision and Pattern Recognition*, 2008, s. 1-7.
- [52] Sokolova, M., Lapalme, G., A systematic analysis of performance measures for classification tasks, *Information Processing and Management*, roč. 45, 2009, s. 427-437
- [53] Kroon, D.-J., Snake: Active Contour, Dostupné z <http://www.mathworks.com/matlabcentral/fileexchange/28149-snake---active-contour>, 2010.
- [54] Kröner, S., Doménech Carbó, M.T., Determination of minimum pixel resolution for shape analysis: proposal of a new data validation method for computerized images, *Powder Technology*, roč. 245, 2013, s. 57-63.
- [55] Walpole R. E., Myers R. H., Myers S. L., Ye. K., *Probability & Statistics for Engineers & Scientists*, 9th edition, Prentice Hall, 2012, s. 268-276.
- [56] Mirmehdi, M., Xie, X., Suri, J., *Handbook of texture analysis*, Imperial College Press, 2008, s. 61-94.
- [57] Bishop, C.M., *Pattern Recognition and Machine Learning*, Springer, 2006, s. 424-428, 124-127.
- [58] Hastie, T., Tibshirani, R., Friedman, J., *The Elements of Statistical Learning, Data Mining, Inference, and Prediction*, Second Edition, Springer, 2008, s. 241-249.
- [59] Kim, Ji-Hyun, Estimating classification error rate: Repeated cross-validation, repeated hold-out and bootstrap, *Computational Statistics and Data Analysis*, roč. 53, 2009, s. 3735-3745.

## Publikace autora

- [60] Křupka, A., Říha, K., Segmentation of Sedimentary Grain in Electron Microscopy Image, *Radioengineering*, roč. 22, č. 3, 2013, s. 883-891, IF:0,653.
- [61] Křupka, A., Říha, K., Minimal prerequisites for measuring two-dimensional contour roundness in a particle classification context, *Powder Technology*, roč. 284, č. 1, 2015, s. 486-495, IF:2,349.
- [62] Křupka, A., Definition of Typical Textures of Sedimentary Grains Using Co-occurrence Features And K-means Clustering Technique, *International Journal of Advances in Telecommunications, Electrotechnics, Signals and Systems*, roč. 2, č. 2, 2013, s. 68-72.
- [63] Křupka, A., Říha, K., Detection of Edge Structures on Surface of Sedimentary Grains Acquired by Electron Microscope, *38th International Conference on Telecommunication and Signal Processing*, Berlin, 2014, s. 785-788.
- [64] Křupka, A., Přinosil, J., Říha, K., Minář, J., Dutta, M., Hair Segmentation for Color Estimation in Surveillance Systems, *The Sixth International Conferences on Advances in Multimedia, MMEDIA 2014*, 2014, s. 102-107.
- [65] Minář, J., Říha, K., Křupka, A., Tong, H., Automatic detection of the macula in retinal fundus images using multilevel thresholding, *International Journal of Advances in Telecommunications, Electrotechnics, Signals and Systems*, roč. 3, č. 1, 2014, s. 13-16.
- [66] Přinosil, J., Křupka, A., Říha, K., Dutta, M., Singh, A., Automatic Hair Color De-identification. *ICGCloT - International Conference of Green Computing and Internet of Things 2015*, 2015, s. 737-741.
- [67] Aplikace pro segmentaci a analýzu tvaru sedimentárních zrn, dostupné z: <http://www.stud.feec.vutbr.cz/~xkrupk01/appGrain/>

## Seznam zkratek

SEM	(Scanning Electron Microscope) - Rastrový elektronový mikroskop
AF	(Angularity Factor) - Faktor angularity
MNP	(Minimal Number of Particle projections) - Minimální počet projekcí částic
LBP	(Local Binary Patterns) - Lokální binární vzory
BIF	(Basic Image Features) - Základní obrazové příznaky
RAG	(Region Adjacency Graph) - Graf přilehlých regionů
TP	(True Negative) - Správně pozitivní
FP	(False Positive) - Falešně pozitivní
FN	(False Negative) - Falešně negativní
TN	(True Negative) - Správně negativní
pph	(Positive Predictive Value) - Pozitivní prediktivní hodnota
<i>k</i> -NN	( <i>k</i> -Nearest Neighbors) - <i>k</i> -nejbližších sousedů

# Přílohy

## A. Obsah přiloženého média

- Databáze sedimentárních zrn pořízených elektronovým mikroskopem.
- Databáze experimentálních částic skenovaných 3D skenerem a databáze jejich vygenerovaných 2D průmětů.

# Curriculum Vitae

## Aleš Krupka

- Datum narození: 2. 9. 1986
- Bydliště: Brno, Česká republika
- Email: Ales.Krupka@seznam.cz

### Vzdělání

- 2011-2016: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikační techniky, Doktorský studijní obor Teleinformatika
- 2009-2011: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikační techniky, Magisterský studijní obor Telekomunikační a informační technika
- 2006-2009: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikační techniky, Bakalářský studijní obor Teleinformatika

### Pracovní zkušenosti a stáže

- 2015 - dosud: Camea s.r.o. - Vývojář software
- 2014: Profactor GmbH, Rakousko - Výzkumný pobyt
- 2012: Escola Universitária Politécnic de Mataró, Španělsko - Studijní a výzkumný pobyt
- 2010: Amberg Technologies a.s. - Tester software

### Účast v projektech

- FEKT-S-11-17 – Výzkum sofistikovaných metod číslicového zpracování obrazu a zvuku
- FEKT-S-14-2335 – Kognitivní multimediální analýza zvukových a obrazových signálů

### Publikace

- Články v odborných impaktovaných časopisech: 2
- Články v odborných neimpaktovaných časopisech: 3
- Články publikované v konferenčních sbornících: 3
- Články indexované databází WoS: 3
- Články indexované databází Scopus: 5
- H-index dle databáze Scopus: 1