



SLOVENSKÁ TECHNICKÁ UNIVERZITA V BRATISLAVE
MATERIÁLOVOTECHNOLOGICKÁ FAKULTA SO SÍDLOM V TRNAVE

Ing. Daniel Kuchár

Autoreferát dizertačnej práce

**Obrazová segmentácia a klasifikácia fázového
zastúpenia a morfológie mikroštruktúry
ZnAlMgSn zliatin**

na získanie akademického titulu: doktor (philosophiae doctor, PhD.)

v doktorandskom študijnom programe: 104217, 2621V15 Automatizácia a informatizácia procesov

v študijnom odbore: 2647 Kybernetika

Forma štúdia: denná prezenčná

Miesto a dátum: Trnava, máj 2023



Dizertačná práca bola vypracovaná na Katedre aplikovanej informatiky a automatizácie, Ústave aplikovanej informatiky, automatizácie a matematiky

Predkladateľ: Ing. Daniel Kuchár
Ústav aplikovanej informatiky, automatizácie a matematiky
Materiálovotechnologická fakulta so sídlom v Trnave
Slovenská technická univerzita v Bratislave
Jána Bottu 2781/25
917 24 Trnava

Školiteľ: prof. Mgr. Róbert Vrábel', PhD.
Ústav aplikovanej informatiky, automatizácie a matematiky
Materiálovotechnologická fakulta so sídlom v Trnave
Slovenská technická univerzita v Bratislave
Jána Bottu 2781/25
917 24 Trnava

Oponenti:

Autoreferát bol rozoslaný:

**Obhajoba dizertačnej práce sa bude konať dňao.....h.
na Materiálovotechnologickej fakulte STU so sídlom v Trnave, Jána Bottu 25, 917 24 Trnava**

.....
prof. Ing. Miloš Čambál, CSc.
dekan MTF STU

OBSAH

ZOZNAM SKRATIEK	4
ÚVOD	5
1 ZMYSEL, CIELE A VÝCHODISKÁ	6
2 ANALÝZA PROBLEMATIKY A TEÓRIA VIZUÁLNYCH DÁT	8
3 POPIS VIZUÁLNYCH DÁT	12
4 NÁVRH RIEŠENÍ VÝSKUMNÝCH OKRUHOV	16
4.1 PROBLEMATIKA ŠUMU, FILTROVANIA A TRANSFORMOVANIA OBRAZU	16
4.1.1 Klasické filtrovanie	17
4.1.2 Technické filtrovanie	17
4.1.3 Optimalizácia MFA	18
4.2 SKALÁRNY MODEL – SEMIAUTOMATICKÝ ALGORITMUS	19
4.3 VEKTOROVÝ MODEL – CLUSTERING	20
5 ZHODNOTENIE RIEŠENÍ VÝSKUMNÝCH OKRUHOV	21
5.1 PROBLEMATIKA ŠUMU, FILTROVANIA A TRANSFORMOVANIA OBRAZU	21
5.2 SKALÁRNY MODEL – SEMIAUTOMATICKÝ ALGORITMUS	22
5.3 VEKTOROVÝ MODEL – CLUSTERING	23
5.4 SPOLOČNÉ	25
6 PRÍNOSY DIZERTAČNEJ PRÁCE A ZÁVER	27
ZOZNAM PUBLIKAČNEJ ČINNOSTI	30
ZOZNAM BIBLIOGRAFICKÝCH ODKAZOV	31

ZOZNAM SKRATIEK

Mikroskopia a modality:

SEM – Scanning Electron Microscope, Scanning Electron Microscopy

TEM – Transmission Electron Microscope, Transmission Electron Microscopy

BSE – Backscattered Electrons

SE – Secondary Electrons

EDX – Energy-Dispersive X-ray spectroscopy

XRD – X-Ray Diffraction

FIB – Focused Ion Beam

Spracovanie obrazu:

BG – Background (trieda útvarov)

BW – Black & White (trieda útvarov)

L – Light (trieda útvarov)

D – Dark (trieda útvarov)

LD – skupina oboch tried spolu: L aj D

PQ – Phase Quantification

IP – Image Processing

ML – Machine Learning

DL – Deep Learning

CV – Computer Vision

PSO – Particle Swarm Optimization

ASF – Alternate Sequential Filter

LVQ – Learning Vector Quantization

SOM – Self-Organizing Map

PNET – názov neurónovej siete typu MLP

MLP – MultiLayer Perceptron

GLCM – Gray Level Cooccurrence Matrix

MFA – Mean Field Annealing

H – Hamiltonian

NLM – NonLocal Mean

Fxx – Feature, príznak so svojim číselným indexom xx

FxxLOG – logaritmovaný príznak

F01(0~1) – príznak s číselným indexom 01 (elevácia), nadobúdajúci hodnoty 0~1 typu single

F01(0~255) – príznak s číselným indexom 01 (elevácia), nadobúdajúci hodnoty 0~255 typu uint8

ÚVOD

Materiály, ktoré sú používané v priemysle, sa vyznačujú rozmanitými vlastnosťami. Elektronová mikroskopia predstavuje jednu z foriem, ako možno tieto vlastnosti skúmať. Ponúka zakódovanú informáciu o skúmanom materiáli v podobe mikroštruktúry, ktorá odzrkadľuje jednak chemické zloženie ale aj procesné postupy prítomné pri vzniku či spracovaní látky. Je tvorená svojimi štruktúrnymi zložkami a predstavuje informačný zdroj, ktorý je však potrebné dokázať správne interpretovať. Táto správna interpretácia pozostáva z viacerých súvisiacich krokov, pričom medzi prvými je segmentácia s následnou klasifikáciou. Po ich úspešnom zvládnutí možno jednotlivé štruktúrne zložky ďalej analyzovať.

Každá obrazová informácia je v elektrónovej mikroskopii v značnej miere jedinečná a preto aj algoritmy používané v praxi majú svoje osobité črty a miery úspešnosti. Zvyčajne je potrebné zvážiť správny pomer medzi časom potrebným na zabezpečenie vstupných dát, časom potrebným na vytvorenie metódy ich spracovania ako aj časom na ich samotné spracovanie a vyhodnotenie.

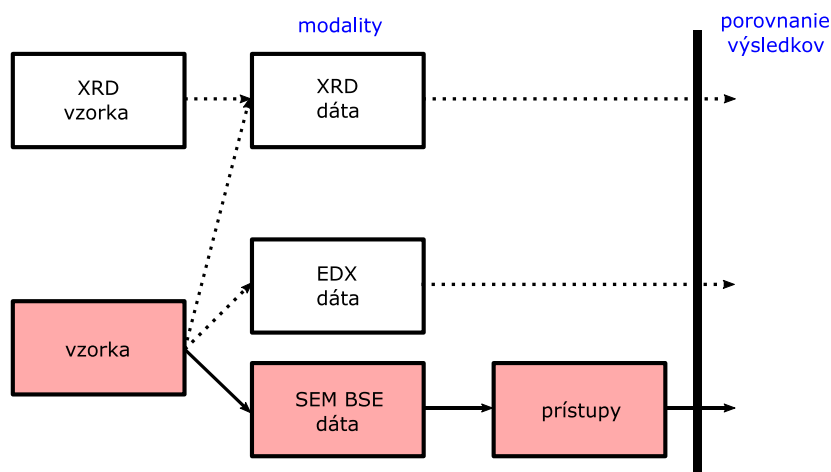
Cieľom práce je ponúknuť viaceré prístupy pre úlohu segmentovania a klasifikovania štyroch štruktúrnych zložiek Zn-Al-Mg-Sn zliatiny. Skúmaný materiál sú žíhané vzorky. Vstupné dáta predstavujú SEM BSE obrázky vyhotovené pre rôzne chemické podiely Sn v zliatine a rôzne priblíženia. Výsledkom budú obrazové masky klasifikačných tried, ktoré umožnia obsluhu alebo ďalšiemu programovému stupňu kvantitatívne a kvalitatívne analyzovať mikroštruktúru.

Označenia obrázkov, tabuliek a rovníc v autoreferáte sú zhodné s označeniami v dizertačnej práci bez ohľadu na ich poradie v autoreferáte. Referencia časť odkazuje priamo na úsek v dizertačnej práci, referencia kapitola odkazuje na úsek v autoreferáte.

1 ZMYSEL, CIELE A VÝCHODISKÁ

Dizertačná práca sa venuje problematike segmentácie a klasifikácie SEM BSE mikroštruktúr žihanej zliatiny Zn-Al-Mg-Sn pre rôzne zastúpenie Sn (0, 1, 2, 3 %) a rôzne úrovne zoom (1000, 2000, 4000).

Primárnym zmyslom dizertačnej práce je odstránenie úzkeho technologického miesta spôsobom znázorneným na Obr. 11:



Obr. 11 Odstránenie úzkeho miesta a porovnanie výsledkov medzi modalitami [1]

Z technologického pohľadu (veda o materiáloch) možno získať riešenie daného zadania aj inými spôsobmi, ktoré sú bežne známe – použitie modalít XRD a EDX. Tieto spôsoby sa však vyznačujú okrem svojich výhod aj nevýhodami. Princiálne rozdiely medzi tromi zobrazovacími modalitami sú ilustrované prostredníctvom Tabuľka 7. XRD potvrdzuje správnosť štruktúrnych zložiek ale nedokáže poskytnúť sémantický kontext vizuálnej scény – vyhodnotenie poskytnutých XRD dát predstavuje len numerické podiely zložiek na vzorke. Kontext chemických prvkov (nie štruktúrnych zložiek!) je poskytnutý prostredníctvom EDX ale zase pri nižšom rozlíšení.

Tabuľka 7 Charakteristiky jednotlivých modalít: SEM BSE, EDX, XRD [1]

Modalita	Dátový formát	Rozlíšenie	Informačný obsah	Akvizičný čas
SEM BSE	obrazové dáta (2D matica)	vysoké	kompozičný kontrast	malý
EDX	EDX dáta (3D matica)	nízke	chemické prvky	veľký
XRD	numerické dáta	-	štruktúrne zložky	-

Modalita SEM BSE poskytuje teda nasledovné výhody:

1. umožňuje snímať veľkú plochu
2. poskytuje 30x až 60x rýchlejšie snímanie a vyššie rozlíšenie pri porovnaní s EDX
3. poskytuje obrazový kontext pri porovnaní s XRD
4. umožňuje spracovanie prípadnej archívnej dokumentácie pri neexistencii vzoriek

Podrobné technologické detaily týkajúce sa mikroskopie a vzoriek sú uvedené v samotnej dizertačnej práci.

Pri riešení zadania boli k dispozícii dve trérovacie sady: sada A (180 snímok) a sada B (2400 snímok). Kým sada A obsahuje snímky lokácií, ktoré boli situované len v blízkosti dna kokily, sada B obsahuje snímky lokácií rovnomerne naprieč celou vzorkou. Ani jedna zo sád A resp. B neobsahuje ground-truth informáciu pre filtráciu či segmentáciu s klasifikáciou.

Hlavným cieľom dizertačnej práce je navrhnutie, implementovanie a overenie segmentačných a klasifikačných algoritmov SEM BSE mikroštruktúr kovovej zliatiny Zn-Al-Mg-Sn s prihliadnutím na kompromis medzi kvalitou dosiahnutých výsledkov a časovými i kapacitnými nákladmi na ich dosiahnutie. Splnenie hlavného cieľa je podmienené jednotlivými **čiasťovými cieľmi**:

- 1) **Analyzujte súčasný technologický stav v oblasti spracovania dát získavaných v elektrónovej mikroskopii s primárnym zameraním sa na modalitu SEM BSE.**
- 2) **Stručne charakterizujte prístupy použité v odbornej literatúre na riešenie analogických úloh.**
- 3) **Na základe získaných analýz a charakteristík stanovte výskumné okruhy.** Nutným výskumným okruhom je vypracovanie časti 3 (Teória vizuálnych dát) a časti 4 (Popis vizuálnych dát). Zvolená zliatina nebola doteraz skúmaná pri takých rôznorodých podmienkach (úrovne zoom, úrovne Sn obsahu). Následne je umožnené stanovenie výskumných okruhov v časti 5.1 (Problematika šumu, filtrovania a transformovania obrazu), časti 5.2 (Semiautomatizovaný algoritmus) a časti 5.3 (Clustering).
- 4) **Navrhňte a implementujte rôzne prístupy/riešenia pre spracovanie vizuálnych dát aj s ohľadom na časové a kapacitné náklady.**
- 5) **Na základe návrhu, implementácie, overenia a zhodnotenia jednotlivých prístupov špecifikujte prínosy dizertačnej práce.**

2 ANALÝZA PROBLEMATIKY A TEÓRIA VIZUÁLNYCH DÁT

Podstatný charakter snímky mikroštruktúry je určený delom resp. elektrónmi, ktoré toto delo emituje [2]. Elektróny z lúča interagujú s atómami vzorky prostredníctvom množstva fyzikálnych procesov pod názvom **scattering**. Z týchto interakcií vznikajú: späťne odrazené elektróny (BSE), sekundárne elektróny (SE) a röntgenove lúče (xrays), ktoré nesú informáciu ohľadom vzorky [2-5]. Rôzne typy materiálov vzorky a rôzne zobrazovacie modality kladú rôzne ale pritom veľmi dôležité nároky na prípravu vzorky ešte predtým, ako začne samotná mikroskopia [6-10].

Snímaním emisií z interakcie dopadajúceho elektrónového lúča na vzorku dochádza k tvorbe grayscale obrázku, ktorý sa vyznačuje zobrazením informácie s určitým kontrastom [5]. Tento komplexný proces nesie označenie **kontrastný mechanizmus**. Celkový kontrast sa skladá v príslušnej miere z nasledovných zložiek: topographic, channelling a composition.

Tavenina látky bola odliata do Cu kokily s priemerom 30 mm a hĺbkou 20 mm. Dno kokily bolo chladené vodou a boky kokily mali kontakt s bežným okolitým vzduchom. Efekt chladenia vodou bol najvýraznejší na dne kokily, následne sa v menšej miere prenášal aj na boky kokily. Pri dne kokily bola spodná časť taveniny navyše prtláčaná tiažou vrchnej časti taveniny (efekt tiaže). Kokila bola zhora plne otvorená a teda tavenina tu mala kontakt s bežným okolitým vzduchom. Všetky vzorky použité pre akékoľvek fotky boli **žíhané** (dosiahnutie teploty 310 °C, podržanie teploty po dobu 1hod a potom ochladenie náhlym ponorením do chladiacej vody). Žíhaním možno výrazne ovplyvniť vlastnosti materiálu.

Nastavenia mikroskopu boli optimalizované pre zefektívnenie rýchlosti fotenia pri pomerne malých zväčšeniach – zoom 1000, 2000 a 4000. Relatívne krátky skenovací čas (čas expozície) umožnil vyhotoviť pomerne veľké množstvo obrázkov – išlo teda o stanovenie kompromisu medzi kvalitou obrazovej informácie a rýchlosťou akvizície. **Mikroštruktúra** kovových materiálov je tvorená rozložením a topologickým usporiadaním zŕn, fáz, rozhraní a iných defektov v troch dimenziách [11-12]. Pri spracovaní mikroštruktúr existuje všeobecná snaha o minimalizáciu resp. úplné vylúčenie interaktívnych zásahov zo strany obsluhy z nasledovných dôvodov [13-17]: prácnosť, subjektívne chyby a potreba domain knowledge.

Vo všeobecnosti možno metódy spracovania mikroštruktúr rozdeliť na: automatické, semiautomatické a manuálne. Je nemožné vyvinúť univerzálny **algoritmus** pre analýzu všetkých mikroštruktúr [18]. Konkrétna metóda bude ovplyvnená najmä: prípravou vzorky, snímacou technikou (mikroskop, operačný mód) a povahou materiálu. Okrem kontrastu k

základným charakteristikám mikroskopických obrázkov patrí aj šum a rozličné poškodenia [19].

Pri prieskume publikačnej činnosti bolo zistené, že daný materiál vzorky je veľmi málo zastúpený. Boli identifikované nasledovné trendy, náročnosti a výzvy pri analýze mikroštruktúr. **Trendy** [20]: signal processing, collaborative microscopy, semi-automation, interdisciplinary cooperation. **Náročnosti** [21]: variabilita textúr a tvarov, fragmentované objekty a nejasné kontúry, nerovnaké percentuálne zastúpenie tried, absencia prior kontext. **Výzvy** [21]: príprava trénovacích dát pre DL, nasadenie predtrénovaných DL modelov, zdieľanie dátových sád, poskytnutie open-source kódu.

V prípade riešenia projektu v oblasti mikroskopie dochádza k **spolupráci** rôznych osôb: technologický expert (zlievač, technik metalografie, operátor mikroskopu) a CV expert (DIP expert, ML expert). V prípade, že je to reálne, je vhodné, aby obe strany participovali pri tvorbe dátovej sady (vizuálny obsah, množstvo snímok, triedy, časová náročnosť) a upresnení detailov zadania.

Tabuľka 3 Vybrané literárne zdroje [1]

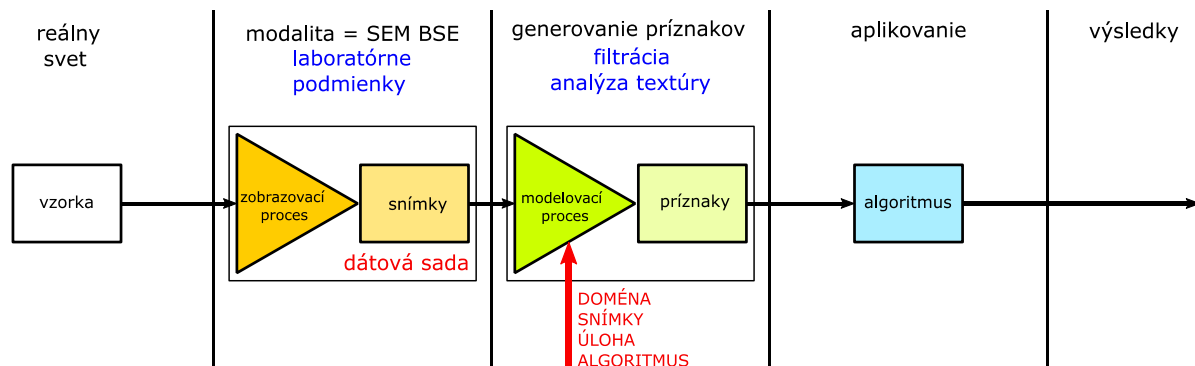
Autor	Skúmaný materiál	Informácia
Gogola a kol. 2021 [22]	Zn-Al-Mg-Sn	SEM, EDX, XRD identifikácia fáz
Ercetin a kol. 2021 [14]	Mg-Al-Sn	SEM, Zoom 500 vzorka: pieskovanie, leštenie, leptanie IP + manuálne korekcie šum: normalised box filter, Gaussian filter
Chalusiak a kol. 2021 [15]	palivové články	FIB SEM testovaných a nastavených niekoľko filtrov prostredníctvom PSO
Li a kol. 2020 [23]	Bridlica	EDX ML
Truglas a kol. 2020 [24]	Zn-Al-Mg	SEM SE, FIB tomography, TEM šum: anisotropic diffusion filter
Le Trong a kol. 2014 [25]	Vápenec	xray microtomography šum: ASF, mosaic operator výhody a nevýhody thresholding histogram deepening

Neexistuje formálna definícia obsahu vizuálnych dát. Bežným spôsobom možno **vizuálny obsah** vnímať ako čokoľvek, čomu možno priradiť označenie a rozoznať vizuálne [26]. Je zrejmé, že sa každá doména bude vyznačovať svojím typickým obsahom. Bude to spôsobené jednak rozdielnou zobrazovacou modalitou a prípadne rozdielnym predmetom skúmania. V prípade mikroskopie máme na výber z viacerých modalít, ktoré determinujú charakteristiky

zobrazovacieho procesu. Toto všetko má vplyv na výsledný ráz zobrazeného obsahu, ktorý sa vyznačuje svojimi osobitými **vizuálnymi atribútmi.**

Dáta sú pozorovania fenoménov z reálneho sveta [27]. Každá dátová položka predstavuje určité malé okno, prostredníctvom ktorého sa limitovaným spôsobom nahliada na realitu [28]. **Raw data** (snímky mikroskopie) sú dáta prichádzajúce priamo z domény, z ktorej vzišla špecifikácia úlohy čiže zadanie [27]. Zvyčajne sú zabezpečené prostredníctvom technologického experta a sú často v neštruktúrovanej forme. Aby bolo možné ich následné spracovanie prostredníctvom ML algoritmu, je potrebné ich často predspracovať – snaha o prechod do štruktúrovanej formy [29-30] na príznaky (feature data). **Feature data** [27] predstavujú numerickú reprezentáciu nejakého atribútu z raw data.

Feature engineering je kreatívny proces extrahovania novej reprezentácie z raw data, ktorá je viac vhodná pre danú výpočtovú úlohu [31] – **reprezentačný problém** [32]. Pri spracovaní obrazu dochádza tak k prechodu od vizuálnych atribútov na príznaky. Tieto môžu byť low-level alebo high-level [33]. Je to proces náročný, zdĺhavý a iteratívny. Začiatok kreatívneho procesu je silne závislý na ľudskom vstupe a je často vedený intuíciou experta [32]. Na Obr. 38 je znázornený reťazec premeny dátových druhov pre potreby dizertačnej práce:



Obr. 38 Reťazec premeny jednotlivých dátových druhov v rámci SEM BSE

Neexistuje formálne jednotná **definícia pre textúru**, slovná a ani matematická [34-40]. Povaha textúry (a teda charakteristická povaha príslušnej vizuálnej informácie) a vnútorná interpretácia pojmu textúra je závislá od aplikačnej oblasti [38,41]. IP sa zameriava iba na povrch objektu, ktorý však vyzerá rôznym spôsobom pri rôznych podmienkach zobrazenia [36,38,40,42]. Možno teda hovoriť o limitáciách IP pri spracovávaní textúr: mierka, zobrazovacia geometria, svetelné podmienky, zmeny v čase. Po predošlom priradení sady príznakov ku každému pixelu sa problém segmentácie obrazu transformuje na problém dátovej analýzy zhlukov v priestore príznakov [42].

Za účelom extrahovania textúrnych deskriptorov sa postupne vyprofilovali štyri skupiny tradičných (teda nie DL) techník [39]:

Tabuľka 16 Skupiny tradičných techník pre analýzu textúry

	Skupina techník	Popis
1	statistical	vhodné najmä pre náhodné textúry, ale nie je vo všeobecnosti možné z jednotlivých príznakov zrekonštruovať textúru [43]
2	structural	vhodné najmä pre makroštruktúry s definovanými pravidlami (periodické textúry)
3	model-based	možnosť generovania textúry
4	transform-based	použitie rôznych transformácií

V odbornej literatúre niekedy nie je rozlišované medzi pojmami **dáta** a **informácie** a sú voľne zamieňané, inokedy môže prísť k ich striktnému oddelovaniu. Potom sa pod informáciou rozumie niečo nové, o čom sa predtým nevedelo. Z pohľadu posudzovania objektu perceptívnym systémom (napr. človekom) možno rozdeliť tento na dve zložky: invariantnú a premenlivú. **Kontext** je potom všetko, čo vysvetľuje premenlivú časť [44]. Vybrané typy kontextu pre mikroskopiu: photogrammetric, spatial, scale, geometric, scene/semantic [45-48]. Pre analýzu obrazu sú príznačné dva rozpory (gaps), ktoré by mal pomôcť preklenúť práve kontext [45]:

- Semantic gap** – rozpor medzi interpretáciou low-level (ľahko zistiteľné pre stroj) a high-level príznakov (ľahko zistiteľné pre človeka ale náročné až nemožné pre stroj [49]).
- Sensory gap** – rozpor medzi snímaným reálnym objektom (spojitý reálny vzor = obraz) a jeho uloženým obrazom (digitálny obraz), ktorý bol zosnímaný prostredníctvom stroja.

Reálne dátové sady sú získavané rôznymi spôsobmi [50], nie vždy sú pripravené v „uľadnej“ forme [51] a teda častokrát môžu dáta skončiť so svojimi inherent problémami: small sample size, class imbalance, data complexity, dataset shift, noisy data, outliers, feature cost, data leakage. Presnejší popis je uvedený v dizertačnej práci v Tabuľka 17.

Pre dizertačnú prácu sú príznačné nasledovné klúčové problémy:

- problém váhovania náročnosti úlohy**
- problém váhovania zmien vo vizuálnom obsahu**
- problém preklenutia sensory gap**
- výsledný problém zovšeobecnenia praxe feature engineering**
- chicken-and-egg problém pri segmentácii**
- dataset so svojimi inherent problémami**
- problém vyhodnocovania kvality vstupných obrazových dát**


3 POPIS VIZUÁLNYCH DÁT

V rámci analýzy obrazu bude potrebné rozlíšiť nasledovné základné štruktúrne zložky: fázu (tiež tuhý roztok) $\eta(\text{Zn})$, intermetalickú fázu $\text{Mg}_2\text{Zn}_{11}$, častice tvorené eutektoidom (tiež zmes fáz alebo zmes tuhých roztokov) $\eta(\text{Zn}) + \alpha(\text{Al})$ a s pribúdajúcim obsahom Sn (1, 2 a 3%) sa bude vyskytovať intermetalická fáza Mg_2Sn :

Tabuľka 20 Skúmané štruktúrne zložky [1]

	Štruktúrna zložka	Popis	Označenie v IP
1	$\eta(\text{Zn})$	fáza	BG background
2	$\eta(\text{Zn}) + \alpha(\text{Al})$	eutektoid (zmes fáz)	BW black & white
3	$\text{Mg}_2\text{Zn}_{11}$	intermetalická fáza	L light
4	Mg_2Sn	intermetalická fáza	D dark


Na Obr. 19 je výrez z pôvodného nefiltrovaného mikroskopického obrázku 3% Sn, zoom 4000. Prítomné sú pozadie BG, eutektoid BW a útvary L a D. Z obrázku sú zrejmé precipitáty vo vnútri pozadia BG vo forme tmavých bodov a na okrajoch útvarov L a D a rovnako je viditeľný typický biely lem na rozhraní styku pozadia BG a útvarov L (v menšej miere), ale najmä D a BW. V strede obrázka je dolu prítomný útvar BW, ktorý postupne smerom hore získava na intenzitných hodnotách. Daná častica teda nie je rozrezaná kolmo priečne ale pod uhlom menším ako 90° . Začína tak postupne presvitáť spod pozadia.



Obr. 19 Základné triedy [1]

Jednotlivé útvary sa vyznačujú značnou **variabilitou**, ktorej výsledné vizuálne variácie sú podrobnejšie predstavené v dizertačnej práci: veľkosť, tvar, intenzitné hodnoty, vnútorná textúra, zreteľnosť delineácie, percentuálne zastúpenie na obraze, sémantické súvislosti, prítomnosť škrabancov.

Na Obr. 22 sú vyobrazené základné podmienky orientácie obrazových mikroštruktúr z oboch sád A a B. Žltozelený odliatok valcového tvaru bol priečne rozrezaný. Na obrázku je vidno jeho polovičku, ktorá po skrátaní z jednej strany obsahuje šedú vzorku. Táto má označené všetky svoje strany čiernym fontom. B-bottom predstavuje stranu, ktorá sa fyzicky dotýkala dna kokily počas odliatia. A-air predstavuje stranu, ktorá bola v kontakte s okolitým vzduchom. S-side(s) predstavujú boky. Ľavá strana bola fyzicky v kontakte s bokom kokily počas odliatia.



Obr. 22 Základné podmienky orientácie mikroštruktúr

Zosnímaný obrázok má takisto značené svoje strany, tentokrát červeným fontom. Písmená teraz neznačia priamo fyzický kontakt s kokilou resp. vzduchom, ale len naznačujú smer, kde boli tieto samotné prítomné. Na zosnímaných obrázkoch je VŽDY v hornej časti to, čo bolo bližšie ku dnu kokily. Na dne kokily mala tvorba vizuálneho obsahu menej času – nastal rýchlejší proces tuhnutia. Je tu väčšia pravdepodobnosť výskytu channelling contrast v pozadí. Priečne rezy dendritických ramien sú tu menšie (tenšie), smerom ku vzduchu väčšie (hrubšie). Smerom do vnútra vzorky sa postupne mení vizuálny obsah – útvary sa začínajú inak prejavovať (intra-class) a usporiadať medzi sebou (semantics).

Vzhľadom na fakt, že v rámci každej triedy bude vo všeobecnosti vystupovať viacero rôznych útvarov je nutné skonštatovať, že sa jedná o identifikáciu typu general category case.

Technologický expert určuje **logický faktor segmentácie** – priradenie konkrétnych vizuálnych atribútov do príslušných segmentov.

Práca s elektrónovým mikroskopom predstavuje prácu v **laboratórnych podmienkach** (controlled situations). Operátor buď priamo ovplyvňuje vhodným spôsobom parametre skúmanej vzorky či zobrazovacieho procesu alebo je o väčšine týchto parametrov aspoň informovaný. Nehľadiac na to všetko, stále nie je možné tvrdiť o 100% kontrole či prehľade nad procesom zobrazovania zo strany operátora.

Medzi jednotlivými fotkami je prítomná rôzna úroveň jasů. Pri generovaní histogramov týchto fotiek by sa tento fakt prejavil ako horizontálny posun histogramu (**histogram shift**).

Obrazové sady A a B sa vyznačujú svojimi **inherent problémami**. Z dôvodu modality SEM BSE je prirodzené hovoriť o šume v dátach. Sada A bola zhotovená s pomerne malým počtom

snímok v jednotlivých kategóriách. Tieto počty snímok stačili na úvodné zoznámenie sa s problematikou ale nie na detailné pochopenie všetkých súvislostí – small sample size. Z tohto dôvodu bolo prístupné k zhotoveniu sady B. Je nutné poznamenať, že posudzovanie veľkosti sady je problém otvorený. V rámci jednotlivých kategórií (0, 1, 2 a 3 % Sn) možno hovoriť o class imbalance 1. druhu – rel. pravidelné nerovnaké zastúpenie jednotlivých základných tried na obrázku. Presné čísla percentuálnych zastúpení uvádza Tabuľka 39. Vzhľadom na sémantické variácie v scéne možno hovoriť o class imbalance 2. druhu. Vtedy najmä pri číselne veľkej hodnote zoom môže nastať prípad, že na snímke sú niektoré základné triedy zastúpené minimálne či dokonca absentujú! Vzhľadom na množstvo vizuálnych atribútov možno hovoriť o data complexity – čiže považovať dátové sady za komplexné a teda nie jednoduché.

Tabuľka 22 predstavuje zoznam vizuálnych atribútov, s ktorými možno prísť do kontaktu pri spracovávaní obrazovej dokumentácie sád A a B:

Tabuľka 22 Druhy vizuálnych atribútov

Číslo	Názov druhu	Popis
Objekty		
1	štyri základné triedy	BG, BW, L, D – komplexné atribúty
2	kontúry objektov	komplexný atribút
3	rozseknutia objektov	okraje obrázku rozseknú objekty
4	textúry objektov	komplexný atribút
5	intenzitné zmeny	presvitanie/vynáranie sa častíc
6	fľaky na pozadí	BG
7	precipitáty v čiare	BG
8	viaceré pozadia	BG: channelling contrast
9	matériový drift	BG: nevodorovnosť pozadia
10	biely lem	okraje medzi BG a (L a D), súčasť BG
11	biele vnútro	D
Sémantika		
12	scény	
13	priestorové súvzťažnosti	vzťahy medzi atribútmi
14	jasové rozdiely medzi obrázkami	histogram shift
Doplnkové objekty		
15	šum	
16	precipitáty	
17	škrabance	
Neuvažované objekty		
18	korózia	
19	póry vzduchu	
20	olovo	malá biela častica
21	nečistota	
22	živica	metalografická príprava
23	prasklina	

Tabuľka je rozdelená do štyroch skupín. Skupina Neuvažované objekty je uvedená len kvôli technologickej kompletnosti. Povinnosťou operátora mikroskopu by malo byť zadržanie všetkej dokumentácie, kde by sa tieto atribúty vyskytli. Môže sa však stať výnimka a preto by CV expert mal mať aspoň v teoretickej rovine základné vedomosti o nej. Dizertačná práca s danou skupinou neuvažuje. V prípade jej zakomponovania do úlohy náročnosť rastie (keďže rastie počet tried a aj ich vizuálne prejavy).

Faktory, ktoré vplývajú na výsledný vizuálny obsah sú zosumarizované v Tabuľka 23:

Tabuľka 23 Faktory vplývajúce na výsledný vizuálny obsah

Faktor	Názov	Informácia
Objektívne faktory – finálny materiál vzorky		Obr. 38: vzorka
1	chemické zloženie materiálu vzorky	Tabuľka 4
2	spôsob odliatia a chladenia vzorky	časť 1.3
3	spôsob žihania vzorky	časť 1.3
4	vystavenie agresívnemu prostrediu	rôzne testy (neuvažuje sa v práci)
5	rozrezanie vzorky – osi, steny	časť 1.3
6	výber lokácií snímania	lokačné mapy v časti 4.1
7	metalografická príprava (brúsenie, leštenie, leptanie)	časť 1.3
8	vek a skladovanie vzorky	stárnutie materiálu (objektívny jav) vs. korózia
Objektívne faktory – mikroskop		Obr. 38: zobrazovací proces
9	delo	Tabuľka 4 a časť 1.1
10	optický systém	el.mag. šošovky
11	typ + poloha detektoru	časť 1.1
Subjektívne faktory – konanie operátora		Obr. 38: zobrazovací proces
12	pomocný materiál (zaliatie vzorky do živice)	časť 1.1 a časť 1.3
13	umiestnenie a uzemnenie vzorky	časť 1.1 a časť 1.3
14	nastavenia na mikroskope (kontrast, jas, zaostrenie)	časť 4.7
15	nastavenia na mikroskope (skenovací čas, zoom)	Tabuľka 4, Obr. 5 a Obr. 6
Subjektívne faktory – „konanie“ mikroskopu		Obr. 38: zobrazovací proces
16	skokové zmeny hodnôt	časť 4.7
17	bližšie nevysvetliteľné vplyvy na vizuálny obsah	šum, iné

4 NÁVRH RIEŠENÍ VÝSKUMNÝCH OKRUHOV

Komplexnosť dát dáva v princípe dve možné cesty ich spracovania: spracovávať každú snímku zvlášť ku protikladu spracovávať viacero snímok spoločne a teda použiť informácie medzi jednotlivými snímkami. Z nasledujúcich dôvodov bolo rozhodnuté pristúpiť k spracovávaniu každej snímky zvlášť:

- 1) Spracovanie každej snímky zvlášť je jednoduchšie a teda vyhovuje to zásade od jednoduchšieho k zložitejšiemu.
- 2) Každá snímka má svoj osobitný vizuálny obsah (Tabuľka 23) a najmä jasové parametre sú odlišné medzi snímkami.
- 3) Pri spracovávaní viacerých snímok naraz je potrebná ground-truth informácia, ktorá nie je súčasťou sád A a B.

4.1 PROBLEMATIKA ŠUMU, FILTROVANIA A TRANSFORMOVANIA OBRAZU

Šum predstavuje fundamentálny problém pri extrahovaní zmysluplnej informácie zo SEM obrázkov [52-53], pretože spolu s inými degradáciami značne komplikujú segmentáciu [54] a zároveň je jedným z aspektov posudzovania kvality obrazovej informácie. Boli identifikované základné **princípy na odstránenie šumu** [54]: smoothing, edge-preserving smoothing, diffusion, optimization. Potrebnou vlastnosťou pri odstraňovaní šumu je nezmenenie originálneho obrázku, čo veľké množstvo filtrov nie je schopné dodržať. Dochádza často pri odstraňovaní šumu aj k neželanému rozostreniu obrázku či k tvorbe neželaných artefaktov najmä v blízkosti hrán [55-57].

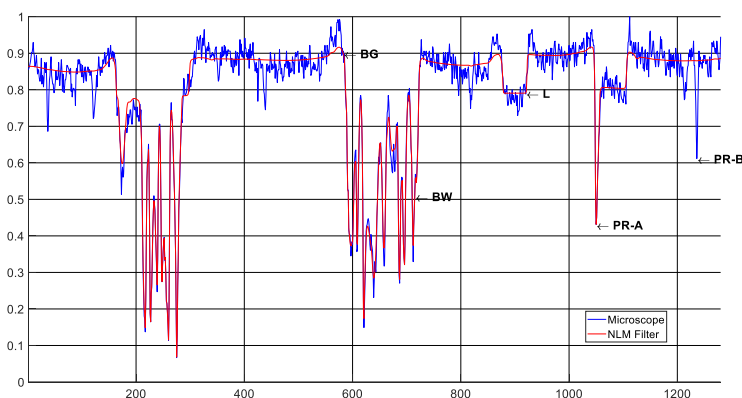
Každú úpravu obrázku možno definovať pojmom **transformovanie**, pričom jeden konkrétny typ je práve filtrovanie. Súhrne sú pre potreby práce uvedené v Tabuľka 28 aj s referenciou na konkrétny typ vizuálneho atribútu, kam je ich činnosť primárne smerovaná. Z pohľadu reprezentácie každého pixelu na obrázku je uvažovaná len elevácia – skalár.

Tabuľka 28 Vzájomné vzťahy medzi filtrovaním a transformovaním obrazu

	Názov	Vizuálny atribút	Analógia: ľudská tvár
1	klasické filtrovanie (estetické)	klasický šum (šum)	oholenie fúzov
2	technické filtrovanie (nivelácia)	verné zobrazenie hladkých detailov (drift)	face lifting
3	cielené a účelové deformovanie	elevácia regiónov (channelling contrast) a kolmosť hrán	chirurgická operácia, silný fyzický úder

4.1.1 Klasické filtrovanie


Činnosť NLM filtra je znázornená na Obr. 40 pre jeden riadok z obrázku 0% Sn a zoom 4000. Originálne dáta z mikroskopu sú modré, filtrované sú červené. Označení sú vždy po jednom zástupcovi z tried BG, BW a L. Rovnako je označený aj precipitát PR-A, ktorý prežil filtráciu a precipitát PR-B, ktorý odfiltrovaný. Je vidno, že filtrácia spôsobila len nepatrné zmeny na BW segmentoch. Na okrajoch BG segmentov sú zrejme drobné vyvýšenia, ktoré predstavujú biele lemy. Z priebehov jednotlivých útvarov je možno pozorovať, že tieto nie sú úplne vodorovné.



Obr. 40 Činnosť NLM filtrácie [1]

4.1.2 Technické filtrovanie

Nevodorovnosť útvarov dáva podnet na uplatnenie nivelácie technického filtra. Táto činnosť je znázornená na Obr. 41 pre úplný stĺpec z obrázku 0% Sn a zoom 4000. Dáta po základnej NLM filtrácii sú modré. Pri ich skúmaní pomocou absolútnej hodnoty gradientu sú nájdené jeho maximá. Po selekcii prejdú len významné maximá – v dolnej časti fialová. Úsek čiarového priebehu medzi takýmito maximami je následne spriemerovaný (znivelovaný) – fialová čiarkovaná.



Obr. 41 Činnosť nivelácie technického filtra pre stĺpec [1]

Hlavným zmyslom činnosti technického filtra je prehĺbovanie histogramu (histogram deepening). Po segmentácii a klasifikácii obrázku tento samotný transformovaný už nie je viac potrebný.

4.1.3 Optimalizácia MFA

Odborná literatúra uvádza optimalizáciu MFA pri minimalizovaní hamiltoniánu definovaného nasledovne [54]:

$$H = H_N + H_P \quad (5)$$


$$H = \sum_i \frac{(g_i - f_i)^2}{2\sigma^2} - \frac{b}{\tau\sqrt{2\pi}} \sum_i \left(\exp\left(-\frac{\left(\frac{\partial f}{\partial x}\right)^2}{2\tau^2}\right) + \exp\left(-\frac{\left(\frac{\partial f}{\partial y}\right)^2}{2\tau^2}\right) \right) \quad (6)$$

$$H = \sum_i \frac{(g_i - f_i)^2}{2\sigma^2} - \frac{b}{\tau\sqrt{2\pi}} \sum_i \left(\exp\left(-\frac{(f \otimes h_x)^2}{2\tau^2}\right) + \exp\left(-\frac{(f \otimes h_y)^2}{2\tau^2}\right) \right) \quad (7)$$

H_N – noise term, H_P – prior term, f – obrázok pred poškodením, g – obrázok po poškodení, i – index i -tého pixelu (zoradenie do vektora), σ – váha šumu, b – váha vodorovných úrovní a teda hrán, ktoré ich budú oddeľovať, τ – analógia s teplotou zo simulovaného žihania. Na voľbe prior term závisí typ obrázku pred poškodením (tu: **po častiach konštantný obrázok**) – napr. z dôvodu potreby dosiahnuť efekt histogram deepening.

Akákoľvek funkcia f , ktorej parciálne derivácie v smere x a y budú nulové, bude minimalizovať časť prior. Šumová časť bude mať svoj príspevok. Ak by táto časť neexistovala, potom by sa cez 3D priebeh funkcie g preložila vo „vhodnej“ výške vodorovná plocha. Príspevky nad a pod by boli rovnaké – akýsi pomyselný priemer. Práve šumová časť rozbíja toto primitívne riešenie, pretože hľadaná funkcia f sa z jednej strany snaží verne kopírovať pôvodný (zašumený) priebeh g ale z druhej strany je naopak penalizovaná za nevodorovnosť svojho aktuálneho stavu. Výsledkom by mal byť „kompromis“ a teda minimalizácia celkovej penalizácie, ktorá je zložená zo šumovej časti a prior časti (tu: vodorovnosť) – snaha o nájdenie odšumenej a po častiach vodorovnej funkcie f . Toto hľadanie má iteratívny charakter, kedy sa postupne f mení a znovu aktuálnejšia vstupuje do ďalšieho iteratívneho kroku.

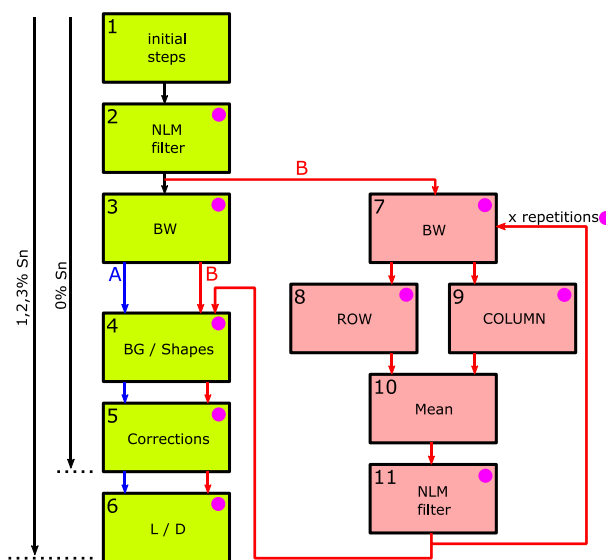
Na Obr. 54 bežal proces len pre jeden stĺpec po tristú iteráciu s časom 17,56 s – potlačený drobný šum ale len na úroveň ešte menších oscilácií. Väčšie precipitáty zostali nedotknuté. Všetko pri daných konkrétnych parametroch (σ , b , τ). Žiaľ, nedochádza k želanému efektu vodorovnosti.



Obr. 54 Optimalizácia MFA – jeden stĺpec, iterácia 300 – čas 17,56 s

4.2 SKALÁRNY MODEL – SEMIAUTOMATICKÝ ALGORITMUS

Na Obr. 51 je znázornená bloková schéma segmentácie a klasifikácie:



Obr. 51 Schéma segmentácie a klasifikácie: semiautomatický algoritmus [1]

Aplikované sú dve metódy:

- 1) level thresholding a morfologické operácie – útvary BW – bloky 3 a 7
- 2) global histogram thresholding – útvary BG, L a D – bloky 4 a 6

Vstupom sú raw data. Jednotlivé bloky sú označené číslami kvôli jednoduchej referencii. Bloky s fialovým kruhom vpravo hore obsahujú konfiguračné parametre, ktoré možno nastavovať. Tieto boli prednastavené na základe expertízy počas vývoja daného algoritmu. Predstavujú tak vlastne a priori K a zároveň bias. Zelené bloky 1, 2, 3, 4, 5, 6 reprezentujú variant bez aplikovania technického filtra, červené bloky 7, 8, 9, 10, 11 reprezentujú práve technický filter. Blok 6 sa uplatní v závislosti na chemickom zložení (% Sn). Voľba aplikovania technického filtra je vyslovene len na uvážení užívateľa.

4.3 VEKTOROVÝ MODEL – CLUSTERING

Štatistický prístup v zmysle Haralick používa príznaky, ktoré sú založené na tzv. intermediate dátových štruktúrach nazvaných GLCM matice [37,58]. Mnohé príznaky navzájom spolu súvisia. Finálnym cieľom je získanie textúrneho vektoru (feature vector, descriptor).

Mnohé parametre pri tvorbe a spracovaní GLCM matice je potrebné prácne zisťovať systémom pokus-omyl [58-59] a nemožno teda hovoriť vo všeobecnosti o nejakom zautomatizovaní úlohy počas ich tvorby [43]: kvantizácia intenzitných úrovní vstupného obrázku, veľkosť okna, vzdialenosť, uhol, normalizácia príznakov.

5 ZHODNOTENIE RIEŠENÍ VÝSKUMNÝCH OKRUHOV

Vyhodnotenie výsledkov klasickej filtrácie bolo zrealizované systémom kvalifikovaného odhadu najmä prostredníctvom výrezov z jednotlivých obrázkov v okolí hrán. Následne boli účinky filtrácie overené aj pomocou čiarových priebehov na vytipovaných miestach. Zvýšená pozornosť bola nutná najmä pri číselne menších hodnotách zoom.

Na vyhodnocovanie presnosti segmentácie a klasifikácie bol použitý systém kvalifikovaného odhadu. Presnosť je teda odhadnutý pomer správne klasifikovaných pixelov ku všetkým pixelom na obrázku. Súčasťou výsledkov sú aj masky jednotlivých tried. Na základe počtu pixelov v jednotlivých maskách je vypočítaný ukazovateľ phase quantification PQ. Vyhodnocovanie úrovne zoom 4000 bolo relatívne ľahké a príjemné. Náročným bol práve zoom 1000, kde bolo potrebné sa vyslovene práčne a namáhavo koncentrovať na drobné obrazové detaily. Z pohľadu chemického zloženia boli najnáročnejšími práve 1 a 2% Sn, menej náročným bol podiel 3% Sn a samozrejme najľahším bol podiel 0% Sn.

5.1 PROBLEMATIKA ŠUMU, FILTROVANIA A TRANSFORMOVANIA OBRAZU

Po určitom experimentovaní s viacerými typmi filtrov bol zvolený NLM filter. Poskytoval kvalitnú filtráciu šumu, časti precipitátov a škrabancov. Užívateľ tak dostane k dispozícii predpokladanú ground-truth informáciu elevačného modelu – plochu v priestore. Výsledné parametre NLM filtra pre každú úroveň zoom boli zistené experimentálne, predstavovali kompromis medzi silou filtra a šetrnosťou k hranám útvarov a je možné ich ľahko upraviť v prípade potreby v budúcnosti či už z dôvodu zmeny skenovacej rýchlosti alebo pri zmene hodnôt zoom. Práca uvádza časové nároky behu v Tabuľka 31. K jeho výhodám patria: ľahko nastaviteľné parametre, filter nie je iteratívny, kvalitné výsledky za rozumný spotrebovaný čas. Po kvalitne zvládnutej segmentácii a klasifikácii umožní skúmanie jeho výstupu kvantitatívnu a kvalitatívnu analýzu pre vedu o materiáloch.

Štatistické skúmanie výsledkov technického filtra viedlo k praktickým záverom, že vo vybraných prípadoch dokáže spresniť segmentáciu a následnú klasifikáciu o približne 1 až 3 %. K jeho nevýhodám patria najmä: neexistencia odporúčania na jeho použitie, rôzne účinky pri rôznych hodnotách zoom a chemického podielu %Sn, možný vznik artefaktov v blízkosti hrán.

Implementácia optimalizácie MFA sa neosvedčila z nasledovných dôvodov: značné časové nároky na beh, iteratívnosť, slabšie filtračné výsledky v porovnaní s NLM filtrom, problematická náhrada parciálnych derivácií kernelom.


5.2 SKALÁRNY MODEL – SEMIAUTOMATICKÝ ALGORITMUS

Tabuľka 39 sumarizuje dosiahnuté výsledky prostredníctvom semiautomatického algoritmu za celú sadu A (180 obrázkov). Väčšina z nich bola spracovaná s prednastavenými konfiguračnými parametrami bez použitia technického filtra, niektoré však bolo potrebné ručne viackrát ladiť. Takýmto spôsobom bolo možné dosiahnuť individuálne zlepšenie až o približne 20%. XRD dáta boli použité ako benchmark.

Tabuľka 39 Porovnanie výsledkov s XRD, sada A [1]

Sn [%]	Obrázky	PQ \pm Std.Dev [%]	XRD \pm Std.Dev [%]
0	45	BG: 66.01 ± 2.01	BG: 66.30 ± 1.50
		BW: 3.37 ± 0.95	BW: 5.50 ± 0.40
		L: 30.62 ± 2.23	L: 28.30 ± 0.50
		Presnosť: 98.12 ± 0.74	
1	45	BG: 72.31 ± 3.78	BG: 73.10 ± 1.00
		BW: 3.16 ± 0.82	BW: 4.90 ± 0.10
		L: 19.19 ± 3.52	L: 19.20 ± 0.20
		D: 5.34 ± 1.40	D: 2.80 ± 0.30
		Presnosť: 95.43 ± 3.64	
2	45	BG: 75.58 ± 4.17	BG: 78.90 ± 1.80
		BW: 3.29 ± 0.69	BW: 5.00 ± 0.10
		L: 12.93 ± 4.60	L: 11.80 ± 0.60
		D: 8.21 ± 1.50	D: 4.30 ± 0.50
		Presnosť: 95.22 ± 3.39	
3	45	BG: 78.93 ± 2.63	BG: 83.60 ± 2.00
		BW: 5.20 ± 1.08	BW: 4.20 ± 0.50
		L: 7.05 ± 1.65	L: 5.30 ± 1.10
		D: 8.82 ± 1.64	D: 6.90 ± 0.80
		Presnosť: 95.56 ± 1.94	

Na Obr. 55 je výrez z obrázku 3% Sn, zoom 4000. Originál je vľavo, maskovaný originál je v pravej časti. Biela farba predstavuje triedu BG, červená farba triedu BW, zelená farba triedu L a na záver modrá farba triedu D.



Obr. 55 Segmentácia a klasifikácia, maska tried [1]

Predstavený algoritmus obsahuje množstvo konfiguračných hodnôt. Tieto boli prednastavené počas vývoja algoritmu. Pre veľký podiel obrázkov zo sady A pracovali dostatočne presne, v prípade potreby ich možno ručne zmeniť. Na základe uvedeného možno skonštatovať, že možnosti skalárneho elevačného modelu sa vyčerpali. Vo vybraných prípadoch (najmä 0% Sn a zoom 4000) ho možno dokonca zautomatizovať. Ale vzhľadom na obsiahlosť zadania (kategórie Sn, kategórie zoom) je vo všeobecnosti nutná prítomnosť človeka v jednotlivých krokoch semiautomatického algoritmu, aby posúdil adekvátnosť dosiahnutých výsledkov, odčítal hodnoty threshold alebo zmenil konfiguračné hodnoty v algoritme.

Kľúčovým aspektom je použitie **global histogram thresholding**, ktorý vychádza zo základného princípu, že intenzitné hodnoty majú svoj význam rovnaký v celom obrázku. Toto platí pri jednom pozadí (nedochádza k channelling contrast) a za predpokladu relatívnej vodorovnosti útvarov. Akonáhle sú prítomné viaceré pozadia resp. presnejšie kontrastné rozdiely pozadí a nevodorovnosti útvarov dosiahnu nezanedbateľnú hodnotu, sú porušené podmienky aplikovania global histogram thresholding a nutne dochádza k chybám.

Po nutnej ručnej úprave výstupu semiautomatického algoritmu možno tento použiť výhodne pre prípravu tréningovej sady pre hlboké učenie.

5.3 VEKTOROVÝ MODEL - CLUSTERING

Systémom viacnásobného skúmania rôznych parametrov pre jednotlivé útvary BG, L, D a BW v záujmových bodoch na obrázkoch boli stanované parametre uvedené v práci. Výpočet príznakov je časovo náročný, pričom táto náročnosť nie je rozdelená medzi príznakmi rovnomerne. Pre príznaky F02 až F21 je potrebných približne 13 hodín za celý mikroskopický obrázok. Podobne sada príznakov F02, F07, F18, F19 spotrebuje 2,8 hodiny. Sada príznakov F22 až F24 len asi 1 sekundu. Mnohé príznaky sú medzi sebou do značnej miery závislé.

Ako rozhodovacie algoritmy boli odskúšané tri rôzne typy plytkých neurónových sietí LVQ, SOM a PNET v rôznych konfiguráciách, tréňované pomocou rôznych tréningových algoritmov a na rôznych sádach príznakov.

LVQ je dvojvrstvová sieť. Prvá vrstva mapuje vstupné vektory do zhlukov, ktoré sú druhou vrstvou pridelené jednotlivým triedam. Celkový počet zhlukov je daný počtom neurónov v 1D topológii prvej vrstvy. Učenie s učiteľom. V práci použité: LVQ36 (36 neurónov v prvej vrstve) a LVQ225 (225 neurónov v prvej vrstve). Nevýhody: nekvalita výsledkov, veľký tréningový čas.

SOM je jednovrstvová sieť slúžiaca na rozdelenie vstupných dát do zhlukov na základe ich podobnosti a topológie vrstvy (počet neurónov a väzby medzi nimi). Učenie bez učiteľa. Boli postupne vyskúšané 1D, 2D a 3D topológie vrstvy – zvolená bola finálna 2D podoba. V réžii autora práce bola prevodová tabuľka zhlukov na triedy. Priebežne počas experimentovania boli vyhodnocované čistota zhlukov a prázdnota zhlukov. V práci použité: SOM900 (900 neurónov v prvej vrstve v 2D topológii: 30 x 30) a SOM1600 (1600 neurónov v prvej vrstve v 2D topológii: 40 x 40). Vlastnosti: rel. veľké požiadavky na operačnú pamäť, dlhší čas tréovania a aplikovania, niektoré kvalitatívne vlastnosti výsledkov sú lepšie ako pri PNET. Účel: najmä experimentovanie s viacrozmernými priestormi.

PNET je viacvrstvový perceptron pozostávajúci zo skrytých vrstiev a jednej výstupnej vrstvy. Učenie s učiteľom. V práci použité: PNET100 (dve skryté vrstvy, každá po 10 neurónov) a PNET8000 (tri skryté vrstvy, každá po 20 neurónov). Vlastnosti: malé požiadavky na operačnú pamäť, krátky čas tréovania a aplikovania, odlišnosť kvalitatívnych vlastností výsledkov pri porovnaní so SOM. Účel: najmä priame použitie.

Analýza zhlukov mala slúžiť podľa nasledovného postupu: pomocou semiautomatického algoritmu pripraviť pre problémovú kategóriu (sada, chemická úroveň Sn, zoom) aspoň jeden správne klasifikovaný obrázok resp. jeho výrez, s možnou ručnou korekciou výsledkov, a túto kombináciu použiť pre natréovanie plytkej neurónovej siete za účelom plne automatickej klasifikácie danej kategórie obrázkov. Na niektorých obrázkoch je možné takýto postup úspešne prevádzkovať ale vo všeobecnosti je nutné skonštatovať, že z dôvodu vnútroobrázkových (channelling contrast, nevodorovnosť útvarov) a medziobrázkových (histogram shift) záležitostí nie je možné dosiahnuť plne automatickú prevádzku v zmysle použitia príznakov uvedených v práci.

Počas modelovania nastala redukcia použiteľných príznakov a následne ich prílišná závislosť na elevácii, čo implikovalo problém prítomný už pri skalárnom modeli hoci v o niečo menšom merítke – reprezentačný problém. Zlepšenie bolo prítomné pre triedu BW. Pri sade A možno v zmysle Tabuľka 39 predpokladať výslednú lepšiu segmentáciu a klasifikáciu BW útvarov o asi 1% (vzhľadom na celý obrázok). Semiautomatický algoritmus odprezentovaný na Obr. 51 by bol teda v blokoch 3 a 7 upravený. Intenzitný level thresholding by bol nahradený analýzou zhlukov prostredníctvom PNET100 natréovanou na príznakoch F01(0~1), F22LOG, F23LOG, F24LOG. Morfologické operácie by boli zachované resp. upravené.

5.4 SPOLOČNÉ

Zmysel pojmu **spatial context** zohral významnú úlohu. V prípade klasického filtra a príznakov vo vektorovom modeli sa jednalo o priame nastavenie pracovného okna. V prípade technického filtra to bolo nepriame nastavenie pomocou hodnoty maxim gradientov.

Samostatným problémom v práci bola úvaha o automatickom zisťovaní charakteru vstupných raw data. Tento charakter sa mohol týkať aj **kvality vstupných dát** v zmysle šumu či škrabancov. V práci bol uvedený problém posudzovania automatickým ale i manuálnym spôsobom bez referencie. Na druhom mieste by bolo možné uviesť automatické zisťovanie **lokálnych prejavov dát**. Tu zostávajú dva hlavné problémy. Prvým je zabezpečenie rozdelenia celkovej množiny dát do jednotlivých skupín, keďže vopred nie je známy počet skupín a ani ich ďalšie vlastnosti. Druhým je v niektorých prípadoch prílišná variabilita scény a z nej vyplývajúci fakt class imbalance.

Na začiatku kapitoly 4 boli predstavené dôvody, prečo práca uvažuje so spracovávaním každej mikroskopickkej snímky zvlášť. Je možné, že dostatočne kvalitné vyriešenie zadania dizertačnej práce si jednoducho bude žiadať upustenie od tohto princípu a potrebu dodatočnej novej informácie – zapracovanie nového kontextu akéhokoľvek typu a to buď v explicitnej forme alebo v implicitnej forme. Z pohľadu CV je práve explicitné formulovanie zákonov riešenej problematiky veľký problém, lebo heterogenita dát v rámci modality (intra-class a inter-class) môže znamenať až nemožnosť explicitného formulovania takéhoto kontextu.

Hlboké neurónové siete boli vyvinuté práve z dôvodu neschopnosti stanovenia explicitného kontextu a nemožnosti riešenia implicitného kontextu vo forme určitej pravidelnosti. Novým významným prvkom je asociatívna pamäť a prostredníctvom nej tvorba world model. Z dôvodu data-hungry požiadaviek prišlo k popisu **hyperkocky problematiky** pri časových nárokoch 4 hodiny na 300 snímok:

zloženie x zoom x lokácia x (operátor+mikroskop) x príprava x počet snímok v kategórii

$$rozsah = (4 \times 3 \times 9 \times 6 \times 3) \times 1000 = 1944000 \text{ ks snímok} \quad (8)$$

$$1944000 \times \frac{4}{300} = 25920 \text{ hodín} \rightarrow \frac{25920}{8 \text{ (zmena)}} = 3240 \text{ dní} \rightarrow \frac{3240}{365} = 8,9 \text{ roku} \quad (9)$$

Uvedené predstavuje pesimistický variant.

Zrejme by bolo potrebné uvažovať s profesionálnou HW výbavou (dotyková obrazovka a pero) a vopred pripraveným GUI rozhraním pre rýchlu, pohodlnú a kvalitnú ručnú editáciu takto zosnímaných obrázkov z mikroskopie. Rovnako bude nutné zvážiť potrebný výpočtový výkon (GPU, operačná pamäť) pri tréningu resp. aplikovaní.

Vzhľadom na črtajúci sa rozsah výkonov, ktoré by bolo nutné vykonať pri riešení tejto problematiky prostredníctvom hlbokého učenia je potrebné rozlišovať medzi „sviatočným“ riešením a „komerčným“ (pragmatickým, opodstatneným). Komerčné zadanie by vyžadovalo čo najpresnejšie popísať konkrétne výrobné a prevádzkové podmienky zliatiny (vyhnutie sa dataset shift a zníženie rozsahu trénovacej sady), poskytnutie predpokladaného výpočtového výkonu a zabezpečenie technologických podmienok (úzke miesto, personál).

Aj keby časová požiadavka na zrealizovanie snímok klesla 100krát (32,4 dňa), je potrebné si uvedomiť, že v univerzitných podmienkach nebude možné dedikovať úzke miesto len na jeden takýto projekt a teda reálne by sa daný termín natiahol kvôli hodinám, kedy by bolo technologické pracovisko venované iným účelom. Z prieskumu odbornej literatúry týkajúcej sa hlbokého učenia možno posúdiť nasledovné fakty:

1. skúmaná látka [60] – kovy (dendrity vs. nedendrity), nekovy, rôzne modality
2. rôznorodosť úloh [61] – semantic vs. instance segmentation
3. reálnosť obrazovej informácie – simulovanie vs. reálnosť
4. rôzne typy data augmentation [62] – Vo všeobecnosti je data augmentation nápomocné, ale nie všetky jeho typy majú priaznivý výsledný účinok. Zvlášť problematické boli reportované zmeny v jase a kontraste, s dôležitou poznámkou, že operátori mikroskopu majú svoje vlastné obľúbené preferencie. Data augmentation viac ovplyvňuje target domain ako source domain.
5. rôzne úrovne zoom [63]
6. veľkosť sady obrázkov zo zobrazovacej modality [60, 63-64]
7. tiling a stitching [64]
8. ohraničenosť rozmerov útvarov [61]
9. typy resp. rodiny hlbokých sietí [64]
10. dostupnosť dát, sietí
11. typ domény predtrénovaných dát [62, 65] – Porovnanie presnosti hlbokých sietí predtrénovaných na veľkom množstve obrázkov z rozdielnej domény vs. predtrénovaných na malom množstve obrázkov z rovnakej resp. veľmi podobnej domény. Daný fenomén nesie názov domain generalizability across data sets (source domain, target domain).

Problémom je nájdenie spoločnej porovnávacjej bázy v problematike. Niektoré fakty spolu navzájom súvisia. Napríklad opodstatnená ohraničenosť rozmerov útvarov (8.), ktorá je odvodená od úrovne zoom (5.), má súvis s rozčlenením obrázkov mikroskopie na menšie dlaždice (7.). Pre optimistickejší variant hovoria fakty (4.), (7.) a (11.).

6 PRÍNOSY DIZERTAČNEJ PRÁCE A ZÁVER

Hlavným cieľom dizertačnej práce bolo navrhnutie, implementovanie a overenie segmentačných a klasifikačných algoritmov SEM BSE mikroštruktúr kovovej zliatiny Zn-Al-Mg-Sn s prihliadnutím na kompromis medzi kvalitou dosiahnutých výsledkov a časovými i kapacitnými nákladmi na ich dosiahnutie. V nasledujúcej časti sú zhrnuté výsledky a najdôležitejšie prínosy dizertačnej práce pre oblasti: teória, prax a veda.

Prínosy dizertačnej práce pre teóriu:

- Boli identifikované kľúčové problémy súvisiace s úlohou z teoretického hľadiska v úvode časti 3.
- Bol identifikovaný reťazec premeny jednotlivých dátových druhov v rámci modality SEM BSE na Obr. 38.

Prínosy dizertačnej práce pre prax:

- Práca bola priekopnícka z pohľadu súčasných viacerých úrovní chemického zloženia (% Sn) a viacerých úrovní zoom. Autorom dizertačnej práce nebola zistená doposiaľ publikovaná literatúra podobného rozsahu. Práca dala k dispozícii dáta a algoritmy.
- Boli overené praktické výsledky a efekt spolupráce strán technológia a počítačové videnie tak, ako jednoznačne odporúča odborná literatúra: logický faktor segmentácie, tvorba dátovej sady, overenie materiového driftu.
- Chyby prítomné vo výsledkoch semiautomatického algoritmu poukazujú na potrebný charakter raw data, ktoré budú vyžadované pri príprave trénovacej sady pri prípadnom nasadení DL.
- Boli identifikované základné druhy vizuálnych atribútov raw data v Tabuľka 22.
- Boli identifikované faktory vplývajúce na výsledný vizuálny obsah raw data v Tabuľka 23. Tieto faktory boli rozčlenené na objektívne a subjektívne. Bol teda použitý iný, nový systém členenia ako v publikovanej odbornej literatúre, keďže tento potrebám práce nevyhovoval.
- Boli demonštrované aspekty aplikovania spatial context na konkrétny typ dát.
- Boli identifikované časové nároky behu jednotlivých výpočtových operácií.
- Bola predstavená hyperkocka problematiky potrebná v prípade riešenia trénovacej sady pre hlboké učenie.

Prínosy dizertačnej práce pre vedu:

- Bolo odstránené úzkeho miesta v technologickom procese. V prospech predstaveného prístupu hovoria jednoznačne rýchlosť akvizície dát, rozlíšenie obrazovej informácie, povaha informačného obsahu a možnosť spracovania aj archívnej dokumentácie v prípade neexistencie vzorky. Vzhľadom na semiautomatizovaný algoritmus zatiaľ splnené čiastočne.
- Bol overený materiálny drift v podobe reálneho prejavu v materiáli a nie v podobe závislosti zobrazovacieho procesu.

Splnenie hlavného cieľa bolo podmienené jednotlivými čiastkovými cieľmi:

1. **Analyzujte súčasný technologický stav v oblasti spracovania dát získavaných v elektrónovej mikroskopii s primárnym zameraním sa na modalitu SEM BSE.** Bolo uvedené opodstatnenie dizertačnej práce z pohľadu technológie a súvis s inými modalitami na jej riešenie. Po predstavení špecifik zvolenej modality sa ďalej uviedli podmienky prípravy vzorky a mikroskopie, základný popis mikroštruktúry a funkcie hlavných aktérov prítomných počas výskumu. Z pohľadu spracovania obrazu mikroštruktúr boli identifikované trendy, náročnosti a z nich plynúce výzvy.
2. **Stručne charakterizujte prístupy použité v odbornej literatúre na riešenie analogických úloh.** Bol vytvorený prehľad predchádzajúcej publikačnej činnosti jednak priamo pre identický materiál, jednak pre podobné materiály a nakoniec pre materiály síce odlišné ale používajúce postupy, ktoré by mohli byť inšpiráciou pre zadanie práce. Daný materiál vzorky bol publikačne veľmi riedko zastúpený. Podobný materiál reportoval poznatok, že mikroštruktúry sú často komplexné a vyžadujú posudzovanie pri rôznych zväčšeniach. Vo zvyšných zdrojoch sa zdôrazňovalo aplikovanie vhodnej filtračnej metódy na odstránenie šumu a efekt histogram deepening.
3. **Na základe získaných analýz a charakteristík stanovte výskumné okruhy.** V práci vystupujú dve tréningové sady A a B. Tieto sa vyznačujú svojimi inherentnými problémami. Pre dôkladné pochopenie charakteristík vizuálnych raw data bolo nutné vytvoriť prehľad jednotlivých vizuálnych atribútov prítomných na obraze a klasifikovať faktory vplývajúce na výsledný obsah vizuálnych dát. Odborná literatúra jednoznačne podčiarkuje vzájomnú aktívnu spoluprácu zástupcov technológie a počítačového videnia. V rámci teórie spracovania vizuálnych dát boli identifikované kľúčové problémy, ktoré sú typické pre dizertačnú prácu.

4. **Navrhňte a implementujte rôzne prístupy/riešenia pre spracovanie vizuálnych dát aj s ohľadom na časové a kapacitné náklady.** Uvedené vizuálne atribúty vstupných raw data zohrávali významnú úlohu pri riešení jednotlivých výzkumných okruhov.
- Boli navrhnuté a implementované viaceré riešenia pre okruh klasickej filtrácie. Pre kvalitu svojho výstupu a jednoducho nastaviteľné parametre bol zvolený NLM filter.
- Pre komplexnejšie transformovanie obrazu bol navrhnutý a implementovaný technický filter. Implementácia optimalizácie MFA sa neosvedčila vôbec.
- V práci sú predstavené dva principiálne prístupy k segmentácii a klasifikácii: elevačný skalárny model a vektorový model. Po vyčerpaní možností skalárneho modelu bolo pristúpené k návrhu a implementácii jednej z viacerých možností analýzy textúry. Pri experimentovaní vo viacrozmernom priestore bola implementovaná plytká neurónová sieť typu SOM. Z dôvodu časových nárokov pri tréňovaní či aplikovaní je výhodnejšie pri nasadení prejsť na plytkú neurónovú sieť typu PNET.
- Pri aktuálne zvolenej sade príznakov sa dospelo k reprezentačnému problému. Daný vektorový model možno použiť len pre triedu BW. Je otázne, či je vôbec možné nájsť lepšiu sadu príznakov prípadne inými možnosťami analýzy textúry.
5. **Na základe návrhu, implementácie, overenia a zhodnotenia jednotlivých prístupov špecifikujte prínosy dizertačnej práce.** Uvedené v časti 6 a časti 7.

Na základe realizovaných čiastkových cieľov je možné skonštatovať, že hlavný stanovený cieľ dizertačnej práce bol splnený čiastočne v podobe semiautomatického algoritmu, ktorý významne uľahčí prípadnú aplikáciu hlbokého učenia v budúcnosti. Poznatky z dizertačnej práce by mali pomôcť pri stanovení obsahu snímok pri príprave tréňovacej sady. Je nutné podotknúť, že zo strany technológie bude musieť v takom prípade prísť k uvedomeniu si rozsahu predostretej problematiky popísanej prostredníctvom hyperkocky, upresniť podmienky zadania kvôli vyhnutiu sa prípadnému problému dataset shift a v neposlednej miere zväžiť pragmatický aspekt úlohy.

ZOZNAM PUBLIKAČNEJ ČINNOSTI**V2 Vedecký výstup publikačnej činnosti ako časť editovanej knihy alebo zborníka**

V2_01 KUCHÁR, Daniel - BARTONĚ, Martin - SCHREIBER, Peter - TANUŠKA, Pavol. Matlab Code Generation and Consumption. In *Intelligent Algorithms in Software Engineering : Proceedings of the 9th Computer Science on line Conference, Volume 1, CSOC 2020*. 1. vyd. Cham : Springer, 2020, S. 261-273. ISSN 2194-5357. ISBN 978-3-030-51964-3 (print). V databáze: DOI: 10.1007/978-3-030-51965-0_22 ; SCOPUS: 2-s2.0-85089715702.
Kategória publikácie do 2021: AFC

V2_02 KUCHÁR, Daniel - SCHREIBER, Peter. Comparison of UAV landing site classifications with deep neural networks. In *Artificial Intelligence in Intelligent Systems : proceedings of 10th Computer Science On-line Conference 2021, Vol. 2*. 1. vyd. Cham : Springer, 2021, S. 55-63. ISSN 2367-3370. ISBN 978-3-030-77444-8. V databáze: DOI: 10.1007/978-3-030-77445-5_6 ; SCOPUS: 2-s2.0-85115836753.
Typ výstupu: príspevok z podujatia; Výstup: zahraničný; Kategória publikácie do 2021: AFC

V2_03 KUCHÁR, Daniel - SCHREIBER, Peter. Intersection as an event and agent-based system. In *Artificial Intelligence in Intelligent Systems : proceedings of 10th Computer Science On-line Conference 2021, Vol. 2*. 1. vyd. Cham : Springer, 2021, S. 45-54. ISSN 2367-3370. ISBN 978-3-030-77444-8. V databáze: DOI: 10.1007/978-3-030-77445-5_5 ; SCOPUS: 2-s2.0-85115822753.
Typ výstupu: príspevok z podujatia; Výstup: zahraničný; Kategória publikácie do 2021: AFC

V3 Vedecký výstup publikačnej činnosti z časopisu

V3_01 KUCHÁR, Daniel - GOGOLA, Peter - GABALCOVÁ, Zuzana - NÉMETHOVÁ, Andrea [Peterková Andrea] - NÉMETH, Martin. Segmentation and Classification of Zn-Al-Mg-Sn SEM BSE Microstructure. In *Applied Sciences*. Vol. 13, iss. 2 (2023), s. 1-21. ISSN 2076-3417 (2021: 2.838 - IF, Q2 - JCR Best Q, 0.507 - SJR, Q2 - SJR Best Q). V databáze: DOI: 10.3390/app13021045 ; SCOPUS: 2-s2.0-85146732769 ; WOS: 000916715700001 ; CC: 000916715700001.
Typ výstupu: článok; Výstup: zahraničný; Kategória publikácie do 2021: ADC

V3_02 NIKMON, Marcel - BUDJAČ, Roman - KUCHÁR, Daniel - SCHREIBER, Peter - JANÁČOVÁ, Dagmar. Convolutional networks used to classify video and audio data. In *Vedecké práce MTF STU v Bratislave so sídlom v Trnave. Research papers Faculty of Materials Science and Technology Slovak University of Technology in Trnava*. Vol. 27, no. 45 (2019), s. 113-120. ISSN 1336-1589. V databáze: DOI: 102478/rput-2019-0034 ; INSPEC.
Kategória publikácie do 2021: ADF

Štatistika: kategória publikačnej činnosti od 2022

V2	Vedecký výstup publikačnej činnosti ako časť editovanej knihy alebo zborníka	3
V3	Vedecký výstup publikačnej činnosti z časopisu	2
Súčet		5

ZOZNAM BIBLIOGRAFICKÝCH ODKAZOV

1. Kuchar, D.; Gogola, P.; Gabalcova, Z.; Nemethova, A.; Nemeth, M. Segmentation and Classification of Zn-Al-Mg-Sn SEM BSE Microstructure; MDPI applied sciences, 2023; DOI: 10.3390/app13021045; pp. 1-20.
2. Goldstein, J.I.; Newbury, D.E.; Michael, J.R.; Ritchie, N.W.M.; Scott, J.H.J.; Joy, D.C. Scanning Electron Microscopy and X-Ray Microanalysis, 4th ed.; Springer Science+Business Media LLC: New York, USA, 2018; pp. 2, 15-37.
3. Amelinckx, S.; van Dyck, D.; van Landuyt, J.; van Tendeloo, G. Electron Microscopy Principles and Fundamentals; VCH Verlagsgesellschaft mbH: Weinheim, Germany, 1997; pp. 315.
4. Bowen, D.K.; Hall, C.R. Microscopy of Materials Modern Imaging Methods Using Electron, X-ray and Ion Beams; The MacMillan Press LTD: London, UK, 1975; pp. 7.
5. Dehm, G.; Howe, J.M.; Zweck, J. In-Situ Electron Microscopy Applications in Physics, Chemistry and Materials Science; Wiley-VCH Verlag & Co. KGaA: Weinheim, Germany, 2012; pp. 19-44.
6. Ul-Hamid, A. A Beginners' Guide to Scanning Electron Microscopy; Springer Nature Switzerland AG: Cham, Switzerland, 2018; pp. 15-76, 83, 309-358.
7. Geels, K.; Fowler, D.B.; Kopp, W.-U.; Rückert, M. Metallographic and Materialographic Specimen Preparation, Light Microscopy, Image Analysis and Hardness Testing; ASTM International: West Conshohocken, USA, 2007; pp. 1-521.
8. Lyman, Ch.E.; Newbury, D.E.; Goldstein, J.I.; Williams, D.B.; Roming Jr., A.D.; Armstrong, J.T.; Echlin, P.; Chiori, Ch.E.; Joy, D.C.; Lifshin, E.; Peters, K.-R. Scanning Electron Microscopy, X-Ray Microanalysis, and Analytical Electron Microscopy A Laboratory Workbook; Plenum Press: New York, USA, 1990; pp. 159-171.
9. Murr, L.E. Electron and Ion Microscopy and Microanalysis Principles and Applications, 2nd ed.; CRC Press: Boca Raton, USA, 2018; pp. 711-752.
10. Echlin, P. Handbook of Sample Preparation for Scanning Electron Microscopy and X-Ray Microanalysis; Springer Science+Business Media, LLC: New York, USA, 2009; pp. 235-299.
11. Laughlin, D.E.; Hono, K. Physical Metallurgy Volume 2, 5th ed.; Elsevier B.V.: Amsterdam, Netherlands, 2014; pp. 1073.
12. Cahn, R.W.; Haasen, P. Physical Metallurgy Volume 1, 4th ed.; Elsevier Science B.V.: Amsterdam, The Netherlands, 1996; pp. 921.
13. Russ, J.C. Image Analysis of Food Microstructure; CRC Press: Boca Raton, USA, 2005; pp. 74, 215.
14. Ercetin, A.; Akkoyun, F.; Simsir, E.; Pimenov, D.Y.; Giasin, K.; Chandrashekarappa, M.P.G.; Lakshmikanthan, A.; Wojciechowski, Sz. Image Processing of Mg-Al-Sn Alloy Microstructures for Determining Phase Ratios and Grain Size and Correction with Manual Measurement. MDPI Materials 2021; DOI: 10.3390/ma14175095; pp. 1-6.
15. Chalusiak, M.; Nawrot, W.; Buchanec, Sz.; Brus, G. Swarm Intelligence-Based Methodology for Scanning Electron Microscope Image Segmentation of Solid Oxide Fuel Cell Anode. MDPI Energies 2021; DOI: 10.3390/en14113055; pp. 1-4, 7.

16. Holm, E.A.; Cohn, R.; Gao, N.; Kitahara, A.R.; Matson, T.P.; Lei, B.; Yarasi, S.R. Overview: Computer vision and machine learning for microstructure characterization and analysis. The Minerals, Metals & Materials Society and ASM International 2020; DOI: 10.1007/s11661-020-06008-4; pp. 1-20.
17. Campbell, A.; Murray, P.; Yakushina, E.; Marshall, S.; Ion, W. New methods for automatic quantification of microstructural features using digital image processing. Elsevier Materials and Design 2018; DOI: 10.1016/j.matdes.2017.12.049; pp. 395-396.
18. Wojnar, L. image analysis Applications in Materials Engineering; CRC Press: Boca Raton, USA, 1999; pp. 90, 130, 221.
19. Drouyer, S. 3D topography by image segmentation approach: application to scanning electron microscopy. Topographie 3D par approche segmentation : application au microscope électronique à balayage. Thèse de Doctorat de l'Université de recherche Paris Sciences et Lettres. 2017; pp. 22.
20. Bonnet, N. Some trends in microscope image processing. Elsevier Micron, 2004; DOI: 10.1016/j.micron.2004.04.006; pp. 635-649.
21. Luengo, J.; Moreno, R.; Sevillano, I.; Charte, D.; Pelaez-Vegas, A.; Fernández-Moreno, M.; Mesejo, P.; Herrera, F.; A tutorial on the segmentation of metallographic images: Taxonomy, new MetalDAM dataset, deep learning-based ensemble model, experimental analysis and challenges. Elsevier Information Fusion 2022; DOI: 10.1016/j.inffus.2021.09.018; pp. 232-253.
22. Gogola, P.; Gabalcová, Z.; Kusý, M.; Suchánek, H. The Effect of Sn Addition on Zn-Al-Mg Alloy; Part I: Microstructure and Phase Composition. MDPI Materials, 2021; DOI: 10.3390/ma14185404; pp. 1-13.
23. Li, C.; Wang, D. Application of Machine Learning Techniques in Mineral Classification for Scanning Electron Microscope – Energy Dispersive X-Ray Spectroscopy (SEM-EDS) Images. Elsevier Journal of Petroleum Science and Engineering, 2021; DOI: 10.1016/j.petrol.2020.108178; pp. 1-26.
24. Truglas, T.; Duchoslav, J.; Riener, C.; Arndt, M.; Commenda, C.; Stifter, D.; Angeli, G.; Groiss, H. Correlative characterization of Zn-Al-Mg coatings by electron microscopy and FIB tomography. Elsevier Materials Characterization, 2020; DOI: 10.1016/j.matchar.2020.110407; pp. 1-8.
25. Le Trong, E.; Rozenbaum, O.; Rouet, J.-L.; Bruand, A. A Simple Methodology to Segment X-Ray Tomographic Images of a Multiphasic Building Stone. Image Analysis & Stereology, 2014; DOI: 10.5566/ias.v27.p175-182 ; pp. 175-182.
26. Lew, M.S. Principles of Visual Information Retrieval; Springer-Verlag London, London, UK, 2001; pp. 144, 297.
27. Brownlee, J. Data Preparation for Machine Learning Data Cleaning, Feature Selection, and Data Transforms in Python; Copyright 2020 Jason Brownlee.
28. Zheng, A.; Casari, A. Feature Engineering for Machine Learning Principles and Techniques for Data Scientists; O'Reilly Media, Inc, Sebastopol, USA, 2018; pp. vii, 1, 3.
29. Gupta, D.; Bhattacharyya, S.; Khanna, A.; Sagar, K. Intelligent Data Analysis From Data Gathering to Data Comprehension; John Wiley & Sons Ltd, Chichester, UK, 2020.
30. Moens, M.-F. Information Extraction: Algorithms and Prospects in a Retrieval Context; Springer, Dordrecht, The Netherlands, 2006; pp. 4.

31. Dong, G.; Liu, H. Feature Engineering for Machine Learning and Data Analytics; Taylor & Francis Group, LLC, Boca Raton, USA, 2018; pp. xv, 1-3, 55-56.
32. Duboue, P. Feature Engineering Essentials for Machine Learning; Cambridge University Press, Cambridge, UK, 2020; pp. 7-9, 25-32.
33. Deserno, T.M. Biomedical Image Processing; Springer-Verlag Berlin, Berlin, Germany, 2011; pp. 3, 4.
34. Chen, M. Computer Vision for Microscopy Image Analysis; Elsevier, 2021; pp. 2-6.
35. Acharya, T.; Ray, A.K. Image Processing Principles and Applications; John Wiley & Sons, Inc, Hoboken, USA, 2005.
36. Castelli, V.; Bergman, L.D. Image Databases Search and Retrieval of Digital Imagery; John Wiley & Sons, Inc., New York, New York, USA, 2002.
37. Cagnoni, S.; Lutton, E.; Olague, G. Genetic and Evolutionary Computation for Image Processing and Analysis; Hindawi Publishing Corporation, New York, USA, 2007.
38. Haindl, M.; Filip, J. Visual Texture Accurate Material Appearance Measurement, Representation and Modeling; Springer-Verlag London, London, UK, 2013.
39. Hung, Ch-Ch.; Song, E.; Lan, Y. Image Texture Analysis Foundations, Models and Algorithms; Springer Nature Switzerland AG: Cham, Switzerland, 2019; pp. 1-47.
40. Distanto, A.; Distanto, C. Handbook of Image Processing and Computer Vision Volume 3 From Pattern to Object; Springer Nature Switzerland AG, Cham, Switzerland, 2020.
41. Zhao, H.; Lai, Z.; Leung, H.; Zhang, X. Feature Learning and Understanding Algorithms and Applications; Springer Nature Switzerland AG, Cham, Switzerland, 2020; pp. 1, 2.
42. Petrou, M.; Sevilla P.G. Image Processing Dealing with Texture; John Wiley & Sons Ltd, Chichester, UK, 2006; pp. 527.
43. Mirmehdi, M.; Xie, X.; Suri, J. Handbook of Texture Analysis; Imperial College Press: London, UK, 2008; pp. 1-32, 375-401.
44. Felsberg, M. Probabilistic and Biologically Inspired Feature Representations; Morgan & Claypool, 2018; pp. 1.
45. Laplante, P.A. Encyclopedia of Image Processing; Taylor & Francis Group, LLC, Boca Raton, USA, 2019; pp. 318, 651-652, 655, 656.
46. Paliouras, G.; Spyropoulos, C.D.; Tsatsaronis, G. Knowledge-Driven Multimedia Information Extraction and Ontology Evolution Bridging the Semantic Gap; Springer-Verlag Berlin, Berlin, Germany, 2011.
47. Strat, T.M.; Natural Object Recognition; Springer-Verlag New York, Inc., New York, USA, 1992.
48. Grauman, K.; Leibe, B. Visual Object Recognition; Morgan & Claypool, 2011; pp. 1-2, 7, 61, 122.
49. Marques, O.; Furht, B. Content-Based Image and Video Retrieval; Springer Science+Business Media New York, New York, USA, 2002; pp. 16, 29.
50. Bolón-Canedo, V.; Sánchez-Marroño, N.; Alonso-Betanzos, A. Feature Selection for High-Dimensional Data, Springer International Publishing Switzerland, Cham, Switzerland, 2015; pp. 2, 4, 13-15.

51. Ozdemir, S.; Susarla, D. *Feature Engineering Made Easy*; Packt Publishing, Birmingham, UK, 2018; pp. 8, 13.
52. Mavrogonatos, A.; Papia, E-M.; Dimitrakellis, P.; Constantoudis, V. Measuring the randomness of micro- and nanostructure spatial distributions: Effects of Scanning Electron Microscope image processing and analysis. *Journal of Microscopy* 2022; DOI: 10.1111/jmi.13149; pp. 6.
53. Burger, W.; Burge, M.J. *Principles of Digital Image Processing Fundamental Techniques*; Springer-Verlag London Limited, London, UK, 2009; pp. 119.
54. Snyder, W.E.; Qi, H. *Fundamentals of Computer Vision*; Cambridge University Press, Cambridge, UK, 2017; pp. 28, 92, 103.
55. Tomasi, C.; Manduchi, R. Bilateral Filtering for Gray and Color Images. *Proceedings of the 1998 IEEE International Conference on Computer Vision: Bombay, India, 1998*; DOI: 10.1109/ICCV.1998.710815; pp. 1-2.
56. Buades, A.; Coll, B.; Morel, J.-M. A non-local algorithm for image denoising. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05), 2005*; DOI: 10.1109/CVPR.2005.38; pp. 3, 5.
57. Aubry, M.; Paris, S.; Hasinoff, S.W.; Kautz, J.; Durand, F. Fast Local Laplacian Filters: Theory and Applications. *ACM Transactions on Graphics*, 2014; pp. 2.
58. Petrosian, A.A.; Meyer, F.G. *Wavelets in Signal and Image Analysis From Theory to Practice*; Springer Science+Business Media Dordrecht, Dordrecht, The Netherlands, 2001.
59. Haidekker, M.A. *Advanced Biomedical Image Analysis*; John Wiley & Sons, Inc., Hoboken, USA, 2011.
60. Banerjee, D.; Sparks, T.D. Comparing transfer learning to feature optimization in microstructure classification. *iScience* 25, 2022; DOI: 10.1016/j.isci.2022.103774; pp. 2-12.
61. Bihani, A.; Daigle, H.; Santos, J.E.; Landry, Ch.; Prodanović, M.; Milliken, K. MudrockNet: Semantic segmentation of mudrock SEM images through deep learning. *Elsevier Computers & Geosciences*, Volume 158, 2022; DOI: 10.1016/j.cageo.2021.104952; pp. 1-12.
62. Thomas, A.; Durmaz, A.R.; Straub, T.; Eberl, Ch. Automated Quantitative Analyses of Fatigue-Induced Surface Damage by Deep Learning. *MDPI materials*, 2020; DOI: 10.3390/ma13153298; pp. 1-21.
63. Bergs, T.; Holst, C.; Gupta, P.; Augspurger, T. Digital image processing with deep learning for automated cutting tool wear detection. *Elsevier Procedia Manufacturing*, 2020; DOI: 10.1016/j.promfg.2020.05.134; pp. 1-10.
64. Chen, Z.; Liu, X.; Yang, J.; Little, E.; Zhou, Y. Deep learning-based method for SEM image segmentation in mineral characterization, an example from Duvernay Shale samples in Western Canada Sedimentary Basin. *Elsevier Computers & Geosciences*, Volume 138, 2020; DOI: 10.1016/j.cageo.2020.104450; pp. 1-11.
65. Goetz, A.; Dumaz, A.R.; Müller, M.; Thomas, A.; Britz, D.; Kerfriden, P.; Eberl, Ch. Addressing materials' microstructure diversity using transfer learning. *npj Computational Materials*, 2022; DOI: 10.1038/s41524-022-00703-z; pp. 1-12.