

# VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

## FAKULTA STROJNÍHO INŽENÝRSTVÍ

FACULTY OF MECHANICAL ENGINEERING

## ÚSTAV MECHANIKY TĚLES, MECHATRONIKY A BIOMECHANIKY

INSTITUTE OF SOLID MECHANICS, MECHATRONICS AND BIOMECHANICS

## DETEKCE DEFECTŮ VÝPLNĚ 3D TIŠTĚNÝCH STRUKTUR S VYUŽITÍM METODY DIC

DETECTION OF INFILL DEFECTS IN 3D PRINTED STRUCTURES USING THE DIC METHOD

### DIPLOMOVÁ PRÁCE

MASTER'S THESIS

### AUTOR PRÁCE

AUTHOR

Bc. Tomáš Doležal

### VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Bořek Ščerba

BRNO 2023



# Zadání diplomové práce

Ústav: Ústav mechaniky těles, mechatroniky a biomechaniky  
Student: **Bc. Tomáš Doležal**  
Studijní program: Inženýrská mechanika a biomechanika  
Studijní obor: Inženýrská mechanika  
Vedoucí práce: **Ing. Bořek Ščerba**  
Akademický rok: 2022/23

Ředitel ústavu Vám v souladu se zákonem č.111/1998 o vysokých školách a se Studijním a zkušebním řádem VUT v Brně určuje následující téma diplomové práce:

## Detekce defektů výplně 3D tištěných struktur s využitím metody DIC

### Stručná charakteristika problematiky úkolu:

V posledním desetiletí došlo v oblasti aditivních technologií k prudkému rozmachu a 3D tisk našel uplatnění v široké škále oborů od rapid prototypingu v automobilovém průmyslu, přes produkci odlehčených součástí nevyrobitelných jinou metodou v leteckém průmyslu, po výrobu implantátů v medicíně. Ovšem tato technologie je kromě nesporných výhod spojena i s jistými limity a komplikacemi. Jednou z nich je i přítomnost inherentních výrobních vad, které je nutné odhalit před uvedením součásti do provozu.

### Cíle diplomové práce:

Cílem práce bude provedení rešerše ohledně vad vznikajících zejména při použití technologií SLM a FDM včetně dostupných defektoskopických metod, která bude následována návrhem defektoskopické metody využívající digitální korelaci obrazu včetně jejího experimentálního ověření.

### Seznam doporučené literatury:

SUTTON, Michael A., ORTEU, Jean-José a SCHREIER, Hubert W.: Image correlation for shape, motion and deformation measurements: basic concepts, theory and applications. New York: Springer, 2009, xx, 312 s. : foto, tab., grafy, il., výpočty. ISBN 978-0-387-78746-6.

ZHAO, Jianlong, SANG, Yong a DUAN, Fuhai: The state of the art of two-dimensional digital image correlation computational method. Engineering reports (Hoboken, N.J.) [online]. Wiley, 2019, 1(2) [cit. 2021-10-21]. ISSN 2577-8196. Dostupné z: doi:10.1002/eng2.12038

Termín odevzdání diplomové práce je stanoven časovým plánem akademického roku 2022/23

V Brně, dne

L. S.

---

prof. Ing. Jindřich Petruška, CSc.  
ředitel ústavu

---

doc. Ing. Jiří Hlinka, Ph.D.  
děkan fakulty

## ABSTRAKT

Výroba součástí pomocí aditivních technologií přináší kromě mnoha výhod také komplikace ve formě vzniku inherentních defektů, které negativně ovlivňují mechanické vlastnosti a jejich odhalení před uvedením součásti do provozu je žádoucí pro zachování spolehlivosti po celou dobu životnosti. Možnosti metody digitální korelace obrazu (DIC) pro detekci defektů výplně v součástech vyrobených aditivními technologiemi nebyly doposud v odborné literatuře popsány. Tato diplomová práce se zabývá návrhem nové defektoskopické metody nedestruktivního charakteru pro detekci vnitřních defektů v součástech vyrobených aditivními technologiemi, která je založená na vyhodnocení pole přetvoření povrchu součásti změřeného metodou DIC. Defektoskopická metoda byla úspěšně experimentálně ověřena na vzorcích s uměle vytvořenými vadami vyrobených technologií FDM. Konvoluční neuronová síť byla použita jako kritérium pro posouzení přítomnosti defektu v naměřených polích přetvoření. S její pomocí bylo dosaženo přesnosti klasifikace vzorků 94,5 %. Přestože navržená defektoskopická metoda podléhá dalšímu výzkumu, navržený způsob detekce vad se jeví jako nadějný pro rychlé a levné odhalování defektů v součástech vyrobených aditivními technologiemi.

### Klíčová slova

Defektoskopie, detekce defektů, DIC, digitální korelace obrazu, aditivní technologie, FDM, strojové učení, konvoluční neuronové sítě

## ABSTRACT

Additive manufacturing offers wide range of advantages. However various internal defects are likely to be formed during the manufacturing process which negatively affect mechanical properties. Detection of those defects is critical to ensure that the manufactured component stays reliable and maintains its dependability throughout its whole life. The potential of the digital image correlation (DIC) method for defect detection in components manufactured using additive technologies has not yet been investigated in the literature. In this master thesis a novel non-destructive defectoscopic method for the internal defect detection in 3D printed structures is presented, based on the evaluation of the strain field obtained by the DIC method. The method was experimentally evaluated on samples with artificial internal defects fabricated by FDM technology. The samples containing defects were successfully visually detected. A convolutional neural network was then used for the defect detection and achieved a classification accuracy of 94,5 %. This methodology has a potential to provide cheap and fast detection of internal defects formed in additive manufactured components in the future although future research is still required.

### Key words

Defectoscopy, defect detection, DIC, digital image correlation, additive technologies, FDM, machine learning, convolutional neural networks

## **BIBLIOGRAFICKÁ CITACE**

DOLEŽAL, Tomáš. *Detekce defektů výplně 3D tištěných struktur s využitím metody DIC* [online]. Brno, 2023 [cit. 2023-05-26]. Dostupné z: <https://www.vut.cz/studenti/zav-prace/detail/149176>. Diplomová práce. Vysoké učení technické v Brně, Fakulta strojního inženýrství, Ústav mechaniky těles, mechatroniky a biomechaniky. Vedoucí práce Bořek Ščerba.

## PROHLÁŠENÍ

Prohlašuji, že jsem diplomovou práci na téma *Detekce defektů 3D tištěných struktur s využitím metody DIC* vypracoval samostatně s použitím odborné literatury a pramenů, uvedených v seznamu, který tvoří přílohu této práce.

.....  
Datum

\_\_\_\_\_  
*Jméno a příjmení*

## PODĚKOVÁNÍ

Děkuji tímto Ing. Bořkovi Ščerbovi za svědomité vedení této diplomové práce, za jeho obrovskou vstřícnost a čas, který věnoval společným konzultacím, a bez kterých by tato práce nemohla vzniknout.

Také děkuji mé nejbližší rodině a prarodičům, především mému dědovi, za neutuchající podporu během celého vysokoškolského studia a za jejich upřímný zájem.

Merci beaucoup!



## OBSAH

ÚVOD.....	11
1 Formulace problémové situace.....	12
2 Formulace problému.....	12
3 Dílčí kroky k vyřešení problému a přínos práce.....	12
4 Současný stav poznání.....	13
4.1 Metoda digitální korelace obrazu (DIC).....	13
4.1.1 Historie metody korelace obrazu.....	13
4.1.2 Základní předpoklady pro použití metody digitální korelace obrazu .....	14
4.1.3 Metoda 2D digitální korelace obrazu (2D DIC).....	14
4.1.4 Metoda 3D digitální korelace obrazu .....	16
4.1.5 Potenciální zdroje chyb při měření metodou DIC.....	18
4.2 Výroba součástí pomocí aditivních technologií.....	18
4.2.1 Aditivní výroba kovových materiálů.....	19
4.2.2 Aditivní výroba polymerních materiálů .....	22
4.3 Defekty a procesní parametry technologie SLM .....	24
4.3.1 Přehled defektů vyskytujících se u technologie SLM.....	26
4.4 Defekty a procesní parametry technologie FDM.....	29
4.5 Defektoskopie .....	31
4.5.1 Zkoušení ultrazvukem .....	31
4.5.2 Zkoušení radiografické.....	32
4.5.3 Zkoušení magnetickou metodou práškovou.....	32
4.5.4 Zkoušení vířivými proudy .....	33
4.5.5 Metoda infračervené termografie .....	33
4.5.6 Metody optické interferometrie .....	33
4.6 Strojové učení .....	35
4.6.1 Strojové učení bez učitele .....	35
4.6.2 Strojové učení s učitelem .....	35
4.7 Odborné články související s tématem práce.....	38
5 Komplexní analýza problému.....	42
6 Systém podstatných veličin .....	43
7 Volba metod řešení problému.....	44
7.1 Nástroje použité pro řešení problému .....	44
7.2 Návrh defektoskopické metody .....	44
8 Experimentální ověření navržené defektoskopické metody .....	46
8.1 Návrh a příprava vzorků použitých v experimentu.....	46
8.2 Návrh a provedení experimentu.....	49
8.3 Vyhodnocení naměřených dat.....	50

8.4	Verifikace naměřených dat výpočtem pomocí MKP .....	53
9	Detekce defektů vnitřních vad s využitím metod strojového učení .....	58
9.1	Příprava a augmentace dat pro strojové učení .....	58
9.2	Trénování neuronových sítí .....	61
9.3	Plně propojená neuronová síť .....	62
9.3.1	Výsledky klasifikace vzorků s využitím plně propojené neuronové sítě ...	63
9.4	Konvoluční neuronová síť .....	64
9.4.1	Výsledky klasifikace vzorků s využitím konvoluční neuronové sítě .....	65
10	Diskuse .....	71
11	Závěr .....	72
12	Bibliografie .....	74
	SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK .....	80

## ÚVOD

Digitální korelace obrazu, zkráceně DIC, je moderní metoda měření deformace součástí s využitím digitálních optických metod. Tato technologie umožňuje velmi přesné měření deformací v reálném čase a je používána v různých odvětvích včetně mechaniky, materiálových věd, biomechaniky a stavebnictví. Metoda pracuje na principu porovnání dvou obrazových snímků pořízených před a po deformaci součástí a určení posuvu pomocí korelačních kritérií. DIC se těší velké oblibě díky její jednoduchosti, univerzálnosti, snadné obsluze a relativně nízké pořizovací ceně, a je hojně používána ve výzkumné činnosti a v průmyslu.

Výroba pomocí aditivních technologií, či 3D tisk, je proces výroby součástí postupným spojováním materiálu. Nejčastěji se používá materiál ve formě prášku či drátu, který je kontrolovaně přidáván, dokud není dosaženo požadovaného tvaru finální součásti. Hlavní výhodou aditivních technologií je snížení počtu technologických operací potřebných pro výrobu tvarově komplexních součástí z kovových a polymerních materiálů. To snižuje výrobní čas, výslednou cenu a také množství použitého materiálu. Nevýhodou těchto technologií je nestabilita výrobního procesu, který je ovlivněn mnoha procesními faktory. Při jejich nesprávné volbě dochází ke vzniku vad a defektů. Ve výrobcích se nacházejí také inherentní vady dané technologií výroby. Tyto vady a defekty se mohou vyskytovat jak na povrchu součásti, tak uvnitř tištěných struktur. Právě detekce defektů výplně je velmi důležitým klíčem pro další rozmach výroby součástí pomocí aditivních technologií.

V současnosti používané metody detekce vad výplně součástí vyrobených pomocí aditivních používají finančně nákladné vybavení. Tato práce si klade za cíl prozkoumat možnosti využití metody digitální korelace obrazu pro účely detekce vnitřních vad. Metoda DIC navíc pracuje s digitálními snímky a nabízí se tedy možnosti automatizace procesu posouzení přítomnosti defektů výplně tištěných součástí.

## 1 Formulace problémové situace

Aditivní technologie jsou kromě nesporných výhod spojeny i s jistými limity a komplikacemi. Jednou z nich je i přítomnost inherentních výrobních vad, které je nutné odhalit před uvedením součásti do provozu pro zachování spolehlivosti po celou dobu plánované životnosti. V současnosti používané defektoskopické metody jsou finančně a časově nákladné a jejich použití vyžaduje drahé vybavení. Právě neexistující dostupná a spolehlivá metoda detekce vad výplně brání většímu rozmachu aditivní výroby a jejímu použití v sériové výrobě.

## 2 Formulace problému

Návrh defektoskopické metody využívající digitální korelaci obrazu (DIC) pro detekci defektů výplně součástí, které jsou vyráběny aditivními technologiemi.

## 3 Dílčí kroky k vyřešení problému a přínos práce

Zamýšleným cílem práce je tvorba nové defektoskopické metody pro detekci defektů výplně 3D tištěných struktur využívající metodu digitální korelace obrazu. Díky relativní jednoduchosti a dostupnosti metody DIC, která vyžaduje jen kameru, či dvojici kamer a vyhodnocovací software, by takováto defektoskopická metoda mohla zpřístupnit použití aditivních technologií v nových aplikacích, přinést zlevnění výroby a také zvýšení spolehlivosti vyráběných součástí.

- Provedení rešerše za účelem určení typických vad vznikajících při použití aditivních technologií a posouzení v současnosti používaných defektoskopických metod.
- Návrh defektoskopické metody využívající metodu DIC.
- Ověření navržené metody na reálném experimentu.
- Vyhodnocení experimentu a formulace závěrů.

## 4 Současný stav poznání

V této kapitole jsou uvedeny výsledky provedené rešeršní práce na téma metoda digitální korelace obrazu, používané aditivní technologie výroby, vady vznikající při použití aditivních technologií typu SLM (*Selective laser melting*) a FDM (*Fused deposition modeling*), přehled v současnosti používaných defektoskopických metod a základní přehled metod strojového učení.

### 4.1 Metoda digitální korelace obrazu (DIC)

Tradiční měření přetvoření pomocí tenzometrů je vhodné díky jejich jednoduchosti především pro vyšetřování uniformní deformace vzorku. V technické praxi se ovšem setkáváme spíše s heterogenními deformacemi, u kterých jednoduché tenzometry naráží na svůj limit použitelnosti. To může způsobit obtíže při vyhodnocení a charakterizování typu deformace ve vyšetřovaném regionu a přehlédnutí podstatných fenoménů, které mají důležitý dopad na interpretaci změřených dat. Z výše zmíněných důvodů je vhodnější použít metody, které umožňují měření přetvoření po celé vyšetřované oblasti [1].

Pro tyto účely je používáno mnoho optických metod na základě fotogrammetrie založených na použití náhodné struktury/vzoru (*“speckled pattern“*) jako například holografická interference (*“holographic interference“*), elektronická tečkovaná interferometrie (*“electric speckle pattern interferometry“*) a digitální korelace obrazu (*“digital image correlation“*). Právě poslední zmiňovaná metoda digitální korelace obrazu je v dnešní době nejpoužívanějším zástupcem těchto metod, neboť nabízí mnoho důležitých výhod jako relativně jednoduchou přípravu měřicího systému, nízké nároky na prostředí, ve kterém experiment probíhá, vysokou míru automatizace v oblasti analýzy dat a velkou míru velikosti vyšetřovaných oblastí (od měření makroskopických rozměrů po měření na úrovni nanometrů) [1].


#### 4.1.1 Historie metody korelace obrazu

Použití metody korelace obrazu pro analýzu fotografií poprvé zmínil Hobrough v 50. let 20. století, který pracoval na analogovém měření proměnlivých půdních podmínek. S nástupem digitálních fotografií v 60. a 70. letech 20. století došlo k rozmachu algoritmů založených na bázi vidění za přispění výzkumníků z oblasti informačních technologií, kteří tyto algoritmy uplatňovali pro analýzu leteckých snímků. S myšlenkou použití digitální korelace obrazu přišli Peters a Ranson v roce 1982. Jejich návrh spočíval ve vystavení měřeného objektu ultrazvukovému vlnění ve dvou stavech. Nejprve v nezatíženém stavu, posléze ve stavu zatíženém a záznamu odražených vln v obou zmíněných případech. Autoři navrhli metodu pro analýzu zaznamenaného záření ve formě takto získaného digitálního *“obrazu“* a vyhodnocení celého měřeného pole. Metoda spočívala v porovnání digitálního obrazů před a po zatížení, jež byly pravidelně rozděleny na mnoho malých podoblastí/fazet (*“subsets“*). Následně byly podoblasti z nezatíženého obrazu lokalizovány v obrazu po aplikaci zatížení [2].

O rok později, v roce 1983, vyvinul Sutton numerický algoritmus, jehož správnost i experimentálně ověřil, pro analýzu opticky pořízených snímků. Tím bylo dokázáno, že výše zmíněný algoritmus, dnes známý jako 2D digitální korelace obrazu (*“2D Digital Image Correlation“*), je vhodný také pro zpracování opticky zaznamenaných snímků. Pro měření prostorových deformací byla vyvinuta metoda 3D digitální korelace obrazu [2].

#### 4.1.2 Základní předpoklady pro použití metody digitální korelace obrazu

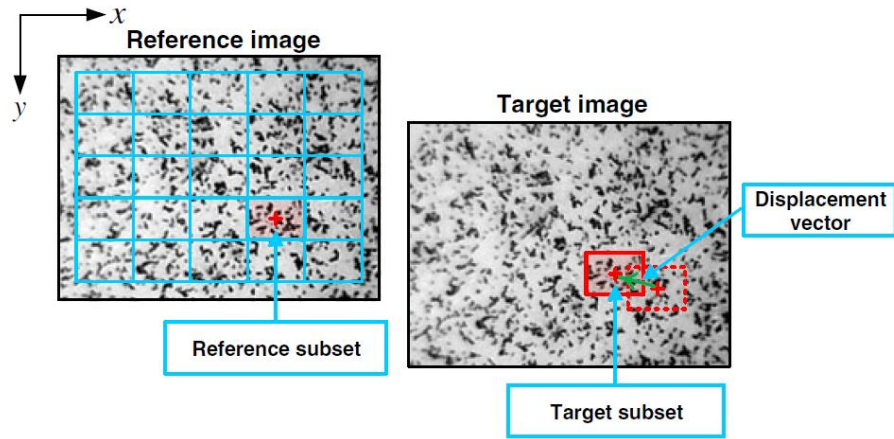
Použití metody DIC předpokládá tři základní skutečnosti – přítomnost náhodného vzoru/textury (“*speckled pattern*“) na měřené součásti, stabilní zdroj světla a zařízení pro záznam obrazu s dostatečným rozlišením. Přestože metoda DIC dokáže pracovat s obrazy pořízenými také například ultrazvukem, elektronovým mikroskopem, či rentgenovými paprsky, v praxi se nejčastěji používá pro zpracování fotografií. Výše zmíněný náhodný vzor (obrázek 1) je nositelem informace o deformaci vyšetřované součásti a jeho kvalita je velmi důležitým faktorem pro přesnost výsledného měření, neboť všechna data získaná měřením vycházejí ze změn na povrchu součásti. Náhodný vzor lze definovat jako s náhodnou intenzitou distribuované konečné množství pixelů, které je vysoce kontrastní, stochastické a izotropní. Tyto požadavky bohužel nesplňuje povrch většiny materiálů, které jsou měřeny a používány v inženýrské praxi. Přistupuje se tedy k umělé tvorbě náhodného vzoru. Nejpoužívanějším postupem je nanesení bílé základové barvy na měřený objekt a tvorba náhodného vzoru barvou černou. Velmi důležité je, aby tento uměle vytvořený povrch nijak neovlivňoval mechanické vlastnosti měřené součásti a neodlupoval se v průběhu měření. Doplnujícími požadavky při použití 2D digitální korelace obrazu jsou kolmost optické osy snímacího zařízení a měřeného povrchu a rovinnost měřeného povrchu [1].



Obrázek 1: Příklady náhodných vzorů používaných pro DIC měření.

#### 4.1.3 Metoda 2D digitální korelace obrazu (2D DIC)

Metoda DIC spočívá ve zpracování dvou po sobě jdoucích obrazů zaznamenaných v rozdílných zátěžných krocích. Obrazy jsou rozděleny na mnoho malých podoblastí (“*subsets*“). Principem metody DIC je sledování pozic jednotlivých podoblastí ve výchozím obrazu (“*reference image*“) a hledání jejich pozic v cílovém obrazu (“*target image*“) pomocí korelačních algoritmů (obrázek 2). Tím dojde k určení vektoru posunutí (“*displacement vector*“) jednotlivých podoblastí, respektive jejich středů  $P$ , a vzniku vektorového pole deformace celé součásti. Před začátkem měření je vždy provedena kalibrace snímání oblasti [1].



Obrázek 2 Schéma principu metody DIC [1].

Je dána podoblast o velikosti  $(2M+1) \times (2M+1)$  pixelů s vypočteným referenčním středem  $P$ , který slouží jako vstup do korelační funkce. Lineární transformace bodů podoblasti je popsána pomocí báze funkce prvního řádu. Pro 2D případ její předpis zní:

$$x^* = u + \frac{\delta u}{\delta x} \Delta x + \frac{\delta u}{\delta y} \Delta y \quad (1)$$

$$y^* = v + \frac{\delta v}{\delta x} \Delta x + \frac{\delta v}{\delta y} \Delta y \quad (2)$$


kde  $x^*$  a  $y^*$  jsou výsledné posuvy podoblasti,  $u$  a  $v$  jsou posuvy středu  $P$  vůči výchozímu obrazu a  $\Delta x$  a  $\Delta y$  jsou vzdálenosti libovolného bodu  $Q$  a středu  $P$  dané podoblasti [1].

Vzhledem k výskytu šumu v pořízených obrazech nelze nikdy nalézt přesnou shodu. Pro posouzení míry podobnosti mezi výchozím a cílovým obrazem je vypočítána korelační funkce pro všechny možné lokace podoblasti v cílovém obrazu a vybrána ta, jež nabývá nejlepší shody. Nejčastěji používanými korelačními funkcemi je kombinace metody nejmenších čtverců (“zero-mean normalized sum-of-square difference criterion, ZNSSD”) a korelačního kritéria (“zero-mean normalized cross-correlation criterion, ZNCC”). Důvodem použití této kombinace je zvýšená odolnost proti chybám vnesenými změnami jasu a kontrastu obrazu. Předpis výše zmíněných korelačních funkcí zní:

$$C_{ZNSSD}(p) = \sum_{i=-M}^M \sum_{j=-M}^M \left[ \frac{f(x,y) - f_m}{\sqrt{\sum_{i=-M}^M \sum_{j=-M}^M [f(x,y) - f_m]^2}} - \frac{g(x^*,y^*) - g_m}{\sqrt{\sum_{i=-M}^M \sum_{j=-M}^M [g(x,y) - g_m]^2}} \right]^2 \quad (3)$$

$$C_{ZNCC}(p) = \sum_{i=-M}^M \sum_{j=-M}^M \left[ \frac{[f(x,y) - f_m] \times [g(x^*,y^*) - g_m]}{\sqrt{\sum_{i=-M}^M \sum_{j=-M}^M [f(x,y) - f_m]^2 \times \sum_{i=-M}^M \sum_{j=-M}^M [g(x,y) - g_m]^2}} \right] \quad (4)$$

kde  $f(x,y)$  jsou hodnoty stupně šedi v jednotlivých pixelech referenční podoblasti,  $g(x^*,y^*)$  jsou hodnoty stupně šedi v jednotlivých pixelech cílové podoblasti a  $f_m$  a  $g_m$  jsou normalizační funkce [1]. Základní měřicí aparatura metody 2D DIC, která sestává z kamery, zdroje světla a zařízení pro zpracování snímků, je zobrazen na obrázku 3.



Obrázek 3 Měřicí aparatura metody 2D DIC [3],(upraveno).

#### 4.1.4 Metoda 3D digitální korelace obrazu


Metoda 3D digitální korelace obrazu je spojením principu stereovize se standartní 2D DIC metodou. Měřicí aparatura sestává ze dvou nebo více napevno upevněných kamer umístěných vůči sobě pod neměnným úhlem (obrázek 4). Velkou výhodou oproti 2D DIC je možnost měřit posuvy také v prostoru, na měřenou součást není kladen požadavek rovinnosti a metoda 3D DIC nevyžaduje, aby měřená součást byla kolmá k optické ose kamery. Pomocí principu stereovize a triangulace je určena prostorová souřadnice bodů měřené součásti a vytvořen její 3D tvar. Pomocí metody DIC je poté určena deformace součásti v prostoru. [4].



Obrázek 4 Konfigurace kamer při 3D DIC.

Pro reprodukci trojrozměrné scény za použití 2 různých pohledů je použita metoda binokulární stereovize ("binocular stereovision"). Schematicky je zobrazena na obrázku 5, kde bod  $P$  je měřený bod, body  $p_1$  a  $p_2$  jsou jeho stereo projekce do čoček měřících kamer a body  $C_1$  a  $C_2$  jsou optické středy měřících kamer [5].





Obrázek 5 Schéma binokulární stereo vize [5].

Dva předpoklady musí být splněny, aby bylo možné spočítat polohu bodu v prostoru z dvojice jeho snímků. Zaprvé relativní poloha a orientace kamer jsou známé veličiny. Toho je dosaženo jejich kalibrací před zahájením měření. A zadruhé body  $p_1$  a  $p_2$  ze snímků obou kamer jsou přiřazeny fyzickému bodu  $P$  na měřené součásti [5].

Kalibrace kamer slouží k určení jejich vnitřních parametrů (souřadnice průmětu osy kamery s rovinou obrazu, měřítko a zkreslení čoček) a určení pozice a orientace kamery v prostoru vzhledem ke zvolenému referenčnímu snímku a poloze kamer navzájem. Tyto kalibrační parametry jsou potřebné během korekce dvojic korespondujících snímků, korekce zkreslení čoček a pro výpočet prostorových souřadnic bodů během triangulace. V praxi se pro kalibraci používají kalibrační šablony, které jsou kamerou zaznamenány v deseti až dvaceti rozdílných orientacích. Výhodou tohoto přístupu je, že neklade velký důraz na kvalitu šablony a není nutné znát pohyb šablon mezi jednotlivými snímky, což velmi usnadňuje praktické provedení kalibrace [5].

Pro hledání odpovídajících si stereo projekčních bodů  $p_1$  a  $p_2$  lze použít dva přístupy. První používá pro přiřazení výrazné prvky jako hrany nebo obrysy. Tento postup je velmi rychlý, neboť jeho numerická náročnost je velmi malá. Naopak nevýhodou je velmi hrubá mapa přiřazených bodů a z ní vyplývající znalost deformace jen v těchto místech. V případech, kdy je vyžadována znalost deformace po celém povrchu součástí se používá postup přiřazení podoblastí. Ten hledá odpovídající podoblasti na základě podobnosti hodnot stupňů šedi v dané oblasti. Okno z prvního obrazu se ve druhém obrazu nachází na pozici, kde korelační funkce dosahuje maxima. Jedná se o analogii k metodě použité pro 2D DIC. V praxi je okno, které se v prvním obrazu jeví jako čtverec, přiřazeno k oknu jiného tvaru, což je dáno zkreslenou projekcí druhé z dvojice kamer. Ze znalosti relativní polohy kamer a souřadnic bodu  $P$  ve snímku 1 ( $p_1$ ) a snímku 2 ( $p_2$ ) je pomocí triangulace dopočítána jeho pozice v prostoru. Opakováním tohoto postupu je zmapován tvar těch částí měřené součásti, které jsou viditelné oběma kamerami zář. Porovnáním poloh bodů součásti mezi scénami v rozdílném čase jsou získány posuvy v konkrétních bodech analogicky jako v případě měření metodou 2D DIC [5].

Metoda 3D digitální korelace obrazu přímo vychází z 2D DIC metody a její přesnost je tedy ovlivněna stejnými faktory. Těmi jsou kvalita kamer a jejich rozlišení a přesnost korelačního algoritmu. Vliv má také rozmístění kamer, které ovlivňuje přesnost triangulace a přesnost kalibrace kamer před zahájením měření. Měření může být jen ta část součásti, která je

viditelná oběma kamerami záraz. Metoda 3D digitální korelace se ukázala jako velmi účinnou pro měření deformací a přetvoření velkého množství aplikací a v dnešní době je velmi často používaná díky své univerzálnosti a všestrannosti [5].

#### 4.1.5 Potenciální zdroje chyb při měření metodou DIC

Hlavní zdroje potenciálních chyb při měření metodou DIC lze rozdělit do dvou skupin: chyby DIC algoritmu a chyby vzniklé při pořizování snímku [1].

Chybou DIC algoritmu je nesprávně zvolená velikost vyšetřované podoblasti hledané mezi referenčním a cílovým obrazem. Jedná se o parametr definovaný uživatelem, který má velký vliv na výslednou přesnost měření. Zvolená podoblast by měla být dostatečně velká, aby obsahovala dostatek prvků pro svůj jedinečný popis a bylo možné ji spolehlivě nalézt na všech vyšetřovaných snímcích. Na druhou stranu volba příliš velké podoblasti může vést k prodloužení výpočetního času a chybnému zachycení přítomných gradientů, v případě, kdy celá oblast deformace je menší než zvolená velikost podoblasti. [1].


První možnou chybou při pořizování snímku je nedostatečná kvalita náhodného vzoru na měřené součásti. Náhodný vzor lze hodnotit z lokálního pohledu, který souvisí s jeho přípravou a kvalitou na úrovni podoblasti, a globálního pohledu souvisejícího s přesností DIC měření. Hodnotícími kritérii lokálních parametrů jsou průměrná změna intenzity osmi sousedních pixelů a suma čtverců gradientu intenzity podoblasti v horizontálním a vertikálním směru. Globální parametry určují kvalitu náhodného vzoru jako celku a nejjednodušším parametrem je průměrná velikost prvku náhodného vzoru. Druhou možnou chybou při pořizování snímku je zkreslení obrazu způsobené samotnou kamerou, které závisí na hardwaru použité digitální kamery. Hlavním důvodem jsou výrobní nepřesnosti kamery a také deformace čočky fotoaparátu způsobená ohřevem čočky odpadním teplem měřicí aparatury. Touto problematikou se zabýval Ma a kolektiv [6] ve studii, ve které určil závislost mezi chybou naměřeného přetvoření a teplotou jako 8 až 20  $\mu\text{m}/\text{mC}^\circ$  a maximální chybu měření přetvoření až 230  $\mu\text{m}/\text{m}$ . Z tohoto důvodu je nutné v případech, kdy měření probíhá po dlouhou dobu, předehřívat kameru před začátkem měření na provozní teplotu po dobu 1 až 2 hodin. Třetí potenciální chybou během získávání snímků je šum vnesený do obrazu. Snímky s náhodným tečkovaným vzorem, jaký je používán při měření metodou DIC, nevyhnutelně obsahují množství šumu způsobeného kolísáním intenzity osvětlení, kabeláží a použitou elektronikou. Poslední a jednou z nejdůležitějších potenciálních chyb u metody 2D DIC je pohyb měřeného objektu z roviny měření. Tomuto nelze nikdy plně zabránit a v jistém rozsahu se děje během každého měření. Dle výzkumu Haddadi a Belhabiba [7] translace z roviny měření o 1 mm, při měření ze vzdálenosti 210 mm, způsobila chybu v naměřené deformaci  $2 \times 10^{-3}$  mm. Pokud se během experimentu vyskytne výrazné vybočení z měřené roviny, je nutné použít měřicí systém používající metodu 3D DIC [1].

## 4.2 Výroba součástí pomocí aditivních technologií

Výroba pomocí aditivních technologií, či 3D tisk, je proces výroby součástí spojováním materiálu do výsledného celku. Nejčastěji se jedná o vrstvení materiálu ve formě prášku nebo drátu na sebe a spojování jednotlivých vrstev procesem tavení, dokud není dosaženo výsledného požadovaného tvaru na základě počítačového modelu. Hlavní výhodou je možnost výroby tvarově komplexních součástí z kovových a polymerních materiálů v jednom výrobním kroku. Díky tomu se tyto technologie v posledních letech staly velmi oblíbenými jak pro použití

v průmyslu, tak výzkumu. Jedná se především o automobilový a letecký průmysl a oblasti biomedicíny a elektrotechniky. Vytiskovaná součást vyžaduje jen malé množství finišujících operací, což snižuje celkový výrobní čas, výslednou cenu a také snižuje objem použitého materiálu. Výroba je velmi flexibilní a vhodná pro výrobu individuálních zakázkových dílů. Na druhou stranu aditivní technologie mají typicky nižší produktivitu a nabízejí menší nabídku odladěných a použitelných materiálů než konvenční technologie jako obrábění, či odlévání. Další velkou nevýhodou je výskyt vnitřních vad a přítomnost residuálních napětí. Vliv výrobních parametrů na výslednou kvalitu a předcházení výskytu vad stále podléhá dalšímu výzkumu. Právě nejistota ohledně vnitřní kvality součásti brání použití aditivních technologií v aplikacích, které vyžadují garanci kvality [8].

Zvyšující se oblibu aditivních technologií dokazuje jejich hodnota na trhu, kdy mezi lety 2015 a 2018 zaznamenaly růst z 5 miliard dolarů na 9,3 miliard dolarů (obrázek 6). Velké společnosti jako Optomec, HP, Renishaw nebo EOS se podílejí na vývoji a studiu nových aditivních systémů. Hlavními důvody tohoto rozmachu jsou jednoduchá obsluha, možnost použití heterogenních materiálů v jednotlivých vrstvách a absence použití forem a obráběcích nástrojů během samotné výroby. Ovšem jak bylo zmíněno v předchozích odstavci, rozšíření aditivních technologií bude přímo závislé na tom, jak úspěšně bude zvládnuto předcházení jejich inherentních nevýhod [9].



Obrázek 6 Odhadovaná velikost trhu s aditivními technologiemi mezi lety 2016 a 2027, popis legendy zleva: Hardware, Materiály, Služby, Software, Celkem [9]


Dle Mezinárodní organizace pro standardizaci (ISO) 52900:2015 se aditivní technologie dělí do 7 kategorií: Binder jetting (BJ), directed energy deposition (DED), material extrusion (ME), material jetting (MJ), powder bed fusion (PBF), sheet lamination (SL) a vat photopolymerization (VP) [10].

#### 4.2.1 Aditivní výroba kovových materiálů

Aditivní technologie výroby kovových materiálů lze rozdělit dle mnoha kritérií jakými jsou například forma vstupního materiálu, zdroj energie nebo velikost výrobků. Nejčastěji se lze setkat s rozdělením do 3 základních kategorií Wire Feed systémy, Powder Feed systémy a Powder Bed systémy [11].

### Wire feed systémy

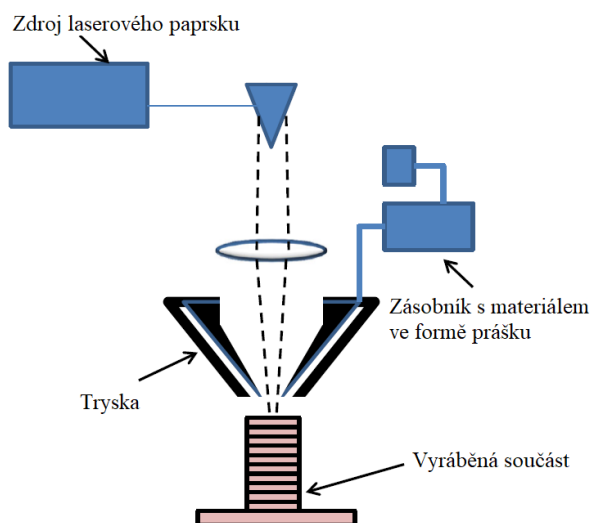
Použitý materiál zde vystupuje ve formě drátu a zdrojem energie je laserový paprsek, elektronový paprsek nebo plasma, které se starají o tavení drátu obklopeného atmosférou s inertním plynem (obrázek 7). Drát se může pohybovat ve třech osách. Výroba začíná nanesením kapičky materiálu na podložku, na kterou je během dalších průchodů drátu nanášena požadovaná trojrozměrná struktura. Systém je vhodný pro aplikace, které vyžadují vysokou rychlost nanášení materiálu a velký objem použitého materiálu. S tím spojenou nevýhodou je náchylnost k pokřivení součástí během výroby a vznik zbytkových napětí. Tento typ výroby také vyžaduje nejrozsáhlejší dodatečné obrobení [9].



Obrázek 7 Schéma wire feed systému [11], (upraveno).

### Powder Feed systémy


Použitý materiál je ve formě prášku dopravován na vyráběnou součást pomocí trysky a taven laserem v daném místě, dokud není dosaženo požadovaného trojrozměrného tvaru (obrázek 8). K tavně může docházet v jedné nebo více vrstvách. Tento typ umožňuje výrobu velkoobjemových součástí (nad 1 m<sup>3</sup>) a vyniká vysokou univerzálností. Velmi dobře se hodí pro opravu opotřebovaných a již použitých součástí, lze je integrovat do obráběcích center a používat kombinace více druhů materiálů. Na trhu lze najít 2 typy tohoto systému. U prvního typu je tisknutá součást stacionární a pohybuje se tryska a u druhého typu je tryska stacionární v kombinaci se součástí pohybující se kolem ní [11].



Obrázek 8 Schéma powder feed systému [11], (upraveno).

### **Powder Bed systémy**

Tento typ systémů používá materiál ve formě prášku, který je dopravován do celého tiskového prostoru ohraničeného tiskovou komorou. Zdroj energie ve formě laserového paprsku (technologie SLM) nebo elektronového svazku (technologie EBM) je zaměřen pomocí skenovací hlavičky na požadovaná místa v tisknuté rovině a prášek roztaven a spečen (obrázek 9). Tím je vyrobena jedna vrstva součástí. Další prášek je dopraven do tiskového prostoru a proces je opakován, dokud nejsou vyrobeny všechny vrstvy a není dosaženo požadovaného trojrozměrného tvaru. Hlavními výhodami jsou výroba součástí se složitými detaily, možnost výroby kapes a vnitřních průchodů a vysoká přesnost výsledného tisku [11]. Nevýhodou je možnost tisku jen maloobjemových součástí (do 0,05 m<sup>3</sup>), neboť maximální velikost vyráběné součásti je omezena velikostí tiskové komory. Navíc finální kvalita výrobku velmi silně závisí na tiskových parametrech a procesních podmínkách jako přehřívací teplota tiskové komory, výkon paprsku, skenovací rychlost, tloušťka vrstvy nebo skenovací krok. Tyto aspekty ovlivňují stabilitu tavního procesu, hustotu tisknuté součásti a přítomnost defektů [12].




Obrázek 9 Schéma powder bed systému [11],(upraveno).

Právě technologie powder bed systémů jsou v dnešní době nejčastěji používanými pro aditivní výrobu z kovových materiálů, a proto jsou níže představeni jejich dva hlavní zástupci.

Prvním zástupcem je technologie *Electron beam melting (EBM)*, která využívá pro tavení kovového prášku elektronového svazku, který je usměrňován magnetickými cívkami. Z tohoto důvodu je tato technologie omezena pouze pro použití elektricky vodivých materiálů. Nejpoužívanějším a nejprozkoumanějším materiálem je titanová slitina Ti-6Al-4V. Dále se používají kobaltové a niklové slitiny, měď nebo nerezové oceli, obecně je nabídka materiálů ovšem menší než pro SLM. Po dopadu elektronového svazku na oblast s kovovým práškem dojde k přeměně kinetické energie letících elektronů na energii tepelnou, která materiál zahřeje a roztaví. Po vychladnutí prášek ztuhne v jeden celek. Toto rychlé tavení a tuhnutí prášku, které probíhá v řádech milisekund, vede k postupné tvorbě součásti vrstvu po vrstvě. Velkou výhodou EBM je, že tisk je prováděn ve vakuu (z tiskové komory je před započnutím tisku snížena tlak na 10<sup>-4</sup> mbar), což předchází vzniku oxidace u materiálů s vysokou afinitou ke kyslíku a dusíku. Tisková komora je navíc vyhřívána, což vede ke snížení zbytkových napětí.

U elektronového svazku také nedochází k odrazu jako u laserového paprsku, což zvyšuje efektivitu výroby [12].

Druhým zástupcem powder bed systémů je technologie *Selective laser melting (SLM)*, která byla vyvinuta firmami Stereolithographietechnik GmbH a Fraunhofer ILT v roce 1995. Princip výroby spočívá v nanesení vrstvy kovového prášku na celé dno tiskového prostoru a jeho roztavení jen v požadovaných místech za pomoci laserového paprsku. Po dokončení vrstvy je dno tiskového prostoru sníženo o výšku jedné vrstvy a pokryto novou vrstvou kovového prášku, který je dopraven ze zásobníku, roztaven laserovým paprskem v požadovaných místech a tím spojen s přechozí vrstvou. Tento postup je opakován, dokud není dosaženo požadovaného výsledného tvaru (obrázek 10). Po skončení tisku je nepoužitý kovový prášek odstraněn a může být recyklován pro další použití. Technologie umožňuje použití podpor, které jsou po konci tisku odstraněny. Rychlé tavení a tuhnutí kovového prášku vede ke tvorbě velmi jemné struktury s malými zrny. To zaručuje těmto součástem vyšší mez kluzu a mez pevnosti než u obráběných součástí. Nicméně tažnost tisknutých součástí je menší, což je dáno přítomností většího počtu defektů. Pro zlepšení mechanických vlastností mohou být díly tepelně zpracovány a mechanicky obrobena. Metodou SLM lze zpracovávat velké množství materiálů. Jedná se o oceli a jejich slitiny, titan a jeho slitiny, slitiny niklu, hliník a jeho slitiny, a inkonel [13].



Obrázek 10 Schéma systému SLM [13],(upraveno).


#### 4.2.2 Aditivní výroba polymerních materiálů

S přihlédnutím k principu aditivní výroby, při které jsou jednotlivé vrstvy materiálu spojovány v kapalném skupenství, nabízejí plasty a další polymerní materiály velkou výhodu vzhledem k jejich relativně nízkým teplotám tání. To umožňuje energeticky úspornější výrobu za nižších teplot a také snižuje nároky kladené na tiskařské zařízení. Navíc polymerní materiály nevyžadují tak striktní podmínky pro tisk jako kovové materiály [10].

Níže jsou představeny dva komerčně nejrozšířenější a nejdostupnější systémy vhodné pro individuální kusový tisk polymerních materiálů. Jedná se o metodu Stereolithography (SLA) a Fused deposition modeling (FDM). Pro úplnost je zde také uveden výčet ostatních používaných technologií pro aditivní výrobu součástí z polymerních materiálů. Jedná se o Selective laser sintering (SLS), Selective heat sintering (SHS), Digital light processing (DLP), Multi jet printing (MJP), Multi Jet Fusion (MJF), Three dimensional printing (3DP), Laminated object manufacturing (LOM) a Continuous fiber reinforcement (CFR) [10].


*Stereolitografie* je první komerčně představenou technologií 3D tisku polymerních materiálů uvedenou na trh v roce 1987. Funguje na principu vytvrzování foto polymerní

pryskyřice pomocí UV laserového paprsku, naváděného skenovacím systémem po požadované dráze odpovídající právě tisknuté vrstvě vyráběné součásti (obrázek 11). Pryskyřice je přítomna v nádrži v tekuté formě, ve které se nachází také tisková podložka. Model součásti je v počítači “nařezán“ na mnoho horizontálních vrstev požadované tloušťky. Pomocí UV laserového paprsku je každá vrstvena vytvrzena a spojena s vrstvou předchozí. Podložka poté klesne o výšku jedné vrstvy a proces se opakuje, dokud není vyrobena celá součást. Výhodou této technologie je vysoká přesnost výroby, výborná úroveň detailů a velmi dobrá kvalita povrchu [14].



Obrázek 11 Schéma systému SLA [15],(upraveno).

Druhým zástupcem systémů pro aditivní výrobu polymerních materiálů je technologie *Fused deposition modeling*, která byla komerčně uvedena v roce 1989. Požadovaného tvaru tisknuté součásti je dosaženo kladením vrstev roztavené plastové struny na tiskovou podložku pomocí nahřívané trysky (obrázek 12). Po ztuhnutí se vrstvy spojí a vytvoří výslednou součást. Tryska se může pohybovat ve třech směrech a je řízena pomocí souřadnic ve formě G-Code. Ten je generován v počítači, kde je součást před tiskem “nařezána“ na jednotlivé vrstvy a v případě potřeby doplněna podporami, které se po tisku odstraní. Tok filamentu skrze trysku je kontrolován dvojicí válečků ovládaných počítačem. Technologie FDM pracuje s navinutými polymerovými strunami vyrobenými z termoplastů a umožňuje použití široké palety materiálů jako jsou ABS (polymer akrylonitrilu, butadienu a styrenu), PLA (kyselina polymléčná), nylon nebo PET. Právě PLA je nejrozšířeněji používaný materiál. Je vyroben z biomasy, je šetrný k přírodě, nepředstavuje zdravotní nebezpečí pro člověka a může být vyroben z plně obnovitelných zdrojů. Teplota tavení PLA je mezi 180 °C až 220 °C. FDM se ukazuje jako velmi jednoduchá a rychlá technologie pro výrobu menších sérií komplikovaných komponent, ale je také vhodná pro výrobu sériových a individuálních součástí pro každodenní použití. To dokazuje použití v automobilovém průmyslu, u designových a okrasných objektů či kosmetických produktů. Velký zájem o FDM v poslední době projevuje medicínský průmysl pro výrobu implantátů, forem pro odlévání a pomůcek na jedno použití. Široké spektrum použití našla technologie FDM v době pandemie koronaviru, kdy sloužila pro tisk medicínských pomůcek a čelních štítů. Oproti technologii SLA nabízí FDM výrazně menší výrobní náklady, velké množství použitelných materiálů a vyšší rychlost výroby. Na druhou stranu výsledné součásti mají nižší kvalitu povrchu a tisk složitějších tvarů vyžaduje přidání podpor [16].



Obrázek 12 Schéma systému FDM [17],(upraveno).

### 4.3 Defekty a procesní parametry technologie SLM

Jak bylo zmíněno v předchozích kapitolách, princip metody SLM spočívá v natavení kovového materiálu ve formě prášku výkonným laserovým paprskem. V místě jeho působení dochází ke vzniku natavené oblasti (“*melt pool*“), která následně ztuhne. Tím dojde ke spojení nově tvořené a předchozí vrstvy. Výsledná mikrostruktura sestává z jednotlivých návarů a její výsledné chování je velmi citlivé na procesní parametry [18].

Stavba součásti vrstvu po vrstvě a silně lokalizovaný zdroj tepla ve formě laseru vedou ke tvorbě zbytkových napětí a vzniku defektů, či vad. Defekty vznikají uvnitř i na povrchu součásti a negativně ovlivňují únavovou životnost součásti. Přestože tyto defekty lze částečně eliminovat dodatečným tepleným zpracováním, například ve formě tzv. “*hot isostatic pressing*“, možnosti předejití jejich vzniku či jejich detekce by vedly ke snížení koncové ceny a umožnily širší použití aditivních metod. Defekty také negativně ovlivňují lomovou pevnost, mez pevnosti a tažnost. Výsledný materiál také často vykazuje anizotropní chování [19].

Geometrie tavené oblasti materiálu definuje strukturu a mechanické vlastnosti tisknuté součásti. Výsledná kvalita součásti je ovlivněna velkým množstvím procesních parametrů, které lze rozdělit do 3 hlavních skupin – související s práškem, související s laserovým systémem a související s tiskovým prostorem. Procesní parametry související s práškem jsou jeho chemické složení, velikost a tvar částic prášku. Procesní parametry týkající se laserového systému jsou výkon laseru, typ laseru, velikost paprsku, skenovací strategie, vzdálenost skenovacích drah a skenovací rychlost. Procesní parametry laserového prostoru souvisejí s mechanismem doplňování nového prášku do tiskové komory a teplotou tiskové komory. Tloušťka vrstvy tisknutého prášku je jedním z významných procesních parametrů [20].

Nejdůležitější procesní parametry souvisí se zdrojem laserového paprsku, neboť přímo určují podmínky, za jakých je taven použitý kovový materiál a tím je definována velikost a tvar natavené oblasti, která má přímou souvislost s formováním vad. Pro kvantifikaci energie dodané laserem je použit vztah, který je v literatuře nazýván měrná dodaná energie  $E [J/mm^3]$  (“*energy density*“) [18].




$$E = \frac{Pw}{v \times h \times t} \left[ \frac{J}{\text{mm}^3} \right] \quad (5)$$

kde  $Pw$  je výkon laseru (“*laser power*“) [W],  $v$  je skenovací rychlost (“*scan speed*“) [mm/s],  $h$  je vzdálenost jednotlivých skenovacích drah (“*hatch spacing*“) [mm] a  $t$  je výška tisknuté vrstvy (“*layer thickness*“) [mm].

Obecně lze mechanismy vzniku vad rozdělit do 2 kategorií, podle toho, zda je dodané množství energie větší nebo menší než optimální (obrázek 13) [18].


- Přebytek dodané energie (nízká skenovací rychlost, velký výkonem laseru a/nebo malá tloušťka vrstvy) vede ke vzniku pórů, kavit a zbytkových napětí. Vady vzniklé tímto mechanismem se nazývají “*keyhole defects*“ [18] [19].
- Nedostatek dodané energie (vysoká skenovací rychlost a/nebo malý výkon laseru) vede k nedostatečnému spojení a natavení jednotlivých částic prášku, ke vzniku pórů a v kombinaci s příliš velkou tloušťkou vrstvy k nedostatečnému spojení vrstev (delaminace). Vady vzniklé tímto mechanismem se nazývají “*lack of fusion defect*“ [18] [19].



Obrázek 13 Schéma mechanismu formování defektů při použití technologie SLM. a) ideální případ bez vzniku defektů, b) nedostatečná výška tisknuté vrstvy vedoucí ke vzniku pórů, c) příliš velká výška tisknuté vrstvy vedoucí k nedostatečnému spojení částic materiálu [19], (upraveno).

Dalším důležitým procesním parametrem je velikost částic použitého kovového prášku, kterou zkoumal Wang a kolektiv [21] u oceli 316 L. Došli k závěru, že plyn obsažený v prášku zvyšuje pravděpodobnost vzniku defektu a prášek o menším průměru má menší náchylnost k formování pórů. Konkrétně v případě použití zrn o velikosti 26,36  $\mu\text{m}$  byla relativní hustota vyrobené součásti 99,75 % zatímco při použití zrn o velikosti 50,81  $\mu\text{m}$  byla relativní hustota vyrobené součásti jen 97,50 %.

Významným procesním parametrem je také skenovací strategie. Existují tři základní typy skenování: jednosměrné, cik cak a mřížkové (“*cross-hatching*“) (obrázek 14). Prvně dvě jmenované jsou více náchylné k tvorbě defektů, neboť na začátku a na konci skenování je proces tavení nestabilní a dochází k vytlačování nečistot [18].



Obrázek 14 Skenovací strategie technologie SLM [22],(upraveno).


#### 4.3.1 Přehled defektů vyskytujících se u technologie SLM

Vady vyskytující se při použití technologie SLM lze rozdělit na 2 druhy. Prvními jsou vady mikroskopické, kterými jsou póry, kavity a neroztavený kovový prášek. Druhým druhem jsou vady makroskopické, kam je řazen výskyt trhlin, delaminace, formování materiálu do malých kapiček (*“melt balls“*) a pokrivení součásti (*“warping“*). Makroskopické vady mohou být projevem vad mikroskopických [23].

**Pórovitost** je běžný mikroskopický defekt v kovových tištěných součástech, který negativně ovlivňuje mechanické vlastnosti. Póry se vyskytují jak v kovovém prášku, tak vznikají během samotného tisku. Již samotný kovový prášek obsahuje vzduch uvnitř jednotlivých částic, který ve výsledné součásti zapříčiní vznik pórů kulovitého tvaru. Nicméně většina pórovitých defektů vzniká během tisku při procesu tavení a následného tuhnutí v případě neoptimálně zvoleného množství dodané energie. Tyto póry lze odlišit od těch majících původ v kovovém prášku, neboť nenabývají kulovitého tvaru. Pokud je dodané množství dodané energie nedostatečné, vyskytují se ve struktuře v těsném okolí póru **části neroztaveného prášku**. V případě že je laserovým paprskem dodáváno příliš mnoho energie dochází k rozstříkovaní nataveného kovu z místa tavby. To se projevuje vznikem dlouhých a tenkých stop ve výsledné struktuře, nazývané **kavity**, neboť chybějící materiál byl energií laseru přesunut na jiné místo [23]. Příklady mikroskopických vad jsou uvedeny na obrázku 15.


Qiu a kolektiv [24] uvedl, že vznik pórů v právě tisknuté vrstvě může souviset s nedostatečným znovu natavením lokálních částí předcházející již vytisknuté vrstvy. Vzhledem k tomu, že povrch tisknutých součástí je velmi drsný, roztavený kov nově tisknuté vrstvy do těchto malých oblastí jen velmi obtížně zatéká a po ztuhnutí zůstávají mezi vrstvami vzduchové kapsy, póry. Další důvod vzniku pórů uvedl Gong a kolektiv [25], který přisuzuje vznik pórů bublinkám plynu, které vznikají při odpařování prvků s nízkým bodem tání při použití příliš výkonného laseru.

Vznik pórů je nevyhnutelně spjatý s výrobou metodou SLM a póry se náhodně vyskytují v celém objemu tisknuté součásti. Správnou optimalizací procesních parametrů lze dosáhnout přítomnosti pórů a kavít menších jak 1 % z objemu výsledné součásti [18] [23].



Obrázek 15 Mikroskopické vady zachycené elektronovým mikroskopem, a) typický příklad pórovitosti, b) podlouhlá kavita a c) oblast malých kavity cylindrického tvaru, [19].

Zbytková napětí se běžně vyskytují v součástech vyrobených aditivními technologiemi z důvodu přítomnosti velkých teplotních gradientů během výroby a mohou negativně ovlivnit mechanické vlastnosti výsledné součásti. Zbytková napětí jsou napětí uvnitř součásti, která zůstávají přítomna i po odstranění veškerého vnějšího zatížení. Pokud jejich velikost překoná mez kluzu materiálu, může dojít k **pokřivení**. Pokud velikost zbytkových napětí překoná mez pevnosti materiálu, může dojít ke vzniku **trhlin** (obrázek 16) a **delaminace** (obrázek 17). Delaminace je makroskopický defekt, při kterém dochází k oddělení sousedních horizontálních vrstev tisknuté součásti v důsledku jejich nedokonalého spojení, způsobeného nedostatečným natavením kovového prášku vyráběné vrstvy nebo nedostatečným znovu natavením již položené vrstvy. Typicky jsou tlaková zbytková napětí uvnitř součásti a tahová zbytková napětí na povrchu součásti. K omezení vzniku zbytkových napětí pozitivně přispívá vyhřívání tisková komora a předehřev používaného kovového prášku na vyšší než pokojovou teplotu [18] [23].



Obrázek 16 Trhliny na vzorcích vyrobených metodou SLM [23].

**Tuhnutí materiálu do malých kapiček** (obrázek 17) namísto rovinných vrstev je další makroskopický defekt. K tomuto jevu dochází, pokud poměr délky ku průměru oblasti nataveného materiálu (výše zmíněný “melt pool”) je větší jak 2:1. V takovém případě se natavená oblast vlivem povrchového napětí změní z válce na koule a na výsledné součásti tak zůstanou malé kapičky roztaveného kovu [23].

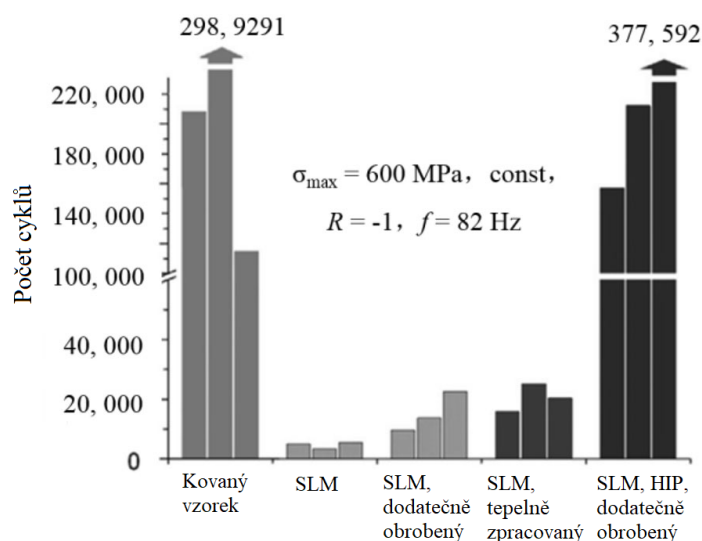


Tuhnutí materiálu do malých kapiček

Delaminace

Obrázek 17 Příklad makroskopických defektů delaminace a tuhnutí materiálu do malých kapiček [23],(upraveno).


Jak bylo zmíněno výše, studiu procesů vzniku a předcházení tvorbě defektů u výrobků vyrobených technologií SLM se věnuje velké úsilí, neboť tato technologie má díky široké nabídce kovových materiálů, volnosti tvaru vyráběné součásti a dobrým mechanickým vlastnostem velký potenciál využití ve všech odvětvích průmyslu. A právě přítomnost defektů vede ke koncentraci napětí, což může vést k havárii součásti. Defekty v tištěné součásti slouží jako zdroj inicializace trhlin, což výrazně zhoršuje také únavové vlastnosti součásti [18]. Kasperovich a kolektiv [26] zkoumali únavové vlastnosti součástí vyrobených z materiálu Ti6Al4V. Jako referenční hodnota cyklů do lomu byly uvažovány výsledky kovaného vzorku, které byly porovnávány s výsledky vzorků vyrobenými metodou SLM s dodatečným obrobením a tepelným zpracováním. Počet cyklů do lomu byl 10krát větší ve prospěch kovaných vzorků (obrázek 18). Nicméně únavové vlastnosti lze u tištěných materiálů výrazně vylepšit vystavením součástí přetlaku za zvýšených teplot (*“hot isostatically pressing/HIP“*), čímž lze dosáhnout srovnatelného počtu cyklů do lomu jako u kovaných součástí. Při tomto typu zpracování dojde ke spojení neroztavených částic prášku a tím výraznému snížení počtu mikrostrukturálních vad. Nevýhodou jsou dodatečné finanční náklady.



Obrázek 18 Porovnání počtu cyklů do lomu různě zpracovaných vzorků z materiálu Ti6Al4V [26],(upraveno).

#### 4.4 Defekty a procesní parametry technologie FDM


Nejvýznamnější vadou metody FDM jsou inherentní strukturální defekty, tedy nevyplněné místo mezi nanášenou strunou a již položenou vrstvou. Na druhou stranu na mechanické vlastnosti ani přesnost součástí vyrobených technologií FDM obvykle nejsou kladeny tak velké nároky [27]. Sun a kolektiv [28] uvedli 3 hlavní mechanismy spojování vláken polymeru při výrobě technologií FDM v závislosti na teplotě vlákna a překryvu se sousedním vláknem (obrázek 19). Těmito mechanismy jsou povrchový kontakt, spojení krčků a spojení molekulární difúzí. Poslední jmenovaný vzniká za vyšších teplot a tlaků a je preferovaný, neboť zajišťuje nejpevnější spojení.



Obrázek 19 Mechanismy spojení vláken u metody FDM, 1) povrchový kontakt, 2) spojení krčků a 3) molekulární difúze [28],(upraveno).


U technologie FDM se vyskytují tyto vady: strukturální defekty, odlepení od podložky, delaminace jednotlivých vrstev a deformace způsobené smrštěním materiálu (*“warping”*) [27].

**Strukturální nehomogenita** (obrázek 20) je daná principem výroby součásti pokládáním struny kruhového průřezu. Nedochozí tedy k dokonalému přilnutí vrstev a vyplnění objemu jako u technologie SLM. Tím vznikají nevyplněné oblasti uvnitř jednotlivých vrstev a také mezi vrstvami. Tyto nehomogenity vedou ke zhoršení mechanických vlastností, anizotropnímu chování výsledné součásti a mohou vést k delaminacím. Předcházet jejich vzniku lze zmenšením tloušťky tisknuté vrstvy, což ovšem negativně ovlivňuje čas potřebný k vytisknutí součásti. Tloušťky vrstev se u metody FDM pohybují v rozmezí 0,05 – 0,4 mm. Nevyplněný objem materiálu také ovlivňuje šrafovací strategie, teplota tavení struny, teplota trysky a okolí a tvar součásti [29].



Obrázek 20 Nehomogenity v objemu součásti [29].

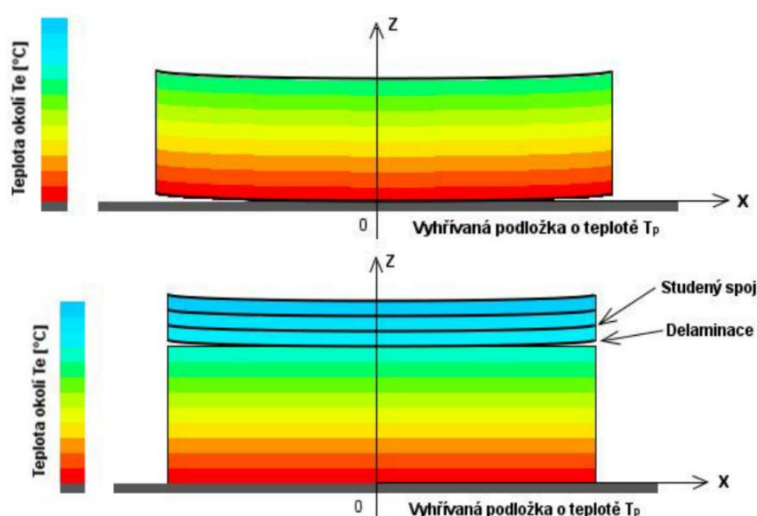
Vliv teploty trysky a teploty okolí na objem nevyplněného materiálu součásti zkoumali ve své práci Gajdoš a kolektiv [29]. Pro experimenty byly použity 2 tvary vzorků z materiálu ABS400 s kruhovým a obdélníkovým průřezem vytištěné za 2 rozdílných teplot okolí 70 °C a 75 °C a za 3 rozdílných teplot trysky 280 °C, 285 °C a 290 °C. Z výsledků měření vyplývá, že s rostoucí teplotou okolí klesá objem nevyplněného materiálu o 1–2 % (obrázek 21) pro obdélníkový průřez vzorku. Zlepšení o cca 5 % také přineslo zvýšení teploty trysky na 290 °C. Naopak u kruhového průřezu je citlivost na teplotní parametry ve většině případů zanedbatelná.



Obrázek 21 Nevyplněný objem součásti s obdélníkovým průřezem v závislosti na teplotě trysky a teplotě okolí [29], (upraveno).

Zbylé defekty **odlepení od podložky, delaminace jednotlivých vrstev a deformace způsobené smrštěním materiálu** jsou spojené s výskytem zbytkových napětí v součásti vyvolaných nerovnoměrným chladnutím jednotlivých vrstev při tisku. Nová vrstva je nejprve nanášena v tekutém skupenství a během chladnutí spojena s vrstvou předchozí. Během chladnutí ovšem dochází u horní vrstvy k smršťování, zatímco zbytek součásti má již přibližně teplotu okolí. To vede ke vzniku vnitřních napětí v nově nanášené vrstvě. V důsledku jejich

uvolnění dochází k výše zmíněné deformaci a zkroucení součásti, k odlepení od podložky a k delaminaci jednotlivých vrstev (obrázek 22) [27] [30].



Obrázek 22 Odlepení od podložky a delaminace u součásti vyrobené technologií FDM [31].

#### 4.5 Defektoskopie

Defektoskopie je soubor metod testování produktů za účelem zjištění přítomnosti vad a defektů v materiálu, které mohou vést k předčasnému poškození součásti a vzniku havárií. Důležitost odhalení těchto defektů přímo souvisí se zachováním spolehlivosti a vysoké kvality vyráběných součástí [32].

Valná a preferovaná část defektoskopických metod jsou nedestruktivního charakteru, neboť nenarušují použitelnost ani schopnost plnit předpokládanou funkci součásti. Tyto metody používají přiměřenou formu energie pro indikaci přítomnosti materiálových diskontinuit (plošných, vnitřních nebo skrytých), necelistvosti materiálu nebo jeho materiálových charakteristik. Nejstarší takovouto metodou je vizuální kontrola součástí. Pokročilejší metody jsou založené na fyzikálních principech a jedná se například o kapilární metody, ultrazvukové metody, metody využívající rentgenové paprsky a metody využívající magnetické pole [32].

Druhým typem defektoskopických metod jsou metody destruktivního charakteru. Většina výrobců preferuje se tomuto typu metod vyhýbat, neboť zkoušená součást po provedení zkoušky již neplní svůj předpokládaný účel. Používají se především u velkosériového typu výroby na principu náhodného výběru daného počtu vzorků z výrobní série, které jsou následně otestovány. Pokud u nich nejsou nalezeny žádné výrobní vady a defekty, je celá výrobní série považována za bez defektní. Otestované vzorky lze ve většině případů znovu použít pro produkci nové výrobní série [32].

Vzhledem k povaze práce, která se zabývá detekcí defektů v tištěných součástech, vyráběných ve většině případů jen ve velmi malých sériích, je zachování schopnosti plnit svoji předpokládanou funkci i po testování podmínkou důležitou a žádoucí. Tím pádem budou dále v práci uvažovány jen metody nedestruktivního charakteru.

##### 4.5.1 Zkoušení ultrazvukem


Zkoušení ultrazvukem využívá principu odrazu ultrazvukových vln na rozhraní vad a necelistvostí zkoušené součásti nebo principu útlumu ultrazvukového signálu ve zkoušené

součásti. Jedná se o jednu ze základních objemových metod nedestruktivního zkoušení materiálu, která dokáže detekovat vady plošné i objemové. Cílem metody je nalezení vnitřních vad zkoušeného materiálu jako jsou bubliny, póry a praskliny a také vady povrchové. Nejspolehlivěji detekuje tato metoda vady, které jsou orientovány kolmo ke směru vysílaných ultrazvukových vln jako jsou vady ve svarech a v kovaných a válcovaných výrobcích a odlitcích. Zkoušené materiály mohou být vyrobeny z oceli a jiných kovových materiálů, plastu, gumy a betonu. Tato metoda je vhodná především pro součásti větších rozměrů a součásti již zabudované, u kterých je přístupný pouze jeden povrch [33].

#### 4.5.2 Zkoušení radiografické

Radiografické zkoušení je založeno na interakci zkoušené součásti s ionizujícím zářením, které součástí prochází. Na opačné straně součástí od zdroje záření je umístěn vhodný detektor. Na základě změny intenzity mezi vyslaným a zachyceným signálem jsou detekovány nehomogenity uvnitř i na povrchu součásti (bubliny ve svarech, staženiny v odlitku, dutiny, trhliny), které způsobují změnu intenzity signálu v menší míře než materiál bez přítomného defektu. Tato metoda se primárně používá v případech, ve kterých nelze využít ultrazvukové zkoušení [33].

Jandýsek a kol. [34] využili kombinaci digitální korelace obrazu a měření pomocí rentgenových paprsků k detekci vzniku trhliny ve vzorku tyčového tvaru vyrobeného z hrubozrnné oceli používané v leteckém průmyslu a zatíženého jednoosým tahem. Iniciační trhlina byla úspěšně detekována v místě intenzivních lokálních napětí, které byly vypočítány metodou digitální korelace obrazu aplikovanou na pořízené rentgenové snímky (obrázek 23).



Obrázek 23 Uprostřed pole přetvoření uvnitř vzorku tyčového tvaru (osa Z je osou vzorku) získané pomocí metody DIC aplikované na CT snímky [34],(upraveno)

#### 4.5.3 Zkoušení magnetickou metodou práškovou

Zkoušení magnetickou metodou práškovou využívá principu detekce rozptylového magnetického toku pomocí jemných železných pilin. Pokud se v materiálu nachází necelistvost kolmá k magnetickým čarám, vystoupí magnetický tok nad vadu což vede ke shromáždění kovových pilin v daném místě. Důvodem tohoto jevu je malá permeabilita vzduchu nacházejícího se uvnitř vady v porovnání s okolním materiálem. Magnetická prášková metoda




je použitelná pro detekci povrchových nebo těsně podpovrchových vad ve feromagnetických materiálech. Jedná se například o studené spoje a podpovrchové trhliny. Pro detekci objemových vad uvnitř materiálu se nehodí [33].

#### 4.5.4 Zkoušení vířivými proudy

Principem metody vířivých proudů je indukování střídavého napětí uvnitř zkoušené součásti pomocí střídavého magnetického pole cívky. Neboť zkoušená součást představuje proudovodič, vznikají uvnitř ní tzv. vířivé proudy, které generují vlastní magnetické pole. Pokud se v součásti vyskytuje vada, dojde ke změně vodivosti materiálu a hustoty vířivých proudů. Tato změna je zaznamenána ve formě rozdílné fáze a napětí na budící cívce nebo na externí měřicí cívce. Metoda je vhodná jen pro elektricky vodivé materiály [33].

#### 4.5.5 Metoda infračervené termografie

Metodou infračervené termografie je měřeno rozložení teplotního pole v čase na povrchu ohřívané součásti. Vývoj teplotního pole a jeho gradientů v čase je vyhodnocován a na základě nehomogenit v jeho rozložení jsou detekovány potenciální defekty, které ovlivňují šíření tepla jiným způsobem, než okolní homogenní materiál (obrázek 24) [35].



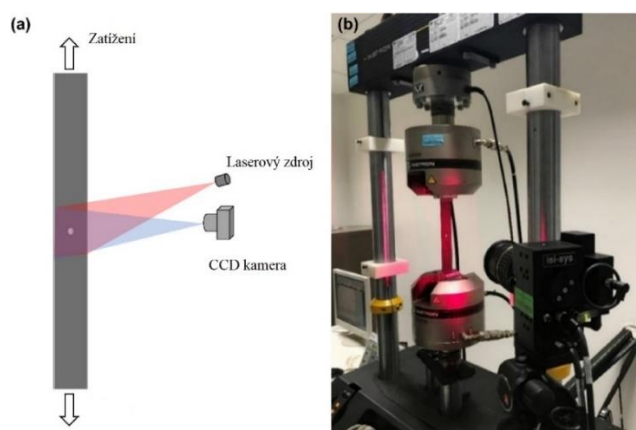
Obrázek 24 Příklad využití metody infračervené termografie [35],(upraveno).

#### 4.5.6 Metody optické interferometrie

Metody optické interferometrie, nebo také optické interferometrické techniky, používají pro posouzení vnitřního stavu součásti osvětlení laserovým nebo viditelným světlem. Hlavní výhodou oproti dříve zmíněným typům zkoušení je rychlost a schopnost vyšetřovat oblast o velké rozloze, což snižuje čas potřebný pro inspekci a s tím spojený čas potřebný pro odstávku posuzované součásti. To spolu s dostupnější použitou technikou výrazně snižuje náklady potřebné pro testování. Mezi nejprogresivnější metody v této oblasti patří shearografie používající laserové světlo a metody využívající digitální korelaci obrazu [36].


**Optická shearografie** je nedestruktivní měřicí metoda vhodná pro měření přetvoření kolmých na rovinu nezátíženého povrchu (*“out-of-plane surface displacement“*) jako jsou delaminace. Je tedy vhodná pro detekci vnitřních defektů, rozšířená je v letectví pro měření kvality kompozitních materiálů a lopatek motorů a také v energetice při kontrole lopatek turbín. Nabízí vysokou citlivost při měření deformací a měření přetvoření na velké oblasti. Její použitelnost je nejvíce prozkoumána pro měření tenkých součástí (cca do 50 mm). Pro úspěšné nalezení defektu je nutné, aby příspěvek deformace zapříčiněné defektem (*“defect-induced deformation“*, DID) v celkové deformaci (*“overall deformation“*, OD) bylo možné detekovat

použitým hardwarem. Obecně by tento poměr DID ku OD by měl být větší jak dva. Při shearografii je povrch hrubé součásti nasvícen koherentním laserovým paprskem, který je rozptýlen po její ploše paprskovým expandérem a tím vytvořen skvrnitý vzor. Odražené světlo je detekováno interferometrem a zaznamenáno CCD kamerou (obrázek 25). Shearografie detekuje defekty v součásti porovnáváním skvrnitého vzoru mezi dvěma stavy, je tedy nutné součást nějakým způsobem zatížit. Toto zatížení může být teplotní nebo mechanické [37] [38] [39].



Obrázek 25 a) schéma měřicího řetězce při použití shearografie, b) fotografie měřicího řetězce [39],(upraveno).

Zhang a kolektiv [39] porovnávali shearografii s metodou DIC během měření kompozitního vzorku vyztuženého uhlíkovými vlákny podrobeného tahové zkoušce po mez pevnosti. Hlavní důraz byl kladen na měření vzniku a rozvoje podpovrchových vad. Pro měření byl vybrán vzorek o rozměrech 300 mm x 36 mm x 2 mm s otvorem uprostřed o průměru 6 mm, u kterého se očekával vznik rozličných defektů. Výsledky získané metodou DIC ukazují kritické místo po stranách otvoru, které roste spolu se zatížením. Žádná další indikace výskytu defektů vidět nelze. Naopak na výsledcích získané shearografií (obrázek 26) lze pozorovat vznik defektů již při zatížení kolem 70 % meze pevnosti. Z porovnání obou metod vyplývá, že shearografie je mnohem citlivější a nabízí větší citlivost pro měření deformací a změn v rovině kolmé na prováděné měření.



Obrázek 26 Výsledky shearografického měření vzorku, číslo udává procentní zatížení vztahené k mezi pevnosti [39].

Pro úplnost je zde uveden přehled zbývajících typů nedestruktivního zkoušení, které ovšem nelze použít pro detekci vad uvnitř materiálu a jsou tedy pro účel této práce nepodstatné. Jedná se o zkoušení vizuální, využívající pro detekci vad jen lidské oko, zkoušení kapilární, využívající kapilární jev spojený s povrchovým napětím, které je vhodné především pro odhalení povrchových necelistvostí, zkoušení akustickou emisí a zkoušení těsnosti, používané pro tlakové nádoby a jiné výrobky vyžadující těsnost [33].

#### 4.6 Strojové učení

Strojové učení (*“Machine Learning“*) pokrývá rozsáhlou škálu oborů informačních technologií, statistiky, pravděpodobnosti, umělé inteligence, psychologie a mnoha ostatních disciplín. Řešení problémů v rámci strojového učení probíhá sestavením modelu, který věrohodně reprezentuje zvolená data. Konkrétně se jedná o sestavení algoritmu, pomocí kterého je schopný počítač nalézat statistické podobnosti a vzory v datech [40].

Od začátku 21. století zažívá strojové učení obrovský rozmach díky nástupu velmi výkonných počítačů a možnostem sběru a uchování velkých objemů dat. Příkladem využití strojového učení v praxi je oblast tzv. Big Dat. Z těch jsou metody strojového učení, v kombinaci s velkým výpočetním výkonem a komplexními matematickými operacemi, schopny rychle a automaticky získávat velké množství informací. Hlavními oblastmi zájmu jsou například rozpoznávání vzorů a souvislostí v předložených datech, učení se procesem zkoušení a následného učení na základě analýzy výsledků, abstrahování nových informací z dat nebo optimalizace přesnosti a efektivity na základě práce se vstupními a výstupními daty. Dalšími důležitými oblastmi využití strojového učení jsou analýza chování uživatelů sociálních sítí a internetových stránek obecně, cílené doporučování obsahu, rozpoznání obrazu, či zpracování řeči a textu [40] [41].

Strojové učení je rozděleno do 2 hlavních kategorií, v závislosti na typu vstupních dat a požadovaných výstupech. Jedná se o strojové učení bez učitele (*“Unsupervised machine learning“*) a strojové učení s učitelem (*“Supervised machine learning“*) [40].

##### 4.6.1 Strojové učení bez učitele

V případě strojového učení bez učitele nejsou předem známy žádné kategorie a vstupní data nejsou nijak blíže popsána. Je tedy cílem samotného algoritmu najít souvislosti a podobnosti mezi daty a na jejich základě provést rozřídění do nově vytvořených skupin. Při použití tohoto typu učení tedy může algoritmus objevit uživateli předem neznámé souvislosti mezi daty a přinést nové skutečnosti. Z tohoto důvodu je mu v dnešní době věnováno mnoho pozornosti v odborných kruzích [40].

##### 4.6.2 Strojové učení s učitelem

V případě strojového učení s učitelem jsou předem dány kategorie, do kterých má algoritmus třídit data. V praxi to znamená, že vstupní data jsou popsána/rozříděna do kategorií a cílem strojového učení je najít mezi daty užitečné vzory a souvislosti. Na jejichž základě je vytvořen matematický model, který bude úspěšně kategorizovat nově dodaná, předem nepopsaná data. Existují dva základní typy učení s učitelem: klasifikační modely (*“classification models“*) a regresní modely (*“regression models“*). Klasifikační modely používají algoritmus pro co nejpřesnější rozdělení dat do stanovených kategorií. Model funguje na základě rozpoznání určitých vlastností každé kategorie dodaných dat. Na základě těchto vlastností poté co nejpřesněji rozříděna také nově dodaná data, která již popsána nejsou.

Naopak regresní modely hledají závislost mezi vstupními a výstupními daty a na jejím základě predikují budoucí vývoj. Typická oblast použití je například projekce zisků, či velikosti chodidla člověka na základě jeho výšky [40].

Vzhledem k tématu práce, která se zabývá detekcí vad, což lze chápat jako klasifikaci posuzovaného vzorku na “s vadou“ nebo “bez vady“, nejvhodnější oblastí strojového učení, která by mohla být vhodná pro navrhovanou defektoskopickou metodu, je strojové učení s učitelem a do ní patří klasifikační modely. Dále je uvedeno několik nejpoužívanějších zástupců učení s učitelem.

**Naivní Bayesovský klasifikátor** (“*Naive Bayes*“) vychází pro odhad příslušnosti daného vstupu do třídy pravděpodobnosti z apriorních pozorování. Tyto pravděpodobnosti jsou spočítány ze vstupních dat. Pro nová data počítá klasifikátor pravděpodobnost přiřazení do jednotlivých tříd. Nejčastěji je používán pro textová data, například spamové filtry a dobře pracuje s daty zatíženými šumem. Předpis pro výpočet pravděpodobnosti nového pozorování  $c$  na základě apriorních pozorování  $x$  o počtu  $N$  zní [40]:


$$P(x|c) = \prod_{i=1}^N P(x_i|c) \quad (6)$$

**Support vector machine** (SVM) je metodou vhodnou především pro binární klasifikaci (tj. do dvou tříd). Algoritmus nalezne nadrovinu (obrázek 27), která co nejlépe oddělí vstupní data tak, aby od ní byly body jednotlivých tříd co nejvíce vzdáleny. Pro lineární model má nadrovina předpis:

$$f(x) = wx + b = 0 \quad (7)$$


kde  $w$  je váhový vector a  $b$  je kompenzační člen.

Dimenze nadroviny odpovídá počtu vstupních parametrů. V základu pracuje metoda jen s lineárně oddělitelnými daty, ale použitím tzv. *kernel trick* lze klasifikovat také nelineárně oddělitelná data. SVM funguje velmi dobře s komplexními daty (text, obrázky) a dává dobré výsledky i při malém počtu trénovacích dat. Na druhou stranu je velmi náchylný k přetrénování, kdy prokládá velmi dobře vstupní data, ale nepřesně klasifikuje data nová [42] [43].




Obrázek 27 Vizualizace nadroviny oddělující 2 třídy dat [44].

**Rozhodovací strom** (“*Decision trees*“) je klasifikátor, který pracuje s vektorem atributů jako vstupními daty a vrací rozhodnutí ve formě příslušnosti do jedné z možných tříd. Základním prvkem rozhodovacího stromu je kořen (“*root*“), který má jen výstupní propojení. Uvnitř stromu jsou uzly (“*nodes*“), které reprezentují podmínky a rozvětvují strom na dvě nové části. Na konci stromu jsou listy (“*leaf*“), které reprezentují jednotlivé kategorie. Nová data jsou klasifikována postupným průchodem celým stromem a navigováním dle splnění podmínek v uzlech (obrázek 28). Výhodou rozhodovacích stromů je jejich snadná vizualizace, nevýhodou jsou sklony k přetrénování dat a jejich nedostatečné generalizaci. Rozhodovací stromy jsou používány například k predikci chování zákazníků [40] [43].



Obrázek 28 Příklad rozhodovacího stromu [45].

**Neuronové sítě** (“*Neural network*“) jsou inspirovány principem lidského mozku a skládají se z několika vrstev navzájem propojených modelů neuronů. Jednotlivým propojením mezi neurony jsou přisuzovány rozdílné váhy, které se mění na základě průchodu vstupních dat sítí. První vrstva se nazývá vstupní (“*Input layer*“), poslední vrstva je výstupní (“*Output layer*“) a zbylé vrstvy se nazývají skryté (“*Hidden layers*“) (obrázek 29). Každý neuron má svoji aktivační funkci, která je nelineární a upravuje výstup z daného neuronu. Díky tomu lze pomocí neuronových sítí řešit i nelineární problémy. Pro většinu základních aplikací se používají sítě s jednou až dvěma skrytými vrstvami. Velikostí jednotlivých vah jsou parametry, které jsou upravovány na základě průchodu vstupních dat sítí tak, aby výstup sítě odpovídal požadované výstupní kategorii. Tomuto procesu se říká trénování sítě. Základním typem neuronových sítí jsou plně propojené neuronové sítě (“*Fully connected neural networks*“), u kterých jsou všechny neurony z jedné vrstvy propojeny se všemi neurony ve vrstvě následující. Dalším typem jsou konvoluční neuronové sítě (“*Convolutional neural networks*“), které jsou široce využívány při zpracování obrazu a jejich výhodou je relativně malá náročnost přípravy dat v porovnání s ostatními algoritmy pro zpracování obrazu. Skládají se z kombinace konvolučních vrstev a pooling vrstev, které slouží k extrakci různých vzorů v obraze, s plně propojenou neuronovou sítí, která připravená data klasifikuje. Tímto postupem jsou z obrazu postupně extrahovány důležité rysy, hrany a tvary, které jsou následně použity pro klasifikaci daného obrazu [42].



Obrázek 29 Příklad plně propojené neuronové sítě [46].

#### 4.7 Odborné články související s tématem práce


V této kapitole je uvedený přehled odborných prací souvisejících s tématem odhalování a předcházení vad u výrobků a struktur vyrobených pomocí aditivních technologií a použití metody DIC a metod strojového učení pro detekci vad v součástech.

Ve svém článku se Binqi Liu a kolektiv [47] zabývali odvozením analytického modelu oblasti tavení (“*melt pool*“) pro výrobu technologií SLM, který by umožnil optimalizovat procesní parametry a tím snížit množství defektů ve vyráběné součásti. Model vychází z tepelné rovnováhy přední části oblasti tavení uvažující tok roztaveného materiálu, tlak plynů vznikajících při tavení a absorbované množství energie laserového paprsku. Navržený analytický model byl porovnán s experimentálně získanými tvary oblastí tavení a vykazuje velmi dobrou shodu v tzv. “*medium energy density*“ oblasti (MED). MED je energetická oblast, která je při výrobě technologií SLM preferovaná, neboť je v ní proces tavení nejstabilnější s nejmenší pravděpodobností vzniku defektů. Velkou výhodou analytického modelu je malá výpočtová náročnost ve srovnání s dříve používanými numerickými modely.

Jiný přístup k problematice návrhu procesních parametrů zvolili ve svém článku Julie Gheysen a kolektiv [48], která navrhla metodu založenou na experimentálních datech získaných pro konkrétní materiál. Návrh procesních parametrů je založen na měření 9 návarů, 18 krychlí a 12 tahových vzorků vyrobených technologií SLM ze zkoumaného materiálu. Na základě analýzy geometrie návarů, hustoty krychlí a výsledků tahových zkoušek vzorků jsou určeny vhodné procesní parametry pro daný materiál. Autoři navržený postup validovali na materiálu AlSi12, u kterého dosáhli lepších mechanických vlastností než při doposud v literatuře uvedených postupech.

Jamison Barlett a kolektiv [19] ve svém článku zkoumali možnosti použití 3D DIC metody pro měření výroby (“*in-situ*“) součástí aditivní technologií SLM (obrázek 30). Pro tisk byly navrženy 3 součásti, které měly několik geometricky složitých prvků, jako jsou přečnívající stěny a vnitřní kavity, v jejichž okolí obvykle dochází ke zvýšenému vzniku vad. Každá součást byla tisknuta se 3 různými nastaveními výrobních parametrů a s rozdílnými hodnotami měrné dodané energie. Výsledkem měření byla data popisující každou tisknutou vrstvu jednotlivých součástí v relativních souřadnicích tiskové komory v osách X, Y a Z. Na základě těchto dat byla vytypována místa s defekty, která byla porovnána s výsledky skenování na elektronovém mikroskopu, kterému byly součásti podrobeny po vytisknutí. Toto porovnání potvrdilo dobrou shodu předpokládaných míst s defekty určených pomocí DIC s defekty

viditelnými na datech z elektronového mikroskopu. Autoři také použili data naměřená metodou 3D DIC pro tvorbu modelu založeném na principu naivního Bayesovského klasifikátoru pro automatickou detekci vrstev obsahujících vady.



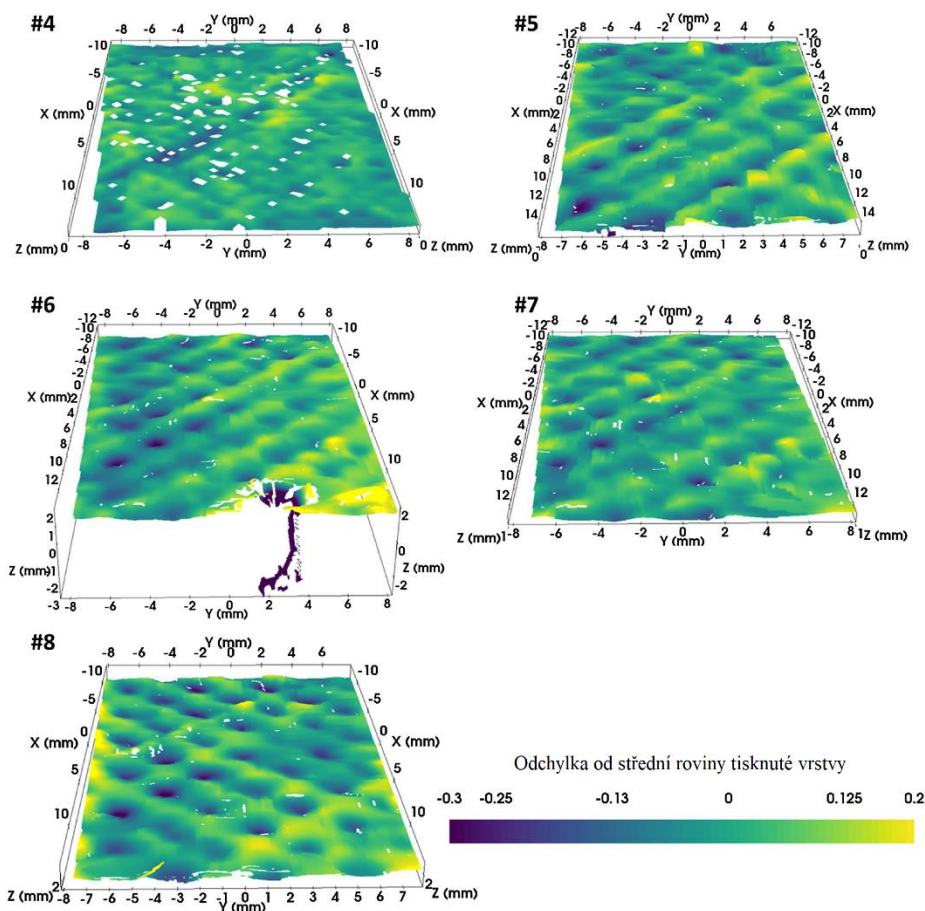
Obrázek 30 a) schéma ukazuje polohu kamer měřících tisknutou součást a obrázek b) ukazuje praktické provedení měření [19]

Zackary Snow a kolektiv [49] porovnávali přesnost plně propojené a konvoluční neuronové sítě pro klasifikaci snímků součástí s vadami z materiálu Ti-6Al-4V. Snímky byly získány metodou výpočetní tomografie (CT) a jednalo se o obrazová data jednotlivých vrstev již vyrobených součástí pořízených za různých světelných podmínek. Lepších výsledků bylo dosaženo ve všech případech při použití konvoluční neuronové sítě, která dokázala lépe generalizovat a správně klasifikovat i napříč snímky pořízených za rozdílných podmínek. Při klasifikaci snímků s velikostí vad nad 0,2 mm byla dosažena úspěšnost klasifikace 87,3 %.

Ruoxin Wang a kolektiv [50] ve své práci použili konvoluční neuronové sítě pro detekci povrchových defektů na snímcích součástí vyrobených technologií SLM pořízených elektronovým mikroskopem. Navržený algoritmus nejen dokázal vady detekovat, ale také rozřadit do 4 předem daných kategorií – trhlina, neroztavené částice kovového prášku, póry a kavity.

Metodu DIC pro vyšetření rozložení přetvoření na povrchu různých typů mřížkových struktur vytištěných technologií EBM použil ve své práci N. Vanderesse a kolektiv [51]. Na základě měření podrobného rozložení přetvoření, ve kterém se zaměřil na místa s lokalizací přetvoření, zkoumal, jakým způsobem dochází ke kolapsu tlakem zatížených struktur.

Oliver Holzmond a kolektiv [52] navrhli metodu, kterou monitorovali tisk aditivně vyráběné součásti (*“in-situ”*) metodou FDM. Metoda se skládá z měření jednotlivých vrstev vyráběné součásti metodou 3D DIC a vyhodnocování rozdílů mezi změřenou souřadnicí tisknuté vrstvy se souřadnicí danou počítačovým modelem vrstvy v ose kolmé na tiskovou rovinu (osa Z). Při experimentálním ověření dokázali pomocí navržené techniky lokalizovat jak lokální defekty jako kapky materiálu, tak globální defekty způsobené například nízkým tokem filamentu (obrázek 31).



Obrázek 31 Rozdíl souřadnic jednotlivých vrstev ve směru kolmém na rovinu tisku, ve vrstvě číslo 6 je vidět defekt vzniklý nedostatečným tokem filamentu [52],(upraveno).

Amir Rezaie a kolektiv [53] ve své práci porovnávali dva přístupy k segmentaci trhlin v tlakově zatížených kamenných blocích používaných ve stavebnictví. Prvním přístupem využíval metodu DIC, pomocí které byla získána pole přetvoření na povrchu krychle. Trhliny fungují jako koncentrátoři přetvoření a v obraze byly lokalizovány na základě překročení nastavené hranice velikosti přetvoření. Druhým přístupem bylo použití konvoluční neuronové sítě na pořízené černobílé snímky ještě před použitím metody DIC. Zatímco mírně lepší citlivost na minimální velikost trhlin (o 4 %) vykazoval přístup využívající metodu DIC, tak výrazně větší přesnosti (o 47 %) bylo dosaženo druhým přístupem využívajícím konvoluční neuronovou síť.

Ve svém přehledu o nedestruktivním zkoušení a aditivních technologiích Isaac Segovia Ramiréz a kolektiv [35] zmiňují v současnosti používané metody pro odhalování vad součástí vyrobených aditivními technologiemi, kterými jsou zkoušení akustickou emisí, testování vířivými proudy, testování pomocí infračervené termografie, testování využívající magnetismus, penetrační metodu vhodnou pro povrchové vady a testování ultrazvukovými vlnami a rentgenovými paprsky. Velký potenciál má dle autorů metoda nedestruktivní evaluace, která je rozšířením metod nedestruktivního zkoušení. Jedná se o automatizované zpracování a vyhodnocení dat získaných z nedestruktivních zkoušek, která umožňuje detekovat defekty, diagnostikovat součásti a předpovídat jejich životnost. Pro zpracování a vyhodnocení dat jsou nejčastěji používány metody strojového učení. Na základě rešerše dostupných článků zmiňují autoři především použití neuronových sítí a algoritmů SVM a K-means. K podobným závěrům



dochází v přehledu o použití strojového učení pro nedestruktivní posouzení svarových defektů také Hongbin Sun a kolektiv [42]. Konkrétně se jedná o posouzení svarů dle normy ASME, při kterém je využíváno ultrazvukových vln. Jako první autoři zmiňují algoritmy SVM, plně propojené neuronové sítě a rozhodovacího stromu, u kterých je doporučována předchozí extrakce důležitých znaků. Nejvhodnější a pro obrazovou klasifikaci nejčastěji používány jsou dle autorů konvoluční neuronové sítě. Vzhledem k tomu, že se při výrobě technologií SLM výsledná součást skládá z mnoha malých návarů, lze považovat jejich zjištění za přínosné také detekci defektů v součástech vyráběných aditivními technologiemi.

## 5 Komplexní analýza problému

Z provedené rešeršní práce vyplývá, že předcházením a detekcí vad výplně je v případě aditivních technologií věnováno mnoho výzkumu a úsilí, neboť se jedná o jev, který omezuje oblast jejich použití a brání širšímu rozšíření takto vyráběných součástí do oblastí průmyslu, které vyžadují záruku kvality a vysokou spolehlivost. Část tohoto úsilí je věnována optimalizaci a metodám návrhu procesních parametrů. Ty sice výrazně zmenšují riziko vzniku vad a pro výrobu jsou velmi cenné, nedokážou ale popsat stav výplně konkrétní součástí. Tím se zabývají metody podrobnější kontrole samotný proces výroby součástí nebo metody měření vyrobené součástí. V této oblasti jsou nejčastěji používány metody infračervené termografie, ultrazvuku, rentgenových paprsků a také metoda DIC. Poslední jmenovaná byla úspěšně použita pro *in-situ* měření během výroby součástí. Měření ovšem předchází technologicky a časově velmi náročná příprava měřeného prostoru. Možnosti použití metody DIC pro detekci vnitřních defektů výplně vyrobených součástí doposud prozkoumány nebyly. Právě to si klade za cíl tato práce, jelikož by se mohlo jednat o v praxi snadno použitelnou a finančně méně náročnou alternativu k výše zmíněným metodám.

Vady vznikají uvnitř součástí vyrobených aditivními technologiemi náhodně a inherentně vzhledem k nestabilitě výrobního procesu a jejich úplná eliminace není možná. Pro jejich detekci jsou v současnosti používány metody využívající typy záření, které dokážou prostoupit skrz materiál, ze kterého je součást vyrobena. Jedná se především o použití ultrazvukového a rentgenového záření. To přímo interaguje s vadami uvnitř součástí. Vady tedy mohou být detekovány bez nutnosti změny tvaru testované součásti, neboť vyhodnocení vychází ze záznamu jen jednoho časového okamžiku. Při použití metody DIC je nutné porovnávat dva časové okamžiky, mezi kterými došlo ke změně tvaru součásti v důsledku deformačního nebo teplotního zatížení. Při použití viditelného světla jako nositele informace je nutné vyházet při odhalování vnitřních vad z jejich projevů na povrchu součástí. Je nutné také uvažovat nejistoty měření vyskytující se při použití metody DIC jako je přesnost kalibrace, rozlišení kamer, či kvalita náhodného vzoru. Tyto aspekty ovlivňují velikost a pozici vad, které je možné tímto způsobem odhalit. Defektoskopická metoda by měla být dostatečně přesná, neboť při neodhalení defektu součásti může dojít k jejímu selhání nesoucí velké finanční a zdravotní následky a při označení součásti bez přítomnosti defektu jako vadné dochází ke zhoršení ekonomičnosti výroby.

## 6 Systém podstatných veličin

Systém podstatných veličin  $\Sigma(\Omega)$  je množinou podstatných veličin a vazeb, které souvisí s řešením problému. Je rozdělený na 9 podmnožin [54].

Podmnožina S0 obsahuje světelné podmínky během testování.

Podmnožina S1 obsahuje topologii a geometrii testované součásti vyrobené pomocí aditivních technologií.

Podmnožina S2 je prázdná.

Podmnožina S3 obsahuje způsob zatížení součástí během jejího testování.

Podmnožina S4 je prázdná.

Podmnožina S5 obsahuje požitou technologii výroby a materiálové charakteristiky součásti.

Podmnožina S6 je změna tvaru součásti v důsledku zatížení.

Podmnožina S7 je deformace povrchu součásti vyhodnocená metodou DIC.

Podmnožina S8 je detekce defektu výplně zkoušené součásti nebo prohlášení součásti za bez defektní.

## 7 Volba metod řešení problému

Tato práce se zabývá novou problematikou detekce vad součástí vyrobených pomocí aditivních technologií s použitím metody DIC. Bylo proto nutné zvolit, jakým způsobem bude využita metoda DIC pro splnění cílů práce.

Ve všech nalezených pracích zabývajících se tématem detekce vnitřních defektů byly použity rentgenové snímky nebo snímky z elektronového mikroskopu, které dokážou vady výplně odhalit přímo. Vybavení nutné pro použití těchto technologií je ovšem finančně nákladné a bylo proto preferované pracovat s fotografiemi, které se v kombinaci s metodou DIC používají nejčastěji a pro jejichž pořízení postačují komerčně dostupné kamery. To přináší nutnost nepřímé detekce vad, tedy odhalení výskytu vad na základě jejich projevů na povrchu součásti.

Problém je řešen experimentálním modelováním, neboť pro něj neexistuje použitelná matematická teorie.

### 7.1 Nástroje použité pro řešení problému

Pro zpracování obrazových dat byl použit komerční software Alpha společnosti X-Sight s.r.o. [55], který obsahuje implementaci metody DIC.

Pro vyhodnocení a další práci s naměřenými daty byl použit programovací jazyk Python a jeho knihovny NumPy a PyTorch.

Výpočty byly prováděny na přenosném osobním počítači výrobce Lenovo typ IdeaPad 700.

### 7.2 Návrh defektoskopické metody

Jak bylo zmíněno výše, navrhovaná defektoskopická metoda bude pracovat s fotografickými snímky. Poloha, velikost ani tvar vad nejsou předem známy, je tedy nutné vyšetřovat celý povrch součásti. Z tohoto důvodu bude pro vyhodnocení použito pole přetvoření po celém povrchu součásti, které nabízí nejkompaktnější popis stavu povrchu součásti a maximalizuje pravděpodobnost detekce vad.

Součást bude zatížena tahovou silou nepřekračující mez kluzu, aby nedošlo k trvalému poškození součásti, neboť navrhovaná metoda má být nedestruktivního charakteru. Při návrhu zátěžné síly je nutné uvážit také možný výskyt vad, které mohou mez kluzu reálné součásti snížit. Zatížení tahovou silou bylo upřednostněno před teplotním zatížením z důvodu jeho snadnějšího praktického provedení, jednodušší kontroly zatížení a také rychlosti měření, která je pro praktické využití důležitá.

Defekty výplně budou v součásti detekovány na základě lokalizace přetvoření v jejich okolí projevujícími se lokálními nehomogenitami v poli přetvoření, ke kterým dochází v důsledku oslabení průřezu součásti přenášejícího zatížení v těchto místech. Viditelnost těchto nehomogenit bude růst se vzrůstajícím zatížením. Je proto preferované, aby materiál součásti byl zatížen co nejbližší mezi kluzu a v co největším objemu součásti. Velmi důležitá je možnost rychlého zastavení zatěžování, aby nedošlo k poškození součásti, pokud se budou hodnoty přetvoření blížit mezním hodnotám.

Na základě vyhodnocení změřeného pole přetvoření a výskytu lokálních nehomogenit bude posouzen výskyt defektů výplně součásti. Pro posouzení přítomnosti defektů bude jako kritérium použita metoda strojového učení, respektive ve výsledném modelu bude toto kritérium obsaženo v konkrétní kombinaci vah a biasů. Bude se jednat o neuronovou síť

naučenou na sadě vzorků s uměle vytvořenými vadami a bez uměle vytvořených vad. Navržená defektoskopická metoda by mohla být z velké části automatizována. Alternativním kritériem posouzení přítomnosti defektu, použitelným v případě malého počtu měření, je vizuální posouzení pole přetvoření.


## 8 Experimentální ověření navržené defektoskopické metody

Pro ověření navržené metody byl zvolen experiment s jedním tvarem vzorků, použit byl jeden typ materiálu a jeden typ aditivní technologie, neboť se jedná o zcela novou defektoskopickou metodu, jejíž schopnost odhalovat vnitřní defekty je nutné postupně prozkoumat.

Pro experimentální ověření navržené defektoskopické metody bylo vyrobeno 6 vzorků se shodnou geometrií vyrobených pomocí aditivní výroby polymerních materiálů. 3 vzorky obsahovaly uměle vytvořené vady výplně ve formě kavit různých tvarů a velikostí, pomocí kterých byly modelovány nejčastěji se vyskytující vady vznikající při 3D tisku vycházející z provedené rešeršní části této práce. Ke tvorbě umělých vad bylo přistoupeno z důvodu lepší kontroly nad reálným výskytem vady v daném vzorku. Druhou možností by byla tvorba defektů nastavením procesních parametrů výroby mimo jejich ideální hodnoty. Pro tuto možnost ovšem neexistuje dostatek podkladů a studií a vzhledem k tomu, že proces výroby není součástí měření, nebylo by jisté, zda se vada výplně uvnitř vzorku opravdu nachází. Skutečnost, zda je uvnitř daného vzorku vada výplně musí být známa pro správné posouzení funkčnosti a přesnosti navržené defektoskopické metody.


### 8.1 Návrh a příprava vzorků použitých v experimentu

Pro experiment byl zvolen takový tvar vzorků, u kterého bude po zatížení jednoosým tahem, pokud nebude ve vzorku přítomný defekt, dosaženo jednoosé tahové napjatosti. Pokud bude ve vzorku přítomný defekt, bude docházet k lokalizaci přetvoření v místě vady a vzniku viditelných nehomogenit v poli přetvoření. Návrh geometrie a rozměrů vzorku se proto řídil požadavky pro tahovou zkoušku dle normy ČSN EN ISO 6892-1. Jeho přesné rozměry jsou uvedeny na obrázku 32. Vzorky byly modelovány v 3D CAD programu Inventor společnosti Autodesk.




Obrázek 32 Tvar a rozměry navrženého vzorku.

Uměle vytvořené vady byly zvoleny na základě rešeršní části práce a jejich tvar byl inspirován přehledem vad zobrazených na obrázku 33. Jedná se o vady typu delaminace, trhliny a póry.



Obrázek 33 V praxi často se vyskytujícími vady výplně dle [35],(upraveno).


Na obrázku 34 je ukázán rovinný podélný řez navrženými vzorky, aby byly viditelné uměle vytvořené vnitřní vady.



Obrázek 34 Zleva vzorky s vnitřní vadou typu delaminace, trhliny a póry.

Pro tisk vzorků byla zvolena metoda FDM a polymerní materiál PLA. Bylo tak učiněno z důvodu dostupnosti tiskárny na pracovišti ÚMTMB. Tisk z kovových slitin byl obtížně dostupný a nákladný, tisk metodou SLA by byl nákladnější a jeho přednosti vyšší kvality by nebyly v tomto případě nijak přínosné. Polymerní materiál má také nižší modul pružnosti a mez pevnosti než materiál kovový, což snižovalo nároky na použitý trhací stroj pro provedení tahových zkoušek. Přestože se komponenty vyrobené FDM technologií standardně nepoužívají pro silně namáhané aplikace, byla výroba vzorků touto technologií mnohem jednodušší pro ověření navržené defektoskopické metody než použití technologií pracujících s kovovými

materiály. Modely vzorků byly pro tisk připraveny v programu PrusaSlicer a vytisknuty na tiskárně Original Prusa i3 MK3 (obrázek 35), se 100 % hustotou výplně, vrstvy byly kladeny po úhlem 45 °, každá vrstva byla vůči předchozí natočena o 90 ° a výška jedné vrstvy byla 0,2 mm. Ostatní parametry tisku byly ponechány ve výchozím doporučeném nastavení pro materiál typu PLA.



Obrázek 35 Vzorky po vytisknutí na 3D tiskárně

Po vytištění bylo na vzorky nanášeno několik vrstev bílé barvy ve spreji, aby byl jejich povrch matný a hladký. Náhodný vzor byl vytvořen rozprašováním černé barvy ve spreji na povrch vzorku. Výsledný vzor je velmi jemný s malým průměrem kapiček, což umožňuje použití malé podoblasti při výpočtu metodou DIC přinášející vysokou přesnost měření a rozlišitelnost vad. Ukázka vytvořeného náhodného vzoru je na obrázku 36.




Obrázek 36 Vytvořeného náhodného vzoru.




## 8.2 Návrh a provedení experimentu

Experiment byl proveden v laboratoři ÚMTMB. Pro pořízení obrazových dat byla použita dvojice kamer FLIR Blackfly S USB3, typu BFS-U3-200S6M-C, o rozlišení 20 Mpx, jejichž závěrky byly synchronizovány a které byly upevněny na společném stativu tak, aby byly od vzorku přibližně stejně daleko a skloněny pod přibližně stejným úhlem. Použití dvojice kamer bylo zvoleno z důvodu využití metody 3D DIC. Ta umožňuje vyhodnocení i posuvů v ose kolmé na čelní plochu vzorku a měření není citlivé na kolmost kamery vůči vzorku, která se při upnutí nového vzorku do trhačího stroje může měnit. Díky tomu je zajištěna vyšší přesnost a lepší porovnatelnost jednotlivých měření.



Obrázek 37 Měřicí vybavení použité při experimentu.

Vzorek byl zatěžován na trhačím stroji značky Zwick vybaveným siloměrem a zatěžovací síla byla zaznamenávána. Scéna byla osvětlena dvojicí výkonných LED reflektorů. Fotografie měřicího vybavení je na obrázku 37. Před začátkem samotného měření byla provedena kalibrace kamer pomocí kalibrační destičky. Souřadný systém, zobrazený na obrázku číslo 38, byl orientován tak, že osa X je osa kolmá na směr zatížení a při čelním pohledu směřuje doprava, osa Y směřuje ve směru zatížení a osa Z je kolmá na měřenou plochu vzorku a směřuje směrem ke kamerám.




Obrázek 38 Orientace použitého souřadného systému

Každý vzorek byl zatěžován do lomu, poté byla zatěžovací hlava vrácena do původní polohy a upevněn nový vzorek. Celý proces zatěžování byl nahráván oběma kamerami. Takto bylo měření opakováno pro každý vzorek.

### 8.3 Vyhodnocení naměřených dat


Naměřená data ve formě fotografií byla zpracována v softwaru Alpha vyvíjeném firmou X-Sight s.r.o., který obsahuje implementaci metody DIC a mnoho možností pro vyhodnocení měření.

Pro zpracování naměřených výsledků byla vybrána funkce zvaná DIC Area, která zvolenou oblast vyplní uživatelem definovaným počtem uzlů. V daném časovém okamžiku je spočítán posuv každého jednotlivého uzlu vůči poloze v referenčním snímku. Z těchto posuvů je dopočítáno pole přetvoření v dané oblasti, hodnoty mezi uzly jsou pro zobrazení interpolovány metodou nejmenších čtverců [56]. Vyšetřována byla oblast ve tvaru obdélníku o velikosti 65 x 21 mm jehož střed odpovídal středu vzorku (obrázek 39). Vyšetřovaná oblast byla umístěna 5 mm od zaoblení vzorku, aby nebylo vyhodnocení zaobleními ovlivněno.




Obrázek 39 Oblast, na které bylo vyšetřováno přetvoření

Velikost oblasti použité pro digitální korelaci obrazu je 37 pixelů a je čtvercového tvaru (obrázek 40). Jednalo se o minimální velikost, s kterou bylo možné spolehlivě korelovat na celé vyšetřované oblasti.




Obrázek 40 Velikost zvolené oblasti (template) pro DIC

Pole přetvoření vzorku bylo vyhodnocováno před dosažením smluvní meze kluzu daného vzorku, aby byl materiál mimo oblast vad stále v elastické oblasti. Smluvní mez kluzu byla odečtena z naměřené tahové křivky zaznamenané siloměrem v zatěžovací hlavě stroje zobrazené na obrázku číslo 41. Lineární oblast zatěžovací síly byla proložena přímkou a daný vzorek vyhodnocován v místě, kde se proložená přímka začala odchylovat od měřené síly. Jako referenční snímek pro výpočet přetvoření byl použit okamžik před začátkem zatěžování.



Obrázek 41 Záznam tahové síly jednoho ze vzorků s vnitřní vadou.

Vyšetřovaná oblast byla diskretizována sítí s 35 uzly v podélném směru a 12 uzly v příčném směru, celkem tedy 420 uzly. Jednotlivé buňky sítě jsou tvořeny pravoúhlými trojúhelníky s uzly ve vrcholech o délce odvěsen přibližně 1,9 mm. Použitá jemnost sítě 35 x 12 bodů byla zvolena na základě porovnání několika různých velikostí sítě jako kompromis mezi přesností a počtem bodů. Jemnější síť již nepřináší vykreslení nových prvků v mapě přetvoření, hrubší síť některé důležité prvky vynechává. Větší počet bodů než nezbytně nutný, nebyl žádoucí vzhledem k plánovanému použití metody strojového učení, neboť by zvyšoval počet parametrů k trénování, který je vhodné udržet co nejnižší vzhledem k relativně nízkému počtu naměřených dat. Vliv jemnosti zvolené sítě je ukázán na obrázku číslo 42. Horní pole přetvoření je popsáno pomocí 80 uzlů, prostřední pomocí zvolených 420 uzlů a spodní pomocí 972 uzlů.

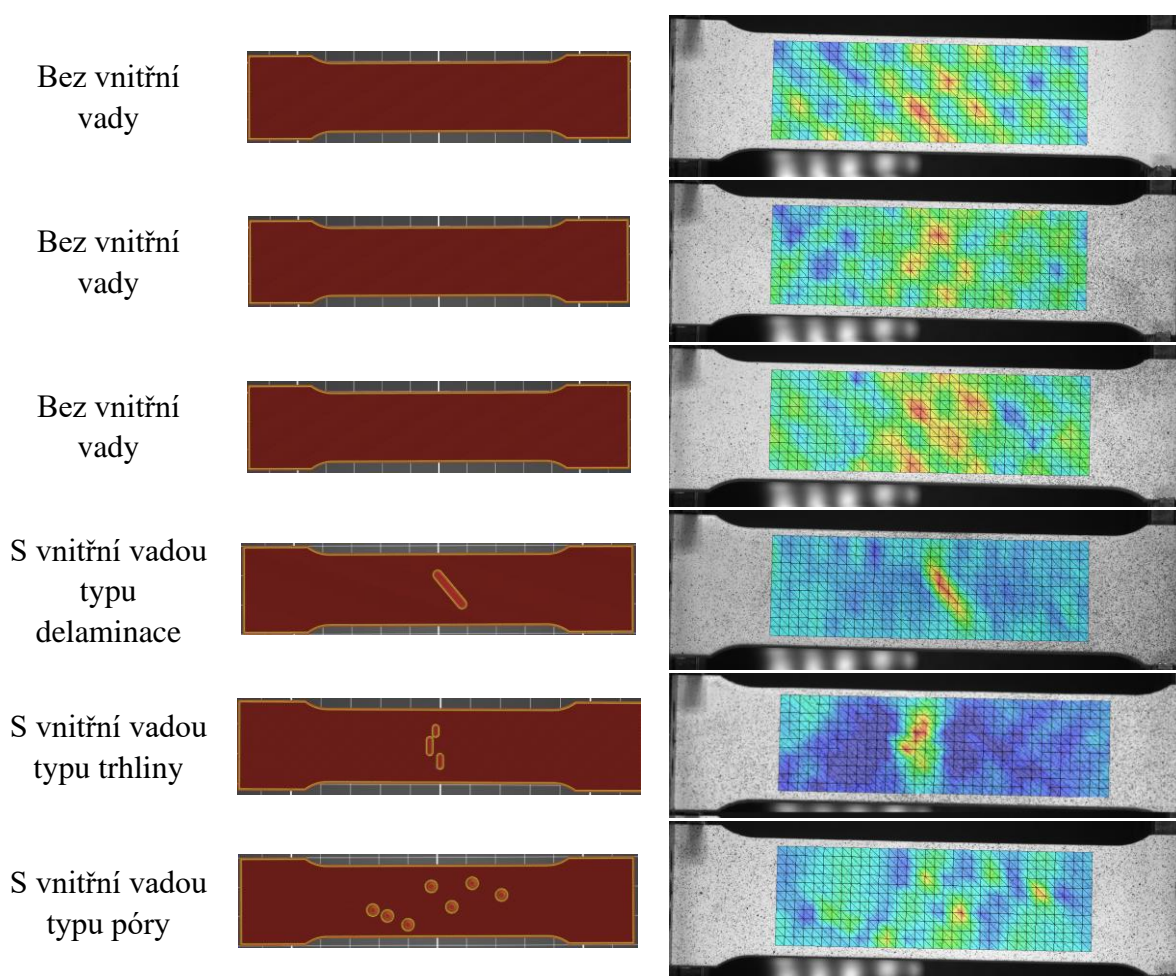


Obrázek 42 Vliv jemnosti sítě na vypočítané pole přetvoření.

Vyhodnocováno bylo první hlavní přetvoření  $\varepsilon_1$ , které je mimo oblast vad totožné s přetvořením ve směru zatěžování  $\varepsilon_Y$ . Ve směru osy Z, která je kolmá na povrch vzorku, jsou posuvy příliš malé na to, aby mohli být použity pro posouzení přítomnosti vad.

Tímto postupem bylo spočítáno pole přetvoření všech 6 naměřených vzorků. Vzorky byly poté rozděleny do dvou kategorií. První kategorie jsou vzorky s vnitřní vadou a druhá kategorie jsou vzorky bez vnitřní vady. Na základě vizuální analýzy výsledků bylo posouzeno, zda lze ze získaných polí přetvoření určit, zda byla v daném vzorku přítomna vada výplně.

Zobecnující závěry jsou, že pole přetvoření vzorků bez uměle vytvořené vady není homogenní, jak bylo původně předpokládáno, ale obsahuje pravidelně se střídající lokalizované oblasti přetvoření skloněné pod úhlem  $45^\circ$ , což odpovídá úhlu, pod jakým jsou položeny jednotlivé vrstvy materiálu. Pole přetvoření vzorků s uměle vytvořenou vadou výplně tuto pravidelnost postrádají a obsahují oblasti zvýšených hodnot přetvoření v okolí míst, kde se nacházejí uměle vytvořené vady. Lze tedy prohlásit, že navržená defektoskopická metoda dokáže odhalit defekty výplně 3D tištěných struktur. Na obrázku 43 jsou vyobrazena pole přetvoření jednotlivých vzorků. Jedná se o kvalitativní porovnání a škála přetvoření není uvedena, neboť není v tomto případě podstatná.



Obrázek 43 Získaná pole přetvoření měřených vzorků.

#### 8.4 Verifikace naměřených dat výpočtem pomocí MKP

Vzhledem k tomu, že měření a vyhodnocení metodou digitální korelace obrazu mohlo být zatíženo různým druhem chyb, bylo vhodné provést alespoň základní verifikaci naměřených polí přetvoření. Pro tento účel byl zvolen výpočet přetvoření 3 vzorků s vnitřní vadou pomocí metody konečných prvků v prostředí ANSYS Workbench a následné kvalitativní i kvantitativní porovnání s hodnotami přetvoření získaných metodou DIC.


Pro zjednodušení byl použitý materiál PLA modelován jako lineární izotropní materiál, neboť část měření sloužící pro vyhodnocení pracovala jen s oblastí zatěžování pod mezí kluzu. Ve skutečnosti ovšem tisknutý materiál vykazuje anizotropní chování, ale použití pokročilejšího modelu materiálu by přesahovalo časové možnosti této práce. Materiál byl modelován s Poissonovým poměrem  $0,35$  [57] a Youngovým modulem pružnosti  $2,4 \text{ GPa}$ , vycházejícím z materiálového listu výrobce [58].

Model vzorku byl použit shodný s modelem použitým pro tisk, jen byl exportován ve formátu *step*, který lze importovat do prostředí ANSYS Workbench. Použitá velikost globální sítě konečných prvků je  $1,5 \text{ mm}$ . Vygenerovaná síť konečných prvků pro vzorek s vnitřní vadou je zobrazena na obrázku 44.




Obrázek 44 Použitá síť konečných prvků.

V okolí vnitřních vad byla síť zjemněna příkazem *Capture Proximity*, jak je ukázáno na obrázku 45.




Obrázek 45 Detail zjemnění sítě konečných prvků v okolí vnitřní vady

Okrajové podmínky (uvedené na obrázku 46) reflektovaly upnutí vzorku do trhačického stroje. Ve spodní části vzorku byly zamezeny posuvy ve všech osách pomocí příkazu *Fixed Support*. V horní části vzorku byly zamezeny posuvy pomocí příkazu *Displacement* v osách X a Y a zadán posuv ve směru osy Z, jednalo se tedy o tvrdé zatěžování.



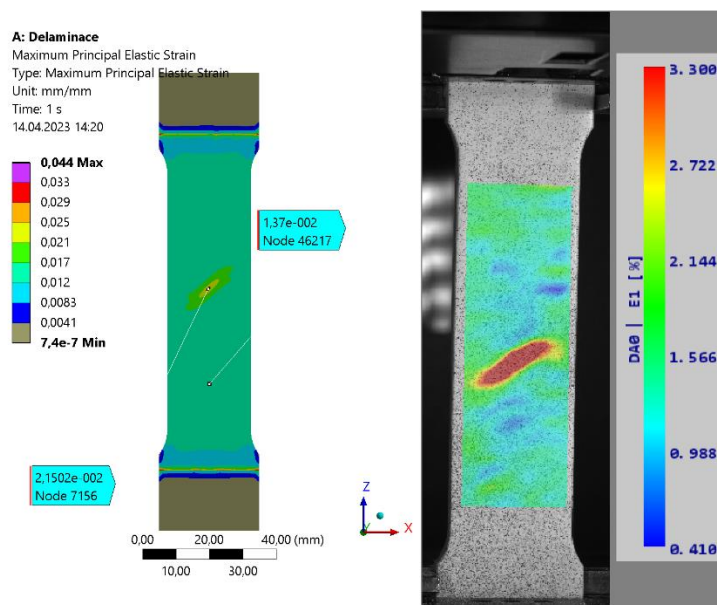
Obrázek 46 Použité okrajové podmínky.

Hodnota posuvu horní části vzorku se pro každý vzorek lišila a byla zvolena dle metodou DIC naměřeného rozdílu mezi posuvem horní části a spodní částí vzorku. Hodnota posuvu byla určena změnou délky liniové sondy o původní délce  $99\text{ mm}$ , což odpovídá vzdálenosti mezi hranicemi oblastí A a B modelu MKP (obrázek 46), na kterých jsou aplikovány okrajové podmínky. Postup určení velikosti posuvu horní části vzorku je demonstrován na obrázku 47. Levý obrázek ukazuje stav před zatížením se sondou o délce  $99\text{ mm}$ , pravý obrázek změnu délky sondy po zatížení. Posuv horní části vzorku byl v tomto případě přibližně  $1,37\text{ mm}$ .



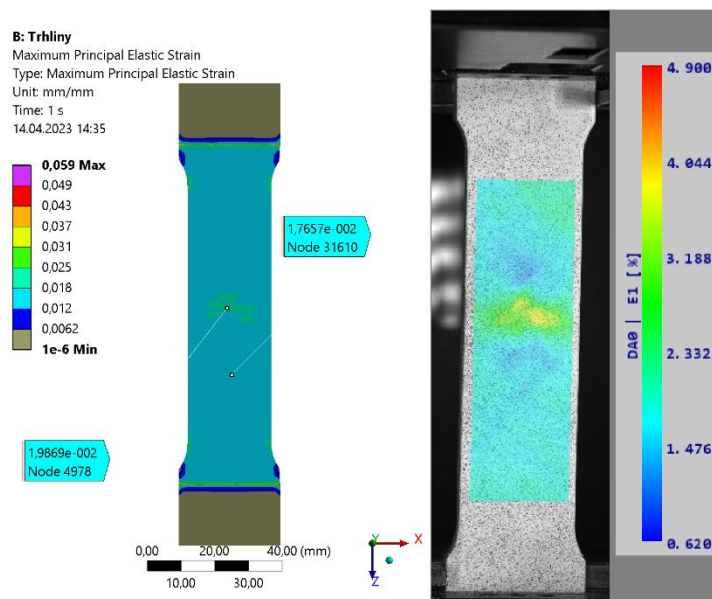
Obrázek 47 Liniová sonda použitá pro vyhodnocení velikosti posuvu horní části vzorku.

Vyhodnocováno bylo první hlavní elastické přetvoření ve střední části vzorku pomocí příkazu *Maximum Principal Elastic Strain*. Pro vzorek s vnitřní vadou typu delaminace se kvalitativně pole přetvoření v obou případech velmi dobře shodují (obrázek 48), je přítomna výrazná lokalizace přetvoření v místě vnitřní kavity. Z kvantitativního pohledu v oblasti mimo vnitřní vadu se obě metody shodují, přetvoření je zde přibližně 1,5 %. Hodnoty přetvoření v těsném okolí vnitřní vady jsou přibližně poloviční v případě MKP. Legenda pole přetvoření změřeného metodou DIC je v procentech.



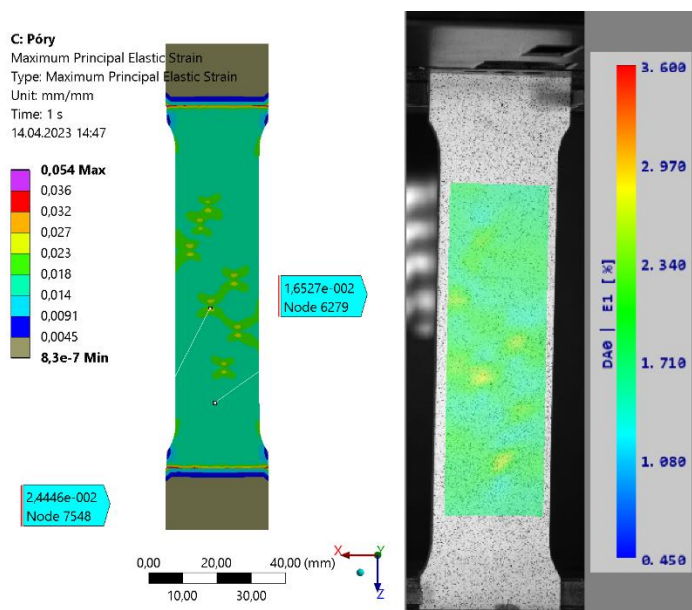
Obrázek 48 Srovnání vzorku s vnitřní vadou typu delaminace (vlevo MKP, vpravo DIC).

Pro vzorek s vnitřní vadou typu trhliny jsou obě pole přetvoření kvalitativně srovnatelná (obrázek 49), lokalizace přetvoření v okolí vnitřní vady je na obou výsledných mapách přetvoření zřejmá. V případě kvantitativního srovnání jsou hodnoty přetvoření v místě vady přibližně poloviční v případě výpočtu MKP oproti DIC.



Obrázek 49 Srovnání vzorku s vnitřní vadou typu trhliny (vlevo MKP, vpravo DIC).

Kvalitativně i kvantitativně jsou obě pole přetvoření v dobré shodě pro vzorek s vnitřní vadou typu póry (obrázek 50), v okolí vnitřních vad dochází ke koncentraci přetvoření a přetvoření v místě vnitřních vad dosahuje hodnot kolem 2,5 %.



Obrázek 50 Srovnání vzorku s vnitřní vadou typu póry (vlevo MKP, vpravo DIC).

Naměřené průběhy přetvoření pomocí DIC a spočítané pomocí MKP jsou v dobré shodě. Hodnoty přetvoření v oblastech neovlivněnými vnitřními vadami vykazují rozdíly do 10 %. Rozdíly kolem 50 % v hodnotách přetvoření v místech vnitřních vad mezi oběma metodami jsou způsobeny použitím zjednodušeného modelu materiálu pro MKP, který neuvažuje vliv použitého typu výplně na mechanické vlastnosti, a nepřesnosti měření. V případě potřeby podrobnějšího porovnání by bylo vhodné provést potřebné materiálové zkoušky použitého PLA



materiálu a použít pro výpočet pokročilejší konstitutivní model materiálu uvažující anizotropní chování.

## 9 Detekce defektů vnitřních vad s využitím metod strojového učení

Jak bylo zmíněno v závěru kapitoly číslo 4 o současném stavu poznání, trendem posledních let v detekci defektů je metoda nedestruktivní evaluace, která využívá statistické metody a metody strojového učení pro automatické vyhodnocování naměřených dat. To šetří jak čas potřebný pro posouzení naměřených dat, tak také zvyšuje přesnost vyhodnocení a přináší možnost objevu nových souvislostí, které nejsou lidským okem pozorovatelné. Příkladem může být použití metod strojového učení a umělé inteligence v sektoru zdravotnictví, kde se úspěšně používá pro diagnostiku zdravotního stavu a predikci zdravotních rizik na základě tělesných ukazatelů.

Vstupem do metody strojového učení bude v případě této práce pole přetvoření. To lze interpretovat jako obraz s uzly místo pixelů nesoucími informaci o přetvoření v dané oblasti. Z rešerše provedené v kapitole 4 vyplývá, že nejvhodnější metodou pro klasifikaci obrazových dat je neuronová síť, která bude využita jako kritérium pro posouzení přítomnosti vnitřních vad v naměřených vzorcích. Neuronová síť bude natrénována na naměřených polích přetvoření, u kterých je známo, zda obsahují vnitřní vadu.

Pro přípravu a úpravu dat a tvorbu modelu strojového učení byl použit programovací jazyk Python a jeho knihovna NumPy, která je vhodná pro práci s vektory a maticovými poli, a knihovna PyTorch, která je přizpůsobená pro tvorbu modelů strojového učení používajících neuronové sítě.


### 9.1 Příprava a augmentace dat pro strojové učení

Počet naměřených vzorků (6) z minulé kapitoly by nebyl pro natrénovaná neuronové sítě dostatečný, v případě velkých modelů se pracuje se stovkami až milióny vstupních dat. Ve svém článku o použití konvolučních neuronových sítí s malým počtem dat L. Brigato a kolektiv [59] provedli porovnání přesnosti klasifikace konvoluční neuronové sítě v závislosti na počtu použitých dat pro trénování. Přesnosti klasifikace kolem 90 % bylo dosaženo přibližně při použití 640 a více vstupních dat pro každou třídu. Přestože se nejedná o zobecňující závěr, přináší alespoň základní představu o počtu potřebných dat. Dále autoři doporučují augmentaci dat. Jedná se o umělé navýšení počtu dat skrze jejich úpravu. Nesmí ovšem dojít ke změně sémantiky potřebné pro provedení klasifikační úlohy. Data si musí zachovat důležité vzory.

Pro navýšení počtu vzorků bylo navrženo a vyrobeno dalších 52 vzorků o stejném tvaru a stejným způsobem jako původních 6 vzorků z předešlé kapitoly. Všechny vzorky byly změřeny a vyhodnoceny způsobem popsáným v kapitole 8. Celkem bylo naměřeno 27 vzorků bez vady a 31 vzorků s uměle vytvořenou vnitřní vadou. Uměle vytvořené vady jsou rozděleny do 3 kategorií a na každém vzorku byla modelována maximálně jedna kategorie vad. První kategorie modeluje různé možnosti nedokonalého spojení jednotlivých vrstev materiálu (delaminace), jako důsledek oxidace, strukturálních vad a nedostatečného natavení materiálu. Druhá kategorie vad modeluje shluky malých trhlin uvnitř materiálu, které vznikají v důsledku relaxace zbytkových napětí. Třetí kategorie modeluje oblasti různých velikostí se zvýšeným výskytem pórů a kavit. Přehled a počty jednotlivých kategorií vzorků jsou uvedeny v tabulce 1. Na obrázku 51 jsou uvedeni 2 zástupci z každé kategorie vnitřních vad.

Tabulka 1 Kategorie měřených vzorků a jejich charakteristika.

Kategorie	Charakteristika kategorie	Počet vzorků
Delaminace	Osamocená podlouhlá kavita skloněná pod úhlem 0 °, 45 ° nebo 90 ° od podélné osy vzorku o délce 6 až 20 mm, šířce 1 až 4 mm a tloušťce 0,5 až 2 mm	16
Trhliny	Blízké uskupení stejně orientovaných 3 až 5 malých kavit podlouhlého tvaru o délce 3 až 10 mm, šířce 1 až 2 mm a tloušťce 1 až 1,5 mm	5
Póry	Blízké uskupení několika kavit cylindrického nebo kulovitého tvaru o velikosti 1 až 3 mm.	10
Bez vnitřní vady	Bez uměle vytvořených vad	27



Obrázek 51 Příklady vzorků s vnitřními vadami, zleva dva zástupci kategorie delaminace, dva zástupci kategorie trhliny a dva zástupci kategorie póry.

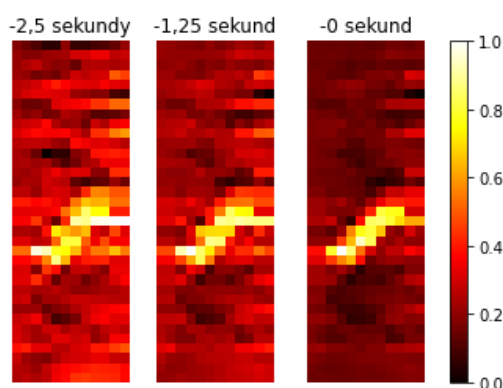
Pro analýzu a následnou práci s naměřenými daty byla využita funkce programu Alpha, která exportuje v průběhu celého měření vypočítané hodnoty metodou DIC do textového souboru ve formátu *tsv*. Každý řádek v tomto souboru odpovídá jednomu změřenému časovému okamžiku. Počet řádků souboru je dán délkou měření a počtem zaznamenaných snímků za sekundu. V případě této práce byl počet zaznamenaných snímků za sekundu (*FPS*) roven 4. Počet sloupců textového souboru je několik tisíc, soubor totiž obsahuje souřadnice a posuvy v osách X, Y a Z všech uzlů, přetvoření uzlů a rychlosti uzlů v osách X, Y a Z. Pro každé jedno měření, tedy každý jeden vzorek, byl exportován jeden textový soubor. Celkem tedy bylo získáno 58 textových souborů. V jazyku Python byl napsán skript, který z každého souboru vyextrahoval první hlavní přetvoření uzlů  $\varepsilon_I$  ve všech změřených časových okamžicích.

Data používaná pro neuronové sítě se normalizují na určitý interval. Nejčastěji se pracuje s rozmezím [0,1]. Data se normalizují pro zvýšení efektivity procesu učení neuronové sítě, neboť různý rozsah dat by byl pro proces učení zavádějící [60]. V této práci byla využita min-max normalizace hodnot každého pole přetvoření na interval [0,1]. Předpis použitého normalizačního vztahu je:

$$x_{norm} = \frac{(1 - 0) \times (x - x_{min})}{x_{max} - x_{min}} \quad (8)$$


Kde  $x_{norm}$  je hodnota pole přetvoření po normalizaci,  $x$  je normovaná hodnota pole přetvoření,  $x_{max}$  je maximální hodnota z daného pole přetvoření a  $x_{min}$  je minimální hodnota z daného pole přetvoření.

Pro zvětšení počtu vstupních dat bylo pracováno nejen s časovým okamžikem těsně před dosažením meze kluzu, ale také s 10 předchozími časovými okamžiky, tedy od okamžiku 2,5 sekundy před dosažením meze kluzu až do okamžiku těsně před mezí kluzu. Tím počet vstupních dat vzrostl na 580. Ukázka polí přetvoření v různých časových okamžicích je na obrázku číslo 52. Každý pixel představuje jeden uzel, v jehož okolí bylo vypočítáno přetvoření metodou DIC. Číslo nad polem uvádí čas do dosažení meze kluzu. Maximální hodnoty přetvoření jsou napříč poli shodně 1, neboť jsou již po normalizaci. Dobře je zde ilustrován průběh lokalizace přetvoření v okolí uvnitř uměle vytvořené kavity. Zatímco v čase -2,5 sekundy je okolní pole světlé barvy, v čase těsně před mezí kluzu je již celé okolí tmavě červené, tedy blízké hodnotě 0. To je dáno tím, že rozdíl maximální a minimální hodnoty přetvoření je v tomto časovém okamžiku výrazně větší, než v časovém okamžiku -2,5 sekundy.



Obrázek 52 Pole přetvoření vzorku s vnitřní vadou v různých časových okamžicích udávající čas do dosažení meze kluzu.

Vstupní data byla augmentována zrcadlením podle vertikální osy, horizontální osy a vertikální i horizontální osy zároveň. Tím bylo modelováno rozdílné upnutí vzorku během zatěžování. Ukázka takto zrcadleného pole přetvoření vzorku bez vnitřní vady je na obrázku 53. Augmentací vzrostl počet dat na 2320, přibližně 1200 pro vzorky s vnitřní vadou a 1100 pro vzorky bez vnitřní vady.




Obrázek 53 Augmentovaná pole přetvoření vzorku bez vnitřní vady, a) naměřené pole přetvoření, b) zrcadlení podle horizontální osy, c) zrcadlení podle vertikální osy, d) zrcadlení podle horizontální i vertikální osy.

Další možností, jak připravit naměřená pole přetvoření pro neuronovou síť, by bylo pracovat přímo s obrazovými daty polí přetvoření uvedenými v předchozí kapitole na obrázku číslo 43. Přestože pole přetvoření by byla výrazně jemnější díky použití interpolačních funkcí mezi uzly, byla tato možnost zamítnuta z důvodu vysoké časové náročnosti přípravy obrázků, jejich složité augmentaci a problémům spojeným se zajištěním stejné kvality obrazu napříč všemi vzorky.

## 9.2 Trénování neuronových sítí

Snahou trénování neuronové sítě je co nejlepší aproximace vstupních dat. Trénování probíhá na základě porovnávání kategorie vstupních dat s neuronovou sítí předikovaným výstupem. V případě klasifikace proto data pro trénování musí být popsána, do jaké kategorie výstupu náleží. Postupným průchodem vstupních dat a porovnáváním, zda predikovaný výstup odpovídá požadovanému výstupu jsou upravovány parametry sítě, označované jako váhy, které jsou na začátku tréninku náhodně inicializovány. Tento proces je opakován, dokud není dosaženo požadované přesnosti proložení vstupních dat. Při praktickém použití jsou vstupní data rozdělena na trénovací data a data testovací. Trénovací data slouží pro natrénování parametrů neuronové sítě a testovací data pro posouzení schopnosti neuronové sítě generalizovat a určit přesnost neuronové sítě. Pokud není proces učení včas zastaven, může dojít k takzvanému přetrénování neuronové sítě (obrázek 54), kdy síť velmi dobře prokládá trénovací data, ale selhává na predikci dat testovacích [61].




Obrázek 54 Příklad vývoje chyby trénování neuronové sítě [62], (upraveno).

V případě této práce sestávala množina trénovacích data z polí přetvoření a byla popsána 0, pokud vzorek, na kterém bylo pole přetvoření naměřeno, neobsahoval uměle vytvořenou vnitřní vadu. Pokud vzorek obsahoval jednu ze 3 kategorií uměle vytvořených vnitřních vad, bylo jeho pole přetvoření označeno jako 1. Kategorie vnitřních vad nebyly rozlišovány, jednalo se tedy o binární klasifikaci vzorků do 2 tříd – ve vzorku není přítomna vada (třída 0) a ve vzorku je přítomna vada (třída 1). Množina testovacích dat sestávala také z polí přetvoření a nebyla pro trénink použita, ale byla predikována po ukončení tréninku pomocí již natrénované neuronové sítě. Pokud predikce neuronové sítě odpovídala třídě daného pole přetvoření, bylo vyhodnocení považováno za úspěšné.

Vzhledem k nízkému počtu vstupních dat byla pro vyhodnocení přesnosti topologie navržené neuronové sítě použita *K-fold cross validate*. Její princip spočívá v rozdělení vstupních

dat na  $K$  podmnožin dat o stejné velikosti. První podmnožina dat je použita jako testovací data a zbylých  $K-1$  podmnožin dat je použito jako trénovací data. Tento postup je opakován tím způsobem, aby každá podmnožina dat byla použita jako testovací data právě jednou. Výsledná přesnost je získána zprůměrováním všech dílčích přesností [63]. Ilustrace tohoto způsobu rozdělení vstupních dat je na obrázku 55.



Obrázek 55 Cross validace, pro  $K$  rovno 5 [64],(upraveno).

Počet naměřených vzorků v této práci je 58, pro vyhodnocení přesnosti použitých topologií neuronových sítí byla proto zvolena cross validace s  $K$  rovno 58. Naměřená data byla rozdělena do 58 podmnožin, kdy každá podmnožina obsahovala pole přetvoření pocházející právě z jednoho vzorku

Pro posouzení schopnosti neuronové sítě klasifikovat trénovací data byla použita evaluační metrika *Precision* (Přesnost), která je definována jako podíl počtu správně predikovaných testovacích dat ku celkovému počtu testovacích dat.

$$Pr = \frac{TP}{TP + TF} \quad (9)$$

Kde  $Pr$  je přesnost,  $TP$  je počet správně určených testovacích dat a  $TF$  je počet chybně určených testovacích dat.


### 9.3 Plně propojená neuronová síť

Nejprve byla jako kritérium pro posouzení přítomnosti defektu použita plně propojená neuronová síť. Iteračním způsobem byly vybrány 3 rozdílné topologie se 1 vstupní vrstvou, 1 nebo 2 skrytými vrstvami a 1 výstupní vrstvou. Vstupní vrstva obsahovala 420 neuronů, což odpovídá počtu uzlů pole přetvoření a výstupní vrstva obsahovala 2 neurony, což odpovídá počtu tříd, do kterých jsou vstupní data klasifikována. Přehled topologií je uveden v tabulce 2. Jako aktivační funkce byla použita funkce *ReLU*, chybová funkce byla použita *cross-entropy* a pro trénování neuronové sítě byl použit optimalizační algoritmus *Adam* s krokem učení  $8 \cdot 10^{-4}$ . Na výstupní vrstvě byla použita aktivační funkce *SoftMax*.

Tabulka 2 Použité topologie plně propojené neuronové sítě.

Topologie	Počet neuronů v jednotlivých vrstvách
A	420 → 64 → 2 (1 skrytá vrstva)
B	420 → 128 → 32 → 2 (2 skryté vrstvy)
C	420 → 64 → 32 → 2 (2 skryté vrstvy)

Při tréninku každé neuronové sítě byla vizualizována přesnost testovacích dat a chyba trénovacích dat. Trénování bylo zastaveno v momentě, kdy přesnost klasifikace testovacích dat již dále nerostla (obrázek 56). Jednalo se o epochu číslo 27.



Obrázek 56 Přesnost testovacích dat v závislosti na délce tréninku plně propojené neuronové sítě.

### 9.3.1 Výsledky klasifikace vzorků s využitím plně propojené neuronové sítě

Přesnosti klasifikace vzorků v závislosti na použité topologii neuronové sítě jsou uvedeny v tabulce 3. Sledovanými parametry byla celková přesnost klasifikace vzorků, přesnost klasifikace vzorků bez uměle vytvořené vnitřní vady a přesnost klasifikace vzorků s uměle vytvořenou vnitřní vadou. Celková přesnost topologie A byla 81,9 %, topologie B 77,4 % a topologie C 81,0 %. Přesnosti klasifikace vzorků bez vytvořené vnitřní vady byly ve všech případech větší o přibližně 5 % v porovnání s přesností klasifikace vzorků s vytvořenou vnitřní vadou (Tabulka 3). To může být způsobeno větší rozdílností polí přetvoření vzorků s vnitřní vadou, neboť bylo pro trénink sítě použito mnoho typů rozdílně umístěných vnitřních vad různých velikostí. Přesnost klasifikace kolem 80 % demonstruje funkčnost navržené defektoskopické metody a zvoleného kritéria pro posouzení přítomnosti defektů ve vzorcích. Pro klasifikaci reálných výrobků je ovšem tato spolehlivost stále nedostatečná. Nevýhodou plně propojené neuronové sítě také je, že vstupní data jsou ve formě vektoru a dochází tak ke ztrátě informace o vzájemné poloze jednotlivých uzlů.

Tabulka 3 Přesnost klasifikace použitých topologií plně propojené neuronové sítě.

Topologie	Celková přesnost klasifikace	Přesnost klasifikace vzorků bez vnitřní vady	Přesnost klasifikace vzorků s vnitřní vadou
A	81,9 %	84,8 %	79,4 %
B	77,4 %	80,1 %	75,0 %
C	81,0 %	84,1 %	78,3 %

#### 9.4 Konvoluční neuronová síť

Za účelem dalšího zvýšení přesnosti byla použita jako vyhodnocovací kritérium konvoluční neuronová síť, která, jak bylo zmíněno v rešeršní části práce, vykazuje velmi dobré výsledky při práci s obrazovými daty.

Do konvoluční neuronové sítě vstupují data ve formě matice, čímž je zachována informace o poloze a sousedství jednotlivých uzlů z pole přetvoření. Vstupní data do použité konvoluční sítě byla ve formě matice o rozměru 35x12 uzlů.


Konvoluční neuronová síť obsahuje kromě plně propojené neuronové sítě také konvoluční vrstvy. Ty mají za úkol připravit vstupní data a extrahovat z nich významné vzory pro následnou klasifikaci pomocí plně propojené neuronové sítě. Tím roste komplexnost sítě a počet parametrů, které musí uživatel zadat, jako je počet neuronů v jednotlivých vrstvách, počet skrytých a konvolučních vrstev a počet a velikost konvolučních jader. Proto byla pro nalezení optimálních parametrů sítě použita volně dostupná knihovna Optuna, která iteračním způsobem hledá nejlepší hodnoty výše zmíněných parametrů na uživatelem definovaném intervalu (tzv. hyperoptimalizace). Optimalizovanými parametry byly počet konvolučních vrstev, počet a rozměr konvolučních jader, počet skrytých plně propojených vrstev, počet jejich neuronů a krok učení. Celkem byly provedeny 3 optimalizace, při každé byl zpřesněn interval, na kterém byly parametry sítě optimalizovány v závislosti na předchozí optimalizaci. Použité topologie jsou uvedeny v tabulce číslo 4. Po každé konvoluční vrstvě byl aplikován *max pooling* o velikosti 2x2. Jako aktivační funkce byla použita funkce *ReLU*, chybová funkce byla použita *cross-entropy* a pro trénování neuronové sítě byl použit optimalizační algoritmus *Adam*. Na výstupní vrstvě plně propojené neuronové sítě byla použita aktivační funkce *SoftMax*.

Tabulka 4 Použité topologie konvoluční neuronové sítě.

Topologie	Počet a rozměr konvolučních jader	Počet neuronů v jednotlivých vrstvách	Krok učení
AC	32(5x3) → 64(4x4)	384 → 64 → 2 (1 skrytá vrstva)	$1 \cdot 10^{-3}$
BC	115(6x2) → 64(5x2)	640 → 124 → 42 → 2 (2 skryté vrstvy)	$5 \cdot 10^{-4}$
CC	117(7x2) → 116(6x2)	928 → 50 → 2 (1 skrytá vrstva)	$6 \cdot 10^{-4}$

Závislost přesnosti konvoluční neuronové sítě na počtu epoch je zobrazen na obrázku 57. Od přibližně 30 epochy se přesnost klasifikace výrazně neměnila a dosahovala hodnot přes 90 %. Pro trénování všech srovnávaných topologií v následující kapitole bylo použito 30 epoch.





Obrázek 57 Přesnost testovacích dat v závislosti na délce tréninku konvoluční neuronové sítě.

#### 9.4.1 Výsledky klasifikace vzorků s využitím konvoluční neuronové sítě

S konvoluční neuronovou sítí s topologií AC bylo dosaženo celkové přesnosti klasifikace 91,7 %, s topologií BC 93,5 % a s topologií CC 94,5 %. V porovnání s plně propojenou neuronovou sítí došlo ke zvýšení přesnosti klasifikace o přibližně 10 %. Pozitivní je také malý rozdíl u topologií BC a CC mezi přesností klasifikace vzorku bez vytvořené vnitřní vady a s vytvořenou vnitřní vadou, který je pod 1 % (Tabulka 5). Topologie konvoluční neuronové sítě s nejlepší přesností klasifikace je topologie CC. Dosažená přesnost klasifikace je 94,5 % a rozdíl v přesnosti klasifikace mezi vzorky s vnitřní vadou a bez vnitřní vady je pouze 0,1 %.

Tabulka 5 Přesnost klasifikace použitých topologií konvoluční neuronové sítě.

Topologie	Celková přesnost klasifikace	Přesnost klasifikace vzorků bez vnitřní vady	Přesnost klasifikace vzorků s vnitřní vadou
AC	91,7 %	94,8 %	88,9 %
BC	93,5 %	93,2 %	93,8 %
CC	94,5 %	94,4 %	94,5 %


V tabulce číslo 6 jsou uvedeny a barevně zvýrazněny přesnosti klasifikace ne zcela přesně klasifikovaných vzorků v závislosti na použité topologii. Vzorky neuvedené v této tabulce byly klasifikovány 100 % správně při použití všech tří topologií. Přesnost klasifikace vzorku je spočítána jako počet správně klasifikovaných polí přetvoření daného vzorku ze všech časových okamžiků a ze všech možností zrcadlení podělená celkovým počtem polí přetvoření daného vzorku. Při použití topologie AC neuronová síť zcela chybně klasifikovala čtyři vzorky s čísly 14, 27, 28 a 57. Při použití topologie BC neuronová síť zcela chybně klasifikovala dva vzorky s čísly 14 a 27 a u třech vzorků s čísly 28, 32 a 43 dosáhla přesnosti jen kolem 50 %. Při použití topologie CC neuronová síť zcela chybně klasifikovala stejné dva vzorky jako při použití topologie BC, tedy vzorky číslo 14 a 27 a u vzorku číslo 28 dosáhla přesnosti mírně pod 60 %.

Tabulka 6 Přesnost ne zcela přesně klasifikovaných vzorků konvoluční neuronovou sítí

Číslo vzorku	Vytvořená vnitřní vada	Přesnost klasifikace vzorku		
		Topologie AC	Topologie BC	Topologie CC
1	Ano	85,4 %	100 %	100 %
14	Ne	2,3 %	0 %	0 %
23	Ne	100 %	100 %	75,0 %
24	Ne	100 %	78,8 %	100 %
25	Ano	93,2 %	100 %	100 %
27	Ano	0 %	0 %	0 %
28	Ano	0 %	50 %	59,1 %
30	Ne	82,5 %	87,5 %	90,0 %
31	Ne	75,0 %	90 %	85,0 %
32	Ne	100 %	60 %	100 %
43	Ano	77,5 %	57,5 %	70 %
57	Ano	0 %	100 %	100 %

Z výsledků vyplývá, že všechna pole přetvoření vzorku číslo 14 (s malou výjimkou 2,7 % u topologie AC) a vzorku číslo 27 ve všech časových okamžicích a ve všech možnostech zrcadlení byla klasifikována chybně. Velmi slabých výsledků bylo dosaženo také u vzorku číslo 28, jehož pole přetvoření byla klasifikována zcela chybně při použití topologie AC a s přesností kolem 50 % při použití topologií BC a CC. Další vzorky, u kterých přesnost klasifikace při použití alespoň jedné z topologií byla menší než 70 %, jsou vzorky číslo 32, 43 a 57.

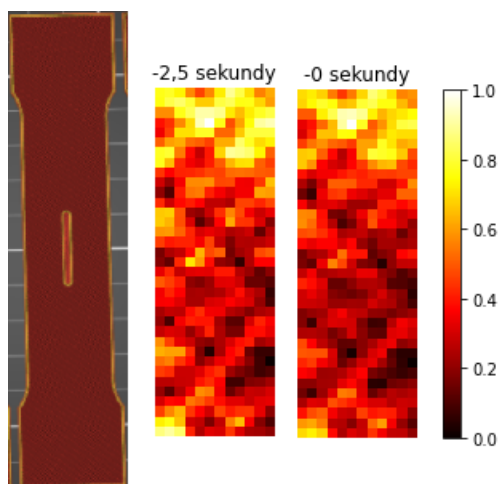
Pole přetvoření vzorku číslo 14 (obrázek 58) obsahuje oblast velké koncentrace přetvoření ve spodní části, přestože v jeho výplni nebyla uměle vytvořena vada. Kvůli tomu v poli přetvoření zaniká vzor typický pro vzorky bez vnitřní vady a pole je klasifikováno chybně ve všech časových okamžicích. Samotný vznik oblasti koncentrace přetvoření mohl být způsoben špatně vytvořeným náhodným vzorem na povrchu součásti, křivým upnutím vzorku do trhačického stroje nebo inherentně vzniklou vadou během výroby.



Obrázek 58 Pole přetvoření vzorku číslo 14.


Pole přetvoření vzorku číslo 27, který obsahoval uměle vytvořenou vnitřní vadu typu delaminace, modelované pomocí podlouhlé podélné kavity, je zobrazeno na obrázku 59. Pole

má pravidelný vzor typický pro vzorky bez vnitřní vady a v okolí vnitřní vady není viditelná žádná koncentrace přetvoření. Z toho důvodu byla pole přetvoření po celou dobu zatěžování klasifikována jako bez vnitřního defektu.




Obrázek 59 Pole přetvoření vzorku číslo 27.

Pole přetvoření vzorku číslo 27, který obsahoval uměle vytvořenou vnitřní vadu typu delaminace, modelované pomocí podlouhlé podélné kavity mírně kratší než v případě vzorku 27, je zobrazeno na obrázku 60. Správně klasifikovaná pole přetvoření v případě topologií BC a CC pocházela z konce zatěžování a jednalo se především o podle horizontální a podle horizontální i vertikální osy zrcadlená pole přetvoření. Naopak pole přetvoření pocházející ze začátku zatěžování byla klasifikována chybně.




Obrázek 60 Pole přetvoření vzorku číslo 28.

Pole přetvoření vzorku číslo 32 klasifikována zcela správně při použití topologií AC a CC. Při použití topologie BC byla správně klasifikována pole přetvoření ze začátku zatěžování a chybně klasifikována pole přetvoření z konce zatěžování. Důvodem jsou abnormální krajní hodnoty přetvoření nacházející se v levém horním rohu. Ty vedly k tomu, že po normalizaci je pole přetvoření blízko konstantně po skoro celé své ploše (obrázek 61).




Obrázek 61 Pole přetvoření vzorku číslo 32.

Správně klasifikovaná pole přetvoření vzorku číslo 43, ve kterém se nacházela vnitřní vada typu trhliny, pocházela z druhé poloviny zatěžování, kdy již došlo k dostatečně velké koncentraci napětí kolem vnitřní vady (obrázek 62). Naopak pole přetvoření ze začátku zatěžování byla relativně pravidelná, bez viditelné koncentrace v okolí vnitřní vady.



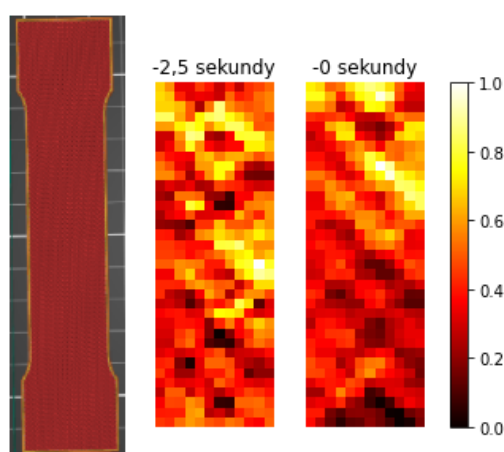
Obrázek 62 Pole přetvoření vzorku číslo 43.

Pole přetvoření vzorku číslo 57, který obsahoval uměle vytvořenou vnitřní vadu typu póry, byla zcela úspěšně klasifikována při použití topologií BC a CC. Při použití topologie AC byla chybně klasifikována pole přetvoření ve všech časových okamžicích a ve všech orientacích (obrázek 63).



Obrázek 63 Pole přetvoření vzorku číslo 57.


Ostatní vzorky, uvedené v tabulce číslo 6, byly vždy klasifikovány s vysokou přesností překračující 70 %. V případě vzorku číslo 1 a topologie AC byly chybně určovány pole přetvoření v prvotních časových okamžicích. V případě vzorku číslo 23 a topologie AC byly chybně klasifikovány všechny pole přetvoření, které byly zrcadleny podle vodorovné osy. V případě vzorku číslo 24 a topologie BC byly chybně klasifikovány pole přetvoření s původní orientací blíže ke konci zatěžování. Pole přetvoření vzorku číslo 25 byla chybně klasifikována při použití topologie AC ve 3 případech napříč všemi časovými okamžiky bez zjevné souvislosti. Chybně klasifikovaná pole přetvoření vzorku 30 a vzorku 31 při použití všech 3 topologií pocházejí ze 2 posledních časových okamžiků zatěžování těsně před dosažením meze kluzu a při všech typech zrcadlení. Chybně a správně klasifikovaná pole přetvoření vzorku číslo 30 jsou zobrazena na obrázku 64. V časovém okamžiku blízkém dosažení meze kluzu dochází k výrazné koncentraci přetvoření v horní části vzorku, což může vést k chybnému závěru, že je v této části přítomný defekt.



Obrázek 64 Uprostřed správně klasifikované pole přetvoření a napravo chybně klasifikované pole přetvoření vzorku číslo 30.

Z rozboru výsledků klasifikace naměřených polí přetvoření za pomoci konvoluční neuronové sítě se 3 použitými topologiemi AC, BC a CC vyplývá, že je obtížné detekovat

vnitřní vady, které jsou orientovány rovnoběžně se zatěžující silou (vzorky číslo 27, 28 a 43). Vzorky bez uměle vytvořených vnitřních vad byly klasifikovány vždy alespoň částečně správně s výjimkou vzorku číslo 14. Důvodem mohlo být chybné upnutí vzorku při zatěžování nebo nedostatečná kvalita vytvořeného náhodného vzoru na povrchu měřeného vzorku. V jistých případech (vzorky číslo 23 a 24) závisela správnost klasifikace na orientaci pole přetvoření, což je jev, který nebyl očekáván. Poloha důležitých struktur v obraze by na přesnost klasifikace mít vliv neměla. Tento jev může být projevem nízké robustnosti konvoluční neuronové sítě a mohl by být eliminován zvýšením počtu trénovacích dat. Pokud byly ve vzorku přítomny uměle vytvořené vnitřní vady, správnost klasifikace se zpravidla zlepšovala s rostoucí zátěžnou silou (vzorky číslo 28 a 43), neboť docházelo k růstu koncentrace přetvoření v okolí vnitřních vad. Naopak správnost klasifikace polí přetvoření vzorků bez uměle vytvořené vnitřní vady měla spíše tendenci s rostoucím zatížením klesat (vzorky 30, 31 a 32). To může být způsobeno vznikem koncentrací přetvoření v okolí inherentně vzniklých defektů výplně, které se více projevují spolu s tím, jak se zatížení blíží k mezi kluzu. Pozitivní je zjištění, že většina vzorků s uměle vytvořenou vnitřní vadou byla správně klasifikována i v časových okamžicích, kdy zatížení bylo vzdálené od meze kluzu (zatížení odpovídající přibližně polovině meze kluzu). To je velmi důležité zjištění pro praktické použití defektoskopické metody, neboť aplikované zatížení může být hluboko pod mezí kluzu, a tedy plně nedestruktivního charakteru. Přehled všech navržených vad výplně je zobrazen na obrázku 65. Zvýrazněny jsou 3 vzorky, které byly klasifikovány konvoluční neuronovou sítí s topologií CC s úspěšností menší jak 70 %. Červené čáry oddělují jednotlivé skupiny uměle vytvořených vnitřních vad. V levé části obrázku jsou vzorky s vnitřní vadou typu delaminace, v pravé horní části jsou vzorky s vnitřní vadou typu trhliny a v pravé spodní části jsou vzorky s vnitřní vadou typu kavity.



Obrázek 65 Kompletní přehled vzorků s navrženými vadami výplně.

## 10 Diskuse

Přestože klasifikace vzorků s vadami výplně při použití konvoluční neuronové sítě s topologií označenou CC dosáhla velmi dobré výsledné přesnosti blíží se 95 %, nelze navrženou defektoskopickou metodu s navrženým kritériem vyhodnocení prohlásit za použitelnou pro komerční využití v průmyslové výrobě, neboť nebyla validována na dostatečně různorodém počtu vzorků a materiálů a není plně známa její citlivost na rozměr a polohu vad.

Tato práce si především kladla za cíl ověřit použitelnost a demonstrovat možnosti dosud nepoužívaného způsobu detekce vnitřních vad 3D tištěných struktur za pomoci metody DIC. Pozitivní výsledky z této práce je nutné dále ověřit a prozkoumat. Vady modelované v této práci byly o minimální velikost 1 mm, maximální hloubce 1,5 mm pod povrchem a byly modelovány v tenké součásti podlouhlého tvaru. Bylo by vhodné provést podrobnější analýzu minimální velikosti a maximální hloubky vad pod povrchem, které je možno detekovat a zda jsou tyto parametry závislé na tvaru vyšetřované součásti. Výše zmíněné parametry bude jistě ovlivňovat také kvalita vytvořeného náhodného vzoru na povrchu součásti a kvalita a rozlišením kamer použitých pro záznam obrazu.

Právě pro součásti složitějších tvarů by mohlo být omezující v této práci použitý způsobem zatěžování na trhacím stroji, neboť by mohly nastat problémy s praktickým provedením upnutí součástí do stroje. Především ovšem nebude napjatost v součásti homogenní a vnitřní vady v méně zatížených částech by nemusely být viditelné. Jako řešení by se nabízelo použít teplotní zatížení a vyhodnocovat pole přetvoření součásti během přechodového stavu.

Z hlediska použité technologie výroby součásti, která byla použita v této práci, by bylo vhodné zopakovat měření pro vzorky vytisknuté s jiným typem výplně, vyrobené z jiného materiálu, a především vyrobené jiným typem aditivní výroby, například technologií SLM používající kovový materiál, a vyhodnotit přesnost klasifikace v této práci použitého kritéria, kterým byla konvoluční neuronová síť. Ta se ukázala jako velmi rychlý a přesný nástroj pro automatizaci procesu detekce vnitřních vad, ale předcházela jí zdlouhavá a náročná akvizice trénovacích dat, kterých je nutné mít k dispozici velké množství pro tvorbu robustní a spolehlivé neuronové sítě. V této oblasti by bylo pozitivním zjištěním, že neuronovou sítí natrénovanou na datech změřených na jednom tvaru součásti vyrobené z daného typu materiálu je možné použít pro detekci vnitřních vad součásti rozdílného tvaru a vyrobené z rozdílného materiálu.

## 11 Závěr

Na začátku rešeršní části této práce byla představena metoda digitální korelace obrazu a její dva hlavní typy. Metoda 2D DIC je vhodná pro měření deformací, které nevystupují z roviny kolmé na objektiv kamery, zatímco metoda 3D DIC je univerzálnější a hodí se pro měření, u kterých se vyskytuje možnost vystoupení měřeného objektu z výše uvedené roviny. Byly zde dále uvedeny jevy, které mohou negativně ovlivnit přesnost měření jako je kvalita použitého náhodného vzoru, nebo velikost použité podoblasti, které byly zohledněny během provedeního experimentu v praktické části práce.

Dále byly v této části představeny používané aditivní technologie výroby součástí. Technologie FDM a SLM byly představeny podrobně, a především byl proveden přehled často se vyskytujících vad u součástí vyrobených těmito technologiemi. Typickými problémy jsou neroztavený materiál, kavity, póry, trhliny, delaminace, pokřivení součásti a strukturální nehomogenity. Na základě tohoto přehledu byly modelovány defekty výplně součástí v experimentální části této práce.

Závěr rešeršní části práce se zabýval přehledem používaných defektoskopických metod. Nebyla nalezena žádná práce, která by zkoumala možnosti detekce vnitřních vad ve vyrobených součástech s využitím metody DIC. Nicméně existuje několik prací, ve kterých byla metoda DIC úspěšně použita pro detekci vad během procesu výroby součástí.

V úvodu praktické části byla navržena defektoskopická metoda detekce výplně 3D tištěných struktur využívající metodu DIC. Jako kritéria posouzení přítomnosti vad byla navržena vizuální kontrola a použití strojového učení umožňující automatické posouzení. Navržená defektoskopická metoda pracuje s pomocí metody DIC vypočítaným polem přetvoření na povrchu kontrolované součásti, která je zatížena tahovou silou nepřekračující mez kluzu. Sledován je výskyt koncentrací přetvoření v jinak pravidelném poli přetvoření.

Navržená metoda byla nejprve ověřena na 6 vzorcích, ze kterých 3 obsahovaly uměle vytvořenou vnitřní vadu. Pro výpočet pole přetvoření byl použit program Alpha společnosti X-Sight s.r.o., který obsahuje implementaci metody 3D DIC. Vizuálním posouzením pole přetvoření, změřeného v okamžiku kdy se zatížení blížilo mezi kluzu, byly spolehlivě určeny ty vzorky, které obsahovaly uměle vytvořené vnitřní vady.

V závěru praktické části práce bylo použito druhé navržené kritérium posouzení přítomnosti vnitřních vad, kterým bylo strojové učení. Konkrétně se jednalo o neuronovou síť. Její správné natrénování vyžaduje velké množství dat, bylo proto připraveno celkem 58 vzorků, z nichž 31 obsahovalo uměle vytvořenou vnitřní vadu o minimální velikosti 1 mm a maximální hloubce 1,5 mm pod povrchem vzorku. Modelovány byly 3 kategorie vad, kterými byly delaminace, trhliny a póry. Pole přetvoření byla augmentována a bylo pracováno s časovými okamžiky od 2,5 sekundy (10 snímků) předtím, než zatížení dosáhlo meze kluzu odečtené ze záznamu zátěžné síly. Při použití plně propojené neuronové sítě bylo dosaženo přesnosti klasifikace přesahující 80 %. Při použití konvoluční neuronové sítě bylo dosaženo přesnosti klasifikace blížící se 95 % bez významného rozdílu mezi přesností klasifikace vzorků s uměle vytvořenou vnitřní vadou a bez uměle vytvořené vnitřní vady. Nízká přesnost detekce defektů výplně byla pozorována u vad, jejichž největší rozměr byl rovnoběžný s nositelkou zatěžující síly. U vzorků s uměle vytvořenou vnitřní vadou přesnost klasifikace se zatěžující silou rostla, u vzorků bez uměle vytvořené vnitřní vady byl pozorován opačný trend. Velmi dobrých



výsledků klasifikace bylo dosaženo napříč všemi posuzovanými časovými okamžiky zatěžování vzorků.

## 12 Bibliografie

- [1] ZHAO, Jianlong, Yong SANG a Fuhai DUAN. The state of the art of two-dimensional digital image correlation computational method. *Engineering Reports* [online]. 2019, **1**(2), 1-2 [cit. 2022-09-03]. ISSN 2577-8196. Dostupné z: doi:10.1002/eng2.12038
- [2] SUTTON, Michael, Jean-José ORTEU a Hubert SCHREIER. *Image correlation for shape, motion and deformation measurements: basic concepts, theory and applications*. New York: Springer, 2009. ISBN 978-0-387-78746-6.
- [3] PAN, Bing. Digital image correlation for surface deformation measurement: historical developments, recent advances and future goals. *Measurement Science and Technology* [online]. 2018, **29**(8), 3 [cit. 2023-03-03]. ISSN 0957-0233. Dostupné z: doi:10.1088/1361-6501/aac55b
- [4] CANDAU, Nicolas, Christophe PRADILLE, Jean-Luc BOUVARD a Noelle BILLON. On the use of a four-camera stereovision system to characterize large 3D deformation in elastomers. *Polymer Testing* [online]. 2016, **2016**(56), 314-320 [cit. 2022-06-20]. ISSN 01429418. Dostupné z: doi:10.1016/j.polymertesting.2016.10.017
- [5] ORTEU, Jean-José. 3-D computer vision in experimental mechanics. *Optics and Lasers in Engineering* [online]. 2009, **47**(3-4), 282-291 [cit. 2022-06-20]. ISSN 01438166. Dostupné z: doi:10.1016/j.optlaseng.2007.11.009
- [6] MA, Shaopeng, Jiazhi PANG a Qinwei MA. The systematic error in digital image correlation induced by self-heating of a digital camera. *Measurement Science and Technology* [online]. 2012, **23**(2), 23 [cit. 2020-06-20]. ISSN 0957-0233. Dostupné z: doi:10.1088/0957-0233/23/2/025403
- [7] HADDADI, H. a S. BELHABIB. Use of rigid-body motion for the investigation and estimation of the measurement errors related to digital image correlation technique. *Optics and Lasers in Engineering*. 2008, **46**(2), 185–196.
- [8] CUNHA, Filipa, Telmo SANTOS a José XAVIER. In Situ Monitoring of Additive Manufacturing Using Digital Image Correlation: A Review. *Materials* [online]. 2021, **14**(6), 1 [cit. 2022-06-25]. ISSN 1996-1944. Dostupné z: doi:10.3390/ma14061511
- [9] SHRINIVAS MAHALE, Rayappa, V. SHAMANTH, K. HEMANTH, S.K. NITHIN, P.C. SHARATH, R. SHASHANKA, Adarsh PATIL a Darshan SHETTY. Processes and applications of metal additive manufacturing. *Materials Today: Proceedings* [online]. 2022, **54**(2), 228-233 [cit. 2022-06-25]. ISSN 22147853. Dostupné z: doi:10.1016/j.matpr.2021.08.298
- [10] TOFAIL, Syed, Elias KOUMOULOS, Amit BANDYOPADHYAY, Susmita BOSE, Lisa O'DONOGHUE a Costas CHARITIDIS. Additive manufacturing: scientific and technological challenges, market uptake and opportunities. *Materials Today* [online]. 2018, **21**(1), 22-37 [cit. 2022-06-25]. ISSN 13697021. Dostupné z: doi:10.1016/j.mattod.2017.07.001

- [11] FRAZIER, William E. Metal Additive Manufacturing: A Review. *Journal of Materials Engineering and Performance* [online]. 2014, **23**(6), 1917-1928 [cit. 2022-06-25]. ISSN 1059-9495. Dostupné z: doi:10.1007/s11665-014-0958-z
- [12] PASAGADA, Venkata, Ni YANG a Chengying XU. Electron beam sintering (EBS) process for Ultra-High Temperature Ceramics (UHTCs) and the comparison with traditional UHTC sintering and metal Electron Beam Melting (EBM) processes. *Ceramics International* [online]. 2022, **48**(7), 10174-10186 [cit. 2022-06-25]. ISSN 02728842. Dostupné z: doi:10.1016/j.ceramint.2021.12.229
- [13] VRÁNA, R. *Study of Energy Absorption in Micro-Strut Lattice Structure Produced by Selective Laser Melting*. Brno, 2018. PhD thesis. Brno University of Technology, Faculty of Mechanical Engineering, Institute of Machine and Industrial Design. Vedoucí práce Doc. Ing. David Paloušek, Ph.D.
- [14] JADHAV, Aniket a Vijay JADHAV. A review on 3D printing: An additive manufacturing technology. *Materials Today: Proceedings* [online]. 2022, **62**(4), 2094-2099 [cit. 2022-06-26]. ISSN 22147853. Dostupné z: doi:10.1016/j.matpr.2022.02.558
- [15] MUZAFFAR, Aqib, M. AHAMED, Kalim DESHMUKH, Tomáš KOVÁŘÍK, Tomáš KŘENEK a S. PASHA. 3D and 4D printing of pH-responsive and functional polymers and their composites. *3D and 4D Printing of Polymer Nanocomposite Materials* [online]. Elsevier, 2020, 85-117 [cit. 2022-06-26]. ISBN 9780128168059. Dostupné z: doi:10.1016/B978-0-12-816805-9.00004-1
- [16] SHARMA, Ankit a Aryan RAI. Fused deposition modelling (FDM) based 3D & 4D Printing: A state of art review. *Materials Today: Proceedings* [online]. 2022, **62**(1), 367-372 [cit. 2023-03-05]. ISSN 22147853. Dostupné z: doi:10.1016/j.matpr.2022.03.679
- [17] KHAN, Saifuddin, Ketan JOSHI a Samadhan DESHMUKH. A comprehensive review on effect of printing parameters on mechanical properties of FDM printed parts. *Materials Today: Proceedings* [online]. 2022, **50**(5), 2119-2127 [cit. 2022-06-26]. ISSN 22147853. Dostupné z: doi:10.1016/j.matpr.2021.09.433
- [18] ZHANG, Bi, Yongtao LI a Qian BAI. Defect Formation Mechanisms in Selective Laser Melting: A Review. *Chinese Journal of Mechanical Engineering* [online]. 2017, **30**(3), 515-527 [cit. 2022-06-30]. ISSN 1000-9345. Dostupné z: doi:10.1007/s10033-017-0121-5
- [19] BARTLETT, Jamison, Alex JARAMA, Jonaaron JONES a Xiaodong LI. Prediction of microstructural defects in additive manufacturing from powder bed quality using digital image correlation. *Materials Science and Engineering: A* [online]. 2020, **794**(9), 1-12 [cit. 2022-06-30]. ISSN 09215093. Dostupné z: doi:10.1016/j.msea.2020.140002
- [20] NAGARAJAN, Balasubramanian, Zhiheng HU, Xu SONG, Wei ZHAI a Jun WEI. Development of Micro Selective Laser Melting: The State of the Art and Future Perspectives. *Engineering* [online]. 2019, **5**(4), 702-720 [cit. 2022-06-30]. ISSN 20958099. Dostupné z: doi:10.1016/j.eng.2019.07.002

- [21] WANG, L, Q WEI a W HE. Influence of powder characteristic and process parameters on SLM formability. *Journal of HuaZhong University of Science and Technology (Natural Science Edition)*. 2012, **40**(6), 20-23.
- [22] THIJS, Lore, Frederik VERHAEGHE, Tom CRAEGHS, Jan HUMBEECK a Jean-Pierre KRUTH. A study of the microstructural evolution during selective laser melting of Ti–6Al–4V. *Acta Materialia* [online]. 2010, **58**(9), 3303-3312 [cit. 2023-03-11]. ISSN 13596454. Dostupné z: doi:10.1016/j.actamat.2010.02.004
- [23] SAMES, W., F. LIST, S. PANNALA, R. DEHOFF a S. BABU. The metallurgy and processing science of metal additive manufacturing. *International Materials Reviews* [online]. 2016, **61**(5), 315-360 [cit. 2022-07-03]. ISSN 0950-6608. Dostupné z: doi:10.1080/09506608.2015.1116649
- [24] QIU, C, N ADKINS a M ATTALLAH. Microstructure and tensile properties of selectively laser-melted and of HIPed laser-melted Ti6Al4. *Materials Science and Engineering: A*. 2013, (578), 230-239.
- [25] GONG, H, K RAFI a H GU. Analysis of defect generation in Ti6Al4 V parts made using powder bed fusion additive manufacturing processes. *Additive Manufacturing*. 2014, **1**(4), 87-98.
- [26] LEUDERS, S, M THONE a N RIEMER. On the mechanical behavior of titanium alloy TiAl6V4 manufactured by selective laser melting: fatigue resistance and crack growth performance. *International Journal of Fatigue*. 2013, **48**(-), 300-307.
- [27] WICKRAMASINGHE, Sachini, Truong DO a Phuong TRAN. FDM-Based 3D Printing of Polymer and Associated Composite: A Review on Mechanical Properties, Defects and Treatments. *Polymers* [online]. 2020, **12**(7), 1-42 [cit. 2023-07-12]. ISSN 2073-4360. Dostupné z: doi:10.3390/polym12071529
- [28] SUN, Q., G.M. RIZVI, C.T. BELLEHUMEUR a P. GU. Effect of processing conditions on the bonding quality of FDM polymer filaments. *Rapid Prototyping Journal* [online]. 2008, **14**(2), 72-80 [cit. 2022-07-12]. ISSN 1355-2546. Dostupné z: doi:10.1108/13552540810862028
- [29] GAJDOŠ, I a J SLOTA. INFLUENCE OF PRINTING CONDITIONS ON STRUCTURE IN FDM PROTOTYPES. *Technical Gazette*. 2013, **20**(2), 231-236. ISSN 1330-3651.
- [30] WANG, Tian-Ming, Jun-Tong XI a Ye JIN. A model research for prototype warp deformation in the FDM process. *The International Journal of Advanced Manufacturing Technology* [online]. 2007, **33**(11-12), 1087-1096 [cit. 2022-08-30]. ISSN 0268-3768. Dostupné z: doi:10.1007/s00170-006-0556-9
- [31] HRDLIČKA, Martin. *Vliv teploty vzduchu na FDM 3D tisk* [online]. Brno, 2017 [cit. 2023-03-13]. Dostupné z: <http://hdl.handle.net/11012/65974>. Diplomová práce. Vysoké učení technické v Brně. Fakulta strojního inženýrství. Ústav strojírenské technologie. Vedoucí práce Oskar Zemčík.

- [32] KOPEC, Bernard. *Nedestruktivní zkoušení materiálů a konstrukcí: (nauka o materiálu IV)*. Brno: Akademické nakladatelství CERM, 2008. ISBN ISBN978-80-7204-591-4.
- [33] *Nedestruktivní zkoušení: Defektoskopie - encyklopedický přehled metod nedestruktivního zkoušení materiálů a výrobků*. Brno: Česká společnost pro nedestruktivní testování, 2015, . ISSN 1213-3825.
- [34] JANDEJSEK, I., F. NACHTRAB, N. UHLMANN a D. VAVŘÍK. X-ray dynamic defectoscopy utilizing digital image correlation. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment* [online]. 2011, **633**(1), 185-186 [cit. 2023-03-15]. ISSN 01689002. Dostupné z: doi:10.1016/j.nima.2010.06.162
- [35] SEGOVIA RAMÍREZ, Isaac, Fausto GARCÍA MÁRQUEZ a Mayorkinos PAPAELIAS. Review on additive manufacturing and non-destructive testing. *Journal of Manufacturing Systems* [online]. 2023, **66**(), 260-286 [cit. 2023-03-26]. ISSN 02786125. Dostupné z: doi:10.1016/j.jmsy.2022.12.005
- [36] NSENGIYUMVA, Walter, Shuncong ZHONG, Jiewen LIN, Qiukun ZHANG, Jianfeng ZHONG a Yuexin HUANG. Advances, limitations and prospects of nondestructive testing and evaluation of thick composites and sandwich structures: A state-of-the-art review. *Composite Structures* [online]. 2021, **256**(15), 29-31 [cit. 2023-03-15]. ISSN 02638223. Dostupné z: doi:10.1016/j.compstruct.2020.112951
- [37] TAO, Nan, Andrei ANISIMOV a Roger GROVES. Shearography non-destructive testing of thick GFRP laminates: Numerical and experimental study on defect detection with thermal loading. *Composite Structures* [online]. 2022, **282**(15), 1-2 [cit. 2023-03-15]. ISSN 02638223. Dostupné z: doi:10.1016/j.compstruct.2021.115008
- [38] ZHANG, Lei, Zi THAM, Yi CHEN, Chin TAN, Fangsen CUI, Bisma MUTIARGO a Lin KE. Defect imaging in carbon fiber composites by acoustic shearography. *Composites Science and Technology* [online]. 2022, **223**(26), 1-2 [cit. 2023-03-15]. ISSN 02663538. Dostupné z: doi:10.1016/j.compscitech.2022.109417
- [39] ZHANG, Lei, Yi CHEN, Huajun LIU, Benjamin RUSSELL, Zi THAM, Lin KE a Uvarajan VELAYUTHAM. In-situ real-time imaging of subsurface damage evolution in carbon fiber composites with shearography. *Composites Communications* [online]. 2022, **32**(-), 1-5 [cit. 2023-03-15]. ISSN 24522139. Dostupné z: doi:10.1016/j.coco.2022.101170
- [40] NASTESKI, Vladimir. An overview of the supervised machine learning methods. *HORIZONS.B* [online]. 2017, **4**(1), 51-62 [cit. 2022-11-24]. ISSN 18578578. Dostupné z: doi:10.20544/HORIZONS.B.04.1.17.P05
- [41] POUYANFAR, Samira, Saad SADIQ, Yilin YAN et al. A Survey on Deep Learning. *ACM Computing Surveys* [online]. 2019, **51**(5), 1-36 [cit. 2022-11-24]. ISSN 0360-0300. Dostupné z: doi:10.1145/3234150
- [42] SUN, Hongbin, Pradeep RAMUHALLI a Richard JACOB. Machine learning for ultrasonic nondestructive examination of welding defects: A systematic review. *Ultrasonics* [online].

- 2023, **127**(-), 5-7 [cit. 2023-03-24]. ISSN 0041624X. Dostupné z: doi:10.1016/j.ultras.2022.106854
- [43] JIANG, Tammy, Jaimie GRADUS a Anthony ROSELLINI. Supervised Machine Learning: A Brief Primer. *Behavior Therapy* [online]. 2020, **51**(5), 675-687 [cit. 2023-03-24]. ISSN 00057894. Dostupné z: doi:10.1016/j.beth.2020.05.002
- [44] SCHAEFFER, Don a Taylor MADDIX. Exploring Support Vector Machine Acceleration with Vitis. In: *XILINX* [online]. -: -, 2020 [cit. 2023-03-24]. Dostupné z: <https://www.xilinx.com/developer/articles/exploring-support-vector-machine-acceleration-with-vitis.html>
- [45] MQ. Lekce 8 - Rozhodovací stromy v Pythonu. In: *Itnetwork* [online]. -: -, - [cit. 2023-03-24]. Dostupné z: <https://www.itnetwork.cz/python/neuronove-site/zaklady/rozhodovaci-stromy-v-pythonu/>
- [46] HOLČÍK, Jiří a Martin KOMENDA. *Matematická biologie: e-learningová učebnice* [online]. 1. vydání. Brno: Masarykova univerzita, 2015 [cit. 2023-03-24]. ISBN 978-80-210-8095-9. Dostupné z: <https://portal.matematickabiologie.cz/>
- [47] LIU, Binqi, Gang FANG a Liping LEI. An analytical model for rapid predicting molten pool geometry of selective laser melting (SLM). *Applied Mathematical Modelling* [online]. 2021, **92**(-), 505-524 [cit. 2023-03-25]. ISSN 0307904X. Dostupné z: doi:10.1016/j.apm.2020.11.027
- [48] GHEYSEN, Julie, Matthieu MARTELEUR, Camille VAN DER REST a Aude SIMAR. Efficient optimization methodology for laser powder bed fusion parameters to manufacture dense and mechanically sound parts validated on AlSi12 alloy. *Materials & Design* [online]. 2021, **199**(-), - [cit. 2023-03-25]. ISSN 02641275. Dostupné z: doi:10.1016/j.matdes.2020.109433
- [49] SNOW, Zackary, Brett DIEHL, Edward REUTZEL a Abdalla NASSAR. Toward in-situ flaw detection in laser powder bed fusion additive manufacturing through layerwise imagery and machine learning. *Journal of Manufacturing Systems* [online]. 2021, **59**(-), 12-26 [cit. 2023-03-25]. ISSN 02786125. Dostupné z: doi:10.1016/j.jmsy.2021.01.008
- [50] WANG, Ruoxin, Chi CHEUNG, Chunjin WANG a Mei CHENG. Deep learning characterization of surface defects in the selective laser melting process. *Computers in Industry* [online]. 2022, **140**(-), - [cit. 2023-03-25]. ISSN 01663615. Dostupné z: doi:10.1016/j.compind.2022.103662
- [51] VANDERESSE, N., A. RICHTER, N. NUÑO a P. BOCHER. Measurement of deformation heterogeneities in additive manufactured lattice materials by Digital Image Correlation: Strain maps analysis and reliability assessment. *Journal of the Mechanical Behavior of Biomedical Materials* [online]. 2018, **86**(-), 397-408 [cit. 2023-03-25]. ISSN 17516161. Dostupné z: doi:10.1016/j.jmbbm.2018.07.010
- [52] HOLZMOND, Oliver a Xiaodong LI. In situ real time defect detection of 3D printed parts. *Additive Manufacturing* [online]. 2017, **17**(-), 135-142 [cit. 2023-03-25]. ISSN 22148604. Dostupné z: doi:10.1016/j.addma.2017.08.003

- [53] REZAIE, Amir, Radhakrishna ACHANTA, Michele GODIO a Katrin BEYER. Comparison of crack segmentation using digital image correlation measurements and deep learning. *Construction and Building Materials* [online]. 2020, **261**(20), - [cit. 2023-03-26]. ISSN 09500618. Dostupné z: doi:10.1016/j.conbuildmat.2020.120474
- [54] JANÍČEK, Přemysl. *Systémová metodologie: brána do řešení problémů*. Vyd. 1. Brno: Akademické nakladatelství CERM, 2014. ISBN 978-80-7204-887-8.
- [55] *X-Sight: Advanced DIC measuring systems for optical investigation of your experiments* [online]. Brno: X-Sight s.r.o, 2023 [cit. 2023-05-15]. Dostupné z: <https://www.xsight.eu/>
- [56] *X-Sight - Alpha: USER MANUAL*. Brno, 2021.
- [57] TORRES, Jonathan, José COTELO, Justin KARL a Ali GORDON. Mechanical Property Optimization of FDM PLA in Shear with Multiple Objectives. *JOM* [online]. 2015, **67**(5), 1183-1193 [cit. 2023-04-07]. ISSN 1047-4838. Dostupné z: doi:10.1007/s11837-015-1367-y
- [58] *TECHNICAL DATA SHEET: Prusament PLA by PrusaPolymers*. -, 2018. Dostupné také z: [https://prusament.com/media/2018/07/PLA\\_datasheet.pdf](https://prusament.com/media/2018/07/PLA_datasheet.pdf)
- [59] BRIGATO, Lorenzo a Luca IOCCHI. A Close Look at Deep Learning with Small Data. *ArXiv* [online]. 2020, -(-), - [cit. 2023-04-13]. Dostupné z: doi:10.48550/arXiv.2003.12843
- [60] BHANJA, Samit a Abhishek DAS. Impact of Data Normalization on Deep Neural Network for Time Series Forecasting. *ArXiv* [online]. 2018, -(-), - [cit. 2023-04-13]. Dostupné z: doi:10.48550/arXiv.1812.05519
- [61] GÜNTHER, Frauke a Stefan FRITSCH. Neuralnet: training of neural networks. *R J*. 2020, **2**(1), 30-38.
- [62] SAXENA, Sharoon. Underfitting vs. Overfitting (vs. Best Fitting) in Machine Learning. In: *Analytics Vidhya* [online]. -: -, 2020 [cit. 2023-04-15]. Dostupné z: <https://www.analyticsvidhya.com/blog/2020/02/underfitting-overfitting-best-fitting-machine-learning/>
- [63] BARON, Grzegorz a Urszula STAŃCZYK. Standard vs. non-standard cross-validation: evaluation of performance in a space with structured distribution of datapoints. *Procedia Computer Science* [online]. 2021, **192**(-), 1245-1254 [cit. 2023-04-15]. ISSN 18770509. Dostupné z: doi:10.1016/j.procs.2021.08.128
- [64] K Fold Cross-Validation in Machine Learning?: How does K Fold Work?. In: *MLTut* [online]. -: -, - [cit. 2023-04-15]. Dostupné z: <https://www.mltut.com/k-fold-cross-validation-in-machine-learning-how-does-k-fold-work/>

## SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK

Symbol	Veličina	Jednotka
<i>3DP</i>	Three dimensional printing	
<i>ABS</i>	Polyamer akrylonitrilu, butadienu a styrenu	
<i>BJ</i>	Binder jetting	
<i>C<sub>1</sub>, C<sub>2</sub></i>	Optické středy měřících kamer	
<i>CAD</i>	Computer aided design	
<i>CCD</i>	Charge-coupled device	
<i>CFR</i>	Continous fiber reinforcement	
<i>CT</i>	Výpočetní tomografie	
<i>DED</i>	Directed energy deposition	
<i>DIC</i>	Digitální korelace obrazu	
<i>DID</i>	Příspěvek deformace způsobené defektem	
<i>DLP</i>	Digital light processing	
<i>E</i>	Měrná dodaná energie	J/mm <sup>3</sup>
<i>EBM</i>	Electron beam melting	
<i>f(x,y)</i>	Hodnoty stupně šedi v pixelech referenční podoblasti	-
<i>FDM</i>	Fused deposition modeling	
<i>FDM</i>	Fused deposition modeling	
<i>f<sub>m</sub>, g<sub>m</sub></i>	Normalizační funkce	
<i>FPS</i>	Počet snímků za sekundu	
<i>g(x*,y*)</i>	Hodnoty stupně šedi v pixelech cílové podoblasti	-
<i>h</i>	Vzdálenost skenovacích drah	mm
<i>HIP</i>	Hot isostically pressing	
<i>LOM</i>	Laminated object manufacturing	
<i>ME</i>	Material extrusion	
<i>MED</i>	Medium energy density	
<i>MJ</i>	Material jetting	
<i>MJF</i>	Multi Jet Fusion	
<i>MJP</i>	Multi jet printing	
<i>MKP</i>	Metoda konečných prvků	
<i>OD</i>	Celková deformace	
<i>P</i>	Měřený bod	
<i>p<sub>1</sub>, p<sub>2</sub></i>	Stereoprojekce bodu P	
<i>PBF</i>	Powder bed fusion	
<i>PET</i>	Polyethylentereftalát	
<i>PLA</i>	Kyselina polyléčná	



$Pr$	Přesnost klasifikace	-
$P_w$	Výkon laseru	W
$SHS$	Selective heat sintering	
$SL$	Sheet lamination	
$SLA$	Stereolitography	
$SLM$	Selective laser melting	
$SLS$	Selective laser sintering	
$SVM$	Support vector machine	
$t$	Výška tisknuté vrstvy	mm
$TF$	Počet chybně klasifikovaných dat	-
$TP$	Počet správně klasifikovaných dat	-
$u, v$	Posuvy středu podoblasti	m
ÚMTMB	Ústav mechaniky těles, mechatroniky a biomechaniky	
$v$	Skenovací rychlost	mm/s
$VP$	Vat photopolymerization	
$x$	Normovaná hodnota přetvoření	mm/mm
$x^*, y^*$	Výsledné posuvy podoblastí	m
$x_{max}$	Maximální hodnota přetvoření daného pole	mm/mm
$x_{min}$	Minimální hodnota přetvoření daného pole	mm/mm
$x_{norm}$	Znormovaná hodnota přetvoření	mm/mm
$ZNCC$	Zero-mean normalized cross-correlation criterion	
$ZNSSD$	Zero-mean normalized sum-of-square difference crit.	
$\Delta x, \Delta y$	Vzdálenosti bodu podoblasti od středu podoblasti	m
$\varepsilon_1$	První hlavní přetvoření	mm/mm