


VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA INFORMAČNÍCH TECHNOLOGIÍ
ÚSTAV POČÍTAČOVÉ GRAFIKY A MULTIMÉDIÍ
FACULTY OF INFORMATION TECHNOLOGY
DEPARTMENT OF COMPUTER GRAPHICS AND MULTIMEDIA

OBRAZOVÁ ANALÝZA
V TRIBOTECHNICKÉ DIAGNOSTICE
IMAGE ANALYSIS IN TRIBODIAGNOSTICS

DISERTAČNÍ PRÁCE
DOCTORAL THESIS

AUTOR PRÁCE
AUTHOR

ING. STANISLAV MACHALÍK

VEDOUCÍ PRÁCE
SUPERVISOR

DOC. DR. ING. PAVEL ZEMČÍK

BRNO 2011

Abstrakt

Obrazová analýza částic opotřebení je v práci využita ke klasifikaci jejich obrazů do tříd odpovídajících stanoveným typům opotřebení. Dává možnost získat informace nejen o základních parametrech otěrových částic, ale také údaje, které by při klasickém způsobu hodnocení bylo možné získat jen velmi obtížně. Na základě analýzy morfologických či obrazových charakteristik částic lze sledovat průběh opotřebení strojních součástí, a tím zabránit případné havárii motoru, případně stanovit optimální lhůty pro výměnu oleje.

Cílem této práce je prozkoumat možnosti využití obrazové analýzy v kombinaci s metodou analytické ferrografie a na základě teoretických poznatků navrhnout nástroj pro automatickou klasifikaci částic.

Současné metody analýzy částic opotřebení jsou založeny na vyhodnocení, které nedává přesnou představu o procesech probíhajících mezi třecími povrchy v motorové soustavě. Práce vychází z metody analytické ferrografie, která umožňuje zhodnotit stav sledovaného stroje z hlediska opotřebení. Přínosem klasifikátorů vytvořených v této práci je možnost automatického vyhodnocení výstupů analytické ferrografie; jejich použití odstraňuje zásadní nevýhodu ferrografické analýzy, kterou je její závislost na subjektivním hodnocení expertem provádějícím analýzu.

Vytvořené klasifikátory jsou založeny na využití metod strojového učení. Na základě rozsáhlé databáze částic, která byla vytvořena v první fázi práce, byly klasifikátory natrénovány – umožňují tak hodnotit ferrograficky separované otěrové částice, které pocházejí z olejů odebraných z mazaných soustav. Následně byly provedeny experimenty, z jejichž výsledků vyplynuly optimální nastavení klasifikátorů.

Abstract

Image analysis of wear particles is a suitable support tool for detail analysis of engine, gear, hydraulic and industrial oils. It allows to obtain information not only of basic parameters of abrasion particles but also data that would be very difficult to obtain using classical ways of evaluation. Based on the analysis of morphological or image characteristics of particles, the progress of wearing the machine parts out can be followed and, as a result, possible breakdown of the engine can be prevented or the optimum period for changing the oil can be determined.

The aim of this paper is to explore the possibilities of using the image analysis combined with the method of analytical ferrography and suggest a tool for automated particle classification. Current methods of wear particle analysis are derived from the evaluation that does not offer an exact idea of processes that take place between the friction surfaces in the engine system. The work is based upon the method of analytical ferrography which allows to evaluate the state of the machine. The benefit of use of classifiers defined in this work is the possibility of automated evaluation of analytical ferrography outputs; the use of them eliminates the crucial disadvantage of ferrographical analysis which is its dependence on the subjective evaluation done by the expert who performs the analysis.

Classifiers are defined as a result of using the methods of machine learning. Based on an extensive database of particles that was created in the first part of the work, the classifiers were trained – as a result, they make the evaluation of ferrographically separated abrasion particles from oils taken from lubricated systems possible. In the next stage, experiments were carried out and optimum classifier settings were determined based on the results of the experiments.

Klíčová slova

Obrazová analýza, analytická ferrografie, klasifikace, částice opotřebení, AdaBoost, obrazové příznaky, metody strojového učení.

Keywords

Image analysis, analytical ferrography, classification, wear particles, AdaBoost, image features, machine learning.

Bibliografická citace díla

MACHALÍK, S. *Obrazová analýza v tribotechnické diagnostice, disertační práce*. Brno, 2011. 118 s. Vedoucí disertační práce Doc. Dr. Ing. Pavel Zemčík. FIT VUT v Brně

Obrazová analýza v tribotechnické diagnostice

Prohlášení

Prohlašuji, že jsem tuto vysokoškolskou kvalifikační práci vypracoval samostatně pod vedením vedoucího disertační práce, s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury. Jako autor uvedené disertační práce dále prohlašuji, že v souvislosti s vytvořením této disertační práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení § 152 trestního zákona č. 140/1961 Sb.

.....
Stanislav Machalík

.....
Datum

Poděkování

Děkuji vedoucímu diplomové práce Doc. Dr. Ing. Pavlu Zemčíkovi za metodické a cíleně orientované vedení při plnění úkolů realizovaných v návaznosti na disertační práci. Dále děkuji kpt. Ing. Josefu Glosovi z Fakulty vojenských technologií Univerzity obrany v Brně za možnost seznámení a práce s v České republice unikátním zařízením Laser Net Fines. Velký podíl na realizaci klasifikátoru částic patří Ing. Romanu Juránkovi z Fakulty informačních technologií VUT v Brně. Za podporu a motivaci, bez které by tato práce nebyla zřejmě dokončena, děkuji své rodině.

© Stanislav Machalík, 2011

Tato práce vznikla jako školní dílo na Vysokém učení technickém v Brně, Fakultě informačních technologií. Práce je chráněna autorským zákonem a její užití bez udělení oprávnění autorem je nezákonné, s výjimkou zákonem definovaných případů.

OBSAH:

1	ÚVOD	7
2	ČÁSTICE OPOTŘEBENÍ V TRIBOTECHNICKÉ DIAGNOSTICE	10
2.1	TRIBOLOGIE A TRIBOTECHNIKA	10
2.2	ČÁSTICE OPOTŘEBENÍ A JEJICH ROZDĚLENÍ	17
2.3	SOUČASNÁ METODIKA A MOŽNOSTI TRIBODIAGNOSTIKY	25
2.4	PRINCIP A METODIKA ANALYTICKÉ FERROGRAFIE	28
2.5	MOŽNOSTI KLASIFIKACE ČÁSTIC OPOTŘEBENÍ	31
2.6	TECHNOLOGIE AUTOMATICKÉ KLASIFIKACE-PUBLIKOVANÉ V LITERATUŘE	37
3	REALIZOVANÁ VYLEPŠENÍ TRADIČNÍCH METOD ANALÝZY ČÁSTIC OPOTŘEBENÍ	44
3.1	OBRAZOVÁ ANALÝZA ČÁSTIC OPOTŘEBENÍ VYCHÁZEJÍCÍ Z TVAROVÝCH FAKTORŮ	44
3.2	ZHODNOCENÍ VÝSLEDKŮ KLASIFIKACE ČÁSTIC VYCHÁZEJÍCÍ Z TVAROVÝCH FAKTORŮ	51
4	MOŽNOSTI METOD STROJOVÉHO UČENÍ V OBLASTI AUTOMATICKÉ KLASIFIKACE ČÁSTIC OPOTŘEBENÍ	53
4.1	PRINCIP A POUŽITÍ KLASIFIKÁTORŮ	53
4.2	METODY STROJOVÉHO UČENÍ	58
4.3	METODY EXTRAKCE OBRAZOVÝCH PŘÍZNAKŮ	69
4.4	ANALÝZA HLAVNÍCH KOMPONENT	74
5	NOVÁ METODA KLASIFIKACE ČÁSTIC OPOTŘEBENÍ	77
5.1	OBRAZOVÁ DATA PRO VSTUP KLASIFIKACE	77
5.2	DEFINICE TŘÍD OPOTŘEBENÍ PRO KLASIFIKACI	79
5.3	NORMALIZACE OBRAZŮ ČÁSTIC PRO TRÉNOVÁNÍ KLASIFIKÁTORU	81
6	POUŽITÁ METODIKA A JEJÍ OVĚŘENÍ NA ZKUŠEBNÍCH VZORCÍCH	85
6.1	NASTAVENÍ PARAMETRŮ NORMALIZACE DAT	86
6.2	VYHODNOCENÍ VÝSLEDKŮ DOSAŽENÝCH V EXPERIMENTECH	87
7	APLIKACE A VÝSLEDKY KLASIFIKÁTORU	92
7.1	ÚPRAVENÁ DEFINICE KLASIFIKAČNÍCH TŘÍD	92
7.2	PRŮBĚH A VÝSLEDKY KLASIFIKACE ČÁSTIC Z LNF	93
7.3	PRŮBĚH A VÝSLEDKY KLASIFIKACE ČÁSTIC Z FERROGRAMŮ	98
8	ZÁVĚR	103
	LITERATURA	106
	SEZNAM OBRÁZKŮ, TABULEK A ZKRATEK	109
	SEZNAM OBRÁZKŮ	109
	SEZNAM TABULEK	111
	SEZNAM ZKRATEK	112
	SEZNAM PŘÍLOH	113
	PŘÍLOHA 1 – ÚPLNÉ VÝSLEDKY KLASIFIKACE ČÁSTIC Z LNF	114
	PŘÍLOHA 2 – ÚPLNÉ VÝSLEDKY KLASIFIKACE ČÁSTIC Z FERROGRAMŮ	134

1 Úvod

S rostoucími nároky na spolehlivost, hospodárnost a bezpečnost provozu dopravních prostředků i dalších strojních zařízení jsou kladeny stále větší nároky jak na vlastní mechanické systémy a mazací prostředky v nich používané, tak i na proces kontroly technického stavu jednotlivých mechanických součástí, sledování funkčnosti celých mechanických systémů i stavu použitého maziva.

S těmito požadavky je úzce spjato sledování technického stavu strojních zařízení i stavu používaných maziv. Tyto úkoly řeší tribotechnická diagnostika, která jako soubor nedestruktivních bezdemontážních metod využívá mazivo jako zdroj informací o dějích a změnách v mechanických systémech, v nichž je mazivo aplikováno.

Obrazová analýza obecně umožňuje získávat kvantitativní informace o různých statistických a morfologických charakteristikách digitálního obrazu a v něm rozpoznávaných objektů. V oblasti analýzy maziv zabývající se hodnocením částic opotřebení lze jejím prostřednictvím určit např. typ a míru opotřebení třecích ploch; to jedním z cílů tribotechnické diagnostiky. Počítačové zpracování obrazu otevřelo rozsáhlé možnosti pro automatizaci zpracování výstupů mikroskopických metod.

Vývoj motorové techniky neustále směřuje k zvyšování výkonů motorů, a to při současném snižování rozměrů a hmotností agregátů. Tyto faktory ovlivňují nejen požadavky na kvalitu materiálu, použitého při výrobě agregátů, ale i na vlastnosti a jakost mazacích olejů, které z hlediska funkčnosti techniky závislé na mazání sehrávají stále důležitější roli, protože nejčastější příčinou vzniku havárií a značných třecích ztrát je nedostatečné mazání exponovaných míst. Nejen ve všech odvětvích průmyslu, ale všude tam, kde je využívána mechanizace, je dnes zcela běžné aktivně předcházet vzniku poruch. Monitorování funkce mazacího oleje a stavu motoru po dlouhou dobu provozu, sledování průběhu změn vlastností oleje a obsahu otěrových částic vytváří podmínky pro zajištění spolehlivé funkce motoru po celou dobu jeho životnosti.

Tato práce je zaměřena na možnosti analýzy otěrových částic, které jsou získávány z oleje odebraného z mazacího systému. Vyhodnocením výsledků analýzy lze určit vhodné výměnné intervaly olejů, specifikovat převládající mechanismy opotřebení, identifikovat katastrofické částice a predikovat vznik havarijního opotřebení. Jednou z metod používaných pro analýzu stavu opotřebení systému je analytická ferrografie, která umožňuje mikroskopicky zkoumat částice opotřebení obsažené v mazacích olejích. Výstupem této

metody jsou ferrogramy, na kterých jsou působením magnetického pole rozloženy částice opotřebení oddělené z oleje.

Interpretace výsledků, která spočívá v určení původu částic opotřebení a stanovení převládajícího typu opotřebení, je však u metody analytické ferrografie do značné míry problematická, protože nejsou definována přesná pravidla pro hodnocení částic a jejich jednoznačné zařazení (klasifikaci) do odpovídající třídy opotřebení. Výsledek vyhodnocení je tak závislý na zkušenostech operátora, který provádí vyhodnocení. Cílem této práce je eliminovat vliv lidského faktoru (z důvodu časové náročnosti, možného subjektivního hlediska osoby, která hodnocení provádí, a rovněž z důvodů ekonomických) použitím automatického klasifikátoru částic. Vyhodnocení výstupů metody analytické ferrografie (ferrogramů) by bylo díky využití automatického klasifikátoru objektivnějším, v mnoha případech i jednodušším a v neposlední řadě levnějším řešením.

Částice, které vznikají v důsledku opotřebení třecích ploch, je možné blíže specifikovat formou popisu jejich tvarů, velikostí, počtu a řadou dalších, především morfologických parametrů. Různá poškození a poruchy vedoucí k opotřebení, ke kterým dochází v mazací soustavě, produkují částice specifických tvarů. Automatická klasifikace je však problematická především z důvodu velkého množství tvarů částic. Ne vždy je možné jednoznačně určit typ částice, třídy opotřebení nejsou zcela disjunktní. Pokud by existoval nástroj umožňující automatickou klasifikaci částic do předem definovaných tříd, nebyla by metoda analytické ferrografie závislá na znalostech a zkušenostech operátora provádějícího vyhodnocení a proces hodnocení stavu opotřebení by tak nebyl zatížen subjektivní chybou.

Myšlenka vylepšení metody analytické ferrografie pomocí nástrojů pro automatickou klasifikaci částic není nová. V odborné literatuře [1], [2], [3] lze nalézt především několik návrhů, ale i popisů implementací systémů, které umožňují objektivní hodnocení částic opotřebení. Nejčastějším přístupem k identifikaci a správnému rozpoznání otěrových částic je využití neuronových sítí či klasifikátoru fungujícího na principu expertního systému „učícího se“ rozpoznávat jednotlivé částice na základě jejich morfologických parametrů nebo obrazových vzorů.

Cílem této práce je prozkoumat možnosti využití obrazové analýzy v kombinaci s metodou analytické ferrografie a na základě teoretických poznatků navrhnout automatický klasifikátor – nástroj pro automatickou klasifikaci částic, který se ze vzorových obrazů částic naučí klasifikovat obrazy částic pořízených metodou analytické ferrografie. Cílem úvodních experimentů bylo ověření funkčnosti navržené metodiky klasifikace částic, prozkoumání

vlivu nastavení parametrů ovlivňujících průběh a výsledky trénování a klasifikace, nalezení optimálního způsobu normalizace obrazů částic. Na základě experimentů byla určena chybovost klasifikace pro jednotlivé třídy. Cílem navazujících experimentů bylo zajistit optimální přesnost klasifikace při testování většího množství dat a ověřit funkčnost klasifikátoru v reálných podmínkách.

Praktickým výstupem této práce je automatický klasifikátor (resp. kaskáda klasifikátorů, nadále bude v textu používán termín klasifikátor) částic opotřebení, který využívá metody strojového učení k analýze obrazů částic. Tyto obrazy jsou podrobeny normalizaci a následně jsou vstupem pro učení (trénování) klasifikátoru. V průběhu trénování jsou v obrazech částic vyhodnocovány specifické příznaky, které jsou poté při klasifikaci vyhledávány v testovaných obrazech. Pokud jsou v obrazech odpovídající příznaky nalezeny, je výsledkem klasifikace zařazení dané částice do odpovídající třídy opotřebení.

Dosažené výsledky ukazují, že využití automatické klasifikace částic v provozu může přinést prakticky využitelné výsledky, které mnohdy nelze získat jinými metodami. V době odevzdání práce je chybovost klasifikace pod hranicí 10 % v závislosti na nastavení klasifikátoru a testované třídě. Dosažená přesnost přináší zlepšení oproti výsledkům doposud používaných metod.

V kap. 2 jsou popsány základní pojmy související s problematikou tribodiagnostiky a přehled částic opotřebení rozdělených podle typu opotřebení, jehož působením částice vznikají. Součástí je bližší popis metody analytické ferrografie, především jejích výstupů, ferrogramů. V kap. 2 je rovněž popsán současný stav problematiky, jsou zde prezentovány alternativní přístupy k analýze částic opotřebení, které jsou popsány v literatuře: Kapitola obsahuje rovněž závěry důležité pro návrh a implementaci vlastního klasifikátoru částic.

Kap. 3 popisuje realizaci aplikace pro klasifikaci částic, která využívá především tvarové faktory. Závěry a jejich vliv na další postup jsou uvedeny na konci kapitoly.

Kap. 4 představuje metody strojového učení, které jsou využívány pro trénování klasifikátoru. Je zde uvedena definice tříd opotřebení, do kterých jsou částice klasifikovány. Rovněž je uveden přehled metod extrakce obrazových příznaků z obrazů částic.

V kap. 5. Je uveden bližší popis klasifikátoru a dosažených experimentálních výsledků. Jsou popsány možnosti nastavení klasifikátoru a zdůvodněny optimální hodnoty nastavení vedoucí k nejlepším výsledkům.

Kap. 6. je věnována popisu provedených experimentů, vyhodnocení výsledků a jejich porovnání s výsledky podobných výzkumů publikovanými v literatuře.

2 Částice opotřebení v tribotechnické diagnostice

V této kapitole je uveden přehled základních pojmů souvisejících s problematikou tribodiagnostiky – bezdemontážní metody umožňující analyzovat aktuální stav sledovaného mechanismu, případně sledovat dlouhodobý trend opotřebení. Nejedná se o úplný výčet všech pojmů a oblastí z daného oboru. Popsány jsou nejdůležitější termíny; je uveden přehled různých typů opotřebení a částic, které následkem opotřebení vznikají.

Uvedené definice a poznatky jsou základem pro automatizaci procesu klasifikace otěrových částic. Výstupy pokročilých experimentálních metod jsou zpracovávány s využitím vhodných nástrojů a algoritmů poskytovaných moderními informačními technologiemi.

2.1 Tribologie a tribotechnika

Tribologie je mezioborová věda, zabývající se obecně vzájemným působením povrchů tuhých těles při jejich relativním pohybu nebo při pokusu o vzájemný pohyb, a s tím souvisejícími technologiemi [4]. Jako nauka o vědeckém výzkumu a technickém použití zákonitostí a poznatků je součástí vědních oborů zaměřených na tření, opotřebení a mazání.

Tribotechnika je jedním z oborů tribologie, který se zabývá aplikací výsledků tohoto vědního oboru v praxi. Tribotechnika v praxi komplexně řeší otázky týkající se tření, opotřebení a mazání. Při vzájemném působení povrchů v pohybu dochází k odporu proti pohybu – tření. Důsledkem tření je opotřebení pohybujících se povrchů. Tření a opotřebení se zmenšuje mazáním, přitom mazivem může být látka jakéhokoliv skupenství [4]. Nejčastěji jsou v praxi jako maziva používány oleje, tj. maziva kapalná, a také maziva plastická.

Mezi oblastmi, kterými se tribotechnika zabývá, patří

- výběr a způsoby aplikace maziv,
- maziva a jejich testování,
- materiály pro třecí dvojice,
- výpočet, konstrukce a optimalizace třecích dvojic,
- mazací technika,
- měřicí a kontrolní metody pro tribotechnické procesy,
- spolehlivost a diagnostika konstrukčních částí a skupin,
- speciální technologické postupy vedoucí ke zvýšení odolnosti proti opotřebení,
- organizace techniky mazání.

Z ekonomického hlediska nabývá v současnosti tribotechnika na důležitosti, neboť pomocí její správné aplikace lze dosáhnout významných úspor v řadě oblastí.

Maziva často musí splňovat protichůdné požadavky na jejich funkci a přitom musí pracovat za extrémních podmínek se stále delší životností. Se zvyšováním spolehlivosti a hospodárnosti provozu je úzce spjato sledování technického stavu strojních zařízení i stavu používaných maziv. Při analýze opotřebeného oleje se v rámci tribotechnické diagnostiky nezjišťují pouze vlastnosti samotného oleje, ale využíváním informací získaných jejím prostřednictvím lze sledovat stav celého systému. Velkou výhodou je zde možnost využití bezdemontážní technologie. Na základě informací získaných z odebraných vzorků maziva lze včas upozornit na závadu, jejímž odstraněním se dá předejít celkové havárii zařízení. Opotřebenění strojních součástí se vždy projeví i na kvalitě maziva – mazivo je proto také nositelem informace o mechanickém opotřebenění v konkrétním stroji.

Tribotechnická diagnostika řeší dva velké okruhy problémů – jednak zjišťování stavu, prodlužování použitelnosti i prognózování degradace mazacích olejů, jednak monitorování režimu, místa a trendu opotřebenění mechanického systému (vozidlový spalovací motor, převodovka, hydraulická soustava aj.) cestou vyhodnocení výskytu cizích látek v mazivu, a to z hlediska jak kvalitativního, tak kvantitativního.

Jedním z významných postupů tribodiagnostiky je metoda analytické ferrografie, pomocí které jsou nejčastěji získávány a podrobně zkoumány vzorky použitých mazacích olejů obsahujících částice opotřebenění z ložisek případně jiných částí motoru, využívá se však i pro analýzy jiných druhů olejů (např. převodových, hydraulických, průmyslových), případně i pro analýzy plastických maziv po jejich rozpuštění ve vhodných rozpouštědlech. Zkoumáním otěrových částic lze určit druh opotřebenění a celkový stav technického zařízení, ze kterého bylo mazivo odebráno. V oblasti ferrografické analýzy se pro vyhodnocování ferrogramů začíná využívat obrazová analýza. Využití obrazové analýzy otěrových částic v mazivu pro oblast ferrografie je jedním z cílů této práce.

2.1.1 Tření

Tření je definováno jako ztráta mechanické energie v průběhu nebo na začátku relativního pohybu hmotných ploch vzájemně se dotýkajících. Tuto ztrátu lze vhodnými prostředky snížit, ne však zcela odstranit [4].

Ke tření dochází v dotykových místech dvou elementů (pevných, tekutých či plyných), kde se projevuje vznikem síly působící proti pohybu. Tření mezi dvěma tělesy

nemusí vždy být jevem škodlivým. V mnoha případech je naopak tření užitečné (např. tření umožňující fungování brzd). V pohonných, výkonných či jiných jednotkách strojních zařízení však tření způsobuje zvýšení teploty materiálu, jeho ztráty a další nepříznivé vlivy.

Tření způsobuje především opotřebení povrchů součástí, které jsou ve vzájemné interakci. Ať už jsou tyto vlivy větší či menší, vždy vedou k částečné nebo úplné destrukci soustrojí. Tření má tedy za následek urychlení opotřebení strojních součástí.

2.1.2 Opotřebení

Opotřebení je trvalá změna tvaru, popř. materiálová změna na plochách pevných těles, která vznikla následkem tření, a nikoliv záměrnou změnou tvaru nebo materiálu. Opotřebení, které nastává při kluzných pochodech, se rozděluje na opotřebení odnosem, opotřebení změnou tvaru, které má za následek vtisky, drážky a rýhy, a opotřebení zadíráním vedoucí k svařování kluzných materiálů až k zastavení strojní součásti [5].


2.1.3 Typy opotřebení

V technické praxi dochází velmi často ke kombinaci různých druhů opotřebení, např. únavové opotřebení ozubených kol při současném působení abrazivních částic. Dle ČSN 015050 „Opotřebení materiálu. Názvosloví.“ [8] se opotřebení rozděluje na šest základních druhů.

Adhezivní opotřebení

Adhezivní opotřebení (obr. 1) je vyvoláno tím, že povrchy tuhých těles nejsou nikdy dokonale hladké, ale vyskytují se na nich mikronerovnosti. Ke styku povrchu dvou protilehlých součástí proto nedochází v celé ploše, ale pouze ve velkém počtu dotykových plošek, kde se vlivem adhezivních sil tvoří mikrospoje. Při porušení mikrospoje dochází k přenosu materiálu.

Pro zmenšení následků tohoto opotřebení se zavádí hydrodynamické mazání, užití vzájemně nesvařitelných materiálů nebo jiných povlaků, přidání vysokotlakého aditiva do maziva nebo účelová, řízená koroze [7].



Obr. 1a) Mechanismus adhezivního opotřebení
(F – přítláčná síla, v – rychlost posuvu) [2]


Obr. 1b) Adhezivní opotřebení pístního čepu [2]

Abrazivní opotřebení


Tento způsob opotřebení se projevuje rýhováním povrchu (obr. 2). Podle příčiny vzniku se dělí do dvou skupin:

- 1) Opotřebení vlivem působení cizorodé částice mezi třecími povrchy má za následek změny tribologického režimu a rychlé opotřebení třecích povrchů. Původcem abrazivního opotřebení bývají např. křemičité prachové částice pronikající do motoru přes netěsnosti vzduchových filtrů.
- 2) Penetrace tvrdšího materiálu třecí dvojice do měkčího. Pravděpodobnost vzniku částic tímto způsobem se zvyšuje při kontaktu třecích dvojic s velkým rozdílem tvrdosti povrchů.

Jako protiopatření se používá zavedení hydrodynamického mazání, snížení drsnosti tvrdého tělesa, zvýšení tvrdosti opotřebované části, zmenšení jmenovitého tlaku nebo vyloučení volných tvrdých částic [2].



Obr. 2a) Mechanismus abrazivního opotřebení [5]




Obr. 2b) Abrazivní opotřebení pístu spalovacího motoru [5]

Únavové opotřebení

Je způsobeno postupným rozšiřováním poruch v povrchové vrstvě materiálu vlivem opakovaných stykových napětí v určitých částech funkčních povrchů (obr. 3). Vzniká především u součástí, na které působí chvění, vysoký tlak, vysoká teplota a další agresivní podmínky, což vede k postupnému oddělení částic od základního materiálu. Dochází k němu také při poškození povrchové vrstvy křehkým lomem.

Aby nedocházelo k tomuto jevu, je třeba užívat materiály a povlaky, které nemají sklon ke zkřehnutí či tvorbě mikrotrhlin. Tyto materiály by měly zároveň tlumit vibrace a nárazové normálové namáhání, jež urychluje destrukci struktury podpovrchových oblastí pevných těles [5].




Obr. 3a) Mechanismus únavového opotřebení [5]



Obr. 3b) Únavový lom spojkové hřídele

Kavitační opotřebení

Kavitační opotřebení vzniká v tekutinových mechanismech, a to v místech s náhlou změnou průřezu. V zúženém průřezu vzrůstá rychlost proudění a současně klesá tlak. Pokles tlaku kapaliny má za následek uvolňování bublinek páry nebo rozpuštěných plynů. Ve zvětšeném průřezu tlak opět vzroste a bublinky zanikají, což způsobuje rázy, a tím poškozování povrchu [5] (obr. 4).




Obr. 4a) Mechanismus kavitačního opotřebení [5]



Obr. 4b) Kavitační opotřebení pouzdra válce spalovacího motoru [5]

Vibrační opotřebení

Vibrační opotřebení se vyskytuje tam, kde při působení normálového zatížení dochází zároveň ke kmitavým tečným pružným deformacím nebo tečným posuvům s malou amplitudou. Známá jsou poškození hřídelů s nalisovanými náboji nebo poruchy nepohyblivých uložení, které vznikají při periodickém zatěžování. Vibrace spolu s malou tuhostí nebo vůlemi vedou k poruchám spojek a valivých ložisek. Vibračním opotřebením vznikají částice, které svým vzhledem připomínají produkty koroze. Tyto částice působí silně abrazivně a jejich působením dochází i k poruchám velmi tvrdých povrchových vrstev [5] (obr. 5).




Obr. 5a) Mechanismus vibračního opotřebení
[5]



Obr. 5b) Vibrační opotřebení valivého ložiska
[5]

Erozivní opotřebení

Erozivní opotřebení je charakterizováno oddělováním částic a poškozováním opotřebovávaného povrchu částicemi nesenými proudem kapaliny (eroze potrubí a čerpadel) (obr. 6). Typické je nerovnoměrné poškození povrchu. Je způsobeno turbulencí proudícího média za nerovnostmi povrchu [5].



Obr. 6a) Mechanismus erozivního opotřebení
[5]



Obr. 6b) Erozivní opotřebení koule uzavěru
[5]

Korozivní opotřebení

Korozivní opotřebení se projevuje zmenšením pevnosti povrchových vrstev následkem tribochemických reakcí (tribokoroze). Je způsobeno korozivním účinkem aktivních složek maziva nebo vzdušného kyslíku a vlhkosti, kyselin a zásad na kovový povrch.

Pro zamezení tohoto opotřebení se využívá protikorozních aditiv v mazivu, používá se základních materiálů nebo povlaků povrchů odolnějších proti korozi a chlazení pro snížení rychlosti chemických reakcí [5].

Kombinované opotřebení

V praxi se často vyskytují kombinace některých typů opotřebení. V mnoha případech opotřebení jednoho typu vyvolá rozvoj opotřebení jiného typu. Po dosažení hranice únavové životnosti tvrzeného povrchu běžným funkčním zařízením dojde k únavovému opotřebení. Velmi tvrdé částice vypadávající z povrchu pak vyvolají rozvoj abrazivního opotřebení [5].

Uvedený přehled uvádí základní rozdělení typů opotřebení. Podrobnější informace o mechanismech a průběhu opotřebení včetně rozsáhlé fotodokumentace jsou uvedeny v [5].

2.2 Částice opotřebení a jejich rozdělení

Na základě výskytu částic ve zkoumaném vzorku oleje lze podle velikosti a tvaru otěrových částic zjistit druh opotřebení.

Částice mohou být obecně dvojího druhu:

- primární částice – jsou generovány přímo třecími dvojicemi. Charakterizují přímo režim opotřebení v souladu s obecně známými poznatky,
- sekundární částice – vznikají přetvořením primárních částic při opakovaném průchodu těchto částic soustavou.

Vzájemný poměr výskytu primárních a sekundárních částic je závislý na mnoha faktorech, např. na velikosti olejové náplně, počtu a účinnosti olejových čističů v soustavě, účinnosti ostatních procesů odlučování částic ze soustavy, reálné velikosti tepelného a mechanického zatížení motoru, počtu tribologických jednotek, použitém druhu mazacího oleje aj. [4].

2.2.1 Rozdělení částic opotřebení podle původu

Tvar a velikost částic opotřebení jsou dány především mechanismem opotřebení působícím při jejich vzniku. Podle původu se dělí částice do následujících skupin [4].

Adhezivní částice

Vznikají, pokud dojde ke smyku pomalu se pohybující tuhých těles přitlačovaných vysokou normálovou silou bez přítomnosti cizích částic mezi povrchy. Dochází k tzv. lokálním svarům za studena, jejichž pevnost může být vyšší než pevnost materiálu přitlačovaných těles. Výsledkem je vytrhávání částic materiálu s nižší mezí pevnosti.

Původ mají v Beilbyho vrstvě (povrchová vrstva deformovaná působením vnějších vlivů), z níž se postupně odlupují a jsou mazivem odplavovány. Jsou to částice, jejichž délka a šířka je přibližně stejná, jejich tloušťka je však velmi malá. Tyto částice jsou charakteristické pro opotřebení ocelových součástí, proto mají velmi dobré magnetické vlastnosti. Při ferrografické analýze je lze téměř vždy identifikovat. Jejich počet a zejména velikost charakterizuje intenzitu adhezivního opotřebení.

Abrazivní částice

Vznikají, pokud dojde ke smýkání tvrdých drsných povrchů po sobě, případně při přítomnosti cizích tvrdých částic mezi smýkajícími se povrchy. Mají tvar srpečků nebo mečíků s ostrými výčnělky na koncích. Vyznačují se velmi malou tloušťkou. Jejich výskyt (zejména při zvýšeném počtu částic větší velikosti) poukazuje na blížící se poruchu zařízení.

Sférické částice

Patří mezi hlavní typy částic vznikajících v důsledku únavového opotřebení valivého charakteru. Zpravidla vznikají v důsledku únavy Beilbyho vrstvy na okraji vnitřních nebo vnějších povrchů ložisek. Sféroidy jsou relativně malé (2–30 μm), v objektivu mikroskopu se při běžném pozorování jeví jako malé černé body, při větším zvětšení je patrný jejich hladký povrch. Výskyt těchto částic na ferrogramu signalizuje nastupující poruchu valivých ložisek

Laminární částice

Nejčastěji vznikají v důsledku opakovaného průchodu oleje (a tím i částic) soustavou. To má za následek plastickou deformaci částic (např. mezi valivým elementem a dráhou kroužku). Rozválcováním sféroidů i jiných třírozměrných částic vznikají tenké ploché lupínky malé tloušťky. Částice mají hladký povrch a nepravidelné okraje, jejich výskyt je zpravidla

doprovázen výskytem sféroidů. V těchto případech nastal proces postupné poruchy valivého ložiska.

Únavové částice


Charakterizují často se vyskytující poškození ozubených kol. Jedná se o trojrozměrné částice se srovnatelnou délkou, šířkou i tloušťkou. Povrch částic je nepravidelný, rýhovaný s nepravidelně členěnými okraji.

Ostatní částice

V určitých situacích lze na ferrogramech pozorovat i „částice“ vymykající se svým vzhledem popsaným typům. Na ferrogramu se mohou objevit např. vlákna filtrů, prach a rostlinné zbytky z nasávaného okolního vzduchu či jiné cizí částice, které nemají souvislost s opotřebením. V praxi jsou většinou dobře identifikovatelné právě pro svůj specifický tvar a většinou výrazně odlišnou velikost (až několik mm).

2.2.2 Ukázka charakteristických částic na ferrogramu


Na obr. 7–9 je uveden ilustrativní výběr z fotodokumentace, zhotovené na ferrografickém pracovišti Dopravní fakulty Jana Pernera Univerzity Pardubice.



Obr. 7: Laminární částice se stopami abrazivního opotřebení (zvětšeno 400x)



Obr. 8: Únavové částice typického kulovitého tvaru (zvětšeno 400x)




Obr. 9: Kombinace částic vzniklých ve smíšených režimech opotřebení s převažujícími částicemi adhezivními (v řetízích) a laminárními; olej je kontaminován i vnějšími nečistotami (vlákny z textilních resp. papírových filtrů) (zvětšeno 100x)

2.2.3 Opotřebení v průběhu životního cyklu zařízení

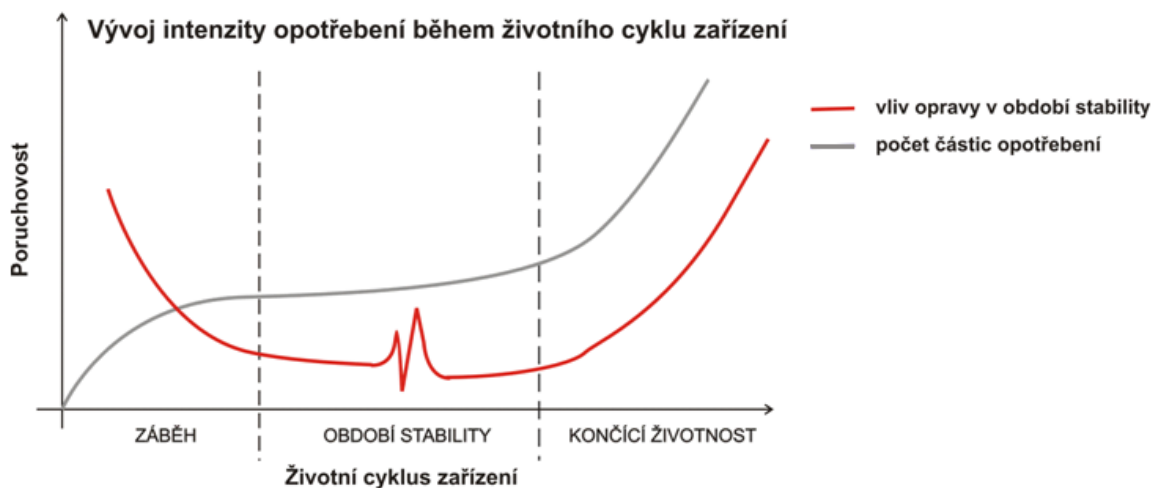
Nejznámějším vyjádřením průběhu životního cyklu zařízení z hlediska četnosti poruch je tzv. vanová křivka. Její typický tvar (obr. 10) znázorňuje tři hlavní fáze životního cyklu zařízení – záběh, provoz v ustáleném režimu a etapu dožití:

- **Doba záběhu** je obdobím častých poruch; intenzita poruch však postupně klesá a spolehlivost zařízení se zlepšuje. V této fázi životního cyklu se projevují nedostatky způsobené chybami (nepřesnostmi) v konstrukci a při výrobě. Tyto skryté nedostatky se při provozním zatížení rychle projeví vznikem částic opotřebení. U vyzrálých nebo sériově, hromadně vyráběných konstrukcí se tato fáze projevuje minimálně. (obr. 13)
- **Období stability** je obdobím běžného provozu zařízení, intenzita poruch se ustaluje na přibližně konstantní hodnotě, případné poruchy vznikají působením náhodných událostí. Z hlediska životnosti je tato etapa nejdelším obdobím. Správný systém údržby může vést k významnému prodloužení tohoto období a úspoře nákladů na provoz. (obr. 14–16)
- **Období končící životnosti** je obdobím dožití a likvidace zařízení. Vlivem opotřebení v průběhu předchozích období a dalších faktorů (koroze, únavové jevy) začne intenzita poruch postupně narůstat. V určitou chvíli je další prodloužování provozuschopnosti zařízení neefektivní (ekonomicky i technicky) a dále neúnosné – provoz zařízení je ukončen. (obr. 17)



Obr. 10: Množství částic opotřebení v průběhu životního cyklu zařízení [5]

Snahou současného systému údržby zařízení je dosažení minimální poruchovosti díky častým preventivním opatřením a průběžným kontrolám. V případě zjištění blížící se poruchy jsou prováděny zásahy do zařízení, vedoucí k nápravě problému. Tyto zásahy (někdy jsou spojeny i s modernizací zařízení) mají často za následek krátkodobé zvýšení intenzity poruch (obr. 11).




Obr. 11: Vliv zásahu do zařízení (opravy) v průběhu na množství částic opotřebení [5]

2.2.4 Částice opotřebení v průběhu životního cyklu zařízení


V práci je pro pořizování a částečně i ověření tříd opotřebení testovaných částic využíván laserový analyzátor částic (LNF, podrobnosti jsou uvedeny v kap. 2.6.3). Jednou z jeho funkcí je schopnost zobrazení obrysu částic obsažených v oleji. Na následujících ukázkách (obr. 12–17) jsou demonstrovány změny především v počtu, velikosti a tvaru částic

objevujících se v oleji. Počet a vlastnosti částic opotřebení se v průběhu životního cyklu zařízení mění způsobem odpovídajícím průběhu vanové křivky.




Obr. 12: Životní cyklus zaznamenaný v ilustrativních ferrogramech

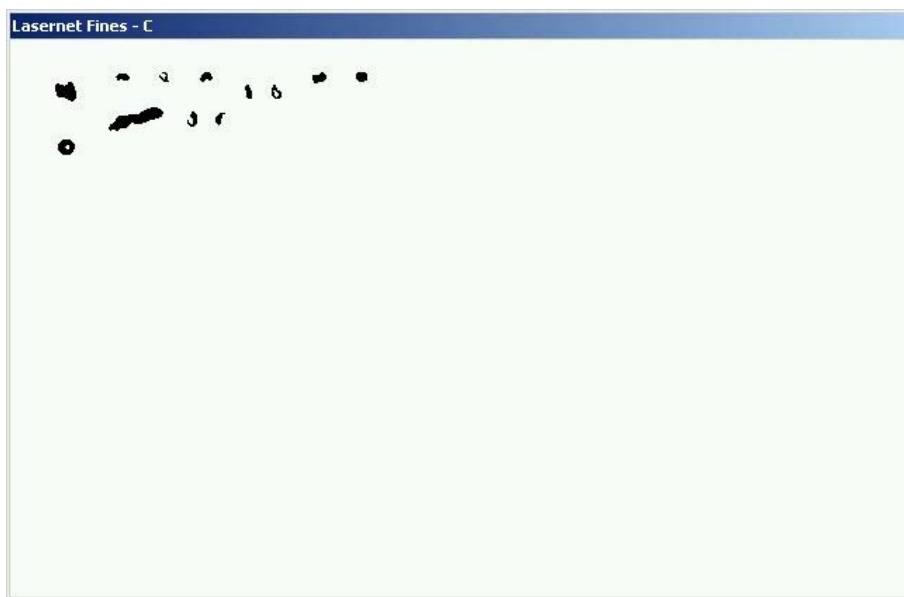
Na obr. 13–17 je demonstrováno, jakým způsobem se v průběhu životního cyklu zařízení mění počet a charakteristiky částic opotřebení. Ukázka je pouze ilustrativní, reálné počty a tvary částic se v jednotlivých případech mohou lišit v závislosti na stupni opotřebení konkrétního zařízení. Uvedené obrázky jsou pořízeny na přístroji LNF.




Obr. 13: Počáteční fáze provozu (záběh), motor v provozu 9 hodin




Obr. 14: Období stability, minimální opotřebení, motor v provozu 254 hodin



Obr. 15: Období stability, minimální opotřebení, motor v provozu 367 hodin



Obr. 16: Období stability, začínající opotřebení, motor v provozu 411 hodin



Obr. 17: Končící období stability, zvýšené opotřebení, motor v provozu 534 hodin

Jednou z metod, které jsou v praxi používány pro sledování průběhu opotřebení, je metoda analytické ferrografie, jejíž výstupem jsou tzv. ferrogramy – fólie nebo skleněné destičky, na kterých jsou zachyceny částice opotřebení získané z testovaných olejů. Mikroskopickou analýzou pořízených ferrogramů lze určit množství, velikosti a tvary částic opotřebení. Jejich vyhodnocením lze zjistit, jakým způsobem se mění vliv opotřebení v průběhu životního cyklu zařízení. Obdobný trend je patrný z obrázků 12–17.

V závěrečné fázi životního cyklu narůstá především množství únavových (fatigue) a kluzných (sliding) částic. Přesto, že často není možné zjistit zdrojové místo zařízení, kde částice vznikají a přesně tak odhalit místo poškození, je zvýšený výskyt částic motivem k podrobnější (např. ferrografické) analýze.

Protože je ferrografie jak časově, tak ekonomicky poměrně náročná metoda a v krátkých časových intervalech je pravidelná analýza vzorků téměř vyloučena, ukazuje se jako velmi výhodné použití vhodného automatického klasifikátoru částic alespoň pro zběžný přehled o stavu sledovaného zařízení. Vytvoření takového klasifikátoru je i cílem této práce.

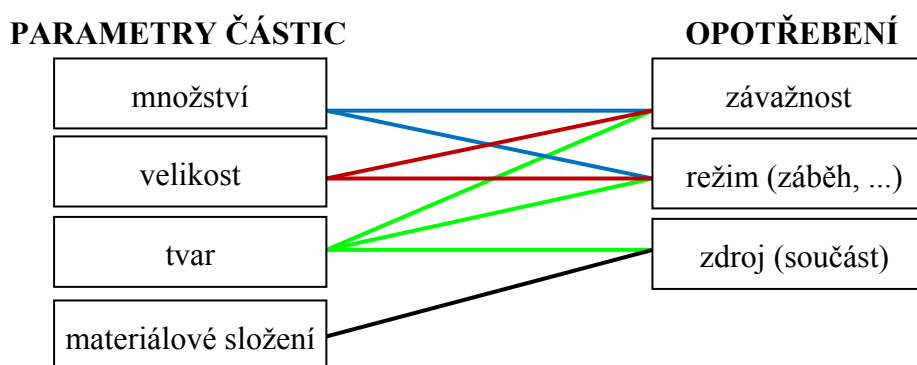
2.3 Současná metodika a možnosti tribodiagnostiky

Analýza částic opotřebení je jednou z mnoha technik diagnostiky mechanických systémů. Vychází z myšlenky, že pokud v systému dochází k nežádoucímu opotřebení, je jeho důsledkem uvolňování otěrových částic do mazací soustavy. Po zachycení těchto částic lze vhodnými metodami identifikovat rozsah, místo, závažnost, typ, případně další požadované atributy opotřebení.

Rozsah analýzy závisí na konkrétních požadavcích na testování. V praxi se nejčastěji objevují tyto testy zaměřené na určení:

- množství a velikosti částic,
- tvaru a odvozených parametrů částic,
- materiálového složení částic.

Užitečné informace, které lze vyvodit ze vztahu základních parametrů částic a charakteristiky opotřebení, jsou nastíněny na obr. 18. Za velmi důležitý je považován především tvar částic.



Obr. 18: Vztah základních parametrů částic a charakteristiky opotřebení [7]

2.3.1 Množství a velikost částic opotřebení




Závažnost opotřebení zařízení je při tomto typu testování dána především množstvím generovaných částic a jejich velikostí. Rychlý přehled lze získat gravimetrickou analýzou, jejímž výsledkem je celkové hmotnostní množství částic na jednotku množství maziva. Tato informace je pro podrobnější závěry příliš obecná, proto je většinou nutné zabývat se i počtem a velikostí částic.

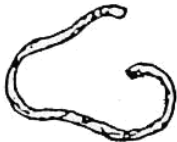
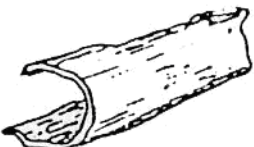

K určení množství částic v odebraném vzorku maziva je běžně využíván optický denzimetr, který však není schopen podat bližší informaci o tvaru či materiálovém složení jednotlivých částic. Přesto znalost množství uvolněných částic v mazivu vede společně se znalostí rozložení velikostí částic k dalším možným závěrům o zdroji a důvodu opotřebení.

Zatímco částice o minimální velikosti (do 10 μm) vznikají převážně mechanismem adhezivního opotřebení a nemají zásadní vliv na funkčnost zařízení, částice větší než 15 μm jsou příznakem nežádoucího opotřebení. Ani znalost velikostí jednotlivých částic není dostatečným důkazem k vyvození závěru o aktuálním stavu testovaného zařízení, proto v praxi následují další zkoušky zaměřené především na testování tvaru částic.

2.3.2 Tvar částic opotřebení

V případě potřeby podrobnějších výsledků vyplývajících z diagnostiky testovaného zařízení je většinou nutné separovat jednotlivé částice opotřebení, z jejichž morfologických parametrů lze následně vyvodit závěry o probíhajícím opotřebení. Typické částice charakterizující opotřebení mají některý z následujících zjednodušených tvarů (tab. 1):

Ukázka částice	Popis tvaru	Možný původ
	sférická částice	únava materiálu,
	plátek, nepravidelný, ostrý okraj	únava materiálu, pitting ložisek
	destička nebo lupínek, oblý okraj	záběh součástí

	závitek nebo spirála	abrazivní působení cizí částice či kontakt třecích ploch
	svitek	podobně jako destička, tvoří se ve formě svitku
	vlákno	polymery, bavlněné nebo papírové vlákno, ojediněle kov, část filtru

Tab. 1: Typické tvary částic opotřebení [7]

Vztah mezi tvarem částic a mechanismem opotřebení, který tyto částice generuje, lze zjednodušeně ukázat v tab. 2.

Typ částice	Popis
Adhezivní částice	Částice minimálních rozměrů (< 10 μm) o velmi malé (< 1 μm) tloušťce. Na ferrogramu vytvářejí charakteristické řetízky. Nemají zásadní vliv na funkčnost zařízení. Jejich přítomnost v mazivu je přirozeným jevem.
Řezné částice	Bývají nejčastěji projevem abrazivního opotřebení. Připomínají třísky, mohou vytvářet spirály.
Laminární částice	Tenké částice s nerovnoměrným okrajem, na povrchu bývají patrné trhliny.
Sférické částice	Drobné kulovité částice minimálního průměru vznikající působením cyklického zatěžování povrchu součásti.
Mezní částice	Abnormálně velké (> 50 μm) částice, jejichž povrch je charakteristicky zbrázděn. Jsou způsobeny kontaktem třecích ploch při nedostatečném mazání.
Nekovové částice	Vlákna filtrů (několikanásobně větší rozměry než výše uvedené částice), nečistoty, oxidy.

Tab. 2: Základní typy částic a jejich popis [7]

2.4 Princip a metodika analytické ferrografie

V experimentálních oborech souvisejících s hodnocením provozních hmot a konstrukčních materiálů používaných v dopravě lze velmi efektivně využít analýzu obrazu získaného prostřednictvím sestavy mikroskopu a digitálního fotoaparátu resp. kamery.

Z metod, které slouží k přípravě vzorku tak, aby bylo možné vytvořit kvalitní snímek otěrových částic v mazivu, byla pro potřeby této práce a následného výzkumu vybrána ferrografie. Jako jediná metoda umožňuje separovat jednotlivé částice ze vzorku. Dává možnost hodnotit vzorky odebrané z mazací soustavy globálně (díky rychlému přehledu separovaných částic na ferrogramu), případně je možné podrobně analyzovat i jednotlivé částice zvlášť.

2.4.1 Základní princip ferrografické metody

Ferrografie je tribodiagnostická metoda, založená na oddělení cizorodých částic obsažených v olejové náplni mazacích soustav strojů od vlastního oleje. Využívá sedimentace částic na speciální podložce (fólie, sklo) při průtoku vzorku oleje v silném nehomogenním magnetickém poli. V současnosti se v praxi používá jak její jednodušší varianta – přímočtená ferrografie, tak zejména analytická ferrografie.

Přímočtená ferrografie

Dává rychlý odhad množství otěrových částic ferromagnetických slitin kovů vyskytujících se ve vzorku oleje. Využívá sedimentace částic při průtoku vzorku oleje v silném nehomogenním magnetickém poli. Částice se usazují podle své velikosti, dělí se pak do dvou skupin, a to

- na tzv. „malé“ částice – menší než 15 μm , odpovídají normálnímu adhezivnímu opotřebení
- na tzv. „velké“ částice – větší než 15 μm , nárůst četnosti jejich zachycení je varovným příznakem blížící se poruchy dílů, omývaných olejem.

Metoda je založena na fotodenzimetrickém hodnocení optické hustoty vytvořené stopy (měří se v definované vzdálenosti od místa vtoku oleje na podložku – pro „velké“ částice ve vzdálenosti 57 mm, pro „malé“ částice 53 mm před místem, kde olej opouští hranu magnetu [9]).

Těsně před poruchou ložiska, ozubených kol apod. prudce roste četnost výskytu velkých otěrových částic [4].

Analytická ferrografie

Vypovídá o skutečném technickém stavu mazací soustavy a mazaných dílů i o způsobu opotřebení jednotlivých třecích dvojic. Mikroskopicky jsou hodnoceny jednotlivé částice.

2.4.2 Experimentální metodika

Příprava vzorku


Před počátkem ferrografické analýzy musí být vzorek oleje nejprve homogenizován, neboť za dobu uplynulou mezi jeho odběrem a analýzou již došlo k částečné či úplné sedimentaci částic na dno a adsorpci na stěny odběrné nádoby. Vzorek je potřebné ohřát na teplotu cca 65 až 70 °C a poté intenzivně protřepávat po dobu asi pěti minut [10].

Dalším krokem je ředění vzorku. Jeho účelem je dosažení vhodné viskozity roztoku oleje s ředidlem. Při správné viskozitě je v magnetickém poli ferrografu vytvářena rovnoměrně hustá stopa otěrových částic. Příliš viskózní olej brzdí částičky při jejich sestupu k povrchu podložní fólie (sklíčka), a proto není zachycena velká část otěrových částic. Naopak příliš nízkoviskózní roztok oleje s ředidlem vyvolává překrývání částic přes sebe, což ferrogram znehodnocuje.

Vhodným ředidlem je technický benzín dostatečné čistoty. Pro potřeby analytické ferrografie je zpravidla optimální poměr ředění cca 1 až 2 ml vzorku oleje ku 1 ml ředidla. Silně znečištěné oleje je potřeba před ředěním benzínem ještě naředit jemně přefiltrovaným olejem stejné značky [10].

Příprava ferrografické stopy

Postup přípravy ferrografické stopy závisí na druhu použitého ferrografu. Ferrografická analýza začíná magnetickou separací částic ze vzorku oleje, který musí být naředěn na optimální viskozitu. Na olej stékající po podložce (v této práci byla použita průhledná plastová fólie, v USA a Austrálii se používá podložka skleněná) působí jednak magnetomotorická síla, která zrychluje pohyb ve svislém směru, jednak viskozita kapalného prostředí, která brzdí klesání částice (obr. 19). Proměnlivá intenzita magnetického pole způsobuje usazování částic, které se nacházejí v oleji, v místě daném jejich velikostí a magnetickými vlastnostmi. Magnetická síla působící na částice je úměrná jejich objemu, brzdná síla prostředí je úměrná příčnému průřezu částice.



Obr. 19: Základní schéma metody analytické ferrografie

Rozmístění částic na ferrogramu

- nejhrubší sedimenty ferromagnetické, paramagnetické i diamagnetické se usazují na začátku stopy (místo vtoku), přičemž většina ferromagnetických (Fe, Co, Ni + jejich slitiny) částic se usazuje do pátého milimetru stopy (velké částice do 2. mm stopy, malé částice tvoří řetízky), podobně paramagnetické slitiny (Fe + Cr, Cu, Al, nerezové, rychlořezné, žárovevné oceli),
- paramagnetické a diamagnetické částice (Al, Cu a jejich slitiny – duraly, bronzy, Ag, Cr, Pb a jeho kompozice) leží mimo řetízky a mají odlišnou orientaci,
- nemagnetické částice leží podél celé stopy ferrogramu,
- na konci stopy jsou nahromaděny oxidy kovů, křemičitanů, vlákna filtračních materiálů.

Magnetické částice se tedy usazují, v závislosti na své velikosti, po celé délce ferrogramu v charakteristických řetízcích. Tyto řetízky se tvoří ve směru siločar magnetického pole, tudíž jsou kolmé na směr proudu oleje.

Nemagnetické částice se usazují náhodně po celé délce ferrografické stopy, často jsou zachyceny v řetízcích magnetických částic.

Vyhodnocení takto získaného ferrogramu umožňuje detailnější analýzu morfologie částic, jejich druhu, povrchu atd. pomocí speciálních mikroskopů. Na základě obrazové analýzy zachycených částic lze určit režim opotřebení mechanické soustavy (motoru, převodovky aj.).

2.5 Možnosti klasifikace částic opotřebení

Pomineme-li samotnou metodu analytické ferrografie, při které jsou ferrogramy vyhodnocovány „ručně“ proškoleným operátorem, současným trendem v oblasti tribodiagnostiky je snaha usnadnit klasifikaci částic pomocí poloautomatických či dokonce plně automatických systémů vyhodnocujících částice opotřebení. V odborné literatuře lze nalézt především několik návrhů, ale i popisů implementací systémů, které umožňují objektivní hodnocení ferrogramů [11].

Identifikace jednotlivých částic a jejich klasifikace do výše uvedených kategorií je v praxi prováděna dvěma způsoby založenými na obrazové analýze. Oba pracují na principu expertních systémů, kdy je nejprve vytvořena databáze vzorových částic a nové částice jsou klasifikovány na základě porovnání jejich vlastností s referenčními údaji v databázi. Kritickým bodem, na kterém závisí úspěšnost rozpoznávání částic, je vytvoření dostatečně rozsáhlé a zároveň kvalitně zpracované databáze vzorů.

Metody klasifikace částic se dělí na:

- metody vycházející přímo z obrazů částic,
- metody vycházející z analýzy morfologických parametrů částic, tzv. tvarových faktorů.

2.5.1 Klasifikace částic vycházející z jejich obrazů

Základem této metody je vytvoření databáze referenčních obrazů částic opotřebení obsahující jejich identifikaci (určení třídy opotřebení) prováděnou odborníkem. Na základě této databáze anotovaných obrazů částic je pomocí metod strojového učení (s učitelem) vytvořen klasifikátor. Z obrazů částic jsou extrahovány specifické příznaky, které umožňují dostatečně přesný popis obrazů. V průběhu trénování klasifikátoru jsou v obrazech částic tyto příznaky vyhodnocovány a následně jsou příznaky podobných hodnot vyhledávány v testovaných obrazech. V praxi se nejčastěji používají LBP nebo Haarovy příznaky (viz kap. 4.3.1, 4.3.2). Pokud jsou v testovaných obrazech odpovídající příznaky nalezeny, je výsledkem klasifikace zařazení dané částice do odpovídající třídy opotřebení.

2.5.2 Klasifikace částic na základě jejich morfologických parametrů

V průběhu analýzy je testováno šest základních parametrů:

- vnější tvar,
- detail hrany,
- povrch,
- barva,
- velikost, tloušťka.

Jednotlivé typy částic (adhezivní, řezné, laminární atd.) se vyznačují typickými hodnotami uvedených parametrů. Bližší popis morfologických parametrů uvádí tab. 3.

Parametr	Testované hodnoty
Vnější tvar	pravidelný nepravidelný oválný protáhlý
Detail hrany	hladký zubatý, pilovitý zakřivený
Povrch	hladký rýhovaný s důlky nebo otvory rozpraskaný vroubkovaný
Barva	jasná nevýrazná barevný odstín
Velikost (μm)	1–5 6–10 11–25 26–50 51–100 >100
Poměr plochy k tloušťce	1:1 1:2–1:5 1:6–1:20 1:21–1:40 >1:41

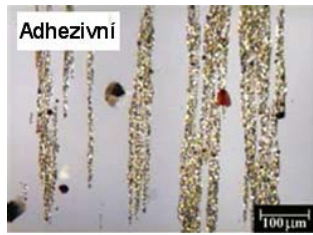
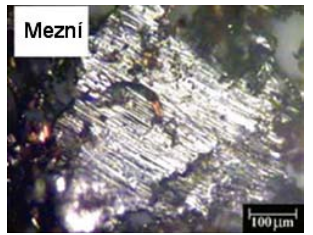
Tab. 3: Hodnoty parametrů pro morfologický popis částic [7]

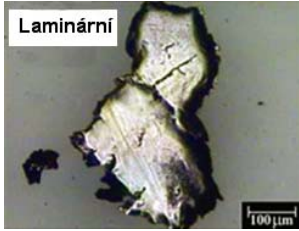
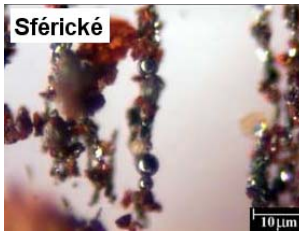


U vybraných typů částic jsou jednotlivé parametry určovány podle priorit uvedených v tab. 4.

	Částice	Priorita parametrů					
		1.	2.	3.	4.	5.	6.
Kovové částice	Adhezivní	Tvar	Povrch	Tloušťka	Hrana	Velikost	*
	Řezné	Tvar	Velikost	Povrch	Barva	Tloušťka	*
	Mezní	Povrch	Tvar	Velikost	Barva	Hrana	Tloušťka
	Sférické	Tvar	Povrch	Velikost	Barva	*	*
	Laminární	Tloušťka	Povrch	Velikost	Tvar	Barva	*
Nekovové částice		Barva	Povrch	Velikost	Tvar	*	*

Tab. 4: Priority parametrů podle typu částic [7]

Ukázka výsledků analýzy typických částic opotřebení je uvedena v tab. 5.

Parametry částic						
Tvar	Hrana	Povrch	Barva	Velikost (μm)	Plocha / tloušťka	Analyzovaná částice
-	-	-	-	1–5	-	
ADHEZIVNÍ ČÁSTICE						
Nepravidelný	Zubatá	Rýhovaný	Jasná	26–50	1:6–1:20	
MEZNÍ ČÁSTICE						

Nepravidelný	Zubatá	Rýhovaný, rozpraskaný, s otvory	Jasná	26–50	1:2–1:5	
LAMINÁRNÍ ČÁSTICE						
Pravidelný	Hladká	Hladký, rozpraskaný	Jasná	6–50	1:1	
SFÉRICKÉ ČÁSTICE						
Protáhlý	Zubatá	Rýhovaný, rozpraskaný	Jasná	51–100	1:21– 1:50	
ŘEZNÉ ČÁSTICE						
Protáhlý	Hladká	Hladký	Jasná	100 +	1:21 +	
NEKOVOVÉ ČÁSTICE (VLÁKNO FILTRU)						

Tab. 5: Ukázka identifikace částic opotřebení (použity obrázky z [6])

Uvedený postup je příliš obecný, je použitelný v teoretické rovině, ale nehodí se pro aplikaci v praxi. Pro implementaci klasifikátoru neposkytuje dostatečně přesnou definici parametrů částic, podle kterých by mohla být prováděna klasifikace.

Možností, která navazuje na analýzu morfologických parametrů částic, je metoda vycházející z tzv. tvarových faktorů. Jedná se o veličiny, které lze vypočítat pomocí osvědčených matematických vzorců, ve kterých figurují parametry částic. Mezi nejznámější patří:

- podle [11]:

$$D_A = 2\sqrt{\frac{\text{plocha}}{\pi}}, \quad \text{průměr ekvivalentního kruhu (kruh o stejné ploše jako částice)}$$

$$D_P = \frac{P}{\pi}, \quad \text{ekvivalentní kruh průměru } D_P, \text{ má stejný obvod jako částice}$$


$$S = \frac{\text{obvod}^2}{4\pi \cdot \text{plocha}}, \quad \text{kruhovitost, odchylka od kruhu. Výsledek je z intervalu } <0;1>, \\ \text{hodnota 1 odpovídá kruhu}$$

$$AR = \frac{\text{délka}}{\text{šířka}}, \quad \text{koeficient vzhledu}$$

$$Ch = \frac{1}{AR} = \frac{\text{délka}}{\text{šířka}}, \quad \text{mohutnost}$$


- podle [12]:

VFD, HFD (Vertical Feret's Diameter, Horizontal Feret's Diameter) – minimální vzdálenost dvou rovnoběžek ve vertikálním (horizontálním) směru, které neprotínají částici (obr. 20),



Obr. 20: Horizontální a vertikální feret [12]


GFD, LFD (Greatest Feret's Diameter, Least Feret's Diameter) – maximální (minimální) vzdálenost mezi dvěma rovnoběžkami ohraničujícími částici (obr. 21),



Obr. 21: Nejmenší a největší feret [12]

ECAD (Equivalent Circular Area Diameter) – průměr kruhu o stejné ploše jako má částice (obr. 22),


LBC (Least Bounding Circle) – průměr nejmenší opsané kružnice (obr. 22),



Obr. 22: ECAD, LBC [12]

CPM (Convex Perimeter) – konvexní obvod částice (obr. 23),

ECPD (Equivalent Circular Perimeter Diameter) – průměr kružnice o stejném obvodu jako má částice (obr. 23),



Obr. 23: CPM, ECPD [12]

VMD, HMD (Vertical Martin's Diameter, Horizontal Martin's Diameter) – délka vertikální (horizontální) úsečky, která dělí částici na poloviny (obr. 24),




Obr. 24: HMD, VMD [12]

LBRL, LBRW (Least Bounding Rectangle Length, Least Bounding Rectangle Width) – výška a šířka nejmenšího opsaného obdélníku (obr. 25),



Obr. 25: LBRL, LBRW [12]

FL, FW (Fibre Length, Fibre Width) – délka (šířka) obdélníku, který má stejnou plochu a délku jako částice (obr. 26).



Obr. 26: FL, FW [12]

2.5.3 Zhodnocení možných přístupů k automatické klasifikaci

Předpokladem úspěšné klasifikace je zejména nalezení vhodné sady tvarových faktorů, která by umožnila jednoznačně definovat jednotlivé třídy opotřebení. Tento předpoklad zatím nebyl úspěšně naplněn, ideální sada tvarových faktorů dosud nebyla specifikována. Jako perspektivnější a pro praxi reálnější se tak jeví možnost implementace klasifikátoru vycházejícího z obrazových dat.

V práci byly použity oba přístupy. Původní cíl práce spočívající ve vytvoření klasifikátoru částic, kterých by pracoval na principu vyhodnocení tvarových faktorů, se ukázal jako nevhodný pro implementaci kvůli problémům s přesnou definicí intervalů hodnot vybraných tvarových faktorů, které by ukazovaly na konkrétní opotřebení. Klasifikátor implementovaný v rámci této práce vychází z obrazů částic, jejichž analýzou jsou získány specifické příznaky, odpovídající třídám opotřebení, které byly při trénování klasifikátoru použity.

2.6 Technologie automatické klasifikace publikované v literatuře

K automatické klasifikaci částic opotřebení je nejčastěji využívána technologie neuronových sítí a dalších metod umělé inteligence vycházejících z metod strojového učení [13]–[15]. Jeden z přístupů ke klasifikaci částic využívá Fourierovu transformaci, která umožňuje dobře vyhodnotit odchylku od kruhovitosti, ale nehodí se k analýze částic s nepravidelnými okraji „nekruhovitého“ tvaru [16]. Při řešení je také někdy využívána matematika fraktálů či fuzzy logika [16].

V práci byly nejprve zkoumány možnosti využití tvarových faktorů pro klasifikaci částic, dosažené výsledky (kap. 3) ukázaly, že tato metoda v kombinaci s výstupy analytické ferrografie není ve srovnání s metodami použitými v práci přínosem.

Metoda odhadů tvarových faktorů a možnosti diskrétní Fourierovy transformace nebyly předmětem výzkumu v této práci.

V literatuře [1] jsou popsány i systémy využívající k analýze povrch částic, tato metoda je však pro použití v kombinaci s metodou analytické ferrografie nevhodná, protože v mnoha případech není textura povrchu částice dobře rozpoznatelná.

V současné době je známo několik přístupů vedoucích k více či méně přesným výsledkům klasifikace částic opotřebením. Každá metoda má určité nedostatky, jako nejefektivnější se nyní jeví využití zařízení LNF, výše popsané důvody ale omezují možnost jeho nasazení v běžné praxi.

2.6.1 Využití neuronových sítí v tribodiagnostice

V situacích, kdy selhávají klasické výpočetní postupy počítačů, přináší technologie neuronových sítí možnost modelovat chování lidského mozku, napodobení jeho schopností vlastního učení a dobře se vyrovnávat se změnou podmínek při hodnocení situace. Neuronové sítě si samy vytvářejí v průběhu učení vazby mezi vstupními a výstupními daty a tyto vazby potom aplikují v okamžiku nalezení „podobných“ vstupních dat při testování. Napodobují tak činnost lidského mozku v možnosti adaptace na různé změny v průběhu řešení či při změnách a velké různorodosti vstupních dat.

Neuronová síť využívá velkého množství vzájemně propojených prvků (neuronů). Jedná se o jednoduchou, samostatně pracující jednotku, která provádí předem definovanou operaci. Počet neuronů v síti se mění od několika jednotek až po desítky. Nejčastěji se používají neuronové sítě s větším počtem prvků rozložených do několika vrstev. První vrstva se označuje jako vstupní, následuje jedna nebo několik skrytých vrstev a vrstva výstupní. Úkolem vstupní vrstvy je příjem dat z vnějšího prostředí; tato data jsou ve vstupní vrstvě zpracována a předávána dále. Skrytá vrstva přijímá signál od předchozí vrstvy (vstupní nebo skrytá) a dále jej zpracovává podle použitého algoritmu. Její výsledek je předán do další vrstvy (skryté nebo výstupní). Výstupní vrstva zpracuje signály od předchozích vrstev, zpracuje je a převádí na výstup sítě. Uspořádání vrstev se liší v závislosti na charakteru sítě, jejím typu a požadovaném úkolu, který má plnit. Nejčastějším typem je vícevrstvá síť se

vstupní, s jednou nebo s několika skrytými vrstvami a s výstupní vrstvou. O neuronových sítích podrobněji pojednává kap. 4.2.2.

V současnosti jsou v tribodiagnostice využívány neuronové sítě ke klasifikaci částic opotřebených [13]. Nejčastěji jsou pro učení sítě použity vybrané morfologické parametry (tvarové faktory) částic. Ze stejného důvodu, proč není možné využít tvarové faktory ve ferrografii (nebyla zatím úspěšně definována taková sada tvarových faktorů, která by umožnila jednoznačně definovat tvary částic vybraných tříd opotřebených), jsou i pro použití za účelem trénování neuronové sítě příliš obecné a nedostačující pro přesnou klasifikaci, a proto také nejsou navržené systémy prozatím realizovány.

Řešení spočívá v nalezení specifických příznaků, které se objevují v závislosti na tvaru částice. Tyto příznaky mohou být hledány buď v samotných obrazech částic, anebo vycházejí z koeficientů diskrétní Fourierovy transformace popisujících detailní prvky tvaru okraje částice [17]. Tímto způsobem jsou dobře odlišitelné oválné tvary (sférické částice) od tvarů s výrazně nepravidelnými hranami, u nichž ale již nejsou dostatečně rozlišitelné tvary částic jako celku. Částice protáhlého pravidelného tvaru a částice nepravidelného tvaru s podobným okrajem jsou jen velmi obtížně rozlišitelné.

Zlepšení lze dosáhnout za cenu doplnění informací o povrchu (textuře) částic. V takovém případě je nutností zajistit velmi kvalitní a přesné obrazy částic (např. pomocí elektronové mikroskopie). Omezením je nutnost pořízení nákladného vybavení.

Z výše uvedených důvodů se pro automatickou klasifikaci částic jeví jako výhodnější obrazy částic, ve kterých jsou vyhledávány specifické příznaky potřebné pro učení neuronové sítě.

2.6.2 Příklady praktické aplikace neuronových sítí v tribodiagnostice

Systém sledování chodu motoru založený na neuronové síti poprvé využil koncern Ford u svých vozů Jaguar. Výsledky sledování jsou předávány řídicí jednotce motoru, která podle nich upravuje řízení zapalování. Princip spočívá v porovnávání přijímaného signálu úhlového zrychlení klikového hřídele a vzorů normálního chodu motoru. Neuronová síť byla zvolena pro lepší schopnost rozpoznávání nepravidelností ve snímaném signálu.

Neuronové sítě se využívají i v off-line diagnostice, tedy při přestávkách v používání. Příkladem může být systém vyvinutý pro potřeby armády USA k diagnostice tlumičů bojových vozidel Bradley během oprav a údržby. Systém sbírající data ze snímačů využívá

třívrstvé neuronové sítě, získaná data potom porovnává s obrazem ideálního chodu tlumiče pro dané vozidlo. Tento systém je případně konfigurovatelný pro libovolné jiné vozidlo.


Na využití neuronových sítí je také založen laserový analyzátor částic, zařízení využívané v této práci pro sběr dat pro trénování klasifikátoru. Jedná se o stolní přístroj, který slouží pro rozборы vzorků hydraulických a mazacích olejů z nejrůznějších typů strojních zařízení (nejnovější variantou praktické aplikace laserového analyzátoru je nasazení pro průběžné sledování stavu provozních kapalin ve velkokapacitních letadlech). Sledování je založeno především na morfologické analýze abnormálních otěrových částic pocházejících z interních částí stroje. Zařízení je schopno klasifikovat částice opotřebením podobným způsobem jako klasifikátor vytvořený v této práci. Podrobnosti jsou uvedeny v kap. 2.6.3.

Jedním z dílčích cílů této práce bylo posouzení a případné využití neuronových sítí při návrhu klasifikátoru.

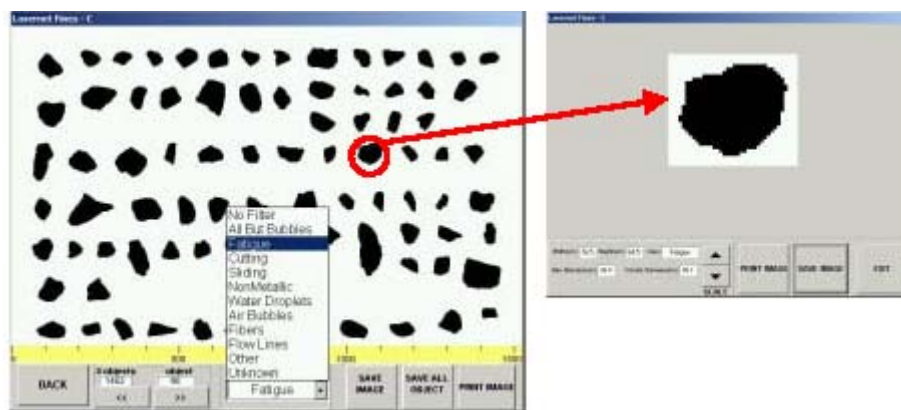
2.6.3 Laserový analyzátor částic jako praktická aplikace neuronových sítí

Praktickým výsledkem využití neuronových sítí v oblasti tribodiagnostiky je laserový analyzátor částic (LaserNet Fines, LNF). Jedná se o stolní přístroj, který slouží pro rozборы vzorků mazacích olejů z nejrůznějších typů strojních zařízení. Cílem je sledování a vyhodnocení pracovních podmínek daného strojního vybavení. Sledování je založeno především na morfologické analýze abnormálních otěrových částic pocházejících z interních částí stroje. Operátor získá informaci o částicích nalezených v odebraném vzorku kapaliny spolu s chronologickým přehledem předchozích výsledků týkajících se téhož zařízení. Doplňující informací je údaj o množství částic rozdělených do skupin podle velikosti (obr. 27).

Přístroj používá laserové technologie a pokročilý software pro identifikaci částic v mazivech. Je založen na technologii slučující laserové zobrazování a neuronovou síť pro charakterizaci otěrových a jiných částic kontaminujících mazivo. Z mazacího systému se odebere reprezentativní vzorek oleje k analýze. LNF čerpá zkoušený olej do tzv. měřicí cely, která je osvětlována impulsní laserovou diodou. Ta umožňuje vytvořit obrazovou dokumentaci. Obraz průběžně snímá videokamera se zvětšovací optikou. Ze snímků jsou získány tvary jednotlivých částic, které jsou analyzovány programem využívajícím neuronovou síť, který určí typ částic i jejich granulometrické rozdělení (obr. 28).



Obr. 27: Histogram rozložení velikostí částic ve vzorku



Obr. 28: Přehled jednotlivých identifikovaných částic (větších než 20 μm)

Přístroj tak do určité míry nahrazuje metodu analytické ferrografie. Výhodou je zjednodušení celého procesu analýzy, který při použití ferrografie sestává z přípravy vzorku (oleje), jehož zpracováním na ferrografu jsou získány ferrogramy, které jsou analyzovány pod mikroskopem. Aby nedošlo k překrytí částic, je pro každý ferrogram použito pouze minimální množství vzorku, zpravidla ředěného vhodným rozpouštědlem nebo čistým olejem.

Velikost ferrogramu je přibližně 60 × 5 mm. Protože je pro posouzení množství a tvaru částic nezbytné dostatečné zvětšení mikroskopu (pro získání globálního přehledu 40–250×, pro detailní zobrazení částic 400×), oblast ferrogramu určená k prozkoumání pod mikroskopem se značně zvětšuje a samotné vyhodnocení je tak závislé nejen na schopnostech operátora, ale je i časově náročné. Naproti tomu LNF analyzuje přímo samotný vzorek, který je postupně čerpán do měřicí cely a průběžně zpracováván. Analyzovaný vzorek je odebírán z přístroje v nezměněné podobě.

Z hlediska funkčnosti je přístroj LNF vhodný k analýze částic opotřebení. Jeho nevýhodou, která ale omezuje jeho praktické využití, je vysoká pořizovací cena a z důvodu netransparentnosti celého procesu hodnocení diskutabilní výsledky. Použité postupy a technologie nejsou zveřejněny. Přístroj je vyvíjen firmou Lockheed Martin, jejímiž zákazníci jsou téměř výhradně ministerstvo obrany USA, americké federální agentury a armády dalších států.

Při podrobnější analýze výsledků LNF lze v klasifikaci nalézt značné nepřesnosti (vychází z principu fungování neuronových sítí), nedostatečném rozlišení některých tříd opotřebení (především únavového a kluzného) a často nepřesnému zachycení tvaru jednotlivých částic. Využití přístroje LNF je nicméně určeno k opakovanému měření a sledování dlouhodobých trendů s cílem sledovat především množství a velikost částic opotřebení. Nepředpokládá podrobnou analýzu tvaru jednotlivých částic, ale zkoumá vzorek oleje spíše komplexně jako celek. Jedním z omezení je také maximální velikost analyzovaných částic, jejichž hlavní rozměr nepřesahuje 100 μm (větší částice jsou zachyceny filtrem přístroje – zabrání se tak ucpání měřicí kyvety).

2.6.4 Zhodnocení současného stavu problematiky

Dosavadní pokusy o automatizaci hodnocení částic opotřebení vychází především z analýzy tvarových faktorů. Předpokladem úspěšné klasifikace je zejména nalezení vhodné sady tvarových faktorů (veličin charakterizujících morfologické vlastnosti částic), která by umožnila jednoznačně definovat parametry částic odpovídajících jednotlivým třídám opotřebení. Tento předpoklad zatím nebyl úspěšně naplněn, ideální sada tvarových faktorů dosud nebyla specifikována.

Další rozšíření spočívá v nahrazení přesných hodnot tvarových faktorů odhady (přibližnými intervaly přípustných hodnot), které jsou vstupem neuronové sítě. Ve fázi učení neuronové sítě je využito větší množství správně klasifikovaných částic (získaných např. metodou analytické ferrografie), z nichž jsou vypočteny hodnoty tvarových faktorů. Ve fázi testování nových částic vyhledává neuronová síť parametry odpovídající naučeným hodnotám a s jejich využitím provádí klasifikaci. Praktickým příkladem uvedeného postupu je výše zmiňované zařízení LNF.

Uvažovanou alternativou je použití koeficientů diskrétní Fourierovy transformace vypočítaných z obrazů částic, které jsou poté společně s tvarovými faktory vstupem pro učení neuronové sítě.

Cílem této práce je navrhnout a implementovat alternativní metodu klasifikace částic vycházející z analytické ferrografie. V následující kapitole jsou popsány postupy, které byly v průběhu výzkumu realizovány a umožňují vylepšení tradičních metod. Jsou zde rovněž uvedeny podrobnější informace o realizaci metod automatické klasifikace.

3 Realizovaná vylepšení tradičních metod analýzy částic opotřebení

První experimenty [46] provedené v rámci práce, které měly za cíl vylepšení metody analytické ferrografie, vycházely z předpokladu, že se podaří vytvořit takovou sadu tvarových faktorů, jejíž definice umožní co nejpřesnější klasifikaci částic vybraných tříd opotřebení. Specifické tvary vyjádřené pomocí vybraných tvarových faktorů tak dosahují hodnot odpovídajících patřičnému opotřebení. Např. částice, jejíž hodnota kruhovitosti je nízká a naopak hodnota elongace (protážení = poměr maximálního a minimálního Feretova průměru) je vysoká, je s vysokou pravděpodobností částice řezného opotřebení. Pomocí hodnot dalších tvarových faktorů je možné s určitou pravděpodobností zařadit částice i do dalších tříd.

Na základě uvedeného předpokladu byl navržen a implementován systém [19], který pro zvolené částice vyhodnotí sadu vybraných tvarových faktorů a pokud získané hodnoty umožňují vyvodit konkrétní závěr, výstupem analýzy je informace o původu částice (jakému typu opotřebení odpovídá).

3.1 Obrazová analýza částic opotřebení vycházející z tvarových faktorů

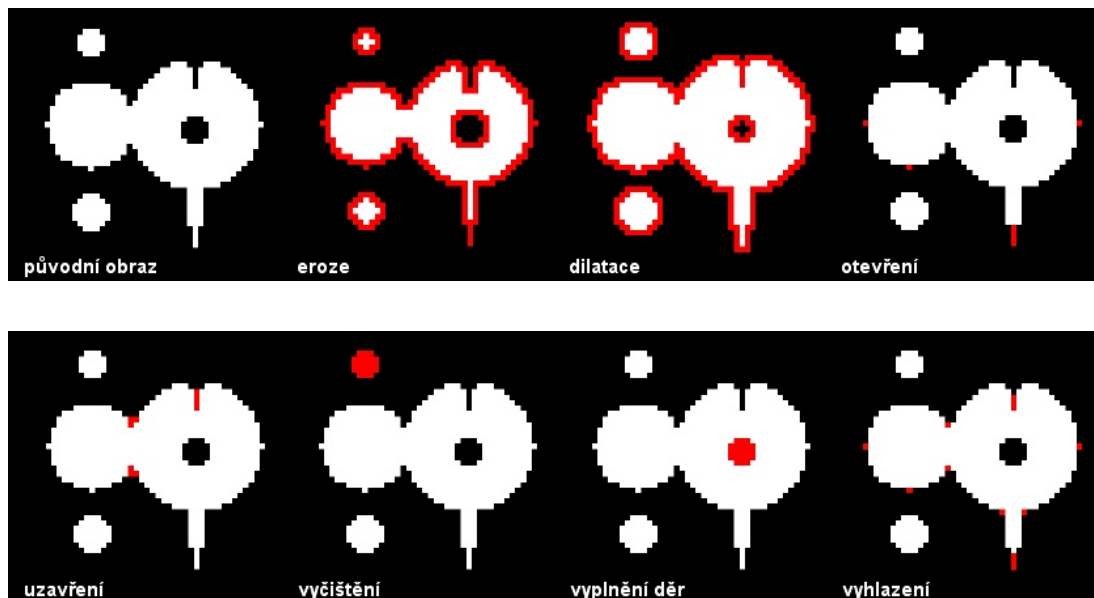
Jednou z možností obrazové analýzy ferrogramů je použití komerční aplikace LUCIA [18]. Ta umožňuje interaktivní a automatizovaná měření a archivaci rozsáhlých obrazových sekvencí. Aplikace je k analýze ferrogramů používána i na pracovišti autora, kterým je Dopravní fakulta Jana Pernera Univerzity Pardubice.

Pro práci s obrazy ferrogramů, spočívající v nalezení a segmentaci částic, jejich následném změření, výpočtu a vyhodnocování tvarových faktorů, analýze pokryté plochy, počtu objektů atd., je nejdůležitější co nejlépe segmentovat objekty, které budou podrobeny zkoumání. Tato část je v celém procesu obrazové analýzy stěžejní, a proto je k dispozici značné množství nástrojů. Hrubý výběr objektů se provádí podle jejich charakteristické barvy prahováním.

Po naprahování lze každý z vybraných objektů dále upravovat pro přesnější segmentaci jednotlivých tvarů (obr. 29). Zpracování binárních obrazů je úzce spjato s matematickou morfologií, nejčastěji s operacemi

- Eroze – objekty se po provedení eroze zmenší o nastavený počet pixelů, neboť se ubírá z jejich okrajů.

- Dilatace – po dilataci jsou objekty zvětšeny o nastavený počet pixelů, tj. k objektu je přidána „slupka“.
- Otevření – eroze následovaná dilatací; vyhlazuje kontury, maže malé objekty a rozpojuje částice spojené tenkou šňůrkou.
- Uzavření – dilatace následovaná erozí, vyhladí se obrysy, zaplní malé díry a zálivy.
- Vyčištění – nejprve eroduje obraz, takže malé objekty zmizí, poté jsou zbývající objekty rekonstruovány do jejich původní velikosti a tvaru.
- Vyplnění děr – zaplní díry uvnitř obrazu.
- Vyhlazení – celkové vyhlazení binárního obrazu, obraz je vyčištěn od malých objektů.




Obr. 29: Morfologické operace nad binárním obrazem, červeně jsou vyznačeny změny

Po provedení potřebných úprav lze přistoupit k obrazové analýze ferrogramu. Při vlastní analýze obrazu lze vyhodnocovat jednotlivé objekty v obraze samostatně nebo celou plochu obrazu najednou.


3.1.1 Ukázka použití programu

Původní obrázek ferrogramu (obr. 30), který je načten z digitálního fotoaparátu případně kamery propojené s mikroskopem, je kvůli lepší manipulaci nejprve převeden z barevného prostoru RGB do prostoru HSI.



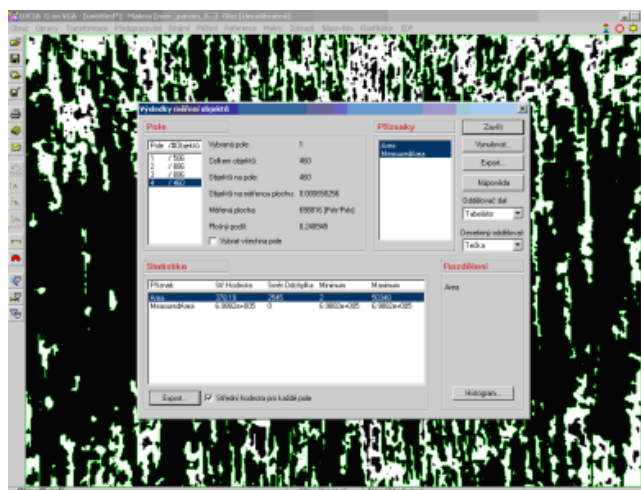
Obr. 30: Originál fotografie ferrogramu (vlevo) a fotografie v barevném prostoru HSI [19]

Poté je obraz třeba správně naprahotvat tak, aby byly pokryty všechny uvažované částice (obr. 31). Další úpravy je vhodné provádět v binárním zobrazení. Tvary částic je možné dále upravovat, aby co nejvíc odpovídaly skutečnosti (odstranění drobných nepřesností vzniklých např. digitalizací obrazu či separace překrývajících se částic).



Obr. 31: Naprahotvaný obraz (vlevo), po binarizaci (vpravo) [19]

Odpovídá-li naprahotvaný obraz dostatečně reálnému, je možno přistoupit k měření. Nejprve je potřeba vybrat příznaky pro měření. V uvedeném příkladě je zvolen příznak Area (měří plochu jednotlivých částic) a Measure Area (měří celkovou plochu částic v celém obraze). Vyhodnocení výpočtu je zobrazeno na obr. 32.



Obr. 32: Výsledky měření [19]


Výsledky měření:

Celkem objektů	460
Měřená plocha	698816 (μm^2)
Plošný podíl	24,89 %
Průměrná plocha objektů	378,19 (μm^2)
Minimální plocha	2 (μm^2)
Maximální plocha	50348 (μm^2)

3.1.2 Efektivní využití programu Lucia pro obrazovou analýzu

Pro rychlejší práci s programem Lucia bylo vytvořeno programové makro, které je dobře využitelné pro vzorky s jednotným pozadím a barvou sledovaných částic, u kterých se zjišťují stejné parametry.

Jako příklad použití je zde uveden snímek z ferrogramu – oblast ve vzdálenosti 45 mm od vtoku, pořízený při stonásobném zvětšení (obr. 33). U jednotlivých částic je měřena plocha, obvod a kruhovitost.




Obr. 33: Původní obraz (vlevo) a výsledky měření po segmentaci částic (vpravo) [19]


Po provedení příkazů v makru jsou všechny naprahované částice očíslovány a v dialogovém okně jsou uvedeny jejich naměřené a vypočtené hodnoty. Podobným způsobem je možné definovat libovolný počet tvarových faktorů, které jsou posléze vyhodnoceny.

3.1.3 Výsledky analýzy vybraných částic

Na následujících ukázkách je demonstrována funkčnost aplikace (obr. 34–36). Pro vybrané částice jsou změřeny jejich parametry a vypočteny potřebné tvarové faktory (tab. 6–8). Z jejich hodnot je odvozen závěr, jakému typu opotřebení daná částice odpovídá.



Obr. 34a) Fotografie části ferogramu po provedení morfologických úprav [19]




Obr. 34b) Výsledky vyhodnocení typu opotřebení pomocí programového makra [19]

Výsledky měření:


Měřeno objektů	1
Měřená plocha	15946 (μm^2)
Plošný podíl	19,64 %

č.	plocha [μm^2]	ekv.průměr [μm]	obvod [μm]	délka [μm]	šířka [μm]	max. feret [μm]	min. feret [μm]	kruhovitost	elongace
1	3058.37	62.4	425.17	197.07	15.52	164.82	34.98	0.21	4.71

Tab. 6: Datový výstup makra



Obr. 35a) Originální fotografie části ferrogramu (400x zvětšeno) [19]




Obr. 35b) Výsledky vyhodnocení typu opotřebení pomocí programového makra [19]

Výsledky měření:


Měřeno objektů 1
 Měřená plocha 719,72 (μm^2)
 Plošný podíl 41,52 %

č.	plocha [μm^2]	ekv.průměr [μm]	obvod [μm]	délka [μm]	šířka [μm]	max. feret [μm]	min. feret [μm]	kruhovitost	elongace
1	298.82	19.51	65.95	21.15	14.13	21.15	18.49	0.86	1.14

Tab. 7: Datový výstup makra



Obr. 36a) Originální fotografie části ferrogramu (100x zvětšeno) [19]



Obr. 36b) Obrázek po segmentaci částic [19]

Výsledky měření:

Měřeno objektů 29

Měřená plocha 881 810 (μm^2)

Plošný podíl 18,97 %

Měřený parametr	Průměr	St. odchylka	Min. odchylka	Max. odchylka
Area [μm^2]	4.72	10.77	8.07e-4	57.82
EqDiameter [μm]	1.76	1.71	0.03	8.58
Circularity	0.58	0.23	0.14	1.00
Elongation	1.59	0.39	1.00	2.88
MinFerret [μm]	1.62	1.63	0.03	7.90
MaxFerret [μm]	2.75	3.15	0.03	16.89

č.	plocha [μm^2]	ekv.průměr [μm]	obvod [μm]	délka [μm]	šířka [μm]	max. feret [μm]	min. feret [μm]	kruhovitost	elongace
1	2.17	1.66	9.52	4.25	0.51	3.17	1.42	0.3	2.22
2	8.2	3.23	17.9	7.91	1.04	4.78	2.89	0.32	1.66
3	1.87	1.54	7.9	3.4	0.55	2.93	1.02	0.38	2.88
4	0.68	0.93	3.4	1.07	0.63	1.29	0.74	0.73	1.75
5	0.14	0.43	1.47	0.52	0.28	0.52	0.42	0.83	1.23
6	0.49	0.79	3.62	1.48	0.33	1.25	0.77	0.47	1.63
7	8.07e-4	0.03	0.08	0.03	0.03	0.03	0.03	1	1
8	19.19	4.94	26.61	11.66	1.65	7.71	5.11	0.34	1.51

9	3.26	2.04	9.48	3.91	0.83	2.85	1.71	0.46	1.67
10	13.35	4.12	16.46	6.01	2.22	5.37	3.94	0.62	1.36
11	0.71	0.95	3.29	1.19	0.6	1.19	0.81	0.82	1.46
12	8.07e-4	0.03	0.08	0.03	0.03	0.03	0.03	1	1
13	0.11	0.38	1.26	0.48	0.23	0.48	0.35	0.87	1.36
14	0.29	0.61	2.16	0.6	0.48	0.78	0.57	0.78	1.38
15	0.73	0.96	4.09	1.59	0.46	1.44	0.77	0.55	1.87
16	0.77	0.99	3.53	0.97	0.8	1.29	0.83	0.78	1.55
17	2.14	1.65	7.99	3.36	0.64	2.46	1.76	0.42	1.4
18	1.86	1.54	7.82	3.36	0.55	2.43	1.61	0.38	1.51
19	57.82	8.58	71.81	34.21	1.69	16.89	7.9	0.14	2.14
20	10.83	3.71	19.47	8.46	1.28	5.51	3.64	0.36	1.51
21	0.52	0.82	4.52	2	0.26	1.63	0.74	0.32	2.19
22	0.72	0.96	3.55	1.15	0.63	1.15	0.97	0.72	1.19
23	1.36	1.32	4.8	1.48	0.92	1.62	1.26	0.74	1.29
24	4.14	2.3	10.24	4.11	1.01	3.48	1.89	0.5	1.84
25	0.65	0.91	3.36	1.08	0.6	1.15	0.88	0.72	1.31
26	3.82	2.21	12.96	5.82	0.66	3.79	1.92	0.29	1.97
27	0.81	1.01	3.72	1.17	0.69	1.29	0.96	0.73	1.34
28	2.66	1.84	8.03	3.17	0.84	2.69	1.71	0.52	1.58
29	2.15	1.65	7.51	3.05	0.7	2.48	1.44	0.48	1.72
30	0.28	0.59	2.09	0.71	0.38	0.71	0.6	0.79	1.2

Tab. 8: Datový výstup makra

3.2 Zhodnocení výsledků klasifikace částic vycházející z tvarových faktorů

Pro obrazovou analýzu ferrogramů byla použita aplikace LUCIA. Pro potřeby hromadné analýzy většího množství částic bylo vytvořeno makro umožňující individuální vyhodnocení všech vybraných částic vyskytujících se na ferrogramu (nebo jeho části). Samotnému vyhodnocení předchází příprava snímku, jejímž stěžejním bodem je segmentace částic. Tuto přípravu je nutné provádět v poloautomatickém režimu vzhledem ke značné variabilitě snímaných ferrogramů, rozdílnému barevnému podání a kontrastu snímku. V některých případech je nutné provést manuální úpravu tvaru částic, např. v případě jejich překrytí či nepřesné segmentaci částic.

Obrazová analýza ferrogramů, resp. jednotlivých částic ve ferrogramech obsažených, vycházející z výpočtu hodnot vybraných tvarových faktorů, potvrdila předpoklad, že částice některých tříd opotřebení (sférické částice únavového resp. částice řezného opotřebení) mají natolik specifické tvary, že je možné na základě výpočtu vybraných tvarových faktorů zařadit částici do odpovídající třídy opotřebení.

Celkové výsledky klasifikace dosažené v praktických testech však nebyly dostatečně přesné. Jako problém se zde jeví klasifikace především částic kluzného a únavového opotřebení, které jsou si svým tvarem v mnoha případech podobné a přesto patří do rozdílných tříd.

Při hodnocení výsledků analýzy tvarových faktorů je zřejmé, že jsou dobře rozpoznatelné částice řezného (cutting) opotřebení a sférické částice (sphere) únavového opotřebení, pro přesnou klasifikaci částic všech posuzovaných tříd opotřebení je ale tato metoda nedostačující a analýza sledovaných tvarových faktorů není vhodnou metodou pro klasifikaci částic. To ovšem neznamená, že pokud by se podařilo lépe specifikovat sadu tvarových faktorů, tzn. najít takové tvarové faktory, které by umožnily jednoznačnou klasifikaci problémových tříd sliding (kluzné) a fatigue (únavové), že by tato metoda nemohla být úspěšná.

Výsledky této práce, které vyplynuly z výzkumu možností využití tvarových faktorů pro klasifikaci částic opotřebení, ukázaly, že metody klasifikace vycházející z tvarových faktorů nejsou dostatečně průkazné – neuspokojivé výsledky vedly ke zvážení alternativních metod klasifikace. Myšlenkou, na které je postaven další výzkum, je klasifikace částic vycházející z analýzy obrazů částic. Je tak vynechán komplikovaný krok výběru vhodných tvarových faktorů, analyzovány jsou samotné obrazy částic. Protože není možné vytvořit dostatečně přesné deskriptory částic, které by byly pro klasifikaci použitelné, dalším logickým krokem bylo využít pro klasifikaci metody strojového učení.

4 Možnosti metod strojového učení v oblasti automatické klasifikace částic opotřebením

Techniky strojového učení (machine learning) jsou metody, které v oblasti klasifikace částic opotřebením, umožňují vytvářet z trénovací množiny dat (v této práci obrazů částic opotřebením) model pro klasifikační třídy (jednotlivé typy opotřebením) tak, že nové případy určené k vyhodnocení mohou být zařazeny (klasifikovány) do jedné nebo více tříd odpovídajících modelu.

Moderní metody aplikované umělé inteligence, jejíž jsou metody strojového učení součástí, umožňují vyhledávat na první pohled skryté znalosti i ve velmi složitých, rozsáhlých mnohazměrných datech, majících formu binární, obrazovou i numerickou. Znalost je automatizovaně získávána generalizací informace obsažené v datech prostřednictvím řízeného nebo neřízeného učení pomocí vhodného algoritmu metodou indukce z trénovacích vzorů dat.

4.1 Princip a použití klasifikátorů

Proces klasifikace objektů ve smyslu jejich zařazování do tříd spočívá v přiřazení objektu popsaného pomocí vybraných příznaků odpovídající třídě. Správné nastavení klasifikátoru pak spočívá v řešení úlohy, jak vzorová data popsaná příznaky přiřadit s co nejvyšší přesností odpovídající třídě. [20]

4.1.1 Metody výběru trénovacích dat

Základním krokem je rozdělení dat na trénovací a testovací. Trénovací množina slouží k nastavení (natrénování) klasifikátoru a testovací množina k otestování, jak úspěšně byl klasifikátor nastaven (natrénován).

Za účelem vhodného rozdělení dat na trénovací a testovací, nalezení optimálních hodnot parametrů použitých při trénování klasifikátoru a k testování přesnosti klasifikace je často používána metoda cross-validation (cross-validace).

Cross-validace je metoda, při které jsou data náhodně rozdělena do S množin, z nichž je vždy jedna vybrána jako testovací a ostatní slouží k trénování. V S iteracích jsou postupně vyzkoušeny všechny kombinace. Výsledkem této metody je procentuálně vyjádřená úspěšnost správně klasifikovaných dat. V případě, že by výsledek předchozí iterace byl lepší než výsledek aktuální iterace, dochází k přetrénování klasifikátoru. Výhodou cross-validace je minimalizace (odstranění) tohoto nežádoucího jevu; s rostoucím množstvím trénovacích dat

roste i úspěšnost klasifikace. Vzhledem k tomu, že se test vždy provádí na nezávislých datech, lze považovat i naměřené hodnoty za nezávislé.

4.1.2 Trénování klasifikátorů

Možné jsou dva hlavní přístupy – buď naučit klasifikátor rozpoznávat vzorky na základě databáze známých případů vytvořené expertem řešícím danou problematiku (učení s učitelem, supervised learning), anebo využít přímo dostupná (měřitelná) data o klasifikovaných objektech a na jejich základě klasifikátor nastavit (učení bez učitele, unsupervised learning). Častější je využití učení s učitelem, které v praxi odpovídá situaci, kdy jsou k dispozici vzorky dat, o nichž je známo, jak mají být klasifikovány; jejich postupným zpracováním se klasifikátor učí poznávat odpovídající třídu pro neznámá data. Učení není nikdy úplně dokonalé, prakticky není možné pokrýt vzorovými daty všechny možnosti vstupu, kvalita (přesnost) klasifikace je vždy do značné míry závislá na kvalitě a množství trénovacích vzorků. Krokem, který následuje po trénování klasifikátoru, je jeho otestování na další sadě dat. I v tomto případě je pro všechny testované objekty dáno, do jakých tříd mají být zařazeny. Porovnáním s výsledky klasifikace lze zjistit přesnost (chybovost) klasifikátoru. Při trénování se s použitím co nejlepších trénovacích dat snažíme tuto chybu minimalizovat. Platí, že se snižující se chybou roste komplexnost klasifikátoru a tady i čas potřebný pro jeho trénování a vyhodnocení. Jednodušší klasifikátory mají na druhou stranu chybu vyšší. Výhodou metod učení bez učitele je, že nepotřebují předem anotovaná data, klasifikace je prováděna na základě vzájemné podobnosti objektů patřících do stejné třídy.

4.1.3 Klasifikace vstupních dat

Klasifikace (v tomto případě obrazových) dat je v problematice rozpoznávání objektů proces, při kterém je s určitou pravděpodobností objekt zařazen do jedné ze dvou, případně více definovaných tříd. Tuto operaci provádí klasifikátor (realizující algoritmus, který objekty zařazuje do tříd). Klasifikátor se snaží zjistit obtížně pozorovatelné, resp. obtížně měřitelné vlastnosti objektů na základě pozorovatelných (měřitelných) vlastností a učinit rozhodnutí o příslušnosti objektů ke správné třídě. Klasifikaci lze rozdělit na [20]

- binární – výsledkem je rozhodnutí, jestli daný objekt patří nebo nepatří do sledované třídy,
- vícehodnotovou – výsledkem jsou hodnoty představující pravděpodobnost úspěšného zařazení objektu do jedné ze sledovaných tříd.

Klasifikátory nejčastěji vyhodnocují vektor tzv. příznaků. Jedná se o určité elementární popisy vybrané části dat (v tomto případě obrazu částice), jejichž vyhodnocením lze zjistit, jestli testovaný objekt (částice) patří do hledané třídy či nikoliv. Objekty, které mají být klasifikovány, jsou nejprve vhodně popsány. To znamená, že na klasifikovaných objektech je vybrána množina příznaků, jejichž způsob získávání je apriorně znám. Všechny příznaky, kterými je popisován objekt, lze uspořádat do tzv. vektoru příznaků. Prostor všech těchto vektorů se nazývá příznakový prostor. Klasifikátor tedy zobrazuje příznakový prostor objektů na množinu indikátorů tříd. Vstupem klasifikátoru jsou vektory vybraných příznaků, výstupem je hodnota, podle které jsou klasifikované objekty zařazovány do tříd.

V současnosti neexistuje jednoznačná rada, podle které by bylo možné rozhodnout, jaké vybrat pro konkrétní objekty příznaky, které by umožnily maximální přesnost klasifikace. Volba vhodných příznaků je individuální pro každý klasifikátor; ideální je zvolit použité příznaky na základě konzultace s odborníkem na danou problematiku, pro kterou bude klasifikátor použit. Teoreticky by bylo možné problém volby vhodných příznaků zjednodušit tak, že z klasifikovaných objektů získáme měřením či výpočty všechny představitelné parametry. Myšlenka, že čím více příznaků objektu bude změřeno, tím více informací bude mít klasifikátor k dispozici pro rozhodování a tím přesněji bude rozhodovat, je v praxi nereálná. Resp. myšlenka není zcela nesprávná, ale složitost realizace klasifikátorů s rostoucím počtem příznaků výrazně narůstá.


4.1.4 Určování chyby klasifikátorů

Předpokladem pro vyhodnocení funkčnosti klasifikátoru a zjištění jeho přesnosti je sada vzorových testovacích dat, jejíž součástí je informace, do jaké třídy každý klasifikovaný objekt patří. Tato sada je podobně jako sada určená pro trénování klasifikátoru nejčastěji hodnocena expertem. Obě sady musí být rozdílné, nemá smysl testovat klasifikátor na stejných datech, na jakých byl natrénován. Pokud známe počty testovaných objektů a jejich rozdělení do klasifikačních tříd a zároveň po testování zjistíme, jak byly klasifikovány jednotlivé objekty, lze snadno zjistit, jak byly klasifikovány konkrétní objekty. Z výsledků lze zjistit, kolik a jakých chyb klasifikátor udělal.

Sledujeme čtyři důležité hodnoty udávající chyby v klasifikaci (obr. 37) [43]:

- false positive (FP) – nesprávně klasifikované pozitivní případy, objekt patří do klasifikované třídy, ale není do ní klasifikátorem zařazen,

- false negative (FN) – nesprávně klasifikované negativní případy, objekt nepatří do klasifikované třídy, přesto je do ní klasifikátorem zařazen,
- true positive (TP) – správně klasifikované pozitivní případy, objekt patřící do klasifikované třídy je správně do třídy zařazen,
- true negative (TN) – správně klasifikované negativní případy, objekt, který nepatří do klasifikované třídy, do ní není zařazen (správně).



Obr. 37: Vyjádření správných a chybných rozhodnutí klasifikátoru

Tyto hodnoty je možné vypočítat ze vztahů:

$$FP = \sum_i H(x_i) \neq y_i, \quad y_i = +1 \quad (1)$$

$$FN = \sum_i H(x_i) \neq y_i, \quad y_i = -1 \quad (2)$$

$$TP = \sum_i H(x_i) = y_i, \quad y_i = +1 \quad (3)$$


$$TN = \sum_i H(x_i) = y_i, \quad y_i = -1 \quad (4)$$

kde $H(x)$ je klasifikační funkce, x_i vzorek a y_i jeho ohodnocení. Z těchto hodnot lze vypočítat chybu klasifikace, která vyjadřuje poměr chybně klasifikovaných objektů k celkovému počtu objektů, přičemž nezáleží na typu chyby. Chyba by se měla vyhodnocovat na vzorku dat, který je typický pro nasazení klasifikátoru.

$$chyba = \frac{FP + FN}{FP + FN + TP + TN} \quad (5)$$

Aby bylo možné výsledky kvantifikovat a porovnat přesnost klasifikace při rozdílném nastavení parametrů normalizace, jsou výsledky testů znázorněny formou ROC křivek

(Receiver Operating Characteristic), kterými lze vyjádřit a graficky znázornit hodnocení chování a přesnost klasifikátorů při klasifikaci do dvou tříd [44]. Křivka vyjadřuje závislost míry true positives na false negatives při různých nastaveních klasifikátoru (obr. 38). Osa x představuje pravděpodobnost špatného zařazení objektů, které ve skutečnosti nepatří do klasifikované třídy (false negative). Na ose y jsou vyneseny hodnoty pravděpodobnosti správného zařazení objektů, které patří do klasifikované třídy (true positive).



Obr. 38: Obecný průběh ROC křivky

ROC křivka vždy prochází počátečním bodem grafu. Křivka je mezi těmito body vždy neklesající. Pokud klasifikátor zařadí všechny objekty správně, tzn. obě chyby (false positive, false negative) budou nulové, ROC křivka kopíruje okraj grafu, z bodu $[0,0]$ do bodu $[0,1]$ a následně do bodu $[1,1]$. Pokud se pravděpodobnost správné klasifikace objektů patřících do klasifikované třídy blíží pravděpodobnosti chybné klasifikace objektů mimo klasifikovanou třídu, ROC křivka se přibližuje diagonále. Pokud ROC křivka splývá s diagonálou, znamená to, že objekty jsou zařazovány do tříd náhodně a ne v závislosti na zjištěných příznacích, trénování klasifikátoru tak na výsledné rozhodnutí nemá vliv. Vhodně zvolené příznaky a metody, podle kterých jsou objekty klasifikovány, vedou k přibližování průběhu křivky ideální situaci, která je ale v praktických aplikacích nedosažitelná.

Pro diskrétní klasifikátory platí, že jejich výsledky jsou charakterizovány jedním bodem grafu. Klasifikátory, jejichž výsledné body se objevují v levé části grafu poblíž osy x , jsou označovány jako „konzervativní“ – při nízké chybě klasifikace false negative je zároveň nízká i úspěšnost true positive, tzn., že klasifikátor dobře rozpozná objekty, které nepatří do

klasifikované třídy, ale má tendenci vyřadit i správné objekty. Naproti tomu klasifikátory, jejichž výsledky jsou v pravém horním rohu, se nazývají „liberální“ – většinu pozitivních objektů klasifikují správně, zároveň mají ale i vysokou chybu false negative, tzn., že klasifikátor má tendenci zařadit do klasifikované třídy i objekty, které do ní nepatří. Rozhodnutí, která z obou variant je výhodnější, záleží na vyhodnocení problému, který z negativních jevů je v praxi přijatelnější.

4.2 Metody strojového učení

Z metod strojového učení, které byly zkoumány z hlediska jejich využití pro potřeby této práce a které by v oblasti tribodiagnostiky mohly výrazně usnadnit proces klasifikace částic, byly jako vhodné vybrány následující metody. Byly zvažovány především metody učení s učitelem, protože vstupem pro trénování klasifikátoru byly částice, které byly nejprve expertem zařazeny do správných tříd.

Z metod učení bez učitele byla vybrána třída metod shlukové analýzy (cluster analysis).

Z metod učení s učitelem byly vybrány

- neuronové sítě (neural networks),
- metoda podpůrných vektorů (Support Vector Machines),
- metoda spojování klasifikátorů (boosting) a její konkrétní realizace
 - metoda AdaBoost (Adaptive Boosting),
 - metoda WaldBoost (podle A. Walda).

4.2.1 Metoda shlukové analýzy

Metoda shlukové analýzy [22] slouží k třídění vstupních dat do skupin (shluků, clusterů) tak, aby si objekty náležející do stejné skupiny byly podobnější než objekty ze skupin různých. Shlukovou analýzu je možné provádět jak na množině objektů, z nichž každý musí být popsán prostřednictvím stejného souboru znaků, které má smysl v dané množině sledovat, tak na množině znaků, které jsou charakterizovány prostřednictvím určitého souboru objektů, nositelů těchto znaků. V případě analýzy částic opotřebení připadá v úvahu použít jako vstupní data obrazy částic. Ze stejného důvodu, jako byla zavržena analýza hodnot tvarových faktorů pro účely kvantitativního popisu částic, nejsou tvarové faktory samy o sobě vhodné ani jako vstupní data pro metodu shlukové analýzy a další metody umělé inteligence a strojového učení.

Shluková analýza vychází z podobnosti resp. vzdálenosti objektů. Její kvantitativní vyjádření je jedním ze základních problémů shlukové analýzy. Nejčastěji používanou metrikou je eukleidovská vzdálenost, existuje ale řada dalších způsobů měření vzdálenosti či podobnosti objektů. Někdy je způsob hodnocení přímo dán shlukovací metodou. Pokud tomu tak není, je třeba při výběru ukazatele brát v úvahu metodu shlukování a charakter souboru.

Mezi základní metody shlukování patří

- metoda nejbližšího souseda – vzdálenost shluků je dána vzdáleností dvou nejbližších objektů z různých shluků. Při použití této metody jsou výsledkem dlouhé řetězce,
- metoda nejvzdálenějšího souseda – vzdálenost shluků je dána naopak vzdáleností dvou nejvzdálenějších objektů z různých shluků. Metoda je výhodná především v případě, kdy objekty tvoří přirozeně oddělené shluky, nehodí se, pokud se projevuje tendence k řetězení,
- centroidní metoda – vzdálenost shluků je určována vzdáleností jejich center (hypotetická jednotka s průměrnými hodnotami znaků). Může být nevážená, nebo vážená (ta zohledňuje velikosti shluků a hodí se, pokud očekáváme jejich rozdílnost),
- párová vzdálenost – vzdálenost shluků je určována jako průměr vzdáleností všech párů objektů z různých shluků. Opět může být ve vážené i nevážené podobě.
- Wardova metoda – vychází z analýzy rozptylu. Vybírá takové shluky ke sloučení, kde je minimální součet čtverců. Obecně lze konstatovat, že je tato metoda velmi účinná, ale má tendenci tvořit poměrně malé shluky.

Při volbě metod použitých při implementaci klasifikátoru byla nicméně metoda shlukové analýzy vyhodnocena jako nepříliš vhodná, resp. další metody lépe odpovídají potřebám klasifikace částic opotřeбенí.

4.2.2 Neuronové sítě

Na prvním místě jsou uvedeny neuronové sítě, které jsou využívány ve většině nástrojů, využívaných v současnosti pro klasifikaci částic opotřeбенí. Na principu neuronových sítí pracuje i aktuálně nejmodernější nástroj – laserový analyzátor částic. V literatuře lze nalézt popisy systémů využívajících pro klasifikaci neuronových sítí, které vyhledávají trénovací vzory jak mezi hodnotami tvarových faktorů, tak v obrazech částic [4].

Pro diagnostiku zařízení obecně jsou neuronové sítě přínosné zejména z hlediska možnosti přímého sledování velkého množství parametrů v reálném čase. Oproti konvenčním počítačům také lépe zpracovávají proměnné veličiny vyjádřené okamžitým průběhem, charakteristikou nebo spektrem.


Prvním předpokladem úspěšného vývoje systému založeného na neuronové síti je možnost vyhledání vhodných trénovacích vzorů v obrazech částic. Protože v tomto případě jsou částice klasifikovatelné do tříd podle svého tvaru, lze předpokládat, že tvary částic resp. specifické příznaky, které mohou být v obrazech částic nalezeny, jsou vhodným prvkem pro učení neuronové sítě.

Dalším krokem je volba vhodného typu, topologie a celkového uspořádání neuronové sítě. Tyto parametry sítě se mohou v dalším průběhu práce ještě měnit, první navržené uspořádání nemusí být definitivní.

Důležitým procesem, který má hlavní vliv na kvalitu výsledků, je učení sítě s využitím obrazů částic, resp. příznaků z těchto obrazů získaných. Výsledkem procesu učení je schopnost neuronové sítě zařadit vstupní data odpovídající trénovacím datům do odpovídající třídy.

Základním stavebním prvkem neuronové sítě je neuron (obr. 39). Neuron představuje jednoduchou funkci provádějící skalární součin vektoru svých vstupů a vektoru vstupních vah. Výsledná hodnota je nakonec transformována výstupní (aktivační) funkcí. Při trénování neuronové sítě se provádí nastavení vah vektoru u každého neuronu tak, aby síť jako celek prováděla požadovanou funkci.

Výstupní hodnota neuronu je definována vektorem vstupů, vektorem vah a výstupní funkcí y .

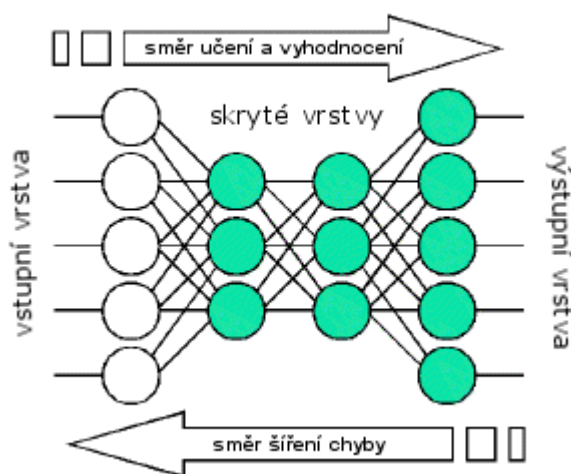


Obr. 39: Schematický model neuronu se vstupy x_0 až x_n a výstupní funkcí y


Rozdělení neuronové sítě do více vrstev (vstupní, skryté, výstupní) umožňuje rozdělit simulaci složitějšího procesu do několika procesů jednodušších. V závislosti na způsobu šíření informace je možné rozdělit neuronové sítě do dvou kategorií.

- Dopředné (feed-forward) – signál se šíří pouze přímo od vstupních neuronů přes skryté k výstupním neuronům (obr. 40a), síť neobsahuje žádné smyčky. Jako učící algoritmus používá zpětné šíření chyby (backpropagation), kdy se po porovnání skutečného výstupu s očekávaným upravují nejvíce váhy v poslední vrstvě, poté v předposlední vrstvě atd.
- Rekurentní (recurrent) – signál se může pohybovat prakticky všemi směry (obr. 40b). Může tak obsahovat i zpětné vazby a smyčky. Speciálním případem je Hopfieldova síť, ve které jsou neurony propojeny navzájem každý s každým. Tato síť je vhodná pro úlohy rozpoznávání.

V našem případě je výhodnější použít dopřednou síť se zpětným šířením chyby. Algoritmus pracuje následujícím způsobem [21]. Na vstupní vrstvu jsou vkládány vzorky trénovacích dat a výstup sítě se porovnává s požadovaným výstupem. V každém výstupním neuronu se vypočítá lokální chyba. Nastavením vstupních vah neuronu se chyba minimalizuje – tímto se zvyšuje chyba neuronů v předchozí vrstvě. Postup se opakuje postupně s neurony předchozích vrstev, dokud se nedojde ke vstupní vrstvě. Průběžně jsou upravovány váhy jednotlivých neuronů tak, aby byla chyba učení minimální.



Obr. 40a) Vícevrstvá dopředná neuronová síť



Obr. 40b) Hopfieldova rekurentní neuronová síť


4.2.3 Metoda podpůrných vektorů

Řada metod strojového učení se vyznačuje jednoduchými a efektivními algoritmy učení. Z hlediska řešení obecné úlohy, kdy je zapotřebí najít hranice, které oddělují určité třídy ve vstupním prostoru dat, mohou být omezeny schopnosti lineárních klasifikátorů (používají pouze lineární oddělovače, jednotlivé třídy lze jasně oddělit pouze přímkou, rovinou).


K alternativám, pomocí kterých je možné tento problém vyřešit, patří metoda podpůrných vektorů (Support Vector Machines, SVM) [24], která patří do kategorie tzv. jádrových algoritmů (kernel machines). Tyto metody se snaží využít výhody poskytované efektivními algoritmy pro nalezení lineární hranice a zároveň jsou schopny reprezentovat vysoce složité nelineární funkce. Jedním z principů je převod původního vstupního prostoru do jiného, vícedimensionálního, kde již lze od sebe oddělit jednotlivé třídy lineárně.

Příklad použití je zobrazen na obr. 41a. Klasifikované objekty patří do třídy modré nebo do třídy červené. Jakýkoli jiný objekt, který by byl na pravé straně, by byl klasifikován jako modrý, pokud by ležel na levé straně, byl by klasifikován jako červený.

Uvedený příklad [24] je typickou ukázkou lineárního klasifikátoru, tj. klasifikátoru, který rozděluje vstupní objekty na dvě skupiny (modrá a červená třída) pomocí přímky. Většina klasifikačních úloh však není tak jednoduchá, aby bylo možné provést tak jednoduché rozdělení. Často je zapotřebí použít složitějších dělicích prvků tak, aby došlo k ideální separaci, tj. ke správné klasifikaci testovaných objektů. O správném rozdělení je rozhodnuto na základě zařazení známých (trénovacích) objektů. Tato situace je znázorněna na obrázku 41b. Ve srovnání s příkladem 41a je zřejmé, že úplné oddělení na modré a červené objekty vyžaduje použití křivky jako oddělovače, což je mnohem složitější než použití přímky. Alternativním postupem je nahrazení nelinearity příznaky; toto řešení je v práci využito. Klasifikační úlohy založené na kreslení dělicí čáry pro rozlišení mezi objekty z různých tříd jsou známé jako nadrovinové klasifikátory. Metoda podpůrných vektorů je vhodná pro řešení podobných úkolů.




Obr. 41a) Příklad lineární klasifikace [24]



Obr. 41b) Klasifikace reálné situace [24]

Obr. 42 demonstruje základní myšlenku metody podpůrných vektorů. Původní objekty (vlevo) jsou přeskupeny pomocí matematických funkcí známých jako jádra (kernels). Proces tohoto přeskupení se označuje jako mapování (transformace). V novém uspořádání lze mapované objekty (vpravo) lineárně oddělit, stačí tak místo původně zvažované křivky najít optimální přímku, která dokáže oddělit objekty modré a červené třídy.



Obr. 42: Mapování klasifikovaných objektů v rámci SVM [24]

Metoda je často využívána v aplikacích pro vyhledávání obrazu. V této práci nejsou jednotlivé třídy klasifikace navzájem disjunktní, nelze definovat jednoznačné hranice mezi třídami. Navíc vstupem klasifikátoru jsou již samotné segmentované obrazy jednotlivých částic, tudíž tato metoda není pro nasazení v řešeném problému vhodná.

4.2.4 Metody spojování klasifikátorů

Cílem metod spojování klasifikátorů (boosting) [32] je zlepšení klasifikační přesnosti libovolného klasifikátoru tak, že vhodnou kombinací více klasifikátorů (tzv. slabých klasifikátorů) vznikne jeden klasifikátor s lepšími vlastnostmi (silný klasifikátor). Základní myšlenka vychází z iterativního přístupu. V každé iteraci jsou ze všech slabých klasifikátorů vybrány ty, které vykazují nejlepší výsledky, a vzájemně se dobře doplňují. Výsledkem je silný klasifikátor, sestavený jako kombinace vybraných jednoduchých (slabých) klasifikátorů. V každém kroku učení je do této kombinace přidán jeden slabý klasifikátor. Slabé klasifikátory mohou mít i relativně špatnou úspěšnost (jen o málo lepší než odhad), ale jejich vzájemným spojením vznikne silný klasifikátor, jehož celková klasifikační přesnost je zesílena (boosted). Vyhodnocení výsledného klasifikátoru spočívá v postupném vyhodnocení odezev všech slabých klasifikátorů a jejich váženém sečtení.

Základem spojení více klasifikátorů je výběr prvního klasifikátoru, jehož klasifikační přesnost je lepší než 50 %. Dále jsou přidávány další klasifikátory mající lepší než 50% přesnost na vážené sadě vzorků. Nakonec je takto vybrána sada (množina) klasifikátorů, které v kombinaci mají lepší klasifikační schopnost než původní klasifikátory, nebo alespoň ne horší, než nejlepší z nich – klasifikace je zesílena (boosted). Výsledná přesnost klasifikátoru

je v nejhorším případě stejná, spíše však mnohem vyšší než přesnost nejhoršího z dílčích klasifikátorů.

V současnosti se boosting metody využívají ani ne tak pro vybrané „ad-hoc“ klasifikátory a jejich kombinace, ale především pro velké množství automaticky generovaných slabých klasifikátorů – příznaků.

4.2.5 AdaBoost

AdaBoost (Adaptive Boosting) je v současnosti nejpoužívanější variantou metody boosting [32]. Podobně jako u ostatních boosting metod, i AdaBoost má za cíl zlepšení přesnosti klasifikace algoritmů strojového učení. I zde je základem výběr slabých klasifikátorů a jejich kombinace. Při klasifikaci lineárně kombinuje rozhodnutí několika i velmi jednoduchých slabých klasifikátorů a potencionálně tak dosahuje lepších výsledků, než jakých by bylo možno dosáhnout použitím jednotlivých klasifikátorů. Jednou z výhod je, že výsledný silný klasifikátor je v reálných podmínkách velmi přesný a zároveň dostatečně rychlý.

Algoritmus AdaBoost je schopen exponenciálně snižovat chybu výsledného klasifikátoru na trénovací sadě vzorků na libovolně nízkou úroveň [25]. Dokáže produkovat klasifikátory s velmi dobrými vlastnostmi i s použitím jen jednoduchých klasifikátorů. Výběr v každém kroku učení je realizován hladovým (greedy) způsobem tak, aby byl minimalizován horní odhad chyby klasifikátoru.

Autory algoritmu AdaBoost jsou Yoav Freund a Robert E. Schapire [25]. AdaBoost umožňuje při návrhu přidávat slabé klasifikátory tak dlouho, dokud není dosaženo požadované hodnoty chyby silného klasifikátoru (postupné snižování chyby). Přitom jediným požadavkem na slabý klasifikátor je, aby jeho chyba byla menší než 0,5 (50 %). Při použití v reálných podmínkách jsou klasifikátory vycházející z metody AdaBoost přesné a jejich vyhodnocení se dá provést velmi rychle, což se dá s výhodou využít například v real-time aplikacích.

Existuje celá řada modifikací algoritmu AdaBoost. Tyto modifikace obecně zlepšují některé vlastnosti algoritmu. Metoda Real AdaBoost [26] nám přidává do výsledku silného klasifikátoru míru příslušnosti k třídě. Rychlost výpočtu snižuje např. algoritmus WaldBoost [29]. Chybu výsledného klasifikátoru zmenšují algoritmy FloatBoost [28] a TCA [29]. Existují i modifikace algoritmu AdaBoost, které umožňují vícetřídní klasifikaci [25]. Tyto

modifikace umožňující algoritmu AdaBoost klasifikovat data do více tříd se však ve větší míře nepoužívají.

Diskrétní AdaBoost

Diskrétní AdaBoost je původní verzí algoritmu AdaBoost, jak ho prezentovali Freund a Schapire [25]. Vstupem algoritmu je anotovaná trénovací množina a výstupem klasifikátor do dvou tříd.

Algoritmus AdaBoost je založen na principu učení s učitelem. Proto jako vstup potřebujeme jak sadu vzorků, tak jejich ohodnocení. V případě diskrétního AdaBoostu platí, že ohodnocení y nabývá hodnot z množiny $\{+1, -1\}$ s tím, že objekty první třídy jsou označeny hodnotou $+1$ a objekty druhé třídy, hodnotou -1 . Algoritmus uchovává distribuci vah trénovacích vzorků D . Díky této distribuci je schopen přizpůsobit se těžko klasifikovatelným vzorkům. Toto přizpůsobení je umožněno krokem, ve kterém po každé iteraci algoritmu AdaBoost správně zařazeným vzorkům váhu sníží a špatně zařazeným vzorkům váhu zvýší. Vzorky s vyšší vahou více ovlivňují výběr dalšího slabého klasifikátoru. Na začátku trénování jsou všechny váhy nastaveny stejně.

V každém kroku učení je do silného klasifikátoru přidán jeden slabý klasifikátor h_t z množiny slabých klasifikátorů. Chybu klasifikátoru ε_t je možné vyjádřit jako součet vah chybně klasifikovaných vzorků.

$$\varepsilon_t = \sum_{i: h_t(x_i) \neq y_i} D_t(i) \quad (6)$$

Pro každý slabý klasifikátor lze vypočítat jeho důležitost α_t , která je nepřímo úměrná chybě klasifikátoru, tzn., čím nižší je chyba klasifikátoru, tím vyšší je jeho důležitost. Následující aktualizace distribuce pro další iteraci algoritmu má za úkol zvýšit váhu u chybně klasifikovaných vzorků a snížit ji u správně klasifikovaných. Důležité je normalizovat distribuci tak, aby zůstala funkcí pravděpodobnosti, tj. $\sum D_t = 1$.

Celý algoritmus lze zapsat pseudokódem [43]:

Vstup: $(x_1, y_1), \dots, (x_m, y_m), x \in X, y \in \{-1, +1\}$

Inicializace: $D_1 = \frac{1}{m}$ (pro všechny vzorky)

Pro $t = 1 \dots T$

- 1) Učení klasifikátorů. Nalezení optimálních parametrů (pokud nějaké má) každého slabého klasifikátoru tak, aby měl co nejmenší chybu ε_j na aktuální distribuci D_t .
- 2) Nalezení klasifikátoru s nejmenší chybou ε_t pro distribuci D_t .

$$h_t : X \rightarrow \{-1, +1\}$$
- 3) Výpočet důležitosti klasifikátoru $\alpha_t = \frac{1}{2} \ln \frac{1 - \varepsilon_t}{\varepsilon_t}$
- 4) Aktualizace vah vzorků v trénovací množině

$$D_{t+1}(i) = \frac{D_t(i) e^{\alpha_t y_i h_t(x_i)}}{Z_t},$$

kde Z_t je normalizační faktor zvolený tak, aby funkce D_{t+1} zůstala pravděpodobnostním rozložením.

Výsledný klasifikátor je lineární kombinací slabých klasifikátorů. Funkce $H : X \rightarrow \{-1, +1\}$ je po T krocích vyhodnocena jako součet odezev klasifikátorů násobených jejich vahou. Lze ji vyjádřit i vektorově jako skalární součin $\vec{a} \cdot \vec{h}$, kde \vec{a} je vektor vah klasifikátorů a \vec{h} je vektor jejich odezev.

$$H(x) = \text{sgn}(\vec{a} \cdot \vec{h}) = \text{sgn} \left(\sum_{t=0}^T \alpha_t h_t(x) \right) \quad (7)$$

Je zřejmé, že chyba výsledného klasifikátoru v kroku $t+1$ je v nejhorším případě stejná jako v kroku t . Pokud lze nalézt takový slabý klasifikátor, jehož chyba je nižší než 0,5 (50 %), což odpovídá náhodné funkci, chyba vždy klesá. AdaBoost redukuje trénovací chybu exponenciálně v závislosti na počtu slabých klasifikátorů. Příliš vysoký počet klasifikátorů může vést k přetrénování, tedy ztrátě schopnosti generalizovat vlivem přílišného zaměření na konkrétní trénovací data. Algoritmus AdaBoost je však vůči přetrénování odolný, což je nesporná výhoda proti některým jiným metodám používaným ke klasifikaci.

AdaBoost od Violy a Jonese

Varianta algoritmu AdaBoost od autorů Violy a Jonese [34][27] se od předchozí varianty liší v rozdílné inicializaci distribuce vah w a jiné aktualizaci vah na konci iterace.

Rozložení w nemusí být skutečným rozložením pravděpodobnosti, a proto se na začátku každé iterace provádí normalizace. Některé další modifikace algoritmu vychází právě z této varianty.

V pseudokódu lze algoritmus vyjádřit takto [43]:

Vstup: $(x_1, y_1), \dots, (x_m, y_m), x \in X, y \in \{0, 1\}$

Inicializace: $w_{1,i} = \frac{1}{2m}, \frac{1}{2l}$, kde m a l je počet negativních, resp. pozitivních vzorků

Pro $t = 1 \dots T$

- 1) Normalizace vah, aby w bylo pravděpodobnostní rozložení.

$$w_{t,i} = \frac{w_{t,i}}{\sum_j w_{t,j}}$$

- 2) Učení klasifikátorů. Nalezení optimálních parametrů (pokud nějaké má) každého slabého klasifikátoru tak, aby měl co nejmenší chybu ε_j na aktuální distribuci w .

$$\varepsilon_j = \sum_i w_i |h_j(x_i) - y_i|$$

- 3) Výběr slabého klasifikátoru h_j s nejnižší chybou.
- 4) Aktualizace vah.

$w_{t+1,i} = w_{t,i} \beta_t^{1-e_i}$, kde $e_i = 0$ pokud je vzorek i klasifikován správně a

$e_i = 1$, pokud je klasifikován špatně. $\beta_t = \frac{\varepsilon_t}{1 - \varepsilon_t}$

Hodnota výsledného silného klasifikátoru se vypočítá podle následujících vztahů (8).

V každém trénovacím kroku se vybírá příznak $h_t(x)$ s naučenými parametry a jeho váha α_t .

$$\begin{aligned}
 H(x) &= 1 && \text{pro } \sum_T \alpha_t h_t(x) > \frac{1}{2} \sum_T \alpha_t \\
 H(x) &= 0 && \text{jinak}
 \end{aligned} \tag{8}$$

$$\alpha_t = \frac{1}{\beta_t}$$

Real AdaBoost

Algoritmus Real AdaBoost je důležitý v tom, že umožňuje efektivně využít složitější slabé hypotézy, které rozdělují prostor na více než dvě části. Takové slabé hypotézy vykazují lepší výsledky než použití jednoduchých funkcí, jako je práh, který použili autoři původního algoritmu Viola a Jones [34].

Nevýhodou algoritmu AdaBoost je jeho binární výstup. Vyhodnocení silným (ani slabým) klasifikátorem ale neříká nic o tom, jak dobře daný vzorek zapadá do dané třídy. V mnoha aplikacích by se však taková informace hodila. Tuto funkčnost nabízí právě modifikace Real AdaBoost.

Rozdíly mezi klasickou verzí algoritmu AdaBoost a algoritmem Real AdaBoost jsou minimální. U algoritmu Real AdaBoost mohou výstupy klasifikátorů, jak silného, tak i slabých, nabývat reálných hodnot, tzn. $h_i : X \rightarrow R$ a $H : X \rightarrow R$. To umožňuje použít složitější příznaky a modifikovat postup trénování. Druhým rozdílem je výpočet parametru důležitosti α . U metody Real AdaBoost není jednoznačně dáno, jaký je ideální postup výpočtu. Pro různé aplikace algoritmu se dokonce může počítat jinak. Všeobecně se dá říci, že výpočet optimální hodnoty není analyticky řešitelný. Existují však numerické postupy vedoucí k výpočtu této hodnoty [26].

WaldBoost

V některých případech je nevýhodou metody AdaBoost nutnost vyhodnocení procesu klasifikace na základě hodnot všech slabých klasifikátorů. Tím může narůst výpočetní složitost. Teprve poté lze rozhodnout, zda testovaný objekt patří nebo nepatří do určité třídy dříve. V případě, že je již v průběhu testování výsledek klasifikace jasný, a je zřejmé, do které třídy bude objekt zařazen, nelze celý proces ukončit.

Na řešení tohoto nedostatku vznikla modifikace metody AdaBoost s názvem WaldBoost. Není nutné vyhodnocovat celý klasifikátor a v případě, že je během vyhodnocování slabým klasifikátorem dosaženo předem požadované přesnosti, objekt je klasifikován do dané třídy. V opačném případě klasifikace pokračuje vyhodnocením dalším klasifikátorem.

Tato výhoda umožňuje použití klasifikátoru v real-time aplikacích, kde je důležité okamžité zpracování dat a rychlé výsledky klasifikace. Oproti metodě AdaBoost je klasifikace rychlejší [23]. Naopak nevýhodou je velká složitost trénování a potenciálně i větší chyba klasifikace. V práci nakonec nebyl tento algoritmus použit, rychlost klasifikace není v případě klasifikace částic rozhodující.

4.2.6 Posouzení metod automatické klasifikace

Původní myšlenka vylepšení metody analytické ferrografie pomocí automatického klasifikátoru byla založena na předpokladu, že se podaří vytvořit co nejpřesnější sadu takových tvarových faktorů, které umožní popsat a vyhodnotit odlišnosti ve tvarech částic

vybraných tříd opotřebení. Ačkoli bylo zvažováno značné množství tvarových faktorů a některé z nich dokonce umožnily dobře odlišit některé třídy opotřebení, klasifikace částic všech požadovaných tříd opotřebení nebyla úspěšná a další výzkum problematiky tvarových faktorů a jejich použití pro automatickou klasifikaci byl ukončen.

Při výběru alternativní metody byla zvažována omezení, která vyplynula z nové situace. Pokud není možné vycházet při klasifikaci z tvarových faktorů, zbývá možnost analyzovat obrazy částic. V literatuře [1] je zkoumán vliv opotřebení na povrch (texturu) částic, např. vliv abrazivního opotřebení se na povrchu částice projeví charakteristickou deformací povrchu laminárních částic. Pro potřeby analytické ferrografie ale nepřipadá tato analýza v úvahu, vzhledem k ne vždy přesné identifikaci textury povrchu částic (částic mají pod mikroskopem různou hloubku ostrosti, tudíž je často část povrchu částic neostrá).

Z výše zmiňovaných metod, které přicházely v úvahu pro automatickou klasifikaci částic, byla zvolena metoda AdaBoost, přesněji její modifikace Real AdaBoost. Tato metoda umožňuje výhodné spojení několika vybraných klasifikátorů s relativně nízkou úspěšností (tzv. slabé klasifikátory) do klasifikátoru (tzv. silný klasifikátor), který je úspěšnější než libovolný slabý klasifikátor.

4.3 Metody extrakce obrazových příznaků

Rozhodujícím faktorem, který nejvíce ovlivňuje výsledek klasifikace, je tvar částic. Z obrazů jednotlivých částic jsou extrahovány příznaky, které jsou charakteristické pro daný tvar. Právě vhodně vybrané příznaky umožní úspěšnou klasifikaci.

V mnoha případech neplatí přímá úměra mezi množstvím příznaků a úspěšností klasifikace. Volba vhodných příznaků má tedy rozhodující vliv na úspěšnost klasifikace. O typu a množství extrahovaných příznaků rozhoduje především důkladná analýza problému a zkušenosti, neexistuje jednoznačný návod, pomocí kterého by bylo možné vybrat v dané situaci optimální příznaky.

Existují však některé univerzální metody, které umožňují vybrat pouze ty příznaky, které mají v dané situaci pro klasifikaci největší informační hodnotu. Při výběru příznaků je rozlišována extrakce příznaků od selekce.

Při extrakci dochází k získání (výpočtu) nových příznaků ze vstupního obrazu, tzn. že z původního obrazu jsou výpočtem získány jiné příznaků se stejnou (v ideálním případě podobnou) informační hodnotou, které dobře charakterizují hledanou informaci.

Selekce je pouze vhodný výběr určitých příznaků z původních. Cílem je snížit složitost měření a získání příznaků. Dá se považovat za extrakci. Metoda AdaBoost používá selekci příznaků.

Volbou, měřením a využitím příznaků se zabývá odvětví počítačové grafiky nazývané počítačové vidění (Computer vision). Nejčastějším důvodem je detekce objektů v obraze. V praxi je tato problematika velmi často využívána např. při detekci obličejů či postav v digitální fotografii, detekci dopravního značení či výstupní kontrole kvality výrobků. Jednotlivé metody detekce se liší složitostí implementace, rychlostí vyhodnocení obrazu; některé metody jsou vhodné pro detekci tváří, další se hodí na jiné objekty.

V této kapitole jsou dále uvedeny vybrané metody extrakce příznaků, které byly zvažovány a nakonec realizovány v této práci.

4.3.1 Local Binary Patterns


Metoda Local Binary Patterns (LBP) je metoda původně vyvinutá pro klasifikaci textur, ale našla uplatnění i v segmentaci obrazu, detekci obličejů a detekci pohybu. Je jednou z metod, které pracují přímo s pixely obrazu. Pro každý pixel vstupního obrazu je vypočítán jeho LBP příznak z hodnot pixelů v jeho okolí, nejčastěji je voleno osmiokolí. LBP příznaky se většinou vyhodnocují nad obrazem převedeným do stupňů šedi.

Výpočet LBP příznaku pixelu probíhá následovně [35]. Pomocí prahování hodnoty středového pixelu se získá matice koeficientů (obr. 43b). Prahování se provádí podle vzorce:

$$f(x) = \begin{cases} 0 & x > y \\ 1 & x \leq y \end{cases} \quad (9)$$

kde x je hodnota středového pixelu a y je hodnota sousedního pixelu. Poté se matice koeficientů vynásobí LBP operátorem (obr. 43c), který vyjadřuje počet a vliv (váhu) okolních pixelů na středový pixel. Vynásobením vznikne výsledná matice (obr. 43d). LBP příznak pro středový pixel je dán součtem prvků výsledné matice. V uvedeném příkladě má LBP příznak středového pixelu hodnotu $4+16+32+64+128=244$.

Pokud je středovým pixelem krajní bod obrazu (nemá úplné uvažované okolí), buď se LBP příznak nepočítá, nebo jsou neexistující body v matici koeficientů nahrazeny nulou.

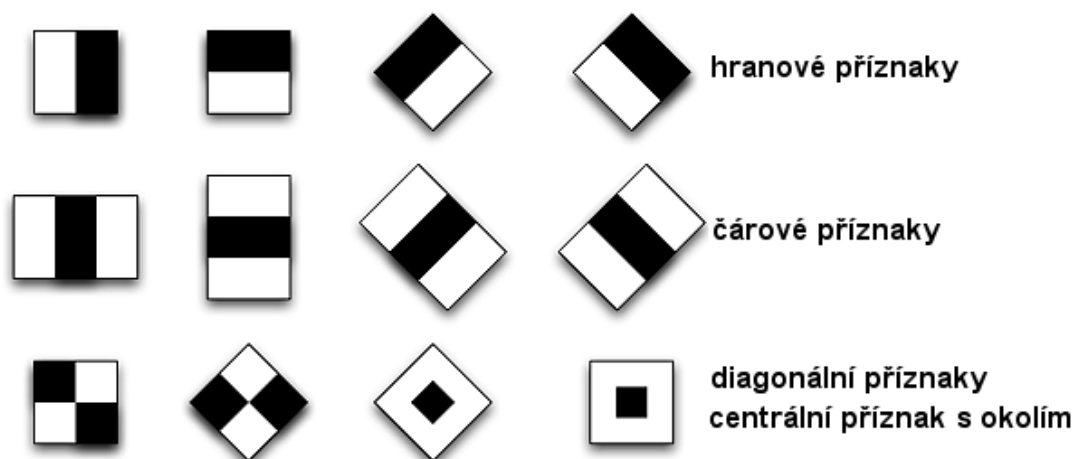


Obr. 43: Výpočet LBP příznaku středového pixelu [35]

4.3.2 Haarovy příznaky

Jak bylo uvedeno výše, principem algoritmu AdaBoost je výběr a spojování slabých klasifikátorů za účelem získání silného klasifikátoru. Protože klasifikátor založený na AdaBoostu prakticky nelze přetrénovat, je žádoucí, aby těchto slabých klasifikátorů bylo co nejvíce. Zvyšuje se tak pravděpodobnost výběru slabého klasifikátoru s vyšší mírou přesnosti. Cílem je tedy získat co největší množství jednoduchých příznaků s minimálními výpočetními nároky.

A právě těmto požadavkům vyhovují příznaky (obr. 44) založené na principu podobném definici Haarovy vlnky (Haar-like features [36]), které jsou schopny detekovat některé důležité vizuální prvky, jako jsou hrany, přímky nebo rohy. Hodnota takového příznaku je rovna rozdílu mezi sumou pixelů odpovídající bílé části a sumou pixelů odpovídající černé části. Příznaky mohou být tvořeny dvěma (hranové), třemi (čárové) nebo čtyřmi (diagonální) obdélníkovými oblastmi. Aplikovány jsou na celý obraz, přičemž se mění jejich velikost. Počínaje velikostí 1×1 až po velikost vstupního obrazu. Tedy pro obraz o velikosti 19×19 pixelů je vypočteno cca 64 tisíc hodnot příznaků, z nichž AdaBoost vybere jen malou podmnožinu.



Obr. 44: Základní tvary Haarových příznaků

4.3.3 Histogramy orientovaných gradientů

Dalším typem příznaků, které se používají jako vstupní hodnoty pro klasifikátory, jsou různé varianty Histogramů orientovaných gradientů (HOG) [36]. Histogramy orientovaných gradientů vycházejí z výpočtu gradientu obrazové funkce (například pomocí Sobelova operátoru). Gradient obrazové funkce je vždy charakterizován dvěma složkami, kterými mohou být směr a velikost gradientu. Klasický HOG pak vznikne spočítáním histogramu gradientů v určité oblasti obrazu. Histogram vždy zachycuje sílu gradientu v dané oblasti v určitém směru – pro každý bod obrazu se akumuluje příspěvek odpovídající velikosti gradientu do binu histogramu odpovídajícímu směru gradientu. Gradienty bývají velmi silné na siluetách objektů a podobných výrazných hranách, a proto jsou histogramy orientovaných gradientů vhodné pro rozpoznávání objektů, jako jsou chodci, dopravní značky a podobně.

Histogramy orientovaných gradientů úspěšně použili Dalal a Triggs [37] ve spojení s lineárními SVM klasifikátory pro detekci chodců. Autoři použili HOG překrývajících se obdélníkových oblastí, které dohromady pokrývaly celý klasifikovaný výřez obrazu. Takto vznikl dlouhý vektor příznaků, který sloužil jako vstup lineárního klasifikátoru. Tyto detektory ale nebyly přímo určeny pro detekci v reálném čase. Zhu [38] využil HOG příznaky a SVM klasifikátory jako slabé klasifikátory pro boosting algoritmus. Tyto klasifikátory již mohou pracovat v reálném čase. Ještě rychlejší jsou klasifikátory používající takzvané rozšířené histogramy orientovaných gradientů (EHOG), které zavedl Hou [39]. EHOG příznaky jsou založeny na výpočtu HOG, ale vstupem slabého klasifikátoru je místo celého histogramu pouze hodnota zachycující sílu gradientu v jednom určitém směru.

4.3.4 Gáborovy vlnky

Mezi lineární příznaky (tedy ty, které jsou kromě normalizace lineárními funkcemi obrazu) používané pro detekci objektu patří také Gáborovy vlnky. Podobně jako Haarovy příznaky dávají informaci o lokálních frekvencích – poskytují ideální poměr mezi lokalizací v prostoru a frekvencí. V praktických aplikacích ale Gáborovy vlnky nevykazují lepší vlastnosti než Haarovy vlnky, jejichž výpočet je mnohem efektivnější. Lze říci, že obecné lineární funkce použité pro extrakci příznaků nepřinášejí výrazné zlepšení úspěšnosti detekce a spíše snižují rychlost kvůli nemožnosti použít integrální obraz jako u Haarových vlnek. Z praktického hlediska jsou významné různé nelineární funkce, jako jsou LBP, nebo histogramy orientovaných gradientů. [36]

4.3.5 Local Rank Differences

Local Rank Differences (LRD) [40][41] jsou příznaky, které jsou založeny na lokálním uspořádání hodnot pixelů nebo oblastí. Pro výpočet příznaku LRD uvažujeme skalární obraz $I(x, y) \rightarrow R$, na němž může být definována následující vzorkovací funkce

$$S_{xy}^{mn}(u, v) = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} I(x + m(u-1) + i, y + n(v-1) + j), \quad (10)$$

kde m, n jsou rozměry vzorkovacího bloku a (x, y) jsou souřadnice pixelu v obrazu. Na základě této funkce lze definovat obdélníkovou masku

$$M_{xy}^{mnwh} = \begin{bmatrix} S_{xy}^{mn}(1,1) & S_{xy}^{mn}(2,1) & \cdots & S_{xy}^{mn}(w,1) \\ S_{xy}^{mn}(1,2) & S_{xy}^{mn}(2,2) & \cdots & S_{xy}^{mn}(w,2) \\ \vdots & \vdots & \ddots & \vdots \\ S_{xy}^{mn}(1,h) & S_{xy}^{mn}(2,h) & \cdots & S_{xy}^{mn}(w,h) \end{bmatrix} \quad (11)$$

Maska je parametrizována stejně jako vzorkovací funkce, parametry w, h udávají rozměry masky. Pro metody spojování klasifikátorů (AdaBoost) pracující s obrazem 32×32 pixelů jsou vhodné vzorkovací rozměry $1 \times 1, 2 \times 2, 2 \times 4, 4 \times 2$.

Pro každou pozici v masce je definován rank:

$$R_{xy}^{mnwh}(u, v) = \sum_{i=1}^w \sum_{j=1}^h \begin{cases} 1, & \text{když } s_{xy}^{mn}(i, j) < S_{xy}^{mn}(u, v) \\ 0, & \text{jinak} \end{cases} \quad (12)$$


Rank udává pořadí daného člena masky v seřazené posloupnosti všech členů masky. Hodnota ranku je nezávislá na lokální intenzitě obrazu, což je důležitá vlastnost pro chování LRD příznaku, který je definován jako rozdíl ranků

$$LRD_{xy}^{mnwh} = (u, v, k, l) = R_{xy}^{mnwh}(u, v) - R_{xy}^{mnwh}(k, l) \quad (13)$$

Local Rank Difference je obrazový příznak který je alternativou k obvykle používaným Haarovým příznakům. Je vhodný pro implementaci v programovatelném (FPGA) a specializovaném (ASIC) hardware, dobře se chová i na grafickém hardware (GPU).

4.3.6 Metody extrakce obrazových příznaků použité v práci

Při učení klasifikátoru a následném vyhodnocování testovacích dat jsou využívány modifikované LBP, tzv. CS LBP příznaky (center-symmetric LBP) [42], které jsou na rozdíl od výpočtu klasických LBP příznaků získávány sice rovněž z osmiokolí středového pixelu, ale při výpočtu jsou po dvojicích vyhodnocovány protější pixely (obr. 45).



Obr. 45: Způsob získání CS LBP příznaku pro středový pixel

Hodnota příznaku je vypočtena podle následujícího vztahu, kde v je vektor intenzit pixelů obrazu a δ_t komparační funkce, jejíž hodnotou je 0, pokud je rozdíl intenzit páru pixelů nižší než nastavený práh t anebo 1, pokud je rozdíl intenzit vyšší nebo roven prahové hodnotě. V práci je nastaven práh na hodnotu $t = 32$.

$$CSLBP(v, t) = \sum_{i=1}^4 \delta_t(v_i - v_{i+4}) 2^i \quad (14)$$

$$\delta_t(x) = |x| > t \quad (15)$$

V průběhu experimentů (popsány v kap. 6) byly rovněž zvažovány další popsané metody extrakce obrazových příznaků. Nejlepších výsledků bylo dosaženo u CS LBP příznaků, byť rozdíly nebyly nijak zásadní. Ve finální verzi jsou tedy při klasifikaci využívány právě CS LBP příznaky. Byla zvažována i možnost kombinace více obrazových příznaků, ta ale nevedla ke zlepšení výsledků.

4.4 Analýza hlavních komponent

Analýza hlavních komponent [25][30][31], metoda známá také pod názvy Principal Component Analysis (PCA), Karhunen-Loévuův rozvoj či Hotellingova transformace, umožňuje výběr těch parametrů zkoumaných objektů, které obsahují statisticky významné informace. Obecně se jedná o techniku redukce vícedimenzionálního prostoru (dimension reduction), při minimální ztrátě informační hodnoty.

Protože sledované objekty v obraze většinou obsahují nadbytečné informace, lze se jejich zjednodušeným vyjádřením v podobě vektoru (sestaveného z hlavních komponent) zbavit redundance dat, a přesto zachovat většinu informační hodnoty původního objektu. Metoda je tedy výhodná pro vyjádření vícerozměrných dat. Nevyužité hlavní komponenty obsahují pouze malé množství informace, které je možné zanedbat. Namísto analýzy velkého

počtu původních znaků objektu s komplexními vnitřními vazbami je analyzován pouze malý počet vzájemně nesouvisejících hlavních komponent.

Příznaky extrahované z objektu v podobě vektoru jsou následně vstupem pro učení a použití klasifikátoru. Hlavní myšlenkou analýzy hlavních komponent je nalezení takových vektorů, které nejlépe vystihují analyzovaný obraz.

V praxi se používá např. při rozpoznávání obličejů v kriminalistice či při kompresi dat. Tato metoda by byla vhodná pro použití s tvarovými faktory, výše uvedené důvody (částice není možné přesně rozpoznávat pouze podle tvarových faktorů) jejímu nasazení v tomto kontextu v tribodiagnostice prozatím brání.

Při návrhu a implementaci klasifikátoru vycházejícího z obrazů částic byla tato metoda využita při normalizaci částic předcházející procesu trénování.

Praktickou ukázkou je klasifikace obrazů částic. Mějme trénovací množinu vzorových částic, o kterých víme, že patří do určité klasifikační třídy. Cílem je vytvořit takový model, pomocí kterého bude možné popsat i částice, které nejsou obsaženy v trénovací množině. Pomocí extrakce příznaků vzorových obrazů můžeme získat hodnoty vyjadřující specifické obrazové vzory, které budeme posléze hledat v testovaných obrazech. Pokud se podaří takový vzor nalézt, můžeme testovaný obraz zařadit do dané třídy.

Z množiny trénovacích tvarů $\{X_1, X_2, \dots, X_n\}$ popsaných distanční funkcí Ψ nebo seznamem bodů (x,y) můžeme vypočítat průměrný tvar Φ

$$\Phi = \frac{1}{N} \sum_{n=1}^N X_n \quad (16)$$

a deformace jednotlivých trénovacích vzorů vzhledem k průměru X_i .

$$\Delta_i = X_i - \Phi \quad (17)$$

Libovolný nový tvar, který patří do stejné třídy lze popsat jako kombinaci jednotlivých deformací vůči průměrnému tvaru:

$$X^* = \Phi + \sum_{i=1}^N \alpha_i X_i, \quad (18)$$

kde α_i je váha pro každou deformaci. V případě nepravidelných objektů to znamená použít pro popis tvaru značné množství deskriptorů. Důsledkem je vysoká časová a paměťová náročnost výpočtu.

Protože objekty, které patří do stejných klasifikačních tříd, mají některé společné rysy, není nutné zvažovat všechny možné deformace. Mnoho objektů lze popsat podobnou

deformací, tzn. že v jejich případě dochází ke zpracování redundantní informace. Analýza hlavních komponent umožňuje získat pouze lineárně nezávislé deformace. Pro každou z nalezených deformací navíc určí její váhu (jak často se v trénovacích datech vyskytuje).

V práci je využita metoda PCA pro zjištění hlavní osy částice, která je poté otočena tak, aby splývala se svislou osou kartézského souřadného systému. Je tak zajištěno jednotné otočení částic. Protože rotace nemá vliv na třídu opotřebení, do které bude částice zařazena, je výhodné rotovat částice podle jednotných pravidel. Tento krok je důležitý především pro částice typu sliding a cutting, které jsou obecně protáhlého tvaru. Větší částice jsou na ferrogramu usazeny v náhodném natočení. Pokud by rotace neproběhla, chybovost klasifikace by byla negativně ovlivněna.

5 Nová metoda klasifikace částic opotřebení

Tato kapitola popisuje definici vstupních obrazových dat a rozhodnutí, které předcházely vytvoření klasifikátoru. V první části je popsána technologie pořizování vzorových částic určených pro trénování klasifikátoru. Dále jsou definovány třídy opotřebení, do kterých budou částice klasifikovány. V další části jsou popsány úpravy (normalizace) obrazů trénovacích částic pro použití v rámci vybrané metody Real AdaBoost, možnosti nastavení klasifikátoru a vliv nastavení parametrů normalizace na výsledek (přesnost) klasifikace. Výsledky experimentů a jejich zhodnocení jsou uvedeny v následujících kapitolách 6 a 7.

5.1 Obrazová data pro vstup klasifikace


Při využití metod strojového učení je stěžejním krokem, který má rozhodující vliv na kvalitu výsledků, zajištění vhodných a kvalitních vstupních dat. Jako vhodná byla zvolena analýza obrazových dat v kombinaci s metodami strojového učení. Z metod uvedených v předchozí kapitole, které byly zvažovány pro realizaci, se jako nejvýhodnější ukázal algoritmus Real AdaBoost.

Z hlediska efektivity by se jako ideální možnost jevila analýza samotných snímků ferrogramů pořízených při dostatečném zvětšení. Tvar částic je dobře rozpoznatelný při 400násobném zvětšení mikroskopu, kdy je pod mikroskopem viditelná oblast o velikosti cca $100 \times 70 \mu\text{m}$. Plocha, na které jsou částice na ferrogramu zachyceny, má velikost cca $60 \times 5 \text{ mm}$. Pro splnění požadavku nasnímání celé plochy ferrogramu by bylo potřeba 42 000 snímků. Ruční posun snímaného ferrogramu je v takovém případě nemyslitelný. S pomocí motorizovaného stolku lze zajistit automatický posun ferrogramu a v kombinaci se sekvenčním snímáním je možné vytvořit kompletní obraz ferrogramu.

Tato metoda snímání obrazů ferrogramů se v praxi ukázala jako uskutečnitelná, ale bez zásahu obsluhy příliš nepřesná kvůli nedostatečné hloubce ostrosti mikroskopu. Částice na ferrogramu nejsou zcela ploché a v mnoha případech je nutné přesné manuální zaostření vybrané oblasti. V praxi je tak nutné přesné nastavení hloubky ostrosti mikroskopu, která se i v rámci konkrétního ferrogramu může měnit (obr. 46). Proces ostření není možné automatizovat kvůli značné variabilitě částic a nutnému posouzení individuálního nastavení (ferrogram na fólii není zcela rovinný).

Jako vstup klasifikátoru tak slouží obrazy jednotlivých částic segmentovaných z obrazu celého ferrogramu. V případě vyřešení problému s ostrostí snímků zachycujících

větší plochy ferrogramu je možné klasifikátor upravit tak, aby jeho vstupem byl automaticky upravený snímek ferrogramu. Jednotlivé částice by bylo možné automaticky v obraze detekovat a použít jako vstup klasifikátoru. Tento krok je řešitelný s využitím známých algoritmů pro detekci objektů v obraze a není přímo řešen v práci.



Obr. 46: V rámci ferrogramu jsou některé částice zachyceny s dostatečnou přesností (1, 2, 3), některé je potřeba zaostřit lépe (4, 5, 6)

Vstupem klasifikátoru jsou tedy obrazy jednotlivých částic, dostatečně zvětšené, aby bylo možné přesně rozpoznat jejich tvar. Protože je přesnost klasifikace do značné míry závislá nejen na kvalitě, ale i na množství vzorových obrazů částic (řádově tisíce obrazů částic) a ruční segmentace částic z ferrogramů by při takových počtech částic byla časově velmi náročná, jsou pro trénování klasifikátoru využity obrazy částic pořízené laserovým analyzátozem částic (LNF, kap. 2.6.3).

Zařízení LNF je samo o sobě rovněž klasifikátorem částic opotřebením. Jeho nevýhodou je netransparentnost algoritmů použitých pro klasifikaci. Zařízení klasifikuje částice, jejichž maximální rozměr je větší než 20 μm a menší než 100 μm . Pro reálné využití je tento rozsah dostatečný; menší částice tvoří na ferrogramu shluky a není tak možná jejich přesná identifikace, větší částice se v mazivu vyskytují jen zřídka a většinou jsou zachyceny na filtrech.

LNF používá pro klasifikaci níže uvedené klasifikační třídy. V mnoha případech je ale tato automatická klasifikace nepřesná, zařízení pak v případě chyb umožňuje „ručně“ překlasifikovat špatně zařazené částice. V průběhu pořizování vzorových obrazů částic byly

chybně klasifikované částice ručně přeřazeny do správné třídy. Dosažené výsledky ukazují, že přesnost klasifikátoru vytvořeného v této práci je vyšší než přesnost LNF.

Z výše uvedených důvodů není možné v případě zajištění pouze menších vzorků provozních kapalin využít zařízení LNF pro pravidelnou údržbu a testování stavu sledovaných zařízení. Cílem této práce je vytvořit podobný automatický klasifikátor, který se ze vzorových obrazů částic naučí klasifikovat obrazy částic pořízených metodou analytické ferrografie. Klasifikátor využívá pro učení částice získané pomocí LNF, klasifikace těchto částic je zkontrolována expertem, který opravil chyby v klasifikaci.

Díky spolupráci s Fakultou vojenských technologií Univerzity obrany v Brně bylo autorovi umožněno dokonalé seznámení s přístrojem LNF a uskutečnění mnoha testů, které prokázaly, že zařízení lze v kombinaci s metodou analytické ferrografie dobře využít pro stanovení závažnosti opotřebení.

Obrazy částic pro trénování klasifikátoru tak byly pořízeny na přístroji LNF. V současnosti obsahuje databáze cca 9000 částic, všechny jsou zařazeny do odpovídajících tříd opotřebení.

5.2 Definice tříd opotřebení pro klasifikaci

Pro potřeby tribodiagnostiky byly jako stěžejní zvoleny tři typy opotřebení a jim odpovídající třídy, do kterých jsou částice klasifikovány. Velmi důležité jsou navíc pro diagnostiku stavu zařízení sférické částice vznikající jako průvodní jev únavového opotřebení valivého charakteru, které jsou sice na ferrogramech dobře identifikovatelné i laickým pohledem kvůli přesně kruhovému tvaru, pro svoji důležitost jsou ale rovněž klasifikovány jako samostatná třída. Částice opotřebení jsou tedy klasifikovány do těchto tříd:

- **Fatigue** – laminární únavové částice. Do této třídy patří částice deformované v důsledku opakovaného průchodu soustavou. Rozválcováním sféroidů i jiných třírozměrných částic vznikají tenké ploché lupínky malé tloušťky. Částice mají hladký povrch a nepravidelné okraje, jejich výskyt je zpravidla doprovázen výskytem sféroidů. Velikost částic se pohybuje od cca 15 μm do 100 μm .
- **Cutting** – částice řezného (abrazivního) opotřebení. Částice vznikající v důsledku působení cizorodé částice mezi třecími povrchy případně penetrací tvrdšího materiálu třecí dvojice do měkčího. Mají vzhled třísek, často mohou tvarem připomínat spirály. Vyznačují se velmi malou tloušťkou. Jejich výskyt (zejména při zvýšeném počtu částic větší velikosti) poukazuje na blížící se poruchu zařízení.

- **Sliding** – částice vznikající při kluzném tření. Jsou menší než fatigue částice, přesto jejich velikost přesahuje 15 μm . Často mají protáhlý tvar s nepravidelným okrajem.
- **Sphere** – často drobné kulovité částice minimálního průměru vznikající působením opakovaného napětí na povrchu součásti. Zpravidla vznikají v důsledku únavy Beilbyho vrstvy na povrchu ložisek. Sféroidy jsou relativně malé (o průměru 2–30 μm). V objektivu mikroskopu se jeví jako malé černé body, při větším zvětšení je patrný jejich hladký povrch. Výskyt těchto částic na ferrogramu signalizuje nastupující poruchu valivých ložisek.


V praxi ale často není možné klasifikovat částice jednoznačně, jednotlivé třídy nejsou navzájem zcela disjunktní, a proto mohou být některé částice přiřazeny více třídám. V důsledku tak nelze dosáhnout stoprocentní přesnosti klasifikace, zejména částice malých rozměrů (do 30 μm) lze v mnoha případech klasifikovat jako „únavové“ (fatigue) a zároveň „kluzné“ (sliding). Pokud je taková částice klasifikována chybně (místo třídy fatigue je zařazena do třídy sliding a/nebo naopak), jedná se o chybu, která ale nemá zásadní vliv na stanovení převládajícího typu opotřebení a určitou nepřesnost při klasifikaci těchto tříd je tak možné tolerovat. Stejně tak ani při ferrografické analýze nelze vždy jednoznačně rozhodnout, do které třídy zařadit tyto „nejednoznačné“ částice.

Kromě uvedených typů částic, resp. opotřebení, jejichž působením sledované částice vznikají, lze na ferrogramu nalézt i další „útvary“. Zpravidla se již ale nejedná o částice opotřebení, ale o cizí částice, které nejsou důsledkem opotřebení. Lze tak narazit na vlákna filtrů, nekovové nebo prachové částice apod., případně na nevymyté zbytky oleje. Tyto „částice“ lze vizuálně dobře odlišit a proto nejsou vyhodnocovány automaticky.

Nedílnou součástí každého ferrogramu je rovněž značné množství částic adhezivního opotřebení. Tyto drobné částice (do 15 μm) nejsou známkou výrazného opotřebení, navíc působením magnetického pole v průběhu zpracování vzorku oleje vytvářejí na ferrogramu shluky (přesněji řetízky orientované podle siločar magnetického pole kolmo na směr proudu oleje) a není možné jednotlivé drobné částice od sebe odlišit. Protože nemají zásadní vliv na funkčnost zařízení a jejich přítomnost v mazivu je přirozeným jevem, nejsou jako částice klasifikovány.

Při klasifikaci tak jsou z ferrogramu segmentovány pouze částice významné z hlediska tribodiagnostiky (všechny kromě vláken filtrů, cizích příměsí a částic adhezivního opotřebení).

Na obr. 47 je uvedena ukázka typických částic vybraných tříd. Aby bylo možné lépe využít možností metod strojového učení (především kvůli časové a paměťové náročnosti) pro automatickou klasifikaci, v tomto případě metody Real AdaBoost, je výhodné, aby měla všechna vstupní data jednotnou velikost. Originální obrazy částic se v některých případech liší ve velikosti až o desítky procent. Částice je proto potřeba nejprve normalizovat, teprve poté je zajištěna jejich porovnatelnost a mohou být použity jako vstupní data pro trénování klasifikátoru.



Obr. 47: Obrazy částic, které jsou po normalizaci vstupem učení klasifikátoru

Při učení klasifikátoru a následném vyhodnocování testovacích dat jsou využívány CS LBP příznaky. Jejich bližší popis je uveden v kap. 4.3.6.

5.3 Normalizace obrazů částic pro trénování klasifikátoru

Obrazy částic, které jsou vstupem pro učení klasifikátoru, je vhodné nejprve normalizovat (obr. 48 a, b). Použití normalizace má zásadní vliv na přesnost klasifikace. Experimentální zjištění optimálních hodnot parametrů normalizace umožnilo dosáhnout vyšší přesnosti klasifikace a je tak stěžejním krokem ve fázi přípravy vstupní dat pro klasifikaci.

Normalizace spočívá v převzorkování obrazů na jednotnou velikost, rotaci částic podle jejich hlavní osy a vycentrování v rámci obrazu. Aby bylo možné lépe využít možností některé z metod strojového učení (především kvůli časové a paměťové náročnosti) pro automatickou klasifikaci, je výhodné, aby měla všechna vstupní data jednotnou velikost. Prvním krokem je tedy zmenšení/zvětšení obrazů částic. V tomto kroku je použita nelineární změna velikosti obrazů částic – menší obrazy podléhají jen malé úpravě, a čím jsou částice větší, tím více jsou zmenšeny. Rozměry většiny obrazů se pohybují v rozsahu 10–30 pixelů, klasifikovány jsou ale i částice velké 70–80 pixelů.



Obr. 48a) Originální obrazy částic před normalizací Obr. 48b) Obrazy částic po normalizaci, s rotací

Původně zvažovaná lineární změna velikosti částic byla nakonec zavržena, protože by jejím použitím vzniklo značné množství velmi malých částic o velikosti několika pixelů a naopak několik málo částic velkých, které by „zabraly“ celou plochu obrazu. Výhody nelineární transformace (zmenšení) tak v tomto případě převažují nad jednodušším postupem při lineárním zmenšení obrazu. Díky nelineární transformaci je rovněž zachována informace o původní velikosti částic, která může při klasifikaci hrát svou roli.

Druhou podstatnou úpravou je rotace částic. Protože rotace nemá vliv na třídu opotřebení, do které bude částice zařazena, je výhodné rotovat částice podle jednotných pravidel. Díky rotaci je možné dosáhnout vyšší přesnosti klasifikace. Pro potřeby normalizace jsou částice rotovány podle své hlavní osy (splývá s osou y souřadného systému), která je nalezena pomocí metody analýzy hlavních komponent (PCA).

Společně s rotací jsou v rámci normalizace částice centrovány. Pomocí bilineární interpolace a následnému vyhlazení je částice transformována tak, aby její těžiště odpovídalo středu obrazu.

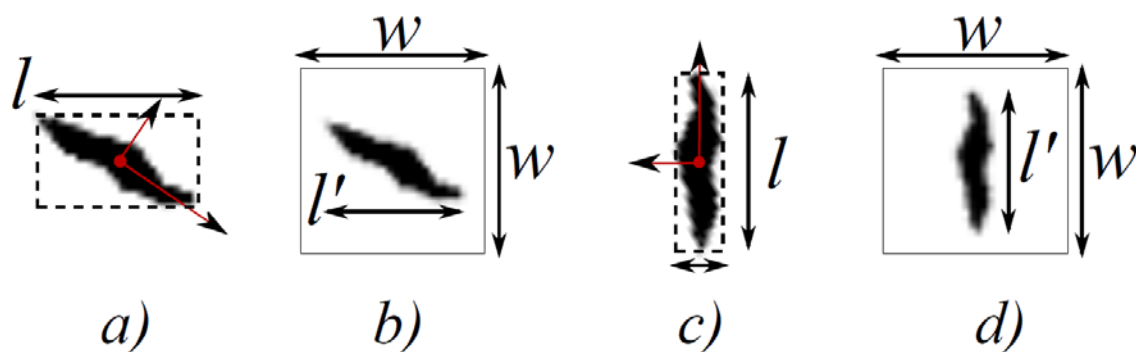
V průběhu experimentů s nastavením parametrů normalizace a testování jejich vlivu na úspěšnost klasifikace byly zkoumány především následující faktory:

- koeficient pokrytí c – ovlivňuje velikost částice v obraze, resp. vzdálenost mezi okrajem částice a okrajem obrazu (nastaven na hodnotu $c = 0,8$),
- velikost obrazů w – velikost obrazu, testovány hodnoty 16, 24, 32 a 48 pixelů,
- normalizační faktor α – určuje relativní velikosti částic v obraze (testovány hodnoty 0,02; 0,05; 0,1; 0,2; a 0,5),
- rotace částic – testován vliv rotace částic na přesnost výsledku (s rotací, bez rotace).

Výsledek normalizace je dán vztahem


$$l' = cw(1 - e^{-\alpha l}) \quad (19)$$

Na obr. 49 je demonstrován postup při normalizaci obrazů částic. V původním obrazu částic je zjištěna velikost l delší strany obrazu, která je transformována (zmenšena) na velikost l' .




Obr. 49: Postup normalizace obrazu: a) původní obraz s nalezenou hlavní a vedlejší osou částice, b) normalizace velikosti obrazu, bez rotace, c) rotace obrazu podle hlavní osy částice, d) normalizovaný obraz s rotací

Z uvedených parametrů má na přesnost klasifikace nejvýraznější vliv normalizační faktor α (obr. 50). Při nízkých hodnotách α je sice zachována relativní velikost částic, ale některé částice mohou být po normalizaci příliš malé (v celkové ploše obrazu tvoří samotná částice jen malou část) a tudíž pro trénování (klasifikaci) nevhodné. Nastavením normalizačního faktoru α na vyšší hodnoty zase dochází ke zvětšování velikosti částic tak, že zaberou velkou část obrazu (obr. 49). V rámci obrazu tak dochází ke zvětšení malých částic. V průběhu testování byly zvažovány různé kombinace velikosti obrazu, koeficientu pokrytí i normalizačního faktoru.



Obr. 50: Závislost velikosti částice v obrazu po normalizaci na skutečné velikosti částice (před normalizací) pro rozsah hodnot normalizačního faktoru α 0,02 až 0,5. Pro velikost obrazu $w = 24px$

Ukázka výsledků normalizace pro různé hodnoty normalizačního faktoru α je uvedena na obr. 51.



Obr. 51: Vliv nastavení normalizačního faktoru na obrázky částic po normalizaci

Uvedené parametry normalizace mají zásadní vliv na výsledek klasifikace, při použití optimálních hodnot se přesnost klasifikace výrazně zvyšuje. Návrh a praktické ověření vlastní metodiky normalizace je jedním z přínosů této práce. Nalezení optimálních hodnot bylo cílem experimentálního výzkumu, kompletní přehled výsledků je uveden v Příloze 1 a 2.

6 Použitá metodika a její ověření na zkušebních vzorcích

Jedním z hlavních cílů této práce je objektivizovat hodnocení stavu strojních zařízení pomocí vylepšení možností metody analytické ferrografie v oblasti tribotechnické diagnostiky. Částice opotřebení, které jsou zachyceny na ferrogramu, jsou v současnosti analyzovány expertem. Klasifikátor vytvořený v průběhu této práce umožňuje nahradit lidský element výpočetními prostředky.

Chyba vyhodnocení závažnosti opotřebení, která je zjišťována analýzou ferrogramu, je závislá na znalostech experta provádějícího opotřebení. Pokud se jedná o zkušeného praktika, analýza může být téměř bezchybná (při zajištění ferrogramů korektně a přesně zachycujících stav zařízení). Cílem práce je vytvořit klasifikátor, který dokáže takového experta zastoupit a vyhodnotí předložené ferrogramy automaticky. Umožní tak rozšíření a častější kontroly, které navíc budou nezávislé na znalostech obsluhy.

Výsledky hodnocení ferrogramů jsou v současnosti zatíženy chybou vznikající subjektivním hodnocením. Automatický klasifikátor umožňuje vyjádřit výsledky hodnocení numericky a na základě testování zkušebních dat lze zjistit chybovost klasifikace pro jednotlivé třídy opotřebení. Lze předpokládat, že chybovost nebude pro všechny třídy stejná. Např. částice třídy sphere jsou velmi dobře rozpoznatelné a chyba v jejich klasifikaci tak bude podstatně nižší než u částic, které jsou svým tvarem na pomezí tříd sliding a fatigue. Pokud by se podařilo dosáhnout úspěšnosti klasifikace v řádu 80–90 procent, lze takové výsledky považovat za úspěšné, pokud by se úspěšnost pohybovala nad hranicí 90 procent, byly by takové výsledky vynikající.

Cílem prvních experimentů bylo ověřit funkčnost navržené metodiky klasifikace částic, zkoumat vliv nastavení parametrů ovlivňujících průběh a výsledky trénování a klasifikace, nalézt optimální způsob normalizace obrazů částic a z experimentů zjistit chybovost klasifikace pro jednotlivé třídy.

V experimentu byly navrženy binární klasifikátory rozlišující vždy jednu vybranou třídu od ostatních, celkem tedy čtyři klasifikátory pro čtyři třídy fatigue, sliding, cutting a sphere. Binární klasifikátor zjišťuje, zda testovaná částice odpovídá dané třídě anebo ne. Pokud částice nepatří do testované třídy, klasifikátor dále nezjišťuje třídu, do které částice patří. Klasifikace v takovém případě pokračuje vyhodnocením částice dalším klasifikátorem testujícím další třídu.

Vzhledem k tomu, že žádná objektivní metoda pro určení chybovosti při klasifikaci částic není k dispozici (ferrografické hodnocení je v praxi založeno na subjektivním posuzování a klasifikaci jednotlivých částic na základě zkušenosti pracovníka), pokud se bude výsledná chyba klasifikace pohybovat v řádu jednotek procent, bude považována za vyhovující (podobně jako např. v analytické chemii je výsledek stanovení v oblasti stopových koncentrací s chybou 10–15 % považován za dostačující).

6.1 Nastavení parametrů normalizace dat

V průběhu testování byl sledován vliv parametrů normalizace na úspěšnost klasifikace. Velikost obrazu byla testována pro hodnoty 16, 24, 32 a 48 pixelů. Větší rozměry obrazu vedou k vyšší výpočetní složitosti, naopak nízké hodnoty negativně ovlivňují kvalitu detailů obrazu – kvůli přílišnému zmenšení může dojít ke zkreslení tvaru částice. Pro realizaci klasifikátoru byla zvolena velikost obrazu $w = 32$ (32×32 pixelů).

Zásadní vliv na přesnost a úspěšnost klasifikace má především tzv. normalizační faktor α , který definuje způsob úpravy velikosti částice v obraze. Při nízkých hodnotách α je zachována relativní velikost částice, ale některé částice mohou být po normalizaci příliš malé (v celkové ploše obrazu tvoří samotná částice jen malou část) a tudíž pro trénování (klasifikaci) nevhodné. Nastavením normalizačního faktoru α na vyšší hodnoty zase dochází ke zvětšování velikosti částic tak, že zaberou velkou část obrazu. V rámci obrazu tak dochází ke zvětšení malých částic.

Koeficient pokrytí ovlivňuje vzdálenost částice od okraje obrazu. Příliš vysoká hodnota způsobí přiblížení částice k okraji obrazu, což může způsobit komplikace při výpočtu příznaků. Naopak příliš nízké hodnoty vedou k situaci, kdy částice pokrývá pouze malou část obrazu, jeho větší část je nevyužita a částice ztrácí detaily. V tomto případě byla experimentem potvrzena zkušenost získaná používáním klasifikátorů obrazu vytvořených na Ústavu počítačové grafiky FIT VUT Brno [36]. Jako optimální se jeví hodnota koeficientu pokrytí $c = 0,8$. Je při ní zachována dostatečná velikost částice pro analýzu detailů a zároveň potřebný okraj.

Pro každou z kombinací hodnot zmiňovaných parametrů byl vytvořen samostatný dataset (sada odpovídajícím způsobem normalizovaných originální obrazů), který byl následně rozdělen na poloviny – polovina náhodně vybraných částic každé třídy byla použita pro trénování klasifikátoru, na druhé polovině byl klasifikátor otestován.

6.2 Vyhodnocení výsledků dosažených v experimentech

Experimentálně bylo potvrzeno, že na výsledky klasifikace má významný vliv nastavení parametrů normalizace. Zajímavým zjištěním je fakt, že pro každou třídu bylo dosaženo nejlepší přesnosti při jiném nastavení normalizace, což lze zdůvodnit specifickými rysy jednotlivých klasifikovaných tříd.




Částice použité v experimentu byly nejprve rozděleny přibližně na poloviny, polovina byla použita pro účely trénování klasifikátoru, na druhé polovině byl naučený klasifikátor otestován. Všechny použité částice byly nejprve správně klasifikovány expertem. Počty částic použitých pro trénování a testování jsou uvedeny v následující tabulce.


Třídy částic	Trénování	Testování
Fatigue	400	507
Sliding	400	389
Cutting	400	335
Sphere	100	166

Tab. 9: Rozdělení částic použitých v experimentu

Pro každý z testů vycházející z datasetu částic normalizovaných podle sledovaných požadavků byly zároveň získány výsledky, a to jak pro případy, kdy byly částice v rámci normalizace jednotně rotovány podle hlavní osy, tak bez předchozí rotace.


Na obr. 52–55 je demonstrováno, jakým způsobem je přesnost klasifikace ovlivněna velikostí použitých obrazů. ROC křivky znázorňují výsledky klasifikace pro každou ze čtyř tříd, velikost obrazu je 16, 24, 32, 48 pixelů.





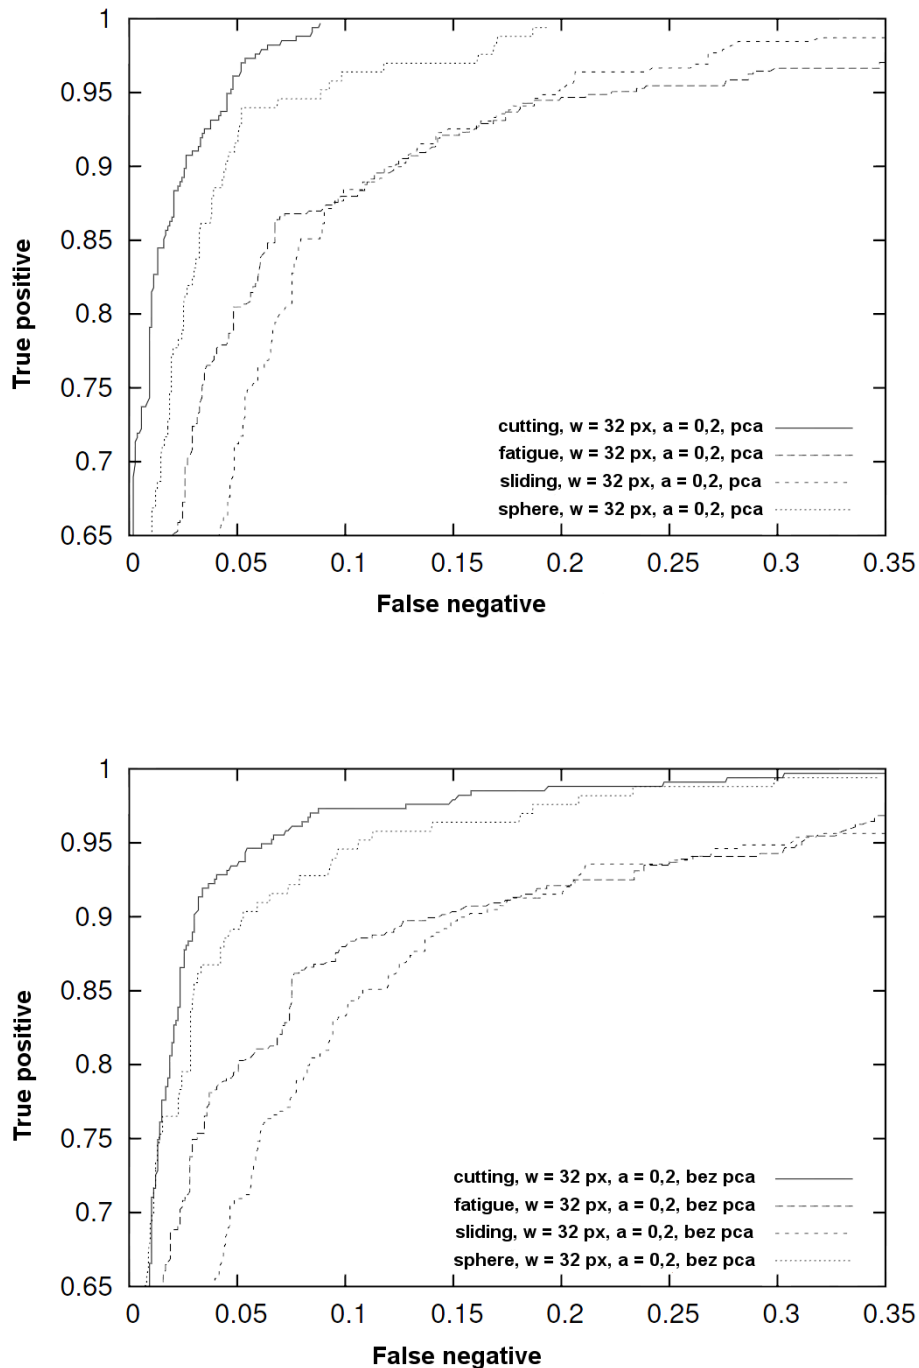
Obr. 52–55: Vliv velikosti obrazu na výsledky klasifikace (pro jednotlivé třídy)

Podobně lze pomocí ROC křivek analyzovat vliv normalizačního faktoru na přesnost klasifikace (obr. 56). Nejlepších výsledků bylo dosaženo pro hodnoty $\alpha = 0,1$ resp. $0,2$. Při nižších hodnotách jsou lépe zachovány rozdíly ve velikosti částic, ale malé částice jsou v obraze zachyceny jen na několika málo pixelech, naopak při vyšších hodnotách normalizačního faktoru jsou částice velké přes celý obraz a téměř není zachována informace o původní velikosti částice.



Obr. 56: Vliv normalizačního faktoru na přesnost klasifikace

Součástí experimentu bylo také vyhodnocení vlivu rotace částic v rámci normalizace obrazů. Částice byly rotovány podle své hlavní osy, jež byla nalezena pomocí metody analýzy hlavních komponent. Na obr. 57–58 jsou vyobrazeny ROC křivky vybraného nastavení normalizace s rotací a bez ní. Z jejich průběhů je zřejmé, že rotace má na přesnost klasifikace pozitivní vliv a je tedy vhodné ji do normalizace zahrnout.



Obr. 57–58: Porovnání přesnosti klasifikace datasetu, ve kterém byla provedena rotace částic (nahore) a datasetu bez rotace (dole)

Z výsledků získaných v experimentu byly jako optimální hodnoty parametrů normalizace získány tyto – faktor pokrytí 0,8; normalizační faktor 0,1; rozměry vstupních obrazů 32×32 pixelů – to vše při použití rotace částic jako součásti normalizace.

Přesné výsledky vypovídající o přesnosti klasifikace pro různě nastavené parametry normalizace jsou uvedeny v tab. 10. Hodnoty v tabulce udávají chybovost klasifikátorů jednotlivých tříd a různé hodnoty parametrů normalizace. Nejlepší dosažené výsledky jsou v tabulce vyznačeny tučně. Důležité je podotknout, že při nasazení v reálné aplikaci může každý klasifikátor pracovat s vlastními (a tedy optimálními) hodnotami parametrů normalizace.

% chyba	$\alpha = 0,02$	$\alpha = 0,05$	$\alpha = 0,1$	$\alpha = 0,2$	$\alpha = 0,5$
Cutting	16,3/13,8	8,3/5,6	6,5/5,6	5,4/ 4,7	6,2/5,9
Fatigue	12,2/12,6	12,0/11,0	10,2/ 9,4	11,2/11,0	15,8/13,2
Sliding	14,4/13,1	12,0/10,0	10,5/ 8,7	12,8/11,0	17,6/13,9
Sphere	16,0/15,8	10,3/11,4	8,4/8,7	7,8/6,0	8,3/ 5,8

Tab. 10: Dosažené chybovosti klasifikace částic pro různé hodnoty normalizačního faktoru (bez rotace/s rotací), velikost vzorků (obrazů) je 32 pixelů, faktor pokrytí 0,8


7 Aplikace a výsledky klasifikátoru

První experimenty popisované v předchozí kapitole potvrdily předpoklad, že obrazy částic získaných z přístroje LNF, které jsou nejprve expertem zařazeny do správných tříd a následně jsou použity pro trénování klasifikátoru, jsou jako trénovací data vhodné. Při testování na další sadě částic z LNF bylo dosaženo vysoké úspěšnosti (91–96 % v závislosti na konkrétní třídě a nastavení klasifikátoru). Experimenty proběhly na sadě 2 697 vzorků, polovina byla použita pro trénování, na zbytku byl klasifikátor otestován.


Z dosažených výsledků ještě není možné vyvodit jednoznačný závěr o přesnosti klasifikace. Důvodem je malé množství testovaných částic. Přesnost výsledku může být ovlivněna náhodným výběrem dat a nelze vyloučit, že při testování jiné sady vzorků by byly výsledky odlišné (horší/lepší).

7.1 Upravená definice klasifikačních tříd

První experimenty ukázaly, že úspěšnost klasifikace částic je vysoká, méně přesné byly výsledky rozpoznání tříd fatigue a sliding navzájem. Obě třídy jsou dobře rozpoznatelné od ostatních, ale v praxi se objevuje rovněž značné množství částic, většinou menších rozměrů, které jsou na pomezí obou tříd a nelze je jednoznačně zařadit ani do jedné z těchto tříd. Tyto částice ale musí být také klasifikovány, jinak by značně zvýšily chybu klasifikace. Na základě výsledků experimentů tak byla klasifikace rozšířena o třídu fatigue/sliding, která obsahuje tyto obtížně zařaditelné částice. Pro další experimenty tak byly klasifikace rozšířena na pět tříd (obr. 59).



Obr. 59a) Původní definice klasifikačních tříd



Obr. 59b) Upravená definice klasifikačních tříd

V přípravě na další testy bylo pomocí LNF pořízeno větší množství dat. Tato data (obrazy částic) měla stejné parametry jako data pořízená pro první experimenty, obě sady jsou tedy srovnatelné. Klasifikátor byl nově trénován pro pět tříd – cutting, fatigue, sliding, sphere + nová třída fatigue/sliding obsahující nerozlišitelné částice.

7.2 Průběh a výsledky klasifikace částic z LNF

Přesnost klasifikace závisí především na množství a kvalitě trénovacích dat. Pro trénování klasifikátoru byly opět použity obrazy částic z přístroje LNF. Toto zařízení je zároveň schopno klasifikovat jednotlivé částice, ale jeho hlavním zaměřením je sledování dlouhodobých trendů opotřebení. Přesná klasifikace jednotlivých částic není z tohoto hlediska zásadně důležitá. Výstupem LNF jsou binární obrazy částic, které jsou v případě potřeby ještě „ručně“ překlasifikovány expertem. V konečném důsledku tak bylo dosaženo přesného zařazení trénovacích dat do klasifikačních tříd.

7.2.1 Parametry experimentálních dat

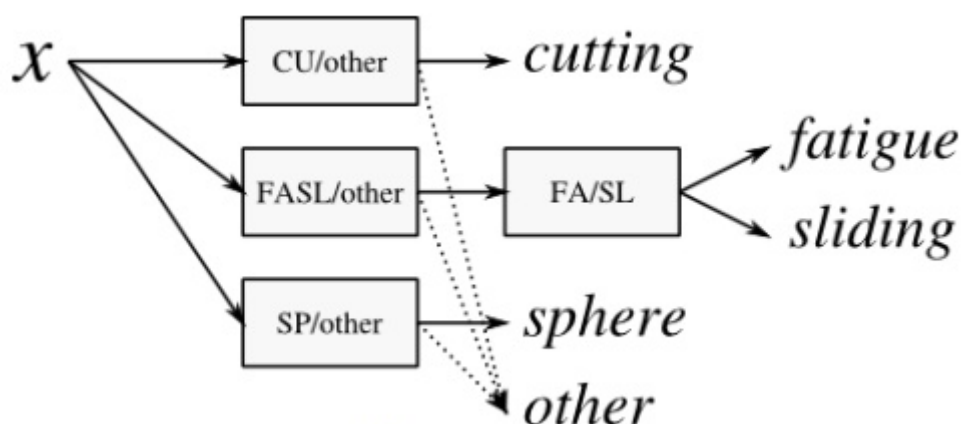
Parametry obrazů částic jsou dány vlastnostmi LNF. Při klasifikaci hraje roli rovněž velikost částic, rozlišení obrazu je dáno rozlišením snímače LNF. Proto 1 pixel obrazu odpovídá reálné velikosti 2,4 mikrometru. Klasifikovány jsou částice, jejichž hlavní osa je větší než 20 mikrometrů.

7.2.2 Průběh a výsledky experimentu

Cílem dalšího experimentu bylo ověřit přesnost klasifikace na větším množství dat. Celkem bylo použito 8502 obrazů částic, cca 500 obrazů z každé třídy bylo použito na

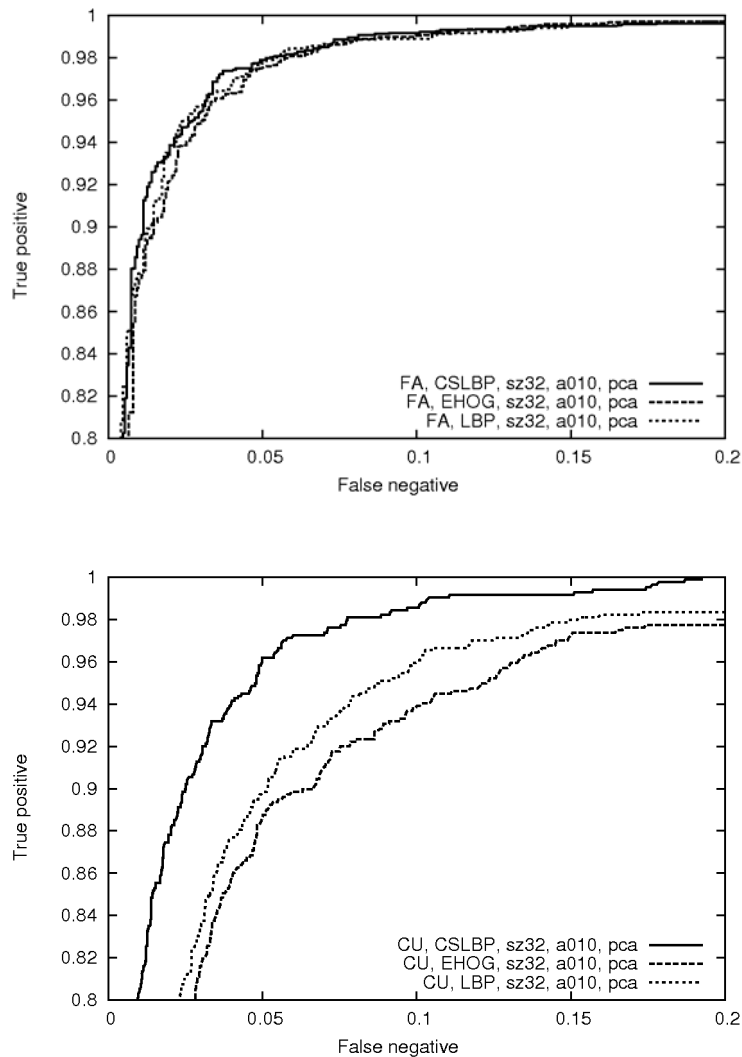
trénování, zbytek posloužil k ověření funkčnosti a zjištění přesnosti klasifikace. Větší množství částic bylo ponecháno pro otestování klasifikátorů kvůli přesnějšímu odhadu chyby (hladší průběh ROC křivek). Všechny částice byly předem klasifikovány expertem.

Pro realizaci experimentů byly vytvořeny čtyři binární klasifikátory. Schéma jejich použití je znázorněno na obr. 60. Pro každé nastavení parametrů normalizace byl vytvořen dataset, na kterém byl každý klasifikátor natrénován a otestován. Klasifikátor označený CU vyhodnocuje částice třídy Cutting, klasifikátor SP vyhodnocuje částice třídy Sphere. Kvůli komplikovanému vyhodnocení „nerozpoznatelných“ částic, které jsou na pomezí tříd Sliding a Fatigue byl vytvořen klasifikátor FASL, který od sebe oddělí částice Cutting nebo Sphere na jedné straně a částice Fatigue, Sliding a „nerozpoznatelné“ Fatigue/Sliding na straně druhé. Tyto částice jsou posléze hodnoceny klasifikátorem FA, který rozpozná částice třídy Fatigue. Podobně by klasifikátor SL vyhodnotil částice třídy Sliding. Klasifikátor SL není potřeba implementovat, třída Sliding je doplňkem k třídě Fatigue.



Obr. 60: Postup analýzy částice X prostřednictvím čtyř binárních klasifikátorů


Z dosažených výsledků, ve kterých jsou zahrnuty výsledky testování CSLBP, EHOG a LBP příznaků, vyplývá, že vhodnými příznaky, které pro obrazy částic opotřeбенí vedou k nejlepším průměrným hodnotám přesnosti klasifikace, jsou příznaky CS LBP. Zatímco v některých situacích je vliv výběru příznaku minimální (obr. 61), při jiném nastavení jsou rozdíly mezi příznaky zřejmé (obr. 62). V dalších experimentech již byly uvažovány především tyto příznaky. Podobně nebyl nadále zkoumán vliv rotace částic – její vliv na přesnost klasifikace je jednoznačně pozitivní, a proto byla rotace v rámci normalizace nadále prováděna automaticky.



Obr. 61–62: Vliv typu příznaku na přesnost klasifikace (testovány příznaky CSLBP, EHO, LBP)


Cílem dalších experimentů prováděných nad CS LBP příznaky bylo ověřit optimální parametry normalizace. Výsledky potvrdily předpoklady získané v průběhu prvních experimentů (kap. 6). I pro větší množství dat platí stejná pravidla a stejné nastavení klasifikátoru.

Vliv velikosti obrazů částic na přesnost klasifikace není významný (obr. 63), finální verze klasifikátoru byla trénována daty o rozměrech 32×32 pixelů; tyto rozměry jsou téměř ve všech případech vyhodnoceny jako optimální.




Obr. 63: Vliv velikosti obrazů na přesnost klasifikace

Vliv normalizačního faktoru α na přesnost klasifikace je pro velikost obrazu 32 pixelů demonstrován na obr. 64. V tomto případě nelze jednoznačně zvolit optimální hodnotu normalizačního faktoru, pro některá nastavení je nejlepších výsledků dosaženo pro hodnoty $\alpha = 0,05/0,1/0,2$. Rozdílně nastavení vede k menším rozdílům ve výsledné chybovosti klasifikátoru u jednotlivých tříd, záleží tedy na konkrétním případě použití a potřebám, na kterou ze tříd je kladen největší důraz a kde tedy je požadována minimální chybovost.



Obr. 64: Vliv normalizačního faktoru na přesnost klasifikace

Celkově bylo v průměru nejlepších výsledků (nejnižších hodnot chybovosti klasifikátoru) dosaženo pro hodnotu normalizačního faktoru $\alpha = 0,1$ a velikost obrazu 32 pixelů (obr. 65).



Obr. 65: Přesnost klasifikátorů při vybraném nastavení parametrů normalizace

V tab. 11 jsou uvedeny výsledky udávající hodnoty chybovostí jednotlivých klasifikátorů pro vybraná nastavení. Nejlepší dosažené výsledky jednotlivých klasifikátorů jsou vyznačeny tučně. I v tomto případě platí důležité pravidlo, že při nasazení v reálné aplikaci může každý klasifikátor pracovat s vlastními (a tedy optimálními) hodnotami parametrů normalizace. Podobně je možné přizpůsobit i výběr obrazových příznaků. Klasifikátory jsou nastaveny tak, aby počet chyb false positives byl stejný jako počet false negatives.

% chyba	$\alpha = 0,05$	$\alpha = 0,1$	$\alpha = 0,2$
Cutting	6,45/7,16	4,79/7,04	4,79/6,69
Fatigue/Sliding	8,96/9,21	7,88/8,58	8,15/8,17
Sphere	4,70/3,50	4,55/ 2,85	4,29/2,98
Fatigue	3,13/3,73	3,40/3,54	3,65/3,59

Tab. 11: Dosažené chybovosti klasifikace částic pro různé hodnoty normalizačního faktoru (příznaky CS LBP/LBP), velikost vzorků (obrazů) je 32 pixelů, faktor pokrytí 0,8

Přehled kompletních výsledků pro všechna nastavení klasifikátorů je uveden v Příloze 1.

7.2.3 Zhodnocení funkčnosti klasifikátoru na LNF datech

Výsledky dosažené v experimentech potvrdily, že s rostoucím počtem trénovacích dat roste i přesnost klasifikace. Dosažené hodnoty přesnosti jsou z hlediska tribotechnické diagnostiky velmi dobré, a pokud budou dlouhodobé výsledky podobné, je automatická

klasifikace jednoznačně přínosem. Do budoucna se předpokládá další rozšiřování databáze trénovacích dat, nicméně již v tuto chvíli lze považovat přesnost klasifikace za velmi dobrou.

Dalším důležitým krokem je ověření funkčnosti klasifikátoru na datech pořízených mikroskopicky, na kterých jsou zachyceny částice získané metodou analytické ferrografie. Nutno zdůraznit, že i když jsou testované částice pořizovány jinou technologií (jsou segmentovány z obrazu ferrogramu), v průběhu normalizace jsou transformovány stejným způsobem jako částice trénovací. Původ a způsob získávání částic tak nemá podstatný vliv na přesnost klasifikace. Tento předpoklad byl předmětem závěrečných testů popsanych v následujícím textu.

7.3 Průběh a výsledky klasifikace částic z ferrogramů

Závěrečným a rozhodujícím krokem celého experimentu bylo ověření funkčnosti klasifikátoru na datech získaných segmentací částic zachycených na reálných ferrogramech.

Pro testování byly použity následující vzorky:

- Motorové oleje pro dopravní prostředky (osobní a nákladní automobily s benzínovými, naftovým a plynovými motory, autobusy, hnací vozidla ČD řady 730, 731, 742, 751, 810, 814 a 854, bojová a speciální vozidla AČR), pro zemědělské stroje (traktory, kombajny), pro lesní a stavební stroje (tahače, těžké nákladní automobily, rypadla a nakladače), pro silniční a terénní motocykly
- Převodové oleje (osobní a nákladní automobily, autobusy, hnací vozidla ČD ř. 810 a 814, vozidla AČR – vyprošťovací tank VT-55, zemědělské stroje, průmyslové převodovky (automatické válcovací stroje, radary)
- Hydraulické oleje (hydraulické nakladače, lisy, zemní stroje KAISER a POCLAIN, frézy a soustruhy, vysoko zdvižné vozíky, hydrodynamické převodovky v hnacích vozidlech řady 854 a 850)
- Průmyslové oleje (kompresorové oleje z chladících kompresorů) aj.

7.3.1 Průběh a výsledky experimentu

Jednotlivé klasifikátory byly natrénovány všemi dostupnými částicemi získanými z LNF. Všechny částice byly nejprve zařazeny do správné třídy expertem. Klasifikační schéma je stejné jako v předchozím případě, klasifikátory CU a SP vyhodnotí částice tříd Cutting, resp. Sphere, klasifikátor FASL rozpozná zbylé částice. Z nich posléze klasifikátor


FA vybere částice třídy Fatigue. Takto natrénovaný klasifikátor byl otestován částicemi získanými z ferrogramů. Počty trénovacích i testovacích částic jsou uvedeny v tab. 12.

Klasifikační třída	Počet trénovacích částic	Počet testovacích částic
Cutting	1337	79
Fatigue	2670	279
Sliding	2003	101
Sphere	885	20
Fatigue/Sliding	1607	300


Tab. 12: Počty trénovacích a testovacích částic jednotlivých klasifikačních tříd

Všechny částice byly podrobeny normalizaci při dodržení stejných pravidel, jaké byly definovány v předchozích experimentech. Na základě předchozích výsledků byly provedeny experimenty s příznaky CS LBP a LBP. Ve všech případech byla v rámci normalizace provedena jednotná rotace částic podle hlavní osy. Velikost obrazu při testování byla 24×24 a 32×32 pixelů. Testované hodnoty normalizačního faktoru byly 0,05; 0,1 a 0,2, to vše pro klasifikátory CU, SP, FASL a FA.

Na následujících obrázcích (obr. 66–67) jsou prezentovány ROC křivky zachycující vliv použitého nastavení na přesnost klasifikátorů. Oproti předchozím experimentům nejsou průběhy jednotlivých křivek tak hladké, což je způsobeno menším počtem testovaných dat (částic).



Obr. 66: Vliv velikosti obrazu na přesnost klasifikace




Obr. 67: Vliv normalizačního faktoru na přesnost klasifikace

Vybrané výsledky klasifikace částic z ferrogramů jsou uvedeny v tab. 13. V závislosti na konkrétních potřebách je možné upravit parametry normalizace a tím ovlivnit přesnost klasifikace vybraných tříd.

% chyba	$\alpha = 0,05$	$\alpha = 0,1$	$\alpha = 0,2$
Cutting	4,19/6,40	4,07/5,35	3,02/1,74
Fatigue/Sliding	3,68/7,33	6,05/6,28	8,61/5,12
Sphere	1,97/3,14	1,62/1,62	0,58/1,28
Fatigue	2,10/4,73	1,57/2,10	7,10/4,21

Tab. 13: Dosažené chybovosti klasifikace částic pro různé hodnoty normalizačního faktoru (příznaky LBP/CS LBP), velikost vzorků (obrazů) je 32 pixelů, faktor pokrytí 0,8

V průměru se při použití CS LBP příznaků jeví jako optimální následující nastavení (obr. 68), velikost obrazu 32 pixelů, normalizační faktor $\alpha = 0,2$. Přehled kompletních výsledků pro všechna nastavení klasifikátorů je uveden v Příloze 2.



Obr. 68: Přesnost klasifikace při v průměru nejlepším nastavení

7.3.2 Zhodnocení dosažené klasifikační chyby

Chybovost klasifikace, která se pohybuje pro většinu nastavení pod hranicí 10 %, je pro účely tribotechnické diagnostiky velmi dobrá a automatizace celého procesu hodnocení opotřebenění je tak přínosem pro praxi. Navíc lze předpokládat, že s rostoucím počtem trénovacích částic bude chybovost klasifikátoru klesat.

Pro srovnání je možno uvést, jakých výsledků bylo dosaženo ve světě při vývoji a testování podobných systémů automatické klasifikace – např. Podsiadlo a Stachowiak [3], kteří při analýze otěrových částic vycházejí z textury jejich povrchu, uvádějí při optimálním nastavení chybu klasifikace cca 3 %. Této hodnoty bylo dosaženo pro zjednodušenou definici tříd opotřebenění a v práci dosažená přesnost klasifikace je tak lepší, než je přesnost této zjednodušené klasifikace. Klasifikátor [3] využívá metodu podpůrných vektorů. Pro trénování a testování klasifikátoru autoři použili celkem 960 obrazů částic. Další výhodou postupu navrženého v předkládané práci je jeho univerzálnost,

Cho [2] uvádí chybu v rozmezí 0–23 % v závislosti na vybraném datasetu částic (v experimentu je použito 11 datasetů). Klasifikátor je založen na metodě shlukové analýzy, analyzovány jsou především morfologické parametry částic.

Stachowiak, Stachowiak a Podsiadlo [1] dosáhli při klasifikaci založené na analýze povrchu částic chybovosti 3–9 %. V tomto případě autoři extrahovali z obrazu celkem 44 příznaků, aplikací metody hlavních komponent snížili jejich počet na 3 a následně klasifikovali metodou podpůrných vektorů. Nízkých chybovostí bylo dosaženo i díky zjednodušení klasifikace pouze na třídy adhezivních a abrazivních částic. V rámci každé třídy

autoři rozlišují 4 podtřídy při snaze o zachycení míry opotřebení. Z hlediska tribotechnické diagnostiky se jedná o úzce zaměřenou úlohu, v tomto výčtu je uvedena kvůli využití podobných přístupů ke klasifikaci.

Autor	Přesnost
Podsiadlo, Stachowiak [3]	~ 3 %
Cho [2]	0–23 %
Stachowiak [1]	3–9 %
Machalík	1–8 %

Tab. 14: Souhrn hodnot přesnosti klasifikace částic publikovaných v literatuře

Aktuální informace a podrobnosti včetně ukázek zpracování dat a průběžných výsledků jsou k dispozici na <http://medusa.fit.vutbr.cz/particles/> [45].

8 Závěr

Metody umožňující zjištění, analýzu a hodnocení průběhu a stupně opotřebení sledovaných zařízení nabývají v posledních letech na významu. V současné době se intenzivně rozvíjejí instrumentální metody, které mohou přinést řadu údajů o průběhu a stupni opotřebení strojních mechanismů na základě analýzy mazacích olejů. Doposud zkoumané postupy hodnocení olejů jako média nesoucího informace o stavu mazaného systému a výsledky těchto procesů prezentují pouze některé možnosti uplatnění obrazové analýzy v oblasti tribodiagnostiky. Současným trendem je snaha o automatizaci procesu hodnocení opotřebení. Jedním z nových přístupů je automatická klasifikace částic opotřebení pomocí metod strojového učení, která byla i předmětem této práce.

Cílem této práce bylo prověřit možnosti automatické klasifikace částic opotřebení v návaznosti na metodu analytické ferrografie, která je v současnosti využívána jak ke kvantitativnímu, tak kvalitativnímu hodnocení stavu strojních zařízení. Práce eliminuje hlavní nedostatek této metody, kterým je možný negativní vliv lidského faktoru při často subjektivním posuzování ferrogramů. Klasifikátor umožňuje provádět analýzu stavu sledovaných zařízení, která se tak stává mnohem dostupnější. Díky využití automatického klasifikátoru se hodnocení stává objektivnějším, jednodušším a v neposlední řadě také levnějším řešením.

Výstupem práce je postup návrhu a implementace automatického klasifikátoru částic opotřebení, který využívá metody strojového učení (konkrétně algoritmus Real AdaBoost) k analýze obrazů částic. Tyto obrazy jsou podrobeny normalizaci a následně jsou vstupem pro učení (trénování) klasifikátoru. V průběhu trénování jsou v obrazech částic vyhodnocovány specifické příznaky (nejlepších výsledků bylo dosaženo s CS LBP příznaky), které jsou poté při klasifikaci vyhledávány v testovaných obrazech.

Přesnost klasifikace je do značné míry závislá na množství a správném zařazení trénovacích částic. Pro trénování klasifikátoru byly použity obrazy částic získané pomocí laserového analyzátoru částic, který na základě využití laserové technologie umožňuje získat obrazy částic obsažených ve vzorku maziva. Tyto částice byly nejprve expertem zařazeny do vybraných tříd opotřebení, poté byly vstupem pro trénování. V současnosti databáze obsahuje cca 9000 obrazů částic, další budou průběžně doplňovány.

Primárním účelem klasifikátoru je vyhodnocení částic separovaných z ferrogramů. Částice jsou zachyceny na snímcích pořízených prostřednictvím optického mikroskopu

s dostatečným zvětšením. Obrazy jednotlivých částic jsou poté normalizovány stejným způsobem jako obrazy trénovací. Experimentálně bylo ověřeno, že trénovací i testovaná data jsou po normalizaci srovnatelná a způsob jejich pořízení nemá vliv na přesnost klasifikace.

V průběhu experimentů byly zkoušeny různé metody strojového učení, z nichž nejlepších výsledků bylo dosaženo při použití algoritmu Real AdaBoost. Uspokojivě dopadly rovněž testy alternativní metody podpůrných vektorů, kterou je možné rovněž použít. Experimentálně bylo ověřeno, že metoda AdaBoost má při klasifikaci obrazu srovnatelné, ale v mnoha případech i lepší výsledky než metoda SVM nebo neuronové sítě. Pro potřeby metody strojového učení je nutný matematický popis obrazu v podobě obrazových příznaků. Jako vhodné byly vyhodnoceny CS LBP a LBP příznaky. Standardně jsou klasifikátory nastaveny na úroveň Equal Error Rate, kdy je počet chyb false positives roven počtu false negatives. Výhodou může být možnost v případě potřeby tento parametr změnit.

Použití normalizace obrazů částic má zásadní vliv na přesnost klasifikace. Experimentální zjištění optimálních hodnot parametrů normalizace umožnilo dosáhnout vyšší přesnosti klasifikace a je tak stěžejním krokem ve fázi přípravy vstupních dat pro klasifikaci. Návrh a praktické ověření vlastní metodiky normalizace jsou hlavním přínosem této práce.

Dosažené výsledky ukazují, že využití automatické klasifikace částic v provozu může přinést prakticky využitelné výsledky, které mnohdy nelze získat jinými metodami. V době odevzdání práce je chybovost klasifikace pod hranicí 10 % v závislosti na nastavení klasifikátoru a testované třídě. Lze očekávat, že v reálných aplikacích bude při zpracování dalších vzorků z provozu vzhledem ke statistickému zpracování dat přesnost klasifikace vyšší.

Dosažená přesnost přináší zlepšení oproti dosavadním výsledkům, kdy jsou ferrogramy hodnoceny vyškoleným pracovníkem, ale výsledek je zatížen chybou subjektivního posouzení. I při znalosti pravidel klasifikace částic nepřesahuje u neškoleného pracovníka-laboranta provádějícího vyhodnocení pouze srovnáním s atlasem částic jeho úspěšnost 60–70 %. Při dostatečně rozsáhlé databázi vhodným způsobem normalizovaných vzorků se klasifikace založená na metodách strojového učení jeví jako výhodná a dosažené výsledky jsou příslibem do dalšího vývoje a zpřesňování výsledků klasifikátoru. Cíle stanovené na začátku řešení se tak podařilo splnit.

Vytvořený nástroj pro klasifikaci částic bude v praxi využíván především pro sledování průběhu opotřebení na vzorcích postupně odebíraných v delším časovém intervalu za účelem trendové analýzy. Hodnocení aktuálního stavu na základě jednoho měření je

problematické, množství a tvary částic se mohou lišit pro různá strojní zařízení. Klasifikátor bude zpočátku využíván v laboratořích Dopravní fakulty Jana Pernera Univerzity Pardubice.

Dalším rozšířením práce by mohlo být vytvoření nástroje pro automatickou segmentaci obrazů částic z ferrogramu. Vzhledem ke značné různorodosti vzhledu ferrogramů nebyl tento krok řešen v rámci dizertační práce, řešením by bylo vytvoření samostatné aplikace (případně modulu) využívající pokročilé mikroskopické metody (motorizovaný stolek, softwarové skládání obrazu, vytváření 3D obrazu apod.), jejíž použití by předcházelo procesu normalizace obrazů částic. Problematika detekce objektů v obraze je řešena i na ÚPGM FIT VUT Brno, vytvoření tohoto modulu je plánováno na rok 2012.

Literatura

- [1] STACHOWIAK, G. P.; STACHOWIAK, G. W.; PODSIADLO, P. Automated classification of wear particles based on their surface texture and shape features. *Tribology International*, volume 41, issue 1, 2008, s. 34-43, ISSN 0301-679X.
- [2] CHO, U., TICHY, J. A. Quantitative correlation of wear debris morphology: grouping and classification. *Tribology International*, volume 33, issue 7, 2000, s. 461-467, ISSN 0301-679X.
- [3] PODSIADLO, P., STACHOWIAK, G. W. Development of advanced quantitative analysis methods for wear particle characterization and classification to aid tribological system diagnosis. *Tribology International*, volume 38, issue 10, 2005, s. 887-897, ISSN 0301-679X.
- [4] Kolektiv autorů, *Tribotechnika*, Praha: SNTL, 1984.
- [5] *Degradace strojních součástí* [online].[cit. 1. září 2010].
Dostupné na WWW: <http://degradace.tf.czu.cz/Dgrd_txt/Mngr_ram_txt2.htm>.
- [6] Firemní materiály ReoTrade, s.r.o., Atlas otěrových částic pro ferrografii.
- [7] ROYLANCE, B. J., HUNT, T. *Wear debris analysis handbook*, Oxford: Coxmoor Publishing Company, 1999, 118 s, ISBN 1901892026.
- [8] ČSN 015050: *Opotřebení materiálu. Názvosloví*.
- [9] STRAKA, B. *Motorové oleje a tribotechnická diagnostika naftových motorů*, Praha: Nadas, 1986.
- [10] *Oleje a vše o nich*. [online].[cit. 11. září 2006].
Dostupné na WWW: <<http://skoda.panda.cz/clanek.php3?id=406>>.
- [11] STACHOWIAK, G. W. Numerical characterization of wear particles morphology and angularity of particles and surfaces. *Tribology International*, volume 31, issues 1-3, 1998, s. 139-157, ISSN 0301-679X.
- [12] NAZAR, A. M., SILVA, F. A., AMMANN, J. J. Image Processing for Particle Characterization. *Elsevier Science*, volume 36, issues 4-5, State University of Campinas, Brazílie, 1996.
- [13] XU, K., LUXMOORE, A. R., JONES, L. M., DERAVIDI, F. Integration of neural networks and expert systems for microscopic wear particle analysis. *Knowledge-Based Systems*, volume 11, issues 3-4, 1998, s. 213-227.
- [14] XU, K., LUXMOORE, A. R. An integrated system for automatic wear particle analysis. *Wear*, volume 208, issues 1-2, 1997, s. 184-193, ISSN 0043-1648.
- [15] RAADNUI, S. Wear particle analysis – utilization of quantitative computer image analysis: A review. *Tribology International*, volume 35, issue 10, 2005, s. 871-878, ISSN 0301-679X.
- [16] LUXMOORE, A.R., DAVIES, T., THOMAS, A.D.H. Computer image analysis for identification of wear particles. *Wear*, volume 142, issue 2, 1991, s. 213-226. ISSN 00431648.

- [17] UMEDA, A., SUGIMURA, J., YAMAMOTO, Y. Characterization of wear particles and their relations with sliding conditions. *Wear*, volume 216, issue 2, 1998, s. 220-228. ISSN 00431648.
- [18] LIM Praha, LUCIA – příručka uživatele.
- [19] KRTIČKA, F. *Obrazová analýza částic v provozních hmotách a konstrukčních materiálech pro dopravní prostředky*. Diplomová práce, Dopravní fakulta Jana Pernera, Univerzita Pardubice, Pardubice, 2007.
- [20] PEŠA, J. *Obličejový anonymizér*. Bakalářská práce, Fakulta informačních technologií, Vysoké učení technické v Brně, Brno, 2009.
- [21] *Neural backpropagation* [online]. [cit. 17. duben 2011].
Dostupné na WWW: <http://en.wikipedia.org/wiki/Neural_backpropagation>
- [22] *Shluková analýza* [online]. [cit. 17. duben 2011].
Dostupné na WWW:
<http://cs.wikipedia.org/wiki/Shlukov%C3%A1_anal%C3%BDza>.
- [23] VAPNIK V. N., LERNER A. Pattern Recognition Using Generalized Portrait Method. *Automation and Remote Control*, volume 6, issue 24, 1963, s. 774-780, ISSN 1608-3032.
- [24] *Support Vector Machines* [online]. [cit. 25. květen 2011].
Dostupné na WWW: <<http://www.statsoft.com/textbook/support-vector-machines>> .
- [25] FREUND, Y., SCHAPIRE, A. A Decision-theoretic Generalization of On-line Learning and an Application to Boosting. In *EuroCOLT '95 Proceedings of the Second European Conference on Computational Learning Theory*, Springer-Verlag London, 1995, ISBN 3-540-59119-2.
- [26] SCHAPIRE, R. E., SINGER, Y. Improved Boosting Algorithms Using Confidence-rated Predictions. *Machine Learning*, volume 37, issue 3, 1999, ISSN 0885-6125.
- [27] ŠOCHMAN, J., MATAS, J. WaldBoost – Learning for Time Constrained Sequential Detection. In *Proceedings CVPR05*, volume 2, IEEE Computer Society, 2005, s. 150-156, ISSN 1063-6919.
- [28] LI, S. Z., ZHANG, Z. Q., SHUM, H., ZHANG, H. J. FloatBoost learning for classification. In *Proceedings of NIPS*, MIT Press, USA, 2002.
- [29] ŠOCHMAN, J., MATAS, J. Adaboost with totally corrective updates for fast face detection. In *Proceedings of the Sixth IEEE international conference on Automatic face and gesture recognition AFGR04*, IEEE Computer Society, 2004, s. 445-450, ISBN 0-7695-2122-3.
- [30] BISHOP, C. M. *Pattern Recognition and Machine Learning*. Springer, Belgium, 2006, ISBN 978-0-387-31073-2.
- [31] DELAC, K.; GRGIC, M. *Face Recognition*. I-TECH Education and Publishing, Vienna, Austria, 2007, ISBN 3-86611-283-1.
- [32] DUDA, R. O., HART, P. E., STORK, D. G. *Pattern Classification*. Wiley-Interscience, USA, 2001, ISBN 0-471-05669-3.
- [33] WRHEL, V. *Rozpoznávání vzorů v obraze pomocí AdaBoost*. Diplomová práce, Fakulta informačních technologií, Vysoké učení technické v Brně, Brno, 2010.

- [34] VIOLA, P., JONES, M. Rapid Object Detection using a Boosted Cascade of Simple Features. In *Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, IEEE Computer Society, volume 1, 2001, s. 511-518, ISSN 1063-6919.
- [35] HOCHMAN, Z. *Sledování pohybujících se objektů ve videosekvenci*. Diplomová práce, Fakulta informačních technologií, Vysoké učení technické v Brně, Brno, 2010.
- [36] *Object detection overview* [online]. [cit. 17. duben 2011].
Dostupné na WWW:
<http://medusa.fit.vutbr.cz/wiki/index.php/Object_detection_overview>.
- [37] DALAL, N., TRIGGS, B. Histograms of Oriented Gradients for Human Detection. In *Proceedings of the 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, IEEE Computer Society, volume 1, 2005, s. 886-893, ISBN 0-7695-2372-2.
- [38] ZHU, Q., YEH, M.C., CHENG, K.T., AVIDAN, S. Fast Human Detection Using a Cascade of Histograms of Oriented Gradients. In *Proceedings of the 2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, IEEE Computer Society, 2006, s. 1491-1498, ISSN 1063-6919.
- [39] HOU, C., AI, H., LAO, S. Multiview Pedestrian Detection Based on Vector Boosting. *Computer science*, volume 4843, 2007, s. 210-219.
- [40] HEROUT, A., ZEMČÍK, P., HRADIŠ, M., JURÁNEK, R., HAVEL, J., JOŠTH, R., ŽÁDNÍK, M. Low-Level Image Features for Real-Time Object Detection, *Pattern Recognition*, Recent Advances, Vienna, Austria, IN-TECH, 2010, s. 111-136, ISBN 978-953-7619-90-9
- [41] TUREČEK, M. *Detekce obličejů v obraze z kamery na mobilním telefonu s WM*. Diplomová práce, Fakulta informačních technologií, Vysoké učení technické v Brně, Brno, 2010.
- [42] HEIKKILÄ, M., PIETIKÄINEN, M., SCHMID, C. Description of interest regions with local binary patterns. *Pattern Recognition*, volume 42, issue 3, 2009, s. 425-436.
- [43] JURÁNEK, R. *Pattern Recognition Using Classifiers*. Diplomová práce, Fakulta informačních technologií, Vysoké učení technické v Brně, Brno, 2007.
- [44] BORTLÍČEK, Z. *ROC křivky*. Diplomová práce, Přírodovědecká fakulta, Masarykova Univerzita v Brně, Brno, 2008.
- [45] JURÁNEK, R., MACHALÍK, S., ZEMČÍK, P. *Wear debris analysis* [online] [cit. 17. květen 2011]. Dostupné na WWW: <<http://medusa.fit.vutbr.cz/particles/>>.
- [46] JURÁNEK, R., MACHALÍK, S., ZEMČÍK, P. Analysis of Wear Debris Through Classification. In *Proceedings of ACIVS*, Springer, Belgium, 2011. (v tisku)

Seznam obrázků, tabulek a zkratk

Seznam obrázků

- Obr. 1: Mechanismus adhezivního opotřebení + Adhezivní opotřebení pístního čepu
- Obr. 2: Mechanismus adhezivního opotřebení + Abrazivní opotřebení pístu spalovacího motoru
- Obr. 3: Mechanismus únavového opotřebení + Únavový lom spojkové hřídele
- Obr. 4: Mechanismus kavitačního opotřebení + Kavitační opotřebení pouzdra válce spalovacího motoru
- Obr. 5: Mechanismus vibračního opotřebení + Vibrační opotřebení valivého ložiska
- Obr. 6: Mechanismus erozivního opotřebení + Erozivní opotřebení koule uzávěru
- Obr. 7: Laminární částice se stopami abrazivního opotřebení
- Obr. 8: Únavové částice typického kulovitého tvaru
- Obr. 9: Kombinace částic vzniklých ve smíšených režimech opotřebení s převažujícími částicemi adhezivními (v řetízcích) a laminárními
- Obr. 10: Množství částic opotřebení v průběhu životního cyklu zařízení
- Obr. 11: Vliv zásahu do zařízení (opravy) v průběhu na množství částic opotřebení
- Obr. 12: Životní cyklus zaznamenaný v ilustrativních ferrogramech
- Obr. 13: Počáteční fáze provozu (záběh), motor v provozu 9 hodin
- Obr. 14: Období stability, minimální opotřebení, motor v provozu 254 hodin
- Obr. 15: Období stability, minimální opotřebení, motor v provozu 367 hodin
- Obr. 16: Období stability, začínající opotřebení, motor v provozu 411 hodin
- Obr. 17: Končící období stability, zvýšené opotřebení, motor v provozu 534 hodin
- Obr. 18: Vztah základních parametrů částic a charakteristiky opotřebení
- Obr. 19: Základní schéma metody analytické ferrografie
- Obr. 20: Horizontální a vertikální feret
- Obr. 21: Nejmenší a největší feret
- Obr. 22: ECAD, LBC
- Obr. 23: CPM, ECPD
- Obr. 24: HMD, VMD
- Obr. 25: LBRL, LBRW
- Obr. 26: FL, FW
- Obr. 27: Histogram rozložení velikostí částic ve vzorku
- Obr. 28: Přehled jednotlivých identifikovaných částic (větších než 20 μm)
- Obr. 29: Morfologické operace nad binárním obrazem
- Obr. 30: Originál fotografie ferrogramu (vlevo) a fotografie v barevném prostoru HSI
- Obr. 31: Naprahovaný obraz (vlevo), po binarizaci (vpravo)
- Obr. 32: Výsledky měření
- Obr. 33: Původní obraz (vlevo) a výsledky měření po segmentaci částic (vpravo)
- Obr. 34: Fotografie části ferrogramu po provedení morfologických úprav + Výsledky vyhodnocení typu opotřebení pomocí programového makra

- Obr. 35: Originální fotografie části ferrogramu + Výsledky vyhodnocení typu opotřebení pomocí programového makra
- Obr. 36: Originální fotografie části ferrogramu + Obraz po segmentaci částic
- Obr. 37: Vyjádření správných a chybných rozhodnutí klasifikátoru
- Obr. 38: Obecný průběh ROC křivky
- Obr. 39: Schematický model neuronu se vstupy x_0 až x_n a výstupní funkcí y
- Obr. 40: Vícevrstvá dopředná neuronová síť + Hopfieldova rekurentní neuronová síť
- Obr. 41: Příklad lineární klasifikace + Klasifikace reálné situace
- Obr. 42: Mapování klasifikovaných objektů v rámci SVM
- Obr. 43: Výpočet LBP příznaku středového pixelu
- Obr. 44: Základní tvary Haarových příznaků
- Obr. 45: Způsob získání CS LBP příznaku pro středový pixel
- Obr. 46: V rámci ferrogramu jsou některé částice zachyceny s dostatečnou přesností (1, 2, 3), některé je potřeba zaostřit lépe (4, 5, 6)
- Obr. 47: Obrazy částic, které jsou po normalizaci vstupem učení klasifikátoru
- Obr. 48: Originální obrazy částic před normalizací + Obrazy částic po normalizaci, s rotací
- Obr. 49: Postup normalizace obrazu: a) původní obraz s nalezenou hlavní a vedlejší osou částice, b) normalizace velikosti obrazu, bez rotace, c) rotace obrazu podle hlavní osy částice, d) normalizovaný obraz s rotací
- Obr. 50: Závislost velikosti částice v obrazu po normalizaci na skutečné velikosti částice (před normalizací) pro rozsah hodnot normalizačního faktoru \square 0,02 až 0,5. Pro velikost obrazu $w = 24px$
- Obr. 51: Vliv nastavení normalizačního faktoru na obrazy částic po normalizaci
- Obr. 52–55: Vliv velikosti obrazu na výsledky klasifikace (pro jednotlivé třídy)
- Obr. 56: Vliv normalizačního faktoru na přesnost klasifikace
- Obr. 57–58: Porovnání přesnosti klasifikace datasetu, ve kterém byla provedena rotace částic (nahore) a datasetu bez rotace (dole)
- Obr. 59: Původní definice klasifikačních tříd + Upravená definice klasifikačních tříd
- Obr. 60: Postup analýzy částice X prostřednictvím čtyř binárních klasifikátorů
- Obr. 61–62: Vliv typu příznaku na přesnost klasifikace (testovány příznaky CSLBP, EHO, LBP)
- Obr. 63: Vliv velikosti obrazů na přesnost klasifikace (LNF data)
- Obr. 64: Vliv normalizačního faktoru na přesnost klasifikace
- Obr. 65: Přesnost klasifikátorů při vybraném nastavení parametrů normalizace
- Obr. 66: Vliv velikosti obrazu na přesnost klasifikace (ferrogramy)
- Obr. 67: Vliv normalizačního faktoru na přesnost klasifikace
- Obr. 68: Přesnost klasifikace při v průměru nejlepším

Seznam tabulek

Tab. 1: Typické tvary částic opotřebení

Tab. 2: Základní typy částic a jejich popis

Tab. 3: Hodnoty parametrů pro morfologický popis částic

Tab. 4: Priority parametrů podle typu částic

Tab. 5: Ukázka identifikace částic opotřebení

Tab. 6, 7, 8: Datový výstup makra

Tab. 9: Rozdělení částic použitých v experimentu

Tab. 10: Dosažené chybovosti klasifikace částic pro různé hodnoty normalizačního faktoru (bez rotace/s rotací), velikost vzorků (obrazů) je 32 pixelů, faktor pokrytí 0,8

Tab. 11: Dosažené chybovosti klasifikace částic pro různé hodnoty normalizačního faktoru (příznaky CS LBP/LBP), velikost vzorků (obrazů) je 32 pixelů, faktor pokrytí 0,8

Tab. 12: Počty trénovacích a testovacích částic jednotlivých klasifikačních tříd

Tab. 13: Dosažené chybovosti klasifikace částic pro různé hodnoty normalizačního faktoru (příznaky LBP/CS LBP), velikost vzorků (obrazů) je 32 pixelů, faktor pokrytí 0,8

Tab. 14: Souhrn hodnot přesnosti klasifikace částic publikovaných v literatuře

Seznam zkratek

CU – klasifikátor třídy Cutting

FA – klasifikátor třídy Fatigue

FASL – klasifikátor částic Sliding + Fatigue + Sliding/Fatigue

SP – klasifikátor třídy Sphere

(E)HOG – (Extended) Histograms of Oriented Gradients – obrazové příznaky

(CS) LBP – (Center Symmetric) Local Binary Patterns – obrazové příznaky

LRD – Local Rank Differences – obrazové příznaky

ROC – Receiver Operating Characteristic – křivka charakterizující přesnost klasifikátoru

LNF – Laser Net Fines – Laserový analyzátor částic

ECAD – Equivalent Circular Area Diameter – tvarový faktor

LBC – Least Bounding Circle – tvarový faktor

CPM – Convex Perimeter – tvarový faktor

ECPD – Equivalent Circular Perimeter Diameter – tvarový faktor

HMD – Horizontal Martin's Diameter – tvarový faktor

VMD – Vertical Martin's Diameter – tvarový faktor

LBRL – Least Bounding Rectangle Length – tvarový faktor

LBRW – Least Bounding Rectangle Width – tvarový faktor

FL – Fiber Length – tvarový faktor

FW – Fiber Width – tvarový faktor

TP – true positives – správně klasifikované pozitivní případy

TN – true negatives – správně klasifikované negativní případy

FP – false positives – chybně klasifikované pozitivní případy

FN – false negatives – chybně klasifikované negativní případy

EER – Equal Error Rate – hodnota, při které počet true positives = počet false negatives

PCA – Principal Component Analysis – metoda Analýzy hlavních komponent

SVM – Support Vector Machines – Metoda podpurných vektorů

Seznam příloh

Příloha 1 – kompletní výsledky klasifikace LNF obrazů částic

Příloha 2 – kompletní výsledky klasifikace částic z ferrogramů

Příloha 1 – úplné výsledky klasifikace částic z LNF

V této příloze jsou uvedeny výsledky všech experimentů prováděných s kompletní sadou obrazů částic pořízených na přístroji LNF.

Klasifikátor	Příznak	Norm. faktor	Velikost	Rotace	EER chyba
CU	CSLBP	0,02	16	Ne	32,82
CU	EHO	0,02	16	Ne	32,70
CU	LBP	0,02	16	Ne	30,33
FA	CSLBP	0,02	16	Ne	14,23
FA	EHO	0,02	16	Ne	15,32
FA	LBP	0,02	16	Ne	14,53
FASL	CSLBP	0,02	16	Ne	39,51
FASL	EHO	0,02	16	Ne	32,36
FASL	LBP	0,02	16	Ne	34,44
SP	CSLBP	0,02	16	Ne	21,93
SP	EHO	0,02	16	Ne	15,32
SP	LBP	0,02	16	Ne	14,31
CU	CSLBP	0,02	16	Ano	30,99
CU	EHO	0,02	16	Ano	23,11
CU	LBP	0,02	16	Ano	23,51
FA	CSLBP	0,02	16	Ano	25,38
FA	EHO	0,02	16	Ano	18,38
FA	LBP	0,02	16	Ano	16,24
FASL	CSLBP	0,02	16	Ano	33,79
FASL	EHO	0,02	16	Ano	24,16
FASL	LBP	0,02	16	Ano	27,92
SP	CSLBP	0,02	16	Ano	28,41
SP	EHO	0,02	16	Ano	13,23
SP	LBP	0,02	16	Ano	14,91

Klasifikátor	Příznak	Norm. faktor	Velikost	Rotace	EER chyba
CU	CSLBP	0,02	24	Ne	18,17
CU	EHOH	0,02	24	Ne	18,50
CU	LBP	0,02	24	Ne	14,23
FA	CSLBP	0,02	24	Ne	11,32
FA	EHOH	0,02	24	Ne	11,36
FA	LBP	0,02	24	Ne	8,00
FASL	CSLBP	0,02	24	Ne	20,43
FASL	EHOH	0,02	24	Ne	18,48
FASL	LBP	0,02	24	Ne	18,83
SP	CSLBP	0,02	24	Ne	9,86
SP	EHOH	0,02	24	Ne	11,51
SP	LBP	0,02	24	Ne	10,27
CU	CSLBP	0,02	24	Ano	18,15
CU	EHOH	0,02	24	Ano	14,70
CU	LBP	0,02	24	Ano	14,52
FA	CSLBP	0,02	24	Ano	12,70
FA	EHOH	0,02	24	Ano	8,58
FA	LBP	0,02	24	Ano	6,50
FASL	CSLBP	0,02	24	Ano	19,16
FASL	EHOH	0,02	24	Ano	12,97
FASL	LBP	0,02	24	Ano	16,39
SP	CSLBP	0,02	24	Ano	10,15
SP	EHOH	0,02	24	Ano	11,98
SP	LBP	0,02	24	Ano	9,07

Klasifikátor	Příznak	Norm. faktor	Velikost	Rotace	EER chyba
CU	CSLBP	0,02	32	Ne	15,64
CU	EHOH	0,02	32	Ne	17,79
CU	LBP	0,02	32	Ne	11,55
FA	CSLBP	0,02	32	Ne	5,47
FA	EHOH	0,02	32	Ne	8,62
FA	LBP	0,02	32	Ne	6,04
FASL	CSLBP	0,02	32	Ne	17,02
FASL	EHOH	0,02	32	Ne	17,25
FASL	LBP	0,02	32	Ne	15,32
SP	CSLBP	0,02	32	Ne	8,28
SP	EHOH	0,02	32	Ne	8,93
SP	LBP	0,02	32	Ne	6,82
CU	CSLBP	0,02	32	Ano	15,20
CU	EHOH	0,02	32	Ano	11,83
CU	LBP	0,02	32	Ano	12,69
FA	CSLBP	0,02	32	Ano	5,12
FA	EHOH	0,02	32	Ano	6,09
FA	LBP	0,02	32	Ano	3,79
FASL	CSLBP	0,02	32	Ano	15,49
FASL	EHOH	0,02	32	Ano	11,36
FASL	LBP	0,02	32	Ano	13,17
SP	CSLBP	0,02	32	Ano	8,04
SP	EHOH	0,02	32	Ano	7,22
SP	LBP	0,02	32	Ano	6,37

Klasifikátor	Příznak	Norm. faktor	Velikost	Rotace	EER chyba
CU	CSLBP	0,02	48	Ne	10,39
CU	EHOH	0,02	48	Ne	13,71
CU	LBP	0,02	48	Ne	7,63
FA	CSLBP	0,02	48	Ne	4,66
FA	EHOH	0,02	48	Ne	6,29
FA	LBP	0,02	48	Ne	3,59
FASL	CSLBP	0,02	48	Ne	13,11
FASL	EHOH	0,02	48	Ne	13,64
FASL	LBP	0,02	48	Ne	11,55
SP	CSLBP	0,02	48	Ne	5,77
SP	EHOH	0,02	48	Ne	6,19
SP	LBP	0,02	48	Ne	4,74
CU	CSLBP	0,02	48	Ano	6,61
CU	EHOH	0,02	48	Ano	9,68
CU	LBP	0,02	48	Ano	7,91
FA	CSLBP	0,02	48	Ano	4,00
FA	EHOH	0,02	48	Ano	4,19
FA	LBP	0,02	48	Ano	2,99
FASL	CSLBP	0,02	48	Ano	11,64
FASL	EHOH	0,02	48	Ano	8,93
FASL	LBP	0,02	48	Ano	10,24
SP	CSLBP	0,02	48	Ano	5,57
SP	EHOH	0,02	48	Ano	6,03
SP	LBP	0,02	48	Ano	3,99

Klasifikátor	Příznak	Norm. faktor	Velikost	Rotace	EER chyba
CU	CSLBP	0,05	16	Ne	14,58
CU	EHOOG	0,05	16	Ne	15,80
CU	LBP	0,05	16	Ne	11,71
FA	CSLBP	0,05	16	Ne	5,29
FA	EHOOG	0,05	16	Ne	7,90
FA	LBP	0,05	16	Ne	4,74
FASL	CSLBP	0,05	16	Ne	17,51
FASL	EHOOG	0,05	16	Ne	16,01
FASL	LBP	0,05	16	Ne	13,79
SP	CSLBP	0,05	16	Ne	7,15
SP	EHOOG	0,05	16	Ne	7,83
SP	LBP	0,05	16	Ne	5,81
CU	CSLBP	0,05	16	Ano	11,63
CU	EHOOG	0,05	16	Ano	11,19
CU	LBP	0,05	16	Ano	10,31
FA	CSLBP	0,05	16	Ano	4,52
FA	EHOOG	0,05	16	Ano	5,39
FA	LBP	0,05	16	Ano	4,60
FASL	CSLBP	0,05	16	Ano	13,40
FASL	EHOOG	0,05	16	Ano	10,83
FASL	LBP	0,05	16	Ano	13,53
SP	CSLBP	0,05	16	Ano	6,22
SP	EHOOG	0,05	16	Ano	7,62
SP	LBP	0,05	16	Ano	6,44

Klasifikátor	Příznak	Norm. faktor	Velikost	Rotace	EER chyba
CU	CSLBP	0,05	24	Ne	9,48
CU	EHOH	0,05	24	Ne	12,67
CU	LBP	0,05	24	Ne	7,53
FA	CSLBP	0,05	24	Ne	4,60
FA	EHOH	0,05	24	Ne	5,89
FA	LBP	0,05	24	Ne	3,81
FASL	CSLBP	0,05	24	Ne	13,11
FASL	EHOH	0,05	24	Ne	12,56
FASL	LBP	0,05	24	Ne	9,99
SP	CSLBP	0,05	24	Ne	5,17
SP	EHOH	0,05	24	Ne	5,57
SP	LBP	0,05	24	Ne	4,16
CU	CSLBP	0,05	24	Ano	7,04
CU	EHOH	0,05	24	Ano	9,41
CU	LBP	0,05	24	Ano	7,80
FA	CSLBP	0,05	24	Ano	3,54
FA	EHOH	0,05	24	Ano	4,52
FA	LBP	0,05	24	Ano	3,86
FASL	CSLBP	0,05	24	Ano	10,44
FASL	EHOH	0,05	24	Ano	7,78
FASL	LBP	0,05	24	Ano	11,20
SP	CSLBP	0,05	24	Ano	5,15
SP	EHOH	0,05	24	Ano	6,57
SP	LBP	0,05	24	Ano	4,37

Klasifikátor	Příznak	Norm. faktor	Velikost	Rotace	EER chyba
CU	CSLBP	0,05	32	Ne	7,76
CU	EHOH	0,05	32	Ne	11,60
CU	LBP	0,05	32	Ne	7,66
FA	CSLBP	0,05	32	Ne	3,73
FA	EHOH	0,05	32	Ne	4,60
FA	LBP	0,05	32	Ne	4,14
FASL	CSLBP	0,05	32	Ne	11,09
FASL	EHOH	0,05	32	Ne	11,90
FASL	LBP	0,05	32	Ne	9,37
SP	CSLBP	0,05	32	Ne	4,29
SP	EHOH	0,05	32	Ne	5,16
SP	LBP	0,05	32	Ne	3,10
CU	CSLBP	0,05	32	Ano	6,45
CU	EHOH	0,05	32	Ano	8,75
CU	LBP	0,05	32	Ano	7,16
FA	CSLBP	0,05	32	Ano	3,13
FA	EHOH	0,05	32	Ano	4,60
FA	LBP	0,05	32	Ano	3,73
FASL	CSLBP	0,05	32	Ano	8,96
FASL	EHOH	0,05	32	Ano	7,61
FASL	LBP	0,05	32	Ano	9,22
SP	CSLBP	0,05	32	Ano	4,70
SP	EHOH	0,05	32	Ano	5,53
SP	LBP	0,05	32	Ano	3,51

Klasifikátor	Příznak	Norm. faktor	Velikost	Rotace	EER chyba
CU	CSLBP	0,05	48	Ne	6,69
CU	EHOH	0,05	48	Ne	10,35
CU	LBP	0,05	48	Ne	6,47
FA	CSLBP	0,05	48	Ne	3,57
FA	EHOH	0,05	48	Ne	5,18
FA	LBP	0,05	48	Ne	3,32
FASL	CSLBP	0,05	48	Ne	9,54
FASL	EHOH	0,05	48	Ne	8,65
FASL	LBP	0,05	48	Ne	8,61
SP	CSLBP	0,05	48	Ne	4,74
SP	EHOH	0,05	48	Ne	4,08
SP	LBP	0,05	48	Ne	2,70
CU	CSLBP	0,05	48	Ano	4,73
CU	EHOH	0,05	48	Ano	7,65
CU	LBP	0,05	48	Ano	6,60
FA	CSLBP	0,05	48	Ano	3,73
FA	EHOH	0,05	48	Ano	3,73
FA	LBP	0,05	48	Ano	3,13
FASL	CSLBP	0,05	48	Ano	8,39
FASL	EHOH	0,05	48	Ano	7,53
FASL	LBP	0,05	48	Ano	8,39
SP	CSLBP	0,05	48	Ano	5,18
SP	EHOH	0,05	48	Ano	5,77
SP	LBP	0,05	48	Ano	3,31

Klasifikátor	Příznak	Norm. faktor	Velikost	Rotace	EER chyba
CU	CSLBP	0,1	16	Ne	9,34
CU	EHOH	0,1	16	Ne	12,41
CU	LBP	0,1	16	Ne	8,28
FA	CSLBP	0,1	16	Ne	3,73
FA	EHOH	0,1	16	Ne	5,47
FA	LBP	0,1	16	Ne	3,79
FASL	CSLBP	0,1	16	Ne	12,12
FASL	EHOH	0,1	16	Ne	14,12
FASL	LBP	0,1	16	Ne	10,60
SP	CSLBP	0,1	16	Ne	3,71
SP	EHOH	0,1	16	Ne	5,82
SP	LBP	0,1	16	Ne	3,51
CU	CSLBP	0,1	16	Ano	7,79
CU	EHOH	0,1	16	Ano	9,22
CU	LBP	0,1	16	Ano	8,22
FA	CSLBP	0,1	16	Ano	4,17
FA	EHOH	0,1	16	Ano	4,46
FA	LBP	0,1	16	Ano	4,02
FASL	CSLBP	0,1	16	Ano	11,32
FASL	EHOH	0,1	16	Ano	9,55
FASL	LBP	0,1	16	Ano	11,07
SP	CSLBP	0,1	16	Ano	4,74
SP	EHOH	0,1	16	Ano	5,97
SP	LBP	0,1	16	Ano	4,56

Klasifikátor	Příznak	Norm. faktor	Velikost	Rotace	EER chyba
CU	CSLBP	0,1	24	Ne	6,93
CU	EHOG	0,1	24	Ne	11,82
CU	LBP	0,1	24	Ne	6,44
FA	CSLBP	0,1	24	Ne	4,06
FA	EHOG	0,1	24	Ne	5,58
FA	LBP	0,1	24	Ne	3,62
FASL	CSLBP	0,1	24	Ne	10,00
FASL	EHOG	0,1	24	Ne	9,47
FASL	LBP	0,1	24	Ne	9,31
SP	CSLBP	0,1	24	Ne	3,92
SP	EHOG	0,1	24	Ne	4,12
SP	LBP	0,1	24	Ne	3,10
CU	CSLBP	0,1	24	Ano	4,66
CU	EHOG	0,1	24	Ano	8,72
CU	LBP	0,1	24	Ano	7,20
FA	CSLBP	0,1	24	Ano	3,67
FA	EHOG	0,1	24	Ano	4,71
FA	LBP	0,1	24	Ano	3,65
FASL	CSLBP	0,1	24	Ano	8,55
FASL	EHOG	0,1	24	Ano	7,00
FASL	LBP	0,1	24	Ano	9,61
SP	CSLBP	0,1	24	Ano	4,54
SP	EHOG	0,1	24	Ano	4,98
SP	LBP	0,1	24	Ano	3,71

Klasifikátor	Příznak	Norm. faktor	Velikost	Rotace	EER chyba
CU	CSLBP	0,1	32	Ne	6,61
CU	EHOH	0,1	32	Ne	10,62
CU	LBP	0,1	32	Ne	6,21
FA	CSLBP	0,1	32	Ne	3,51
FA	EHOH	0,1	32	Ne	4,35
FA	LBP	0,1	32	Ne	3,07
FASL	CSLBP	0,1	32	Ne	9,21
FASL	EHOH	0,1	32	Ne	8,56
FASL	LBP	0,1	32	Ne	8,86
SP	CSLBP	0,1	32	Ne	4,14
SP	EHOH	0,1	32	Ne	3,34
SP	LBP	0,1	32	Ne	3,26
CU	CSLBP	0,1	32	Ano	4,79
CU	EHOH	0,1	32	Ano	7,81
CU	LBP	0,1	32	Ano	7,05
FA	CSLBP	0,1	32	Ano	3,40
FA	EHOH	0,1	32	Ano	3,78
FA	LBP	0,1	32	Ano	3,54
FASL	CSLBP	0,1	32	Ano	7,88
FASL	EHOH	0,1	32	Ano	6,79
FASL	LBP	0,1	32	Ano	8,58
SP	CSLBP	0,1	32	Ano	4,55
SP	EHOH	0,1	32	Ano	5,37
SP	LBP	0,1	32	Ano	2,85

Klasifikátor	Příznak	Norm. faktor	Velikost	Rotace	EER chyba
CU	CSLBP	0,1	48	Ne	6,11
CU	EHOOG	0,1	48	Ne	9,845
CU	LBP	0,1	48	Ne	6,10
FA	CSLBP	0,1	48	Ne	3,70
FA	EHOOG	0,1	48	Ne	4,79
FA	LBP	0,1	48	Ne	3,32
FASL	CSLBP	0,1	48	Ne	9,00
FASL	EHOOG	0,1	48	Ne	7,67
FASL	LBP	0,1	48	Ne	8,76
SP	CSLBP	0,1	48	Ne	4,49
SP	EHOOG	0,1	48	Ne	3,93
SP	LBP	0,1	48	Ne	2,47
CU	CSLBP	0,1	48	Ano	4,90
CU	EHOOG	0,1	48	Ano	7,05
CU	LBP	0,1	48	Ano	6,33
FA	CSLBP	0,1	48	Ano	3,32
FA	EHOOG	0,1	48	Ano	3,73
FA	LBP	0,1	48	Ano	3,54
FASL	CSLBP	0,1	48	Ano	7,43
FASL	EHOOG	0,1	48	Ano	6,58
FASL	LBP	0,1	48	Ano	8,04
SP	CSLBP	0,1	48	Ano	4,54
SP	EHOOG	0,1	48	Ano	4,54
SP	LBP	0,1	48	Ano	3,06

Klasifikátor	Příznak	Norm. faktor	Velikost	Rotace	EER chyba
CU	CSLBP	0,2	16	Ne	8,72
CU	EHOOG	0,2	16	Ne	11,85
CU	LBP	0,2	16	Ne	7,66
FA	CSLBP	0,2	16	Ne	4,11
FA	EHOOG	0,2	16	Ne	6,26
FA	LBP	0,2	16	Ne	4,31
FASL	CSLBP	0,2	16	Ne	9,82
FASL	EHOOG	0,2	16	Ne	11,24
FASL	LBP	0,2	16	Ne	9,58
SP	CSLBP	0,2	16	Ne	3,92
SP	EHOOG	0,2	16	Ne	5,19
SP	LBP	0,2	16	Ne	2,88
CU	CSLBP	0,2	16	Ano	6,24
CU	EHOOG	0,2	16	Ano	8,39
CU	LBP	0,2	16	Ano	6,93
FA	CSLBP	0,2	16	Ano	4,14
FA	EHOOG	0,2	16	Ano	4,46
FA	LBP	0,2	16	Ano	3,73
FASL	CSLBP	0,2	16	Ano	8,64
FASL	EHOOG	0,2	16	Ano	7,86
FASL	LBP	0,2	16	Ano	9,38
SP	CSLBP	0,2	16	Ano	4,33
SP	EHOOG	0,2	16	Ano	5,95
SP	LBP	0,2	16	Ano	3,72

Klasifikátor	Příznak	Norm. faktor	Velikost	Rotace	EER chyba
CU	CSLBP	0,2	24	Ne	6,20
CU	EHOH	0,2	24	Ne	10,91
CU	LBP	0,2	24	Ne	7,11
FA	CSLBP	0,2	24	Ne	3,81
FA	EHOH	0,2	24	Ne	5,15
FA	LBP	0,2	24	Ne	4,00
FASL	CSLBP	0,2	24	Ne	8,56
FASL	EHOH	0,2	24	Ne	8,48
FASL	LBP	0,2	24	Ne	8,75
SP	CSLBP	0,2	24	Ne	3,11
SP	EHOH	0,2	24	Ne	3,72
SP	LBP	0,2	24	Ne	2,89
CU	CSLBP	0,2	24	Ano	4,78
CU	EHOH	0,2	24	Ano	7,55
CU	LBP	0,2	24	Ano	6,81
FA	CSLBP	0,2	24	Ano	3,16
FA	EHOH	0,2	24	Ano	4,41
FA	LBP	0,2	24	Ano	3,92
FASL	CSLBP	0,2	24	Ano	7,61
FASL	EHOH	0,2	24	Ano	6,79
FASL	LBP	0,2	24	Ano	9,50
SP	CSLBP	0,2	24	Ano	3,71
SP	EHOH	0,2	24	Ano	4,50
SP	LBP	0,2	24	Ano	2,91

Klasifikátor	Příznak	Norm. faktor	Velikost	Rotace	EER chyba
CU	CSLBP	0,2	32	Ne	6,58
CU	EHOH	0,2	32	Ne	9,21
CU	LBP	0,2	32	Ne	6,83
FA	CSLBP	0,2	32	Ne	3,86
FA	EHOH	0,2	32	Ne	5,15
FA	LBP	0,2	32	Ne	3,79
FASL	CSLBP	0,2	32	Ne	9,23
FASL	EHOH	0,2	32	Ne	7,74
FASL	LBP	0,2	32	Ne	9,30
SP	CSLBP	0,2	32	Ne	3,71
SP	EHOH	0,2	32	Ne	3,71
SP	LBP	0,2	32	Ne	2,68
CU	CSLBP	0,2	32	Ano	4,79
CU	EHOH	0,2	32	Ano	7,19
CU	LBP	0,2	32	Ano	6,69
FA	CSLBP	0,2	32	Ano	3,65
FA	EHOH	0,2	32	Ano	3,79
FA	LBP	0,2	32	Ano	3,59
FASL	CSLBP	0,2	32	Ano	8,15
FASL	EHOH	0,2	32	Ano	6,13
FASL	LBP	0,2	32	Ano	8,17
SP	CSLBP	0,2	32	Ano	4,29
SP	EHOH	0,2	32	Ano	4,74
SP	LBP	0,2	32	Ano	2,98

Klasifikátor	Příznak	Norm. faktor	Velikost	Rotace	EER chyba
CU	CSLBP	0,2	48	Ne	6,31
CU	EHOH	0,2	48	Ne	8,51
CU	LBP	0,2	48	Ne	6,69
FA	CSLBP	0,2	48	Ne	3,54
FA	EHOH	0,2	48	Ne	5,07
FA	LBP	0,2	48	Ne	3,67
FASL	CSLBP	0,2	48	Ne	8,39
FASL	EHOH	0,2	48	Ne	7,98
FASL	LBP	0,2	48	Ne	8,87
SP	CSLBP	0,2	48	Ne	3,55
SP	EHOH	0,2	48	Ne	3,92
SP	LBP	0,2	48	Ne	3,30
CU	CSLBP	0,2	48	Ano	5,15
CU	EHOH	0,2	48	Ano	6,90
CU	LBP	0,2	48	Ano	6,80
FA	CSLBP	0,2	48	Ano	3,40
FA	EHOH	0,2	48	Ano	4,54
FA	LBP	0,2	48	Ano	3,46
FASL	CSLBP	0,2	48	Ano	7,94
FASL	EHOH	0,2	48	Ano	6,59
FASL	LBP	0,2	48	Ano	8,32
SP	CSLBP	0,2	48	Ano	4,34
SP	EHOH	0,2	48	Ano	5,14
SP	LBP	0,2	48	Ano	3,10

Klasifikátor	Příznak	Norm. faktor	Velikost	Rotace	EER chyba
CU	CSLBP	0,5	16	Ne	8,01
CU	EHOOG	0,5	16	Ne	11,53
CU	LBP	0,5	16	Ne	7,51
FA	CSLBP	0,5	16	Ne	4,33
FA	EHOOG	0,5	16	Ne	6,42
FA	LBP	0,5	16	Ne	4,27
FASL	CSLBP	0,5	16	Ne	10,43
FASL	EHOOG	0,5	16	Ne	9,71
FASL	LBP	0,5	16	Ne	9,83
SP	CSLBP	0,5	16	Ne	3,09
SP	EHOOG	0,5	16	Ne	4,17
SP	LBP	0,5	16	Ne	3,15
CU	CSLBP	0,5	16	Ano	5,98
CU	EHOOG	0,5	16	Ano	8,32
CU	LBP	0,5	16	Ano	7,79
FA	CSLBP	0,5	16	Ano	4,52
FA	EHOOG	0,5	16	Ano	4,79
FA	LBP	0,5	16	Ano	4,33
FASL	CSLBP	0,5	16	Ano	7,69
FASL	EHOOG	0,5	16	Ano	7,08
FASL	LBP	0,5	16	Ano	9,97
SP	CSLBP	0,5	16	Ano	3,67
SP	EHOOG	0,5	16	Ano	5,75
SP	LBP	0,5	16	Ano	3,71

Klasifikátor	Příznak	Norm. faktor	Velikost	Rotace	EER chyba
CU	CSLBP	0,5	24	Ne	6,54
CU	EHOH	0,5	24	Ne	10,44
CU	LBP	0,5	24	Ne	7,06
FA	CSLBP	0,5	24	Ne	4,11
FA	EHOH	0,5	24	Ne	5,70
FA	LBP	0,5	24	Ne	3,73
FASL	CSLBP	0,5	24	Ne	8,98
FASL	EHOH	0,5	24	Ne	8,11
FASL	LBP	0,5	24	Ne	9,24
SP	CSLBP	0,5	24	Ne	3,48
SP	EHOH	0,5	24	Ne	3,73
SP	LBP	0,5	24	Ne	2,86
CU	CSLBP	0,5	24	Ano	5,37
CU	EHOH	0,5	24	Ano	7,75
CU	LBP	0,5	24	Ano	7,49
FA	CSLBP	0,5	24	Ano	3,43
FA	EHOH	0,5	24	Ano	4,87
FA	LBP	0,5	24	Ano	3,65
FASL	CSLBP	0,5	24	Ano	7,64
FASL	EHOH	0,5	24	Ano	6,34
FASL	LBP	0,5	24	Ano	8,79
SP	CSLBP	0,5	24	Ano	3,68
SP	EHOH	0,5	24	Ano	4,35
SP	LBP	0,5	24	Ano	3,10

Klasifikátor	Příznak	Norm. faktor	Velikost	Rotace	EER chyba
CU	CSLBP	0,5	32	Ne	6,44
CU	EHOH	0,5	32	Ne	10,02
CU	LBP	0,5	32	Ne	7,53
FA	CSLBP	0,5	32	Ne	4,00
FA	EHOH	0,5	32	Ne	4,90
FA	LBP	0,5	32	Ne	3,86
FASL	CSLBP	0,5	32	Ne	9,12
FASL	EHOH	0,5	32	Ne	7,90
FASL	LBP	0,5	32	Ne	9,50
SP	CSLBP	0,5	32	Ne	2,93
SP	EHOH	0,5	32	Ne	3,51
SP	LBP	0,5	32	Ne	3,06
CU	CSLBP	0,5	32	Ano	4,86
CU	EHOH	0,5	32	Ano	7,17
CU	LBP	0,5	32	Ano	6,47
FA	CSLBP	0,5	32	Ano	3,40
FA	EHOH	0,5	32	Ano	3,67
FA	LBP	0,5	32	Ano	3,67
FASL	CSLBP	0,5	32	Ano	7,63
FASL	EHOH	0,5	32	Ano	6,87
FASL	LBP	0,5	32	Ano	8,20
SP	CSLBP	0,5	32	Ano	3,93
SP	EHOH	0,5	32	Ano	4,33
SP	LBP	0,5	32	Ano	2,26

Klasifikátor	Příznak	Norm. faktor	Velikost	Rotace	EER chyba
CU	CSLBP	0,5	48	Ne	6,93
CU	EHOH	0,5	48	Ne	8,82
CU	LBP	0,5	48	Ne	6,56
FA	CSLBP	0,5	48	Ne	3,67
FA	EHOH	0,5	48	Ne	5,39
FA	LBP	0,5	48	Ne	3,73
FASL	CSLBP	0,5	48	Ne	9,08
FASL	EHOH	0,5	48	Ne	7,41
FASL	LBP	0,5	48	Ne	8,91
SP	CSLBP	0,5	48	Ne	3,72
SP	EHOH	0,5	48	Ne	3,88
SP	LBP	0,5	48	Ne	2,27
CU	CSLBP	0,5	48	Ano	4,90
CU	EHOH	0,5	48	Ano	8,09
CU	LBP	0,5	48	Ano	6,91
FA	CSLBP	0,5	48	Ano	3,54
FA	EHOH	0,5	48	Ano	4,60
FA	LBP	0,5	48	Ano	3,46
FASL	CSLBP	0,5	48	Ano	7,94
FASL	EHOH	0,5	48	Ano	6,34
FASL	LBP	0,5	48	Ano	8,76
SP	CSLBP	0,5	48	Ano	4,54
SP	EHOH	0,5	48	Ano	4,77
SP	LBP	0,5	48	Ano	2,47

Příloha 2 – úplné výsledky klasifikace částic z ferrogramů

Klasifikátor	Příznak	Norm. faktor	Velikost	Chyba
CU	CSLBP	0,05	24	11,99
CU	LBP	0,05	24	6,29
FA	CSLBP	0,05	24	5,26
FA	LBP	0,05	24	3,95
FASL	CSLBP	0,05	24	9,55
FASL	LBP	0,05	24	8,50
SP	CSLBP	0,05	24	1,75
SP	LBP	0,05	24	1,98
CU	CSLBP	0,05	32	6,40
CU	LBP	0,05	32	4,19
FA	CSLBP	0,05	32	4,74
FA	LBP	0,05	32	2,11
FASL	CSLBP	0,05	32	7,33
FASL	LBP	0,05	32	3,68
SP	CSLBP	0,05	32	3,14
SP	LBP	0,05	32	1,98
CU	CSLBP	0,1	24	5,82
CU	LBP	0,1	24	3,14
FA	CSLBP	0,1	24	3,16
FA	LBP	0,1	24	2,11
FASL	CSLBP	0,1	24	5,70
FASL	LBP	0,1	24	3,73
SP	CSLBP	0,1	24	1,86
SP	LBP	0,1	24	1,86
CU	CSLBP	0,1	32	5,36
CU	LBP	0,1	32	4,07

FA	CSLBP	0,1	32	2,11
FA	LBP	0,1	32	1,58
FASL	CSLBP	0,1	32	6,29
FASL	LBP	0,1	32	6,05
SP	CSLBP	0,1	32	1,63
SP	LBP	0,1	32	1,63
CU	CSLBP	0,2	24	1,40
CU	LBP	0,2	24	2,33
FA	CSLBP	0,2	24	2,11
FA	LBP	0,2	24	7,39
FASL	CSLBP	0,2	24	2,91
FASL	LBP	0,2	24	5,24
SP	CSLBP	0,2	24	1,51
SP	LBP	0,2	24	1,98
CU	CSLBP	0,2	32	1,75
CU	LBP	0,2	32	3,03
FA	CSLBP	0,2	32	4,21
FA	LBP	0,2	32	7,11
FASL	CSLBP	0,2	32	5,12
FASL	LBP	0,2	32	8,61
SP	CSLBP	0,2	32	1,28
SP	LBP	0,2	32	0,58