

Automatická klasifikace částic opotřebení

Analýza částic opotřebení a jejich klasifikace do tříd odpovídajících typům opotřebení umožňuje sledovat jak aktuální stav, tak (v případě opakované aplikace) dlouhodobý trend opotřebení strojních součástí. V případě včasného zjištění blížící se závady dává možnost preventivních opatření, které mohou zabránit hrozcí poruše zařízení.

Možnosti metody analytické ferrografie, která je dnes jednou z používaných metod částicové analýzy provozních kapalin (především mazacích olejů), mohou být výrazně rozšířeny vytvořením nástroje, který umožní automatickou klasifikaci částic opotřebení.

SOUČASNÝ STAV

V současnosti je metoda analytické ferrografie využívána především díky velmi dobrým výsledkům při zjišťování aktuálního stavu, případně dlouhodobého trendu, opotřebení sledovaných součástí motorů a dalších strojních zařízení. Částice opotřebení, které jsou separovány z provozních kapalin, jsou vyhodnocovány mikroskopicky, výsledkem metody je určení tříd opotřebení vybraných částic a stanovení převládajícího typu opotřebení.

Interpretace výsledků je však do značné míry závislá na zkušenostech operátora, který provádí vyhodnocení. Cílem tohoto výzkumu je eliminovat vliv lidského faktoru (z důvodu časové náročnosti a možného subjektivního pohledu operátora) pomocí automatického klasifikátoru částic.


Myšlenka vylepšení metody analytické ferrografie pomocí nástrojů pro automatickou klasifikaci částic není nová. V odborné literatuře lze nalézt především několik návrhů, ale i popisů implementací systémů, které umožňují objektivní hodnocení ferrogramů (tj. výstupů metody analytické ferrografie). Jejich cílem je více či méně automatická klasifikace částic do tříd odpovídajících typům opotřebení.

K analýze částice je nejčastěji využívána technologie neuronových sítí a dalších metod umělé inteligence vycházejících z metod strojového učení. 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. Při řešení je také někdy využívána matematika fraktálů či fuzzy logika.

Dosavadní pokusy o automatické hodnocení částic vychází především z analýzy tvarových faktorů. Předpokladem úspěšné klasifikace je zejména nalezení vhodné sady tvarových faktorů (veličím charakterizujících morfologické vlastnosti částic), která by umožnila jednoznačně definovat jednotlivé třídy opotřebení. Tento předpoklad zatím nebyl úspěšně naplněn, ideální sada tvarových faktorů dosud nebyla specifikována. Snahou zde popisovaného systému je vytvořit alternativní metodu klasifikace částic pracující místo tvarových faktorů s obrazy částic. Základem jsou metody strojového učení. Databáze, která je základem pro proces učení klasifikátoru, je tedy naplněna obrazy částic.

V současnosti obsahuje databáze částic cca 2500 vzorků, které byly získány dvojím způsobem. Část vzorků jsou obrazy, které vznikly separací jednotlivých částic z ferrogramů, což je časově i technologicky náročný proces. Z toho důvodu byl pro pořízení vzorových dat použit i systém SpectroLNF, který slouží k analýze částic opotřebení a jehož výstupem jsou množství částic rozdělené podle definovaných tříd opotřebení. Jeho nevýhodou je vysoká pořizovací cena a netransparentnost použitých algoritmů.

Výsledkem procesu pořizování částic je sada jejich obrazů (obr. 1), která je po separaci jednotlivých částic a následné normalizaci vstupem pro učení klasifikátoru. Tyto částice jsou předem rozděleny do tříd podle typu opotřebení.



Obr. 1a) Snímek ferrogramu pořízený na mikroskopu při zvětšení 400x



Obr. 1b) Binární obraz se segmentovanými částicemi

Cílem klasifikace je v ideálním případě zařadit každou částici do jedné ze čtyř tříd opotřebení. V praxi je takový ideální stav nedosažitelný, jednotlivé třídy nejsou navzájem zcela disjunktí, a proto mohou být některé částice přiřazeny více třídám. Protože klasifikátor vyhodnocuje v obrazech částic společné vzory, které byly zjištěny při trénování, je výsledek do značné míry závislý na množství a kvalitě vzorových dat. V následujícím textu jsou popsány výsledky prvních experimentů; do budoucna se předpokládá intenzivní nárůst vzorových dat v databázi.

Pro potřeby výzkumu byly zvoleny následující třídy opotřebení (obr. 2), do kterých jsou částice klasifikovány:


■ **Fatigue** – do této třídy patří částice deformované v důsledku opakovaného průchodu soustavou. Rozválcováním sféroidů i jiných třírozměrných částic vznikají tenké ploché lupínky malé tloušťky.

■ **Cutting** – částice vznikající v důsledku působení cizorodé částice mezi třecími povrchy případně penetrací tvrdšího materiálu třecí dvojice do měkčího. Částice mají vzhled třísek, často mohou tvarem připomínat spirály.

■ **Sliding** – 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.

Klasifikátor není určen pro analýzu částic adhezivního opotřebení, které se na ferrogramu vyskytují prakticky vždy a nejsou známkou poškození. Tyto částice mají minimální velikost (menší než 15 μm), na ferrogramu vytváří působením magnetického pole souvislé řetízky.



Obr. 2: Obrazy částic, které jsou po normalizaci vstupem učení klasifikátoru

PŘÍPRAVA VSTUPNÍCH DAT


Obrazy částic, které jsou vstupem pro učení klasifikátoru, je nutno nejprve normalizovat (obr. 3). Normalizace spočívá v převzorkování obrazů na jednotnou velikost a rotaci částic podle jejich hlavní osy. Aby bylo možné lépe využít možnosti 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 (kterých je většina) podléhají jen malé úpravě, a čím větší částice, tím více jsou zmenšeny.

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. Pokud by rotace neproběhla, chybovost klasifikace by byla negativně ovlivněna; díky rotaci je možné dosáhnout vyšší přesnosti klasifikace. Pro potřeby normalizace jsou částice rotovány podle svlé osy, která je nalezena pomocí metody analýzy hlavních komponent (PCA).

KLASIFIKACE ČÁSTIC

Normalizované obrazy částic jsou vstupem pro učení (trénování) klasifikátoru. Pro klasifikaci je použita metoda Real AdaBoost (Adaptive Boosting), která 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.

Sada normalizovaných obrazů částic, které jsou rozděleny podle tříd opotřebení, je společně s množinou slabých klasifikátorů vstupem pro trénování klasifikátoru. Výstupem je pro každou ze tříd opotřebení klasifikátor, který je schopen s určitou pravděpodobností (chybovostí) určit,



Obr. 3a) Originální obrazy částic před normalizací

Obr. 3b) Obrazy částic po normalizaci, s rotací

jestli testovaná částice patří do dané třídy opotřebení či nikoliv. Cílem je minimalizovat chybovost jednotlivých klasifikátorů.

PŘÍPRAVA EXPERIMENTŮ

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 – testovány hodnoty 16, 24, 32 a 48 pixelů,
- normalizační faktor α – určuje vliv velikosti obrazů částic na přesnost klasifikace (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).

Pro všechny kombinace parametrů proběhlo trénování a následná klasifikace metodou Ada-Boost. V každém testu bylo použito celkem 100 slabých klasifikátorů. Tabulka 1 uvádí počty obrazů pro trénování a následně testování.

Tabulka 1: Počty obrazů částic jednotlivých tříd pro trénování klasifikátorů a testování

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

VÝSLEDKY EXPERIMENTŮ

Přesnost klasifikace závisí na nastavení vybraných parametrů, především normalizačního faktoru α , velikosti obrazů částic a přesnosti jejich rotace. Experimentálně bylo zjištěno, že nejlepší výsledky jsou dosaženy při nastavení $\alpha = 0,2$, při které si malé částice (do 20 μm) zachovávají svou velikost a větší částice jsou nelineárně zmenšovány na jednotnou velikost obrazu. Při větší velikosti obrazů je sice možné dosáhnout vyšší přesnosti pro větší částice, nejedná se ale

o významný vliv, protože velká většina obrazů částic má malé rozměry. Jako optimální se jeví velikost obrazů v rozmezí 32–48 pixelů. Podobně lze jednoznačně potvrdit hypotézu, že rotace částic při normalizaci vede k vyšší přesnosti klasifikace.

Tabulka 2 ukazuje výsledky klasifikace pro velikosti obrazů $w = 32$ pixelů v závislosti na použití/nepoužití rotace částic při normalizaci pro všechny uvažované hodnoty normalizačního faktoru α . Hodnoty tabulky představují dosažené chybovosti při klasifikaci částic jednotlivých tříd (uvedeny v procentech). Nejlepší dosažené hodnoty jsou vyznačeny tučně.

Tabulka 2: Dosažené chybovosti klasifikace částic pro různé hodnoty normalizačního faktoru (bez rotace/s rotací), velikost vzorků (obrazů) 32 pixelů

	$\alpha = 0,02$	$\alpha = 0,05$	$\alpha = 0,1$	$\alpha = 0,2$	$\alpha = 0,5$
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

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), lze považovat výslednou chybu klasifikace za vyhovující (podobně jako např. v analytické chemii je výsledek stanovení v oblasti stopových koncentrací s chybou 10–15% považováno za dostačující).

V současné době se intenzivně rozvíjejí instrumentální metody, které mohou přinést řadu údajů o průběhu a stupni opotřebení mazacích olejů pro dopravní prostředky. Doposud zkoumané postupy a jejich výsledky prezentují pou-

ze některé možnosti 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.

V tomto článku jsou demonstrovány možnosti využití automatické klasifikace vycházející z obrazů částic získaných pomocí analytické ferrografie. Tyto obrazy jsou podrobeny normalizaci a následně jsou vstupem pro učení (trénování) klasifikátoru. V průběhu trénování jsou v obrazech částic vyhodnocovány specifické vzory (CS-LBP příznaky), které jsou poté při klasifikaci vyhledávány v testovaných obrazech. Pokud jsou v testovaných obrazech nalezeny odpovídající vzory, je výsledkem klasifikace zařazení dané částice do odpovídající třídy opotřebení.

Přesnost klasifikace je do značné míry závislá na množství a správném zařazení trénovacích částic. V současnosti obsahuje databáze částic cca 2500 vzorků, do budoucna se předpokládá intenzivní nárůst jejich počtu.

Výsledky prvních experimentů naznačují, že využití automatické klasifikace částic v praxi může přinést zajímavé výsledky. V tuto chvíli je chybovost klasifikace v řádu 5–15%. Dosažená přesnost přináší zlepšení oproti výsledkům subjektivnímu hodnocení. I při znalosti pravidel klasifikace částic nepřesahuje u neznalého pracov-

níka provádějícího vyhodnocení jeho úspěšnost 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.

PODĚKOVÁNÍ

Tento příspěvek vznikl díky finanční podpoře VZ MŠM 0021627505 Teorie dopravních systémů a VZ MŠM 0021630528 Výzkum informačních technologií z hlediska bezpečnosti.

ING. STANISLAV MACHALÍK
ING. ROMAN JURÁNEK
DOC. ING. PAVEL ZEMČÍK, CSC.



Pojďte s námi
do světa průmyslu
a nových technologií

www.techtydenik.cz