

VĚDECKÉ SPISY VYSOKÉHO UČENÍ TECHNICKÉHO V BRNĚ

*Edice PhD Thesis, sv. 690*

*ISSN 1213-4198*

*thesis* IS

*Ing. Ondřej Janda*

**Umělá inteligence  
v diagnostice výkonových  
olejových transformátorů**

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ  
FAKULTA STROJNÍHO INŽENÝRSTVÍ  
ÚSTAV VÝROBNÍCH STROJŮ, SYSTÉMŮ A ROBOTIKY

**Ing. ONDŘEJ JANDA**

**UMĚLÁ INTELIGENCE V DIAGNOSTICE VÝKONOVÝCH  
OLEJOVÝCH TRANSFORMÁTORŮ**

ARTIFICIAL INTELLIGENCE IN POWER OIL  
TRANSFORMERS DIAGNOSTICS

TEZE DIZERTAČNÍ PRÁCE

OBOR	Konstrukční a procesní inženýrství
VEDOUCÍ PRÁCE	doc. Ing. MILOŠ HAMMER, CSc.
OPONENTI	Ing. Radek Szabó, Ph.D. Ing. Petr Kratochvíl, Ph.D.
DATUM OBHAJOBY	17. 1. 2013

## **Klíčová slova**

Výkonový olejový transformátor, diagnostika, expertní systém, DGA, umělá inteligence, softcomputing, predikce, optimalizace

## **Keywords**

Power Oil Transformer, Diagnostics, Expert Systems, DGA, Artificial intelligence, Soft computing, Prediction, Optimization

## **Místo uložení dizertační práce**

Oddělení vědy a výzkumu Fakulty strojního inženýrství VUT v Brně, Technická 2, 616 69 Brno

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

© Ondřej Janda, 2013

ISBN 978-80-214-4677-9

ISSN 1213-4198

# OBSAH

1	ÚVOD .....	5
2	STAV PROBLEMATIKY .....	5
2.1	Stav problematiky ve světě .....	5
2.1.1	<i>Expertní systémy</i> .....	5
2.1.2	<i>Fuzzy inferenční systémy</i> .....	6
2.1.3	<i>Neuronové sítě</i> .....	6
2.1.4	<i>Evoluční systémy</i> .....	6
2.1.5	<i>Hybridní systémy</i> .....	6
2.2	Stav problematiky v ČR.....	6
2.3	Souhrn .....	6
3	CÍLE PRÁCE .....	7
4	DIAGNOSTICKÉ PŘÍSTUPY .....	7
5	EXPERTNÍ DIAGNOSTICKÝ SYSTÉM TRANSFORMÁTORŮ .....	8
5.1	Návrh a SUBSYSTÉMY ŘEŠENÉHO EXPERTNÍHO SYSTÉMU .....	8
6	DGA MODUL.....	9
6.1	Výsledky DGA modulu .....	10
7	PREDIKČNÍ MODUL .....	10
7.1	Vyhodnocení na bázi časové náročnosti .....	11
8	OPTIMALIZACE POMOCÍ UMĚLÉ INTELIGENCE.....	12
8.1	Výsledky optimalizace DGA modulů .....	12
	ZÁVĚR .....	13
	PŮVODNOST PRÁCE.....	15
	SEZNAM POUŽITÉ LITERATURY .....	16
	ŽIVOTOPIS .....	17
	VLASTNÍ PUBLIKACE .....	18
	ABSTRACT .....	19
	ABSTRAKT.....	20



# 1 ÚVOD

Výkonové transformátory jsou nejdražší a nejkritičtější prvky dnešních rozvodných sítí. Vzhledem k faktu, že jejich selhání může vést až k přerušení distribuce elektrické energie, je nutné detekovat vznikající poruchy. Včasná detekce může minimalizovat poškození zařízení a tím předejdeme selhání nebo výpadku. Druhotným přínosem může být značná ekonomická úspora a větší stabilita a spolehlivost celého distribučního systému.

Z pohledu diagnostiky je transformátor komplexní systém, který se dá obtížně hodnotit standartními postupy. Je potřeba aplikovat přístup zahrnující více pohledů na transformátor jako celek, i na jeho kritické části. Dále je nutné brát v úvahu nejenom minulé a aktuální stavy, ale i predikovat stav budoucí. Takto navržený diagnostický postup je zpravidla možné realizovat zejména nasazením skupiny expertů, kteří mají zkušenosti v dané oblasti. Tento přístup je možný, ale značně nákladný. Náklady na tuto skupinu expertů, která může být ve finále využitelná třeba jen v omezeném časovém intervalu, nebo cena za outsourcing těchto znalostí (v tomto případě služeb), může vést až k celkovému zanedbání diagnostiky transformátorů.

Zde se naskýtá velký prostor pro aplikaci ucelených diagnostických systémů, které by byly právě schopny zastoupit skupinu expertů. Je nutností, aby takový systém byl efektivní a konkurence schopný, proto je potřeba implementovat moderní přístupy a řešení, a to např. v podobě metod umělé inteligence. Tyto metody zažívají značný rozvoj v období po 90-tých letech minulého století a v současné době jsou v podobě, kdy se dají se značnou úspěšností aplikovat, resp. použít jako nástroje např. v oblasti diagnostiky.

Cílem této disertační práce je právě návrh diagnostického expertního systému. Tento systém by měl kombinovat nashromážděné expertní znalosti i obsahovat další rozšíření založená na umělé inteligenci. V této problematice jsou pak zejména využitelné metody na bázi neuronových sítí, fuzzy logiky a genetických algoritmů. Jejich aplikace může být např. v problematice klasifikace, učení, predikce, optimalizace, atd.

V současné době „úspor“ a minimalizací nákladů může být takový systém vítaným prostředkem pro prvotní nebo až celkovou diagnostiku cílového technického zařízení, v tomto případě výkonového olejového transformátoru.

## 2 STAV PROBLEMATIKY

### 2.1 STAV PROBLEMATIKY VE SVĚTĚ

#### 2.1.1 Expertní systémy

Vývojem expertních systém se zabýval C. F. Lin [1], který vytvořil systém na detekci poruch transformátorů pomocí DGA („Dissolved Gas Analysis“ - DGA). Tento systém následně navrhne vhodný postup údržby. Expertní systém byl dále fuzzifikován pro překonání nepřesností a nejistoty v datech.

### **2.1.2 Fuzzy inferenční systémy**

K. Tomsovic v [2] navrhl přístup pomocí fuzzy množin, který umožnil sjednotit různé diagnostické metody. V úvahu bylo bráno pět plynů a byl sestaven strom chyb. Ten v kombinaci s fuzzy logikou má podávat přesnější diagnózy.

### **2.1.3 Neuronové sítě**

Použití neuronových sítí je zpravidla výhodné z hlediska jejich generalizačních schopností a také z důvodu možnosti konstrukce sítě bez expertní znalosti dané simulované problematiky. Někteří autoři [3] využívají DGA kritéria jako předlohu k sestavení neuronových sítí. Tyto sítě jsou učeny na množině vzorových dat odebraných ze skutečných transformátorů. V případě absence dat reprezentující specifickou poruchu jsou chybějící data uměle vytvořeny. Je patrné, že vyváženost a kvalita trénovačích dat je kritická pro výslednou efektivitu neuronové sítě.

### **2.1.4 Evoluční systémy**

Aplikace evolučních systémů je zpravidla zaměřena na učící, resp. optimalizační problémy. Např. zde autor Huang [4] využívá evoluční systémy k nastavení vah neuronové sítě, které provádí analýzu plynů rozpuštěných v oleji.

### **2.1.5 Hybridní systémy**

Nejčastějším příkladem hybridních systému v diagnostice transformátorů jsou fuzzy-neuronové systémy ANFIS. Různí autoři přistupují k problematice jinými způsoby. Například v [7] je pomocí ANFIS sestaven nový fuzzy inferenční systém, který je založený čistě na základě učící množiny.

## **2.2 STAV PROBLEMATIKY V ČR**

Problematika umělé inteligence v diagnostice byla řešena na pracovišti v rámci ČVUT. Nejznámější expertní systém v oblasti elektrických strojů je expertní systém IZOLEX [6]. Jedná se o pravidlový expertní systém, který byl vybudován jako nadstavba prázdného expertního systému Spel-Expert (tento byl vyvinut na ČVUT v Praze). IZOLEX je určen pro vyhodnocování diagnostických měření v off-line diagnostice. V expertním systému IZOLEX byly zvoleny tyto oblasti možné diagnostiky: Elektrické stroje točivé, Elektrické stroje netočivé – transformátory Izolační oleje. Podrobnější rozbor těchto systémů je uveden v předkládané práci.

## **2.3 SOUHRN**

Vývoj problematiky v ČR byl vyvíjen v omezeném rozsahu a dle dostupných informací dále ve větší míře nepokračuje. Ve světě je však výzkum v této oblasti zcela odlišný i přesto ale se neřeší problémy, jaké naznačuje tato práce tj. kombinace expertního systému a dalších rozšiřujících modulů. Z výše uvedených důvodů je cílena tato práce právě na využití umělé inteligence v problematice diagnostiky transformátorů.

### 3 CÍLE PRÁCE

- Definovat hlavní možné příčiny poruch výkonových olejových transformátorů a uvést v praxi používané diagnostické přístupy v oblasti izolačních systémů se zaměřením na problematiku analýzy plynů rozpuštěných v oleji
- Stanovit možné přístupy k diagnostice transformátorů s využitím umělé inteligence a definovat teoretické základy použitelných metod a technik
- Navrhnou a implementovat základní strukturu diagnostického expertního systému s možností modulárního rozšiřování
- Sestavit modul zaměřený na analýzu plynů rozpuštěných v oleji, rozšířit jej o prostředky umělé inteligence a vyhodnotit celkovou přesnost modulu na skupině reálných dat
- Analyzovat možnosti predikce diagnostických veličin pomocí softcomputingových metod, implementovat tyto metody do systému v podobě predikčního modulu
- Porovnat a vyhodnotit zvolené predikční přístupy na souboru dat konkrétních transformátorů
- Definovat základy jednoúčelové, resp. víceúčelové optimalizace a uvést přístupy k optimalizaci fuzzy modelů
- Vyhodnotit základní možnosti optimalizace metodami umělé inteligence a následně je aplikovat na problematiku optimalizace fuzzy modelů metod analýzy plynů rozpuštěných v oleji

### 4 DIAGNOSTICKÉ PŘÍSTUPY

Určení stavu transformátoru je důležité z několika důvodů [7]: monitorování vývoje stavu transformátoru a odhalení možných chybových stavů, diagnostikování problému při anomálním chování zařízení popřípadě při detekci varovných signálů monitorovacích systémů, jako pomůcka pro návrh zkoušek stavu transformátoru, pro sestavení a plánovací strategie obnovy. Odvození stavu transformátoru je založeno na stavu hlavních částí transformátoru, které jsou kritické pro normální chod transformátoru. Statistika poruchovosti velkých transformátorů může být pomocným nástrojem pro určení těchto kritických částí. Z [7] je patrné, že největší množství chyb se vztahuje k izolačnímu systému. Obdobné závěry jsou získány z [8]. Z tohoto důvodu se v dalším této práci soustředí zejména na možnosti diagnostiky stavu izolace transformátoru.

Nejpoužívanějším přístupem pro analýzu izolačního systému je skupina metod DGA. Tyto metody jsou používány pro údržbu i posouzení stavu transformátorů. Základem je odběr vzorku izolačního oleje a jeho následná analýza a vyhodnocení pomocí poměrů určitých plynů, rychlosti tvorby plynů, popřípadě vyhodnocením celkové koncentrace specifických plynů. Na základě této metodiky je možné predikovat možné chyby izolace a navrhnout vhodné servisní zásahy. Metoda DGA je více rozebrána v předkládané práci a v [14], resp. [15].



## 5 EXPERTNÍ DIAGNOSTICKÝ SYSTÉM TRANSFORMÁTORŮ

Počátečním a hlavním cílem při návrhu diagnostického systému transformátorů bylo vytvořit kompaktní, rozšiřitelný systém, který by byl schopen využít a zpracovat znalosti od příslušných expertů, resp. informace a data převzatá z reálného provozu těchto zařízení. Řešením tohoto cíle je modulární diagnostický expertní systém, založený na principech metod umělé inteligence. Takto sestavený systém je pak možné využít při diagnostice transformátorů v situacích, když je nutné získat více závěrů.

### 5.1 NÁVRH A SUBSYSTÉMY ŘEŠENÉHO EXPERTNÍHO SYSTÉMU

Z globálního pohledu je systém dělen do tří logických celků: základní vrstvy, datových zdrojů a části obsahující diagnostické moduly (Obr. 1). Základní vrstva pak dále obsahuje čtyři základní subsystémy, podrobněji popsané dále, a jádro expertního systému. Toto jádro je sestaveno na základě [6]. Obsahuje tedy všechny základní prvky expertního systému: bázi dat, bázi znalostí, inferenční mechanismus, uživatelské rozhraní, atd. Báze znalostí je pravidlového typu a je založena na podnikové normě ČEZ 00/05 [9].

V navrhovaném systému jsou čtyři subsystémy, které jsou naimplementovány na stejné úrovni jako jádro expertního systému. Prvním a nejjednodušším subsystémem je komunikační subsystém. Ten zastupuje prostředníka mezi datovými zdroji a zbytkem systému, a to zejména bázi dat. Obsahuje metody a prostředky pro komunikaci s databázemi a konverzi různých typů souborů.

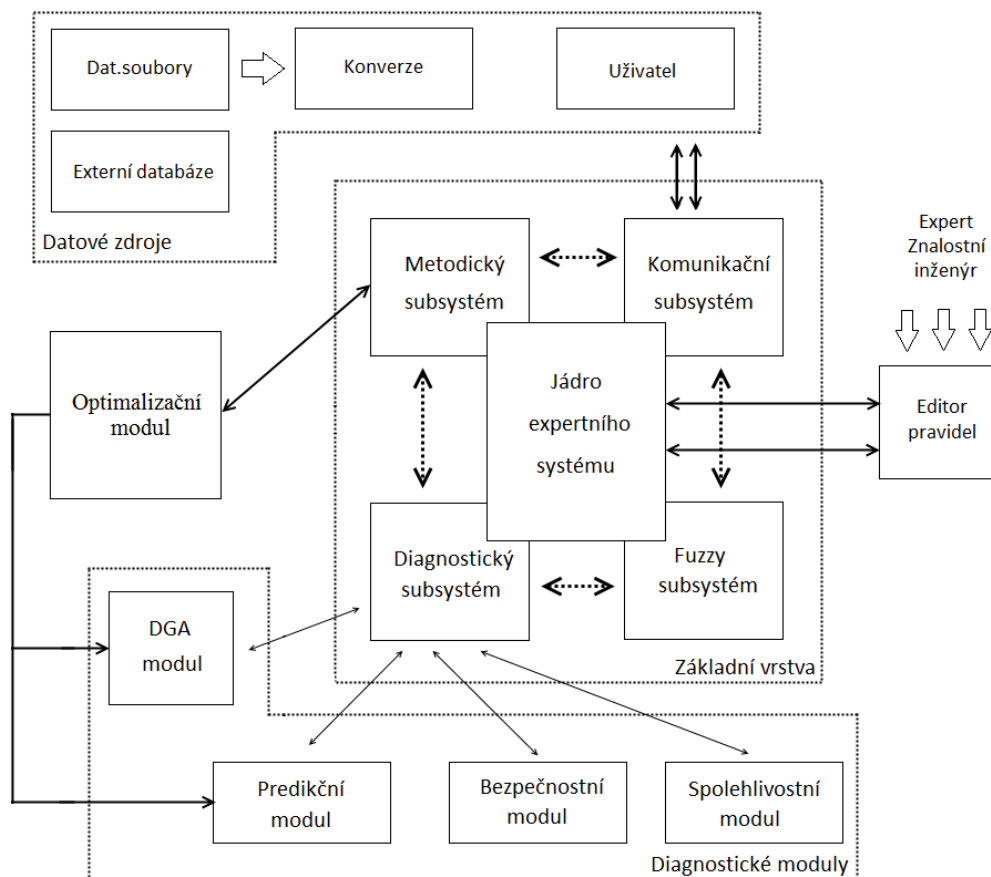
Další subsystém je metodický subsystém. Ten slouží jako základna metodik a prostředků využívaných v jiných částech systému zejména fuzzy subsystému a dílčích modulech diagnostického subsystému. Můžeme sem zařadit např. tyto prvky a jejich kombinace: fuzzy logika, neuronové sítě, evoluční systémy, analýza časových řad, faktorová analýza a Coxův model.

Další ze série subsystému je subsystém diagnostický. Ten v sobě soustřeďuje dílčí moduly zastupující rozdílné pohledy a možnosti na diagnostiku transformátorů. Těmto modulům se podrobněji věnují následující podkapitoly. Můžeme sem zařadit následující moduly: DGA modul, predikční modul, optimalizační modul, spolehlivostní modul a bezpečnostní modul.

Každý tento modul je provázaný s celým systémem, a to zejména s komunikačním (pro přístup k datovým zdrojům) a metodickým subsystémem. Pojem diagnostický subsystém tedy jen zastřešuje množinu samostatně paralelně fungujících diagnostických modulů. Problematika spolehlivostního a bezpečnostního modulu není hlouběji řešena v rámci této práce.

Jedním z cílů při návrhu systému bylo vytvořit platformu schopnou pojmout expertní zkušenosti a znalosti rozličných expertů z oblasti diagnostiky výkonových olejových transformátorů. To je umožněno zejména pomocí fuzzy subsystému. Získání a zakomponování znalostí v znalostní bázi je obecně základním

předpokladem pro funkci FIS systému. Znalostní báze může být vytvořena manuálně nebo automaticky. V současné podobě fuzzy modulu jsou zakomponovány oba procesy získávání znalostí.



Obr. 1 - Celkové schéma navrhovaného diagnostického systému

## 6 DGA MODUL

Z pohledu implementace je tento modul zařazen do skupiny diagnostických modulů a přímo rozšiřuje diagnostický subsystém. Pro svou činnost využívá základní subsystémy, a to zejména metodický a fuzzy subsystém. Vlastní modul je pak rozdělen na část obsahující poměrové metody a na část obsahující fuzzifikované verze vybraných poměrových metod. Vlastní část pak tvoří metoda Duvalova trojúhelníku. Fuzzifikované metody jsou dvojího typu. První skupinu tvoří metody vytvořené příslušným expertem (popřípadě uživatelem) pomocí editoru fuzzy pravidel (Mamdani inference a Takagi-Sugeno inference – T-S), skupina druhá obsahuje metody vytvořené za pomoci automatického učícího procesu techniky ANFIS nad skupinou dat. Při učení pomocí ANFIS jsou zvoleny dva způsoby tvorby základního FIS, a to „Sub. clustering“, resp. „Grid partition“. Důvodem implementace více skupin metod je snaha získat více posudků na řešený diagnostický úkol.

## 6.1 VÝSLEDKY DGA MODULU

V této podkapitole jsou ukázány praktické výsledky celého DGA modulu. Uváděné hodnocení je v procentech z celkového počtu testovacích vzorů. Pro účely vyhodnocení je sestavena množina 38 záznamů plynových koncentrací a odpovídajících stavů. Data jsou převzata zejména z [10] a databáze dostupné na našem pracovišti.

V první řadě jsou otestovány klasické poměrové metody včetně Duvalova trojúhelníku. Velkým problémem poměrových metod jsou situace, kdy se kódové hodnocení dostane mimo hodnotitelný rozsah. Tímto nedostatkem nejvíce trpí Doernenburgova metoda, a to v míře lehce přes 75%. Ostatní metody neklasifikovaly přibližně třetinu testovacích vzorů. Co se úspěšnosti týká, nejlépe dopadly metody Duvalův trojúhelník, Rogers a C.E.G.B, zde se úspěšnost pohybovala v rozmezí 57 – 68 %. Podobnost výsledků metod Rogers a C.E.G.B. se dala předpokládat, jelikož C.E.G.B. z metody Rogers vychází. Překvapivě horší výsledky obdržela metoda IEC (43%), která v dalším dosahuje jedny z nejlepších výsledků.

Následně jsou shrnuty výsledky fuzzy metod na reálných hodnotách ze zkušební množiny. Až na případy využívající trapezoidní a trojúhelníkové MF jsou eliminovány stavy bez podání výsledku. I celková úroveň úspěšných diagnóz vzrostla v průměru až k hodnotám okolo 60%. Některé metody dosahují až hodnot v řádu 70 až 80%. V případě porovnání typů FIS je jednoznačně úspěšnější T-S inference a to zejména za použití Gaussovských MF („Membership functions“ – funkcí příslušnosti).

Vyhodnocení ANFIS je následující. Už z principu fungování ANFIS, resp. T-S (je vyžadován pro aplikaci ANFIS) inference jsou eliminovány stavy bez podání diagnózy. Úspěšnost metod se pomocí optimalizace hybridním učícím algoritmem ANFIS podařilo posunout o další jednotky procent. Nejvíce pak u metody IEC o 11% na hranici 80%. Celkově nejlepších výsledků dosáhla metoda Rogers.

Dále je patrné, že použití původního fuzzy modelu je efektivnější než použití „Sub. clustering“ popřípadě „Grid partition“. Při celkovém vyhodnocení se dá konstatovat, že se podařilo jak zvýšit efektivitu DGA metod a to z hodnot v rozmezí 55 a 66% (při uvažování klasických poměrových metod) na hodnoty v okolí 80%, tak eliminovat neklasifikovatelné stavy zapříčiněné podstatou poměrových metod. Podrobnější popis a rozbor je uveden v předkládané dizertační práci.

## 7 PREDIKČNÍ MODUL

V této části je pozornost soustředěna na implementaci a vyhodnocení predikčního modulu diagnostického systému. K vlastní predikci jsou použity neuronové sítě, genetické programování (GP) a genetické evoluční programování (GEP).

Vyhodnocení daných predikčních mechanismů je prováděno na jejich odpovědích na známé (učící), resp. neznámé (validační) hodnoty z celé dostupné vstupní časové řady. Jsou použity následující prostředky: RMSE (odmocnina střední kvadratické chyby) [11],  $(r)$  [12], koeficient determinace ( $R^2$ ) [13] a časová náročnost. Dále je nutné uvést, že jsou posouzeny dva přístupy k predikci, kdy pro oba případy je poslední třetina časových řad pro predikční mechanismy skryta a použita pouze jako prostředek pro porovnání skutečných a predikovaných hodnot. Nejprve se posuzuje predikce pouze jednoho kroku napříč neznámou částí časové řady. Po každé predikci je časová řada rozšířena o další krok ze skryté části řady (známá hodnota) a predikuje se další krok. V druhém případě se jedná o postupnou predikci více kroků, kdy je časová řada rozšiřována vlastními predikovanými hodnotami. Rozbor predikcí vybraných veličin (plynové charakteristiky a  $\text{tg } \delta$ ) je uveden v předkládané práci. Zde jsou prezentovány jen časové náročnosti predikčních algoritmů.

## 7.1 VYHODNOCENÍ NA BÁZI ČASOVÉ NÁROČNOSTI

Je logickým předpokladem, že s rostoucí velikostí učící množiny porostou i časové nároky na běh algoritmu. Pro tento účel je použita konkrétní časová řada vybraného transformátoru (popis řad a transformátorů je uveden ve vlastní práci), která je následně vzorkována do učících množin o velikostech 50, 100, 200, 500 a 1000. Hodnoty v Tab. 1 jsou průměry deseti různých predikčních procesů.

Tab. 1 – Časy a koeficienty determinace vztažené k dosažení 1000 iterace při dané velikosti učící množiny

1000 iterací	Neuronová síť		GP		GEP	
	Velikost množiny	Čas [s]	$R^2$	Čas [s]	$R^2$	Čas [s]
50	4	0,725	13	0,825	21	0,813
100	3	0,798	58	0,811	47	0,803
200	12	0,815	134	0,85	158	0,861
500	36	0,81	328	0,82	295	0,863
1000	97	0,712	693	0,763	659	0,788

Ve všech případech časy predikce rostou s velikostí učící množiny, výjimkou je případ neuronové sítě pro učící množiny o velikosti 50 a 100. Neuronové sítě obecně zdaleka překonávají GP a GEP v rychlosti predikce. Rozdíl mezi mechanismy na bázi evolučních systémů nedosahuje takového řádu jako při porovnání s neuronovou sítí. Jako výpočetně nejnáročnější predikční metoda je GP, nicméně rozdíl mezi GEP není nikterak markantní.

V dalším je možné si povšimnout klesající přesnosti predikčního modelu při velikostech učících množin 500 a 1000. Tento fakt mohou mít za následek dvě příčiny:

- Množství informací v řadách těchto velikostí jsou pro predikční modely nezvládnutelné
- Velké množství trenovacích vzorů vede k přeučení predikčního modelu

Možným řešením může být použití menšího objemu dat, použití části dat na validaci modelu nebo použít jiné parametry pro neuronové sítě, GP a GEP. Ve finálním posouzení v podobě poměru cena\výkon, resp. čas\přesnost lze jednoznačně jako nejlepší predikční mechanismus označit neuronové sítě.

## 8 OPTIMALIZACE POMOCÍ UMĚLÉ INTELIGENCE

Cílem této kapitoly je vyhodnotit možnosti optimalizace postavené na principech umělé inteligence a následně ji aplikovat na úlohu optimalizace fuzzy modelů. Rozbor možnosti jednoúčelové a víceúčelové optimalizace na skupině syntetických testů je uveden v předkládané dizertační práci. Z optimalizačních algoritmů jsou použity: diferenciální evoluce (DE), úlový algoritmus (PSO) a genetické algoritmy (GA).

### 8.1 VÝSLEDKY OPTIMALIZACE DGA MODULŮ

V rámci návaznosti na předchozí práci je jako konkrétní cíl optimalizace vybrány Takagi-Sugeno (T-S) fuzzy modely zkoušek IEC a Rogers s Gaussovou funkcí příslušnosti. Pro účely optimalizace je sestavena množina 240 záznamů plynových koncentrací a odpovídajících stavů. Data jsou převzata zejména z [10] a databáze dostupné na našem pracovišti. 200 záznamů koncentrací pak slouží jako učící množina a zbylých 40 záznamů jako množina testovací. Vycházíme-li z faktu, že struktura modelu je pevně daná normou IEC [14], resp. IEEE [15], ze které vychází daný model, uvažujeme pouze požadavek na provedení parametrické optimalizace. V takovém případě hledaný jedinec má následující tvar:

$$s_k(t) = [v_{11} \ v_{12} \ \dots \ v_{1M_1} \ \dots \ v_{N_11} \ \dots \ v_{N_1M_1}],$$

kde  $v_{ij} = [w_{ij}, \sigma_{ij}^{lt}, \sigma_{ij}^{rt}]$  reprezentuje parametry  $j$  – té MF pro  $i$  – tou vstupní proměnnou,  $t$  je číslo generace a  $k$  označuje jedince. Střed MF se mohou pohybovat kdekoliv v rozmezí minima a maxima vstupu. Pro naše účely byly zvoleny následující fitness funkce, které dělí náš problém na jednoúčelovou, resp. víceúčelovou optimalizaci:

- jednoúčelová

$$f_i(P_{train}, P_{test}) = \alpha * P_{train} + (1 - \alpha) * P_{test}$$

- víceúčelová

$$f_{i1} = \alpha * P_{train} \text{ a } f_{i2} = \beta * P_{test}$$

V obou případech  $P_{train}$  a  $P_{test}$  reprezentují chybu (RMSE - střední kvadratická chyba) učení, resp. chybu testovací (validační),  $\alpha$  a  $\beta$  jsou pak váhové koeficienty. V průběhu následujících testů se uvažuje stejná důležitost učící i trénovací množiny. V prvním případě je tedy  $\alpha = 0.5$  a v případě víceúčelové optimalizace  $\alpha = \beta = 1$ . Velikosti populací optimalizačních algoritmů jsou stanoveny na 100 a 250. Celkové vyhodnocení (metoda Rogers a populace o velikosti 100) je uvedeno ve vlastní dizertační práci.

Tab. 2 - Výsledky fuzzy IEC modelu po optimalizaci; populace 250

Vyhodnocení / metoda	Jednoúčelová optimalizace			Víceúčelová optimalizace		
	DE	GA	PSO	DE	GA	PSO
Úspěšná diagnóza [%]	85	80	78	88	81	69
Přijatelná diagnóza [%]	5	4	10	2	10	10
Neúspěšná diagnóza [%]	10	16	12	10	9	21
Bez podání diagnózy [%]	0	0	0	0	0	0

V obou případech optimalizace metoda DE přinesla navýšení úspěšnosti diagnózy v řádu jednotek až desítek procent v závislosti na zvolené referenční metodě (popsaných v kapitole 6.1). Logicky nejvyšších rozdílů je při porovnání se základními metodami. V přímém porovnání s metody fuzzy DGA (zejména s MF typu Gauss, které slouží jako základ optimalizace) už rozdíly nejsou tak značné. Naopak v případě IEC je rozdíl až 19 procent. Je zde patrný i pokles v případě PSO algoritmu.

## ZÁVĚR

Předkládaná dizertační práce se soustřeďuje na tvorbu modulárního diagnostického expertního systému, který by byl schopen podat objektivní pohled na stav výkonového olejového transformátoru.

Tento systém je založen na pravidlovém expertním systému, který pro základní vyhodnocení dělí diagnostiku transformátoru na vyhodnocení veličin plynové chromatografie, veličin stavu oleje a veličin stavu izolace vodičů. Nedílnou částí

tohoto diagnostického systému je jeho modulární koncepce, která jej umožňuje rozšířit pro získání kvalitnějších hodnocení a pro podání více pohledů na řešený stav transformátoru. Finální systém obsahuje několik rozšiřujících diagnostických modulů, kde jen dva jsou řešeny v rámci této práce.

Před návrhem rozšiřujících modulů proběhla analýza problematiky diagnostiky transformátorů. Bylo zjištěno, že kritickým místem výkonového olejového transformátoru je především izolační systém. V problematice analýzy stavu izolačního systému byla stanovena jako nejpříjemnější prostředkem technika analýzy plynů rozpuštěných v oleji, resp. skupina metod zastřešovaný tímto pojmem. Na této metodice je založen první modul – DGA modul. Metody byly otestovány skupinou validačních dat o 38 vzorcích se známým stavem transformátoru. Implementace základních vybraných metod (IEC, Rogers, Doernenburg, C.E.G.B. a metoda Duvalova trojúhelníku) ukázala silnou citlivost na nejednoznačnosti a nepřesnosti v datech. Úspěšná klasifikace poruchy se pohybovala v rozmezí 24% pro metodu Doernenburg až 68% pro metodu Duvalova trojúhelníku. Největší slabinou se ukázaly situace, kdy metody nebyly schopny podat žádný závěr, a to zpravidla v 33% případech. Aplikací fuzzy logiky a následně fuzzy-neuronových sítí se tento jev podařilo kompletně eliminovat. Výjimku tvoří některé implementace fuzzy inferenčního systému s trojúhelníkovými, resp. trapezoidními funkcemi příslušnosti. Následná úspěšnost DGA metod byla tímto přístupem navýšena až do oblasti 60% až 78%, resp. 70% až 81% pro fuzzy-neuronové sítě.

Druhý navržený a realizovaný rozšiřující modul se zabývá problematikou predikce. Umělá inteligence zastřešuje několik prostředků pro predikce, pro účely této práce jsou vybrány neuronové sítě a dvojice evolučních algoritmů – GP a GEP. Práce se zabývá popisem implementace a následným porovnáním predikčních mechanismů co se přesnosti a náročnosti na výpočetní prostředky týká. Porovnání proběhlo na množině dat vybraných transformátorů. Ve vlastní části práce jsou uvedeny jen výsledky pro první vybraný transformátor, zbylé hodnoty jsou umístěny v příslušné příloze. K posouzení bylo použito zejména koeficientů korelace a determinace. Při vyhodnocení predikcí na datech plynové chromatografie není jasně stanovitelné, který ze dvou, resp. tří algoritmů podává přesnější predikce. U hodnot  $t_g \delta$  je situace odlišná. Zde se dají stanovit algoritmy GP a GEP jako lepší predikční mechanismy než neuronové sítě. Při hodnocení časové náročnosti je vyhodnocení zcela jasné – neuronové sítě mají minimální nároky oproti evolučním mechanismům. Hodnocení poměru cena/výkon je pak jednoznačně ve prospěch neuronových sítí.

Poslední část práce se zabývá problematikou optimalizace. Zde je cílem základní rozbor zvolených optimalizačních technik na bázi umělé inteligence (DE, PSO a GA), tzn. uvedení, porovnání a posouzení možností optimalizace a následná aplikace na optimalizaci fuzzy modelů. Zde je zjištěno, že v případě jednoúčelové optimalizace jsou vhodné všechny zvolené algoritmy, nicméně nejlepších výsledků dosahuje DE a PSO. U víceúčelové optimalizace se vyčleňuje algoritmus PSO, ten

má v tomto typu úloh problémy s konvergencí k optimálnímu řešení. Výsledky podobného charakteru jsou získány při aplikaci optimalizace na fuzzy modely. Finální optimalizované DGA modely jsou opět vyhodnoceny s úspěšností v řádu 80% - 88% po optimalizaci metodami DE a GA a 69% - 78% pro PSO, kde dochází i k mírnému poklesu oproti původním fuzzy modelům.

## PŮVODNOST PRÁCE

Za původní v práci považují:

- Návrhem a realizací diagnostického expertního systému bylo dosaženo
  - Stanovení a ucelení teoretických základů pro použité prvky umělé inteligence
  - Navržení diagnostického systému a rozšiřujících subsystémů a modulů
  - Implementace základní vrstvy diagnostického systému v podobě expertního systému
  - Implementace rozšiřujících subsystémů
- Tvorba DGA modulu
  - Návrh a popis struktury DGA modulu
  - Implementace metod pro analýzu plynů rozpuštěných v oleji, jejich analýza a ověření
  - Zjištění velké chybovosti a citlivosti klasických metod DGA na nepřesnosti, nejistoty a mnohoznačnost v datech
  - Rozšíření metod pro analýzu plynů rozpuštěných v oleji o fuzzy přístupy a fuzzy-neuronové sítě
  - Zvýšení přesnosti a eliminace neznámých stavů metod pro analýzu plynů rozpuštěných v oleji
- Tvorba predikčního modulu
  - Návrh, implementace a popis predikčního modulu a jeho rozhraní
  - Rozbor přesnosti a náročnosti predikčních přístupů za použití umělé inteligence
  - Ověření a vyhodnocení na reálných datech vybraných transformátorů
- Rozbor možností optimalizace fuzzy modelů
  - Rozbor a porovnání základních optimalizačních metod na bázi umělé inteligence
  - Optimalizace fuzzy modelů metod pro analýzu plynů rozpuštěných v oleji
  - Další navýšení přesnosti fuzzy DGA modelů, ověření a porovnání výsledků s předchozími verzemi



## SEZNAM POUŽITÉ LITERATURY

- [1] LIN, C. F.; LING, J. M.; HUANG, C. L. „*An Expert System for Transformers Fault Diagnostics Using Dissolved Gas Analysis*“. IEEE Transaction on Power Delivery. 1993, Vol. 8, No. 1, s. 231 -238.
- [2] TOMASOVIC, K.; TAPPER, M.; INGVARSSON, T. „*A Fuzzy Information Approach to Integrate Different Transformer Diagnostic Methods*“. IEEE Transaction on Power Systems. 1993, Vol. 8, No. 3, s. 1638 - 1646.
- [3] CHANG, CS; LIM, CW; SU, Q. „*Fuzzy-Neural Approach for Dissolved Gas Analysis of Power Transformer Incipient Faults*“. Australian Universities Power Engineering Conference. 2004.
- [4] HUANG, Y.-C., „*Evolving Neural Nets for Fault Diagnosis of Power Transformer*“, IEEE transactions on power delivery. 2003, Vol. 18, No. 3, s. 843-848.
- [5] CHANG, CS; LIM, CW; SU, Q. „*Fuzzy-Neural Approach for Dissolved Gas Analysis of Power Transformer Incipient Faults*“. Australian Universities Power Engineering Conference. 2004.
- [6] M. HAMMER, *Metody umělé inteligence v diagnostice elektrických strojů*, Praha: BEN – technická literatura, 2009.
- [7] J. A. LAPWORTH, P. N. JARMAN a I. R. FUNNELL, „*Condition Assessment Techniques for Large Power Transformers*“, v Of The Reliability of Transmission and Distribution Equipment Conference, Coventry, 1995.
- [8] D. S. KOVAČEVIC, S. P. ŠKUNDRIC a J. M. LUKIC, „*Monitoring and Diagnostics of Power Transformer Insulation*“, v Thermal Science, Serbia, 2006.
- [9] ČEZ, a.s., PODNIKOVÁ NORMA evid.č. 00/05. *Profylaktika elektrických strojů netočivých - výkonové transformátory*. Praha: ČEZ, a.s., 2006. 93 s.
- [10] M. DUVAL a A. DEPABLA, „*Interpretation of gas-in-oil analysis using new IEC publication 60599 and IEC TC 10 databases*“, IEEE Electrical Insulation Magazine, pp. 31-41, 3 2001.
- [11] F. R. NAU, „*What's the bottom line? How to compare models*“, [Online]. Dostupné z: <http://www.duke.edu/~rnau/compare.htm>. [Přístup získán 30.10.2012].
- [12] S. DEVIANT, „*Statistics How To*“, 12.3.2012. [Online]. Dostupné z: <http://www.statisticshowto.com/articles/how-to-compute-pearseons-correlation-coefficients/>. [Přístup získán 30.10.2012].
- [13] J. A. MINCER, *Economic Forecasts and Expectations: Analysis of Forecasting Behavior and Performance*, NBER, 1969.
- [14] IEC 60599, *Mineral oil-impregnated electrical equipment in service – Guide to the interpretation of dissolved and free gases analysis*, Geneva, Switzerland: IEC, 2007, p. 69.
- [15] IEEE Std C57.104-1991, *IEEE Guide for the Interpretation of Gases Generated in Oil-Immersed Transformers*, IEEE, 1992, p. 30.

## ŽIVOTOPIS

### Osobní informace

Příjmení, jméno	Janda, Ondřej
Datum narození	16. února 1984
Stav	svobodný
Adresa	Prušánecká 2, Brno – 628 00
Telefon	+420 605 472 410
E-mail	janda.o@seznam.cz

### Vzdělání

2009 – dosud	VUT v Brně, Fakulta strojního inženýrství, Ústav výrobních strojů, systémů a robotiky, Ph.D. student, téma: <i>Umělá inteligence v diagnostice výkonových olejových transformátorů</i>
2006 – 2009	VUT v Brně, Fakulta strojního inženýrství, Ústav automatizace a informatiky, Diplomová práce: <i>Zpracování obrazů mikroskopických vzorků</i>
2003 – 2006	VUT v Brně, Fakulta strojního inženýrství, Ústav automatizace a informatiky, bakalářská práce: <i>Interaktivní webová prezentace pomocí technologie Flash – datové komprese</i>
1999 – 2003	SPŠ Slévárenská

### Pracovní zkušenosti

2011 – dosud	VUT v Brně, Fakulta strojního inženýrství, Ústav výrobních strojů, systémů a robotiky, asistent
--------------	---

### Znalosti a dovednosti

Jazykové znalosti	Anglický jazyk
Práce na PC	Vybrané programy: MS Office, Maple, Matlab Programovací jazyky: C#, C++
Pedagogická činnost	2009 – 2012 Vedení laboratorních cvičení z předmětu <i>Elektrotechnika a elektronika (2. a 3. ročník bakalářského studia na FSI VUT v Brně)</i>

## VLASTNÍ PUBLIKACE

- HAMMER, M.; JANDA, O. Expertní systémy v diagnostice transformátorů - 1. část. *Elektrorevue - Internetový časopis* (<http://www.elektrorevue.cz>). 2011. 2011(28). p. 1 - 12. ISSN 1213-1539.
- HAMMER, M.; JANDA, O. Expertní systémy v diagnostice transformátorů - 2. část. *Elektrorevue - Internetový časopis* (<http://www.elektrorevue.cz>). 2011. 2011(28). p. 1 - 12. ISSN 1213-1539.
- ERTL, J.; HAMMER, M.; MINISTR, M.; JANDA, O. Failure Probability Prediction of Power Oil Transformers. *MM Science Journal*. 2011. 4(3). p. 237 - 246. ISSN 1803-1269.
- JANDA, O.; HAMMER, M.; ERTL, J.; MINISTR, M. Application of Fuzzy Logic in Power Oil Transformers Diagnostics. *MM Science Journal*. 2011. 4(3). p. 319 - 324. ISSN 1803-1269.
- JANDA, O.; HAMMER, M.; MINISTR, M.; ERTL, J. Adaptive Neuro-Fuzzy Inference System for Power Oil Transformer Diagnostics. *MM Science Journal*. 2011. 4(3). p. 325 - 331. ISSN 1803-1269.
- MINISTR, M.; HAMMER, M.; ERTL, J.; JANDA, O. Ratio Methods Confrontation of Dissolved Gas Analysis. *MM Science Journal*. 2011. 4(3). p. 228 - 236. ISSN 1803-1269.
- HAMMER, M.; MINISTR, M.; ERTL, J.; JANDA, O.; BARVENČÍK, O. Power Oil Transformer Reliability Assessment Based on Fuzzy Inference Systems and Time Series Analysis. *Energyspectrum - International e-Journal*, [www.energyspectrum.net](http://www.energyspectrum.net). 2011. 6(1). p. 5 - 16. ISSN 1214-7044.
- HAMMER, M.; ERTL, J.; JANDA, O.; BARVENČÍK, O.; MINISTR, M. Predikce poruch výkonových olejových transformátorů na základě časových řad a fuzzy přístupů. *Technická diagnostika*. 2012. 21(z1/2012). p. 69 - 75. ISSN 1210-311X.
- HAMMER, M.; ERTL, J.; JANDA, O. Cox Model in Reliability Theory of Power Oil Transformers. *International Review on Modelling and Simulations*. 2012. 5(2). p. 953 - 958. ISSN 1974-9821.
- HAMMER, M.; JANDA, O.; ERTL, J. Využití vybraných soft-computingových metod v diagnostice výkonových olejových transformátorů - 3. část. *Elektrorevue - Internetový časopis* (<http://www.elektrorevue.cz>). 2012. 2012(33). p. 1 - 7. ISSN 1213-1539.
- HAMMER, M.; JANDA, O.; ERTL, J. Využití vybraných soft-computingových metod v diagnostice výkonových olejových transformátorů - 1. část. *Elektrorevue - Internetový časopis* (<http://www.elektrorevue.cz>). 2012. 2012(33). p. 1 - 13. ISSN 1213-1539.
- HAMMER, M.; JANDA, O.; ERTL, J. Využití vybraných soft-computingových metod v diagnostice výkonových olejových transformátorů -

2. část. *Elektrorevue - Internetový časopis* (<http://www.elektrorevue.cz>). 2012. 2012(33). p. 1 - 14. ISSN 1213-1539.

- HAMMER, M.; ERTL, J.; JANDA, O. Estimation of Reliability Characteristics of Power Oil Transformers. *Engineering Mechanics*. 2012. 19(1). p. 61 - 72. ISSN 1802-1484.
- HAMMER, M.; ERTL, J.; JANDA, O. Predikce vícestavové spolehlivosti výkonových olejových transformátorů. *Elektrorevue - Internetový časopis* (<http://www.elektrorevue.cz>). 2012. 2012(63). p. 1 - 8. ISSN 1213-1539.
- HAMMER, M.; ERTL, J.; JANDA, O. Návrh spolehlivostního modulu expertního systému pro vyhodnocení stavu výkonových olejových transformátorů. *Elektrorevue - Internetový časopis* (<http://www.elektrorevue.cz>). 2012. 2012(64). p. 1 - 8. ISSN 1213-1539.
- HAMMER, M.; JANDA, O, ERTL, J. „*Model Parameters Optimization for State Assessment of Power Oil Transformers*“. *Energyspectrum – International e-journal*, [www.energyspectrum.net](http://www.energyspectrum.net). 2012. V tisku.

## ABSTRACT

This dissertation deals with the application of the expert systems and soft computing methods in the field of the power oil transformers. The main work is divided into the theoretical and practical part.

First, the theoretical part presents the basic elements of the transformer, and approaches to its diagnosis. The work focuses mainly on the diagnostics of the insulation system, and on the diagnostic methods and approaches in this specific area. Next part describes the basics of the expert systems and other soft computing methods such as: fuzzy logic, neural networks, and genetic algorithms and their combinations and extensions. At the end of the theoretical part, the possibility of optimization approaches by means of artificial intelligence and its application in fuzzy model optimization is described.

The practical part begins with the description of the used data file which runs through the entire work. The work is then divided into four parts, namely in parts which deal with the expert system for transformer diagnostics, DGA module, prediction module, and optimization by using artificial intelligence. The section describing the expert system gives specific information about the particular expert system. The means and techniques used for constructing given system are described, and then the complete system design and description of all subsystems and modules are presented. The next section describes the developed DGA module and all selected approaches to its implementation and expansion. At the end of the chapter, the results of comparison between all implemented methods are evaluated. The third part deals with the prediction module and describes its design and construction, including description of the main parts which are based on the selected predictive approaches. Also, the predictions of selected quantities from the data file are included. There are two predictive approaches being used: the one step prediction,

and the multiple step prediction. The comparison of prediction accuracy and computational cost of given methods is presented at the end of this chapter. The last part deals with the possibilities of optimization using artificial intelligence methods, namely differential evolution, PSO, and genetic algorithms. Both the single-objective and the multi-objective optimization are considered. The methods are compared in a series of synthetic tests and then applied to optimize the fuzzy models of DGA tests from an earlier part of this work.

The dissertation also includes chapters: "The Aims", "The Contribution of the Work", and a list of publications, products, and projects of the author.

## **ABSTRAKT**

Disertační práce se zabývá aplikací expertních systémů a softcomputingových metod v problematice diagnostiky výkonových olejových transformátorů. Práce je rozdělena na část teoretickou a část praktickou.

Teoretická část popisuje základními částmi transformátoru a možnostmi jeho diagnostiky. Práce se zaměřuje zejména na diagnostiku izolačního systému a diagnostické metody a přístupy v této oblasti. Následně jsou popsány základy expertních systémů a dalších softcomputingových metod jako: fuzzy logika, neuronové sítě, genetické algoritmy a jejich kombinace a rozšíření. Závěrem se teoretická část zabývá optimalizací pomocí umělé inteligence a postupy při optimalizaci fuzzy modelů.

Praktická část se v úvodu věnuje rozboru a popisu datového souboru, který je využíván v rámci celé práce. Dále je pak práce členěna do čtyř částí, a to na expertní diagnostický systém transformátorů, modul analýzy plynů rozpuštěných v oleji, predikční modul a optimalizaci pomocí umělé inteligence. V části popisující expertní systém jsou uvedeny konkrétní informace o daném expertním systému, následně jsou zde popsány použité prostředky a techniky. Dále je rozebrán kompletní návrh systému a popis všech subsystémů a modulů. Další část popisuje řešený DGA modul včetně všech zvolených přístupů k jeho implementaci a rozšíření. Na závěr kapitoly je provedeno porovnání všech implementovaných metod a vyhodnocení výsledků. Část třetí, zabývající se predikčním modulem, řeší návrh a konstrukci tohoto modulu včetně popisu hlavních částí obou zvolených predikčních přístupů. Jsou zde uvedeny predikce vybraných veličin z datového souboru pomocí dvou predikčních přístupů: po jednom kroku a po více krocích. Porovnání přesnosti predikcí a výpočetní náročnosti metod je uvedeno v závěru této kapitoly. Poslední část práce se věnuje možnostem optimalizace za použití metod umělé inteligence, a to diferenciální evoluce, částicových (úlových) algoritmů a genetických algoritmů. Je zde zvažována jednoúčelová a víceúčelová optimalizace. Metody jsou porovnány v sérii syntetických testů a následně aplikovány při optimalizaci fuzzy modelů DGA zkoušek z předchozí praktické části práce.

Součástí disertace jsou také kapitoly: „Cíle práce“, „Přínos práce“ a seznam publikací, produktů a projektů autora.