

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
Fakulta elektrotechniky a komunikačních technologií
Ústav výkonové elektrotechniky a elektroniky

Doc. Ing. Čestmír Ondrůšek, CSc.

**NESTANDARDNÍ METODY OPTIMALIZACE NÁVRHU
ELEKTRICKÝCH STROJŮ**

**NONSTANDARD METHODS OF ELECTRICAL
MACHINES DESIGN OPTIMIZATION**

TEZE HABILITAČNÍ PRÁCE



Brno 2002

KLÍČOVÁ SLOVA

elektrické stroje, optimalizace návrhu, genetický algoritmus, simulované žíhání

KEY WORDS

Electrical Machines, Design Optimization, Genetic Algorithm, Simulated Annealing

MÍSTO ULOŽENÍ PRÁCE

Vědecké oddělení FEKT, VUT v Brně

© Čestmír Ondrůšek
ISBN 80-214-2057-X
ISSN 1213-418X

Obsah

ÚVOD	5
1. OPTIMALIZAČNÍ METODY	6
1.1 ÚVOD DO OPTIMALIZACE	6
1.2 PARAMETRICKÁ OPTIMALIZACE	6
1.2.1 <i>Matematický popis parametrické optimalizace</i>	7
1.3 OPTIMALIZAČNÍ METODY	7
1.3.1 <i>Klasické metody optimalizace</i>	7
1.3.2 <i>Evoluční metody optimalizace</i>	9
1.4. GENETICKÝ ALGORITMUS	9
1.4.1 <i>Biologická podstata GA</i>	9
1.4.2 <i>Použití GA pro řešení problémů v technické praxi</i>	10
1.5. SIMULOVANÉ ŽIHÁNÍ	12
1.5.1 <i>Úvod</i>	12
1.5.2 <i>Analogie SA s fyzikálním systémem</i>	12
1.5.3 <i>Popis algoritmu SA</i>	13
2. OPTIMALIZACE TRANSFORMÁTORU PROUDU	13
2.1 POPIS ŘEŠENÉ ÚLOHY	13
2.1.2 <i>Optimalizace přístrojového transformátoru proudu</i>	15
2.1.2.1 <i>Návrh konstrukční řady transformátorů</i>	16
2.4. DOSAŽENÉ VÝSLEDKY	16
2.4.1 <i>Optimalizace pomocí genetického algoritmu</i>	16
2.4.2 <i>Optimalizace pomocí algoritmu simulovaného žihání</i>	20
2.4.3 <i>Zhodnocení výsledků</i>	20
3. OPTIMALIZACE ASYNCHRONNÍHO MOTORU	20
3.1 KONSTRUKČNÍ NÁVRH ASYNCHRONNÍHO MOTORU (ASM)	20
3.2.2 <i>Jmenovité hodnoty motoru</i>	21
3.2.3 <i>Charakteristiky motoru</i>	21
3.3 POSOUZENÍ KLASICKÉHO NÁVRHU ASM	22
3.4. POPIS PROGRAMU	22
3.4.1 <i>Úvod k programu</i>	22
3.4.2 <i>Popis řešené úlohy</i>	23
3.5. DOSAŽENÉ VÝSLEDKY	24
3.5.1 <i>Popis návrhu motoru 5,5 kW, 380 V</i>	24
3.5.1.2 <i>Souhrnné výsledky</i>	25
3.6. ZHODNOCENÍ VÝSLEDKŮ	26
4. ZÁVĚR	27
5. SEZNAM POUŽITÉ LITERATURY	29
ABSTRACT	30

ČESTMÍR ONDRŮŠEK se narodil v roce 1941 v Uherském Hradišti. V roce 1959 absolvoval studium na VŠE v Břeclavi, obor Výroba a rozvod elektrické energie. V roce 1959 nastoupil do Centroprojektu Gottwaldov, kde pracoval jeden rok jako projektant silnoproudých zařízení. V roce 1965 ukončil studium na letecké fakultě VA AZ v Brně, obor Elektrická a speciální výzbroj letadel. V roce 1965 nastoupil na VA AZ v Brně jako asistent. V roce 1976 obhájil kandidátskou disertační práci na téma „Závislost zátěžného úhlu synchronního generátoru na otáčkách se zřetelem na řízení předstihu spalovacích motorů“. V roce 1986 byl jmenován docentem v oboru Elektrické stroje. Od 1. 1. 1991 nastoupil na Ústav elektrických strojů a přístrojů FEI VUT v Brně. V současné době je vedoucím Ústavu silnoproudé elektrotechniky a elektroniky na FEKT VUT v Brně. V letech 1968 – 1970 působil na MTC Cairo, Egypt. V letech 1978 – 1981 působil na MTC Bagdad, Irák.

Na VA AZ přednášel a cvičil v předmětech Silnoproudá elektrotechnika, Obecná elektrotechnika a podílel se na cvičeních z Teorie elektromagnetického pole a Elektrická měření. V zahraničí, MTC Bagdad, přednášel a cvičil předměty Electrical Machines, Electric Drives and Power Electronics.

V oblasti výzkumu se v současné době se zabývá především užitím umělé inteligence v silnoproudé elektrotechnice, identifikací a optimalizací parametrů elektrických strojů.

ÚVOD

Elektromechanické soustavy jsou nedílnou součástí mechanických systémů. Jejich optimalizace je základním předpokladem konkurence schopného výrobku. Cílem této práce je využití umělé inteligence, zejména genetického algoritmu pro optimalizaci návrhu elektrických strojů. Genetický algoritmus byl úspěšně ověřen na úloze optimalizace návrhu měřicího transformátoru proudu a konstrukčního návrhu asynchronního motoru s kotvou nakrátko. Snahou je nalézt optimální kombinaci konstrukčních parametrů, která dává nejlepší řešení stroje při minimalizaci jeho rozměrů. Dalším úkolem je posouzení vhodnosti využití genetických algoritmů na řešení obdobných úloh inženýrské praxe.

V inženýrské praxi se poměrně často vyskytují optimalizační a identifikační úlohy, které je možné řešit pouze pomocí výpočetní techniky. Současný stav technického rozvoje se vyznačuje zvyšováním výkonu strojů při udržení přijatelných výrobních nákladů. Značné požadavky jsou rovněž kladeny na provozní spolehlivost a bezpečnost navrhovaných strojů.

Z provozní praxe se neustále přesvědčujeme o značném vlivu dynamických vlastností elektromechanických systémů na jejich spolehlivost a bezpečnost. Přitom tendence snižovat cenu stroje vede často k nepříznivým dynamickým vlastnostem, projevujícím se růstem vibrací a hluku v provozních režimech. Také elektrické vlastnosti se výrazně zhoršují při snižování množství aktivních materiálů ve stroji. Zvýšené zatížení se v neposlední řadě projeví nadměrným oteplením, které nepříznivě působí na izolaci a snižuje životnost stroje.

Tyto nepříznivé vlastnosti lze sice odstranit růstem hmotnosti, ale stroj je pak materiálově i energeticky náročný, což se zpětně projeví na jeho ceně i provozních nákladech. Je zřejmé, že tímto způsobem nelze postupovat, protože takto navržený stroj by byl v současné tržní ekonomice neprodejný. Nelze zanedbat ani jeho energetickou náročnost. V době, kdy je životně důležité maximální využívání dostupných energetických zdrojů, by byl takový návrh nejen neekologickým, ale také neetickým řešením. Z popsanych skutečností vyplývá důležitost zkoumání elektrických a mechanických vlastností strojů jako elektromechanických soustav, jakož i hledání optimálních řešení. Zejména cílené změny konstrukčních parametrů, vedoucí k optimalizaci dynamických vlastností při splnění vhodných vedlejších podmínek (např. hmotnosti), nabývají stále většího významu.

Pro mnoho takových úloh je použití klasických numerických metod, založených na lineárním nebo nelineárním programování, značně omezené nebo dokonce nemožné. Zdá se tedy vhodnější využití evolučních optimalizačních metod, vycházejících z Darwinovy teorie přírodní evoluce a poznatků moderní genetiky. Jednou z takových metod je i genetický algoritmus. Jedná se o stochastickou optimalizační metodu, vhodnou pro řešení takových inženýrských problémů.

1 OPTIMALIZAČNÍ METODY

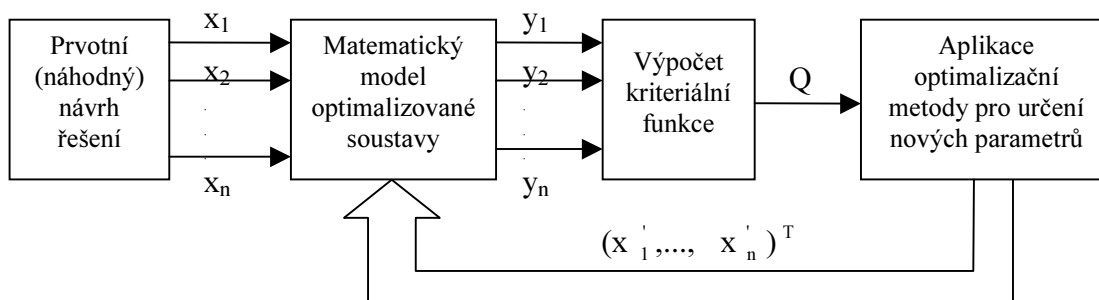
1.1 Úvod do optimalizace

Současný stav technického rozvoje se vyznačuje zvyšováním výkonu technických zařízení při udržování přijatelných výrobních nákladů. Značné požadavky jsou kladeny na provozní spolehlivost a bezpečnost konstrukcí. Z tohoto důvodu jsou cílené změny konstrukčních parametrů vedoucí k optimalizaci vlastností při splnění vhodných vedlejších podmínek (např. hmotnosti, objemu apod.) značně důležité.

Vlastnosti měřicího transformátoru proudu lze prostřednictvím stavových veličin spolehlivě matematicky popsat. Míru těchto vlastností popíšeme proto pomocí matematicky formulované tzv. cílové (účelové, kritériální, optimalizované) funkce. Nezávisle proměnné této funkce budou konstrukčními parametry transformátoru, pohybující se v příslušných oblastech. Konkrétní tvar této funkce závisí na konstrukčním řešení transformátoru. Matematicky formulované optimalizační úlohy ve spojení s numerickými metodami optimalizace umožňují v relativně krátké době propočítat značné množství konstrukčně odlišných variant transformátoru. Umožňují rovněž tyto výpočty provést již v předvýrobních etapách tak, aby prototyp měl vlastnosti optimalizované a tím ušetřit množství času i prostředků.

1.2 Parametrická optimalizace

Protože cílem této práce je nalezení vhodných (optimálních) konstrukčních parametrů konkrétních elektromechanických soustav, lze tuto optimalizační úlohu zařadit mezi úlohy parametrické optimalizace¹. Základní problém parametrické



Obr.1.1 Schéma parametrické optimalizace

(x ...optimalizované parametry, y ...odezva soustavy, Q ...parametr popisující kvalitu řešení)

optimalizace lze dekomponovat na tři části (Obr. 1.1):

1. Výběr vhodné kritériální funkce
2. Určení nastavitelných parametrů
3. Výběr a počítačová realizace metody nastavování parametrů pro automatickou optimalizaci (extremalizaci) kritériální funkce.

¹ Matematický popis parametrické optimalizace vychází z [2]

1.2.1 Matematický popis parametrické optimalizace

Parametrickou optimalizací rozumíme nalezení parametrů matematického modelu soustavy uspořádaných do vektoru p , který na určité množině P přípustných hodnot extremalizuje vhodně zvolenou cílovou kriteriální funkci k těchto parametrů. Kriteriální funkce $k(p)$ kvantifikuje míru vlastností soustavy (jako je např. hmotnost, cena, objem, nebo u transformátoru chyby proudu v přípustných oblastech stanovených normou), kterou je třeba extremalizovat (vybrat parametry s nejlepší mírou této vlastnosti). V definici přípustné množiny P (speciálně přípustné oblasti) zohledníme jednak konstrukční možnosti změn jednotlivých parametrů, případně do nich zavedeme vedlejší kritéria typu „míra vlastnosti nesmí překročit zadané kritické meze“. Možnost zohlednění konstrukčních možností změn parametrů vede na tzv. triviální (přirozená) nerovnicová omezení typu $p_i^d \leq p_i \leq p_i^h$, kde p_i^d je dolní a p_i^h horní omezení i -té optimalizační proměnné. Zavedení vedlejších kritérií vede k definici omezujících funkcí \bar{g}_i optimalizačních proměnných, pro které platí $g_i^d \leq \bar{g}_i(p) \leq g_i^h$, kde g_i^d je dolní a g_i^h horní omezení příslušné funkce.

Z matematického hlediska je parametrická optimalizace technických soustav formulována jako úloha nalézt vektor p z přípustné množiny P , ve kterém kriteriální funkce $k(p)$ nabývá svého globálního extrému vzhledem k P . Přípustná množina je popsána obecně m nerovnicovými omezeními definovanými prostřednictvím funkcí $g_j(p)$, kde $j=1, \dots, m$.

Pro vyřešení úlohy je zejména nutné vyřešit následující problémy:

1. formulovat matematický model
2. vybrat vhodné optimalizační parametry
3. formulovat konkrétní tvar kriteriální funkce
4. provést formulaci konkrétního tvaru omezujících funkcí
5. vybrat vhodnou optimalizační metodu
6. matematicky zvládnout formulovanou optimalizační úlohu.

Pokud při optimalizačním procesu provádíme optimalizaci více parametrů, stává se cílová funkce funkcí vícekriteriální. Cílová funkce je potom ve tvaru váženého součtu jednokriteriálních funkcí. Každá z těchto funkcí nabývá svého minima obecně v jiném místě prostoru optimalizačních parametrů. Proto vícekriteriální funkce může mít větší množství mělkých lokálních minim, případně je na změnu optimalizačních parametrů málo citlivá. Tato skutečnost klade vyšší nároky na výběr vhodné optimalizační metody, která se s tímto nepříjemným jevem vícekriteriální optimalizace umí vypořádat.

1.3 Optimalizační metody

1.3.1 Klasické metody optimalizace

Metody optimalizace mohou být analytické nebo numerické. Jelikož většina optimalizačních úloh v technické praxi (na reálných soustavách) vede na soustavu nelineárních (transcendentních) rovnic (viz.[2]), které jsou analyticky řešitelné jen

ve zcela ojedinělých případech, budu se v tomto textu orientovat výhradně na metody numerické optimalizace.

Podle počtu nezávisle proměnných kriteriální funkce lze optimalizační metody rozdělit na metody hledání minima funkce jedné proměnné a hledání minima funkce více proměnných. Protože optimalizace parametrů měřicího transformátoru proudu je úlohou hledání minima funkce více proměnných, budu se nadále věnovat pouze těmto metodám.

- **Gradientní metody**

Strategie gradientních metod je založena na skutečnosti, že gradient skalární funkce je vektor, který udává směr největšího vzrůstu dané kriteriální (optimalizované) funkce $f(x)$. Je tedy přirozené, že hledáme-li minimum, snažíme se postupovat opačným směrem, než nám udává gradient (v praxi se počítá se zápornou hodnotou gradientu).

- **Simplexové metody**

Při popisu simplexové metody je nejdříve nutné popsat definici pojmu regulární simplex, na níž je tato metoda postavena.

Simplexy jsou regulární mnohoúhelníky v n -rozměrném prostoru, tzn. nejjednodušší útvary v dané dimenzi tohoto prostoru. Např. při dvou proměnných je regulárním simplexem rovnostranný trojúhelník, v případě tří proměnných je simplexem tetraedr atd.

Každý vrchol simplexu je definován vektorem souřadnic x . Vrchol, v němž je hodnota účelové funkce nejvyšší, je z pravidelného simplexu vypuštěn. Nový vrchol simplexu vznikne jako obraz vypuštěného bodu v symetrii přes těžiště simplexu daného zbývajícími vrcholy. Takto pokračujeme do té doby, než se přestanou nacházet nové vrcholy simplexu s nižší hodnotou, než je hodnota předcházející.

- **Stochastické metody optimalizace**

Dosud uvedené metody jsou vhodné spíše pro optimalizaci kriteriální funkce s jedním extrémem (globálním minimem). Mimo to mohou tyto metody konvergovat velmi pomalu, jestliže se jedná o hřebenovitý charakter kriteriální funkce, nebo jestliže je kriteriální funkce po částech diferenciable nebo po částech spojitá.

Jisté řešení těchto problémů je v použití tzv. *stochastických metod optimalizace*, které místo výpočtu směru a kroku postupu počítají funkční hodnoty kriteriální funkce ve velkém množství náhodně vybraných bodů ze stavového s -rozměrného prostoru (s - počet optimalizačních proměnných). Tyto body jsou vybírány podle určitých kritérií tak, aby byla zajištěna stejná pravděpodobnost výběru pro každý bod tohoto prostoru. Srovnáním funkčních hodnot pro všechny vypočítané body vybíráme nejlepší řešení, ve kterém tato funkce nabývá minima. Z principu těchto metod vyplývá, že provádění vyčíslení funkčních hodnot pro velké množství bodů, což přináší značné prodloužení výpočtového času. U kriteriálních funkcí s velkým počtem extrémů však umožňují nalezení právě globálního minima, což je jejich nespornou výhodou.

- **Algoritmus „Hill Climbing“ (horolezecký algoritmus)**

Tento algoritmus je v podstatě jistou obdobou gradientní metody, kde směr nejprudšího spádu kriteriální funkce neurčuje gradient dané funkce, ale získává se

při prohledávání okolí aktuálního bodu stavového prostoru. Tato metoda, stejně jako gradientní metody, snadno končí v lokálních minimech kriteriální (optimalizované) funkce. Tento jev se potlačuje tím, že je metoda „nastartována“ několikrát z různých počátečních bodů stavového prostoru² a jako globální minimum je vzato nejlepší dosažené řešení. Pro každý nově navržený bod se generuje pomocí konečného počtu transformací určité okolí a v tomto okolí se nalezne nejlepší minimum optimalizované funkce. Toto získané lokální minimum je pro další krok použito jako střed nového okolí a celý proces se opakuje. Nevýhodou této metody je to, že po určitém počtu kroků se algoritmus může vrátit do lokálního minima z předchozího kroku (tomuto jevu se říká *zacyklení*).

- **Algoritmus „Tabu Search“ (zakázané prohledávání)**

Tato metoda je postavena na principech výše popsaného *horolezeckého algoritmu*, snaží se však odstranit problém *zacyklení*. Do *horolezeckého algoritmu* je zavedena tzv. *krátkodobá paměť*, do které se po určitou dobu ukládají předcházející inverzní transformace t k lokálně optimálním transformacím řešení, použitým k získání nových středů pro jednotlivé iterace. Tyto transformace jsou při tvorbě nového okolí pro dané aktuální řešení zakázány (odtud název *tabu*). Tímto způsobem je možno podstatně omezit *zacyklení* algoritmu při pádu do lokálního minima

1.3.2 Evoluční metody optimalizace

Evoluční metody optimalizace patří k stochastickým optimalizačním metodám, liší se však principy, které do jisté míry napodobují procesy probíhající v reálných fyzikálních systémech nebo v živé přírodě. Typickým zástupcem těchto algoritmů je *genetický algoritmus (GA)*, který napodobuje procesy probíhající v živé přírodě při evoluci organismů a *algoritmus simulovaného žhání (SA)* napodobující žhací procesy při ochlazování kovových materiálů. Obě tyto metody byly použity v této práci při optimalizaci transformátoru proudu a jsou popsány v kapitolách 1.4. a 1.5.

1.4. Genetický algoritmus

1.4.1 Biologická podstata GA

Princip GA, jak již naznačuje jeho název, vychází z teorie popisující přírodní evoluci. V této části práce se pokusíme představit základní pojmy a zákony genetiky potřebné k pochopení principů probíhajících v živé přírodě.

Základní stavební jednotkou každého živého organismu je buňka, která právě ve svém jádře uchovává genetické informace jedince. Soubor dědičných informací (*genů*) je ve formě kyseliny DNK (kyselina deoxiribonukleová) vázán na zvláštní tyčinkové útvary, které se nazývají *chromozomy*. Genetická proměnlivost vzniká při dělení buněk. V živých organismech jsou známy dva druhy tohoto dělení. První způsob se nazývá *mitóza*, při které dostává dceřinná buňka stejnou genetickou sadu jako má buňka rodičovská. Druhý způsob, pro nás zajímavější, se nazývá *meióza*. Probíhá při dělení pohlavních buněk a dochází při ní k výměně

² Tyto body jsou vybírány náhodně. Z tohoto důvodu byla tato metoda zařazena mezi metody stochastické.

částí chromozomů mezi buňkami různých pohlaví a tím i ke změně informačního obsahu jednotlivých chromozomů při pochodu zvaném *křížení*.

Soubor všech genů, které má organismus k dispozici pro zajištění svých biochemických, fyziologických a morfologických vlastností a znaků se nazývá *genotyp*. Soubor všech pozorovatelných znaků a vlastností organismu (barva očí, barva vlasů, výška, apod.) se nazývá *fenotyp*, který vzniká činností genotypů. Jedinci příslušní k stejnému genotypu mohou mít jiné fenotypové projevy. Na těchto rozdílech se podílí vnější podmínky prostředí, v nichž se daný organismus nachází. Z toho vyplývá, že každý gen může nabývat více hodnot, které se nazývají *alely*. Gen je potom pouze obecné označení vlastnosti, naproti tomu je alela konkrétním označením stavu, ve kterém se gen nachází.

Soubor geneticky navzájem příbuzných jedinců se nazývá *populace*, která se však liší ve fenotypových projevech jednotlivých jedinců. Populace lze rozlišit na autogamické a alogamické, lišící se typem reprodukce. U autogamické populace organismu probíhá reprodukce principem samooplození. Naproti tomu alogamická populace provádí reprodukci pomocí křížení s opačným pohlavím. Genotyp každého potomka je potom dán kombinací alel jednotlivých genů dvou rozdílných rodičů.

Výsledný fenotyp potomka může být i odlišný od obou rodičů, tzn. že potomek nemá žádnou vlastnost nebo rys, který má alespoň jeden z rodičů. K tomuto velice zajímavému jevu přispívá vliv vnějšího okolí, který může způsobit náhodnou změnu hodnoty alely některých z genů. Tento jev se nazývá *mutace*.

V teorii genetických algoritmů se používá stejných pojmů stejného významu jako u živých organismů. U GA je pojmem chromozóm myšlena datová struktura obsahující zakódované hledané řešení daného problému (v našem případě se jedná o konkrétní hodnoty konstrukčních parametrů transformátoru). Geny jsou jednotlivé prvky výše zmíněné datové struktury. Uspořádání jednotlivých parametrů do řetězce udává genotyp hledaného řešení daného problému a fenotyp, který je reprezentován vlastnostmi a jejich projevy konkrétních návrhů možného řešení. Křížení v GA probíhá, obdobně jako u chromozomů živých jedinců, zkopírováním jedné části genů jednoho z rodičů a druhé části druhého z rodičů do datové struktury nového chromozomu, který je jejich potomkem. Mutace je prováděna změnou konkrétní hodnoty náhodně vybraného genu v řetězci. Hodnota kritériální funkce (kvalita navrhnutého řešení) je posuzována jako schopnost určitého jedince přežít.

1.4.2 Použití GA pro řešení problémů v technické praxi

GA je úspěšně aplikován v mnoha oblastech technické praxe při řešení složitých problémů, což vypovídá o jeho robustnosti a univerzálnosti. Protože oblast aplikace GA je velice rozsáhlá a v rámci tohoto textu stěží uspokojivě popsatelná, pokusím se v následujícím textu představit některé z oblastí inženýrské praxe, na kterých byl GA s úspěchem aplikován. Podrobný popis jednotlivých aplikací je v [6].

Identifikace parametrů soustavy: Při simulaci reálného objektu nebo ve fázi návrhu objektu je velice užitečné znát jeho matematický model. Tento model je

obvykle vyžadován ve formě přenosové funkce (odezva soustavy na jednotkový skok) nebo ve formě impulsní funkce (odezva na jednotkový impuls).

Parametry žádaného matematického modelu je proto nutné nastavit tak, aby chování modelu i reálného objektu bylo co nejvíce shodné. Protože při použití přenosových a impulsních funkcí stabilita systému klesá s rostoucí přesností řešení³, nelze použít gradientní numerické metody, které pro takovýto typ úloh nejsou účinné. Naproti tomu GA poskytuje přijatelné řešení v relativně krátkém čase.

Jako konkrétní příklad mohu uvést použití GA při identifikaci parametrů náhradního schématu piezokeramického aktuátoru. V této úloze byla pomocí modální analýzy zjištěna vlastní frekvence na reálném piezokrystalu a pomocí ní se prováděla identifikace členů náhradního schématu rezonančního obvodu, kde do chromozomu GA byly zakódovány parametry tohoto obvodu ovlivňující chování celé soustavy. Dalším příkladem mohou být identifikace náhradních schémat asynchronního a reluktančního motoru (více viz. [10]a [11]).

Řízení: V mnoha řídicích systémech se GA používá pro zlepšení chování a vlastností (např. rychlost a přesnost řízení atd.). Vhodné nastavení řady parametrů regulátoru výrazně zlepší i celkové chování systému. Například u klasického PID regulátoru se jedná o tříparametrickou optimalizaci. Vlastnosti PID regulátoru ovlivňuje proporcionální, integrační a derivační složka (proporcionální, integrační a derivační zesílení). Vhodné nastavení těchto složek ovlivňuje celkové vlastnosti regulačního procesu, jako je například rychlost akčního zásahu regulátoru, přesnost regulace a jiné.

Rozpoznávání řeči: V systému automatického rozpoznávání řeči je velice často mluvené slovo, které je testovaným objektem, ztotožňováno s předem uloženými řečovými referenčními modely. Právě porovnávání hlasového signálu s sebou nese řadu potíží, jako například kolísání testovaného signálu v čase nebo nestálost časových měřítek testovaného a referenčního hlasového signálu. Pro tento typ úloh byla vyvinuta metoda dynamické časové deformace (DTW). Tato metoda poskytuje přesné řešení, selhává však při nelineárních časových měřících. Experimentální výsledky prokázaly, že GA provede velmi přesné rozpoznání řeči. Oproti klasickým metodám, jako je DTW, poskytuje GA lepší výsledky i při rozpoznávání nejasných slov.

Inženýrský design: GA není používán pouze pro řešení problémů čistě matematicky orientovaných. GA může být také užíván pro inženýrský design, který zahrnuje optimalizaci tvaru předmětu, optimalizaci elektrických obvodů, redukci jejich složitosti a při mnoha jiných aplikacích. Příkladem může být optimalizace tvaru listu vrtule vrtulníku nebo optimalizace vodivých spojů na desce plošného spoje při návrhu složitých elektronických zařízení.

Robotika: Aplikace GA v robotice je především v navigačním systému robota. Navigace je v podstatě schopnost řízení směru a orientace robota ve vymezeném prostředí. Tato navigace by měla být navržena tak, aby robot dosáhl cílového určení bez ztráty orientace nebo kolize s jinými objekty. GA byl například použit při řízení trajektorie koncového efektoru ramene robota

³ Větší přesnost souvisí s větším počtem časových konstant a řádem soustavy, který nepříznivě působí na stabilitu soustavy.

skládajícího se ze tří částí. Výsledná trajektorie koncového efektoru je dána sérií možných uspořádání jednotlivých částí ramene. Protože počet těchto uspořádání není znám, musí být GA uzpůsoben na proměnnou délku řetězce s proměnným počtem neznámých.

Rozpoznávání objektů: Problém rozpoznávání objektů se dá rozdělit na dvě základní části: *Získání významných objektů z obrazových dat* - GA je použit pro automatické vygenerování obrazového filtru, který se používá pro dvourozměrné rozpoznávání objektů. Jedná se o úlohu potlačení pozadí a rozpoznání významných geometrických tvarů a klasifikaci objektů. Při této aplikaci se používá reálné kódování.

Rozpoznání objektů - Rovinný objekt je získán ze dvou relativních pohledů, jejichž závislost je řízena afinními transformační maticí. Transformační parametry jsou zjišťovány z trojice párových dominantních bodů získaných z hranic objektů.

Využití GA v neuronových sítích: V oblasti neuronových sítí (NS) se GA může použít např. pro učení (nastavování váhových koeficientů jednotlivých neuronů) neuronových sítí (jako náhrada za matematicky složité a ne vždy vhodné algoritmy učení), navrhování struktury NS (topologie uspořádání neuronů v jednotlivých hladinách) nebo při optimalizaci tvaru pravidla učení.

1.5 Simulované žihání

1.5.1 Úvod

Algoritmus simulovaného žihání (dále jen SA) lze, stejně jako genetický algoritmus, zařadit do skupiny evolučních algoritmů, které popisují evoluci reálných systémů. Narozdíl od GA, který v jednom kroku pracuje s velkým množstvím náhodně vygenerovaných řešení, pracuje algoritmus SA v jednom kroku pouze s řešením jediným.

1.5.2 Analogie SA s fyzikálním systémem

Problém žihání je v technice znám jako teplotní proces, při kterém dochází ke snižování vnitřní energie systému (např. odstraňování vnitřního pnutí u odlitků atd.). Tento proces se dá popsat následujícími kroky:

1. zahřátí tělesa na dostatečně vysokou teplotu
2. pozvolné snižování této teploty

Zahřátí tělesa na dostatečně vysokou teplotu umožňuje atomům překonávat lokální energetické bariéry, čímž se dostávají do rovnovážných poloh, kde na ně působí stejně velké přitažlivé a odpuzivé síly. Následným snižováním žhací teploty dochází k postupné fixaci atomů v rovnovážných polohách. Se snižující se teplotou klesá i schopnost atomů tyto lokální bariéry překonávat, až od určité teploty přestane k přeskokům atomů zcela docházet. Další snižování teploty již nemá vliv na velikost výsledné vnitřní energie, která je u ideálního systému nulová. Kvalitu výsledného systému tedy ovlivňuje velikost a gradient poklesu výchozí teploty. Nastavení příliš vysoké počáteční teploty zapříčiní nežádoucí, například geometrické změny odlitku. Naopak při nedostatečném zahřátí tělesa nedojde k uspořádání všech atomů. Tento, pro výslednou vnitřní energii systému, nepříznivý stav nastává i při rychlém poklesu teploty.

1.5.3 Popis algoritmu SA

Pomineme-li fyzikální význam žhacího procesu, můžeme dříve popsané postupy zobecnit a použít je při řešení úloh kombinatorické optimalizace, kde optimalizační problém je ekvivalentem ke stavu fyzikálního systému a kvalita řešení je ekvivalentem k vnitřní energii systému. Další pojmy jako je žhací teplota nebo míra snižování teploty jsou totožné a mají stejný význam.

Celý algoritmus se tedy dá popsat následujícími kroky:

1. nastavení dostatečně vysoké počáteční teploty T_{max}
2. určení počátečního stavu systému reprezentovaného vektorem x
3. výpočet funkční hodnoty počátečního stavu $y=f(x)$ (ohodnocení)
4. navržení nového bodu stavového prostoru x' pomocí funkce hustoty pravděpodobnosti nového bodu $g(z, T)$
5. výpočet funkční hodnoty nového bodu $y'=f(x')$
6. podle pravděpodobnostní funkce $h(x, x', T)$ rozhodnout o akceptaci nového bodu
7. snížení teploty $T_k=T(k)$, kde $T(k)$ je funkce určující způsob snižování teploty
8. test ukončovací podmínky. Pokud podmínka není splněna, algoritmus se vrací do bodu 4. Pokud podmínka splněna je, poslední akceptovaný bod je současně globálním minimem funkce $f(x)$. Ukončovací podmínka může být ve tvaru minimální hodnoty žhací teploty (blížící se 0) nebo minimální hodnoty kritériální funkce ($f(x)=min$) atd.

Algoritmus prohledává prostor možných řešení zprvu silně stochasticky s velkou pravděpodobností akceptace horších stavů, což umožňuje vymanit se z lokálních minim. Tato schopnost klesá se snižující se teplotou. Různé modifikace algoritmu závisí na tvaru použitých funkcí.

2 OPTIMALIZACE TRANSFORMÁTORU PROUDU

2.1 Popis řešené úlohy

- *Generované parametry*

Při výběru optimalizačních parametrů byl proveden rozbor úlohy a byly vybrány ty optimalizační parametry, které nejvíce ovlivňují vlastnosti navrženého transformátoru. Jedná se především o parametry, které při klasickém návrhu transformátoru volí konstruktér na základě svých zkušeností. Tyto parametry se však mohou pohybovat v širokém intervalu, proto navržení jejich hodnot je velice pracné a zdlouhavé. Konečný počet parametrů byl stanoven na 5. Tyto parametry, včetně popisu a intervalu možných hodnot, jsou uvedeny v tab. 2.1.1.

Označení	Dolní mez	Horní mez	Název
F1 [Az]	100	1500	Primární proudění
korekce_1 [z]	0	10	Závitová korekce sekundárního vinutí měř. jádra
h_1 [mm]	10	120	Výška magnetického jádra měřicí části
%Py [%]	0	100	Procentuelní část materiálu Py v měřicím jádře
korekce_2 [z]	0	10	Závitová korekce sekundár. vinutí jisticího jádra

tab.2.1.1 Optimalizační parametry

Změna počtu těchto parametrů je možná pouze zásahem do zdrojových kódů jednotlivých programů. Hodnoty horních a dolních mezí uvedených v tabulce jsou pouze orientační, proto je jejich změna v programu pracujícím s genetickým algoritmem umožněna. V programu pracujícím s algoritmem simulovaného žihání je nutný opět zásah do zdrojového kódu. Uvedené hodnoty jsou inicializovány při spuštění obou programů.

Pro obě optimalizační metody platí, že čím je interval těchto hodnot menší, tím metoda rychleji konverguje ke globálnímu minimu účelové funkce a množství lokálních minim je menší. U programu s genetickým algoritmem je možné volit počet inkrementů (dílků), na které bude daný interval rozdělen. Obecně se dá opět říci, že množství inkrementů ovlivňuje rychlost algoritmu v hledání globálního minima. Menší počet inkrementů výpočet sice urychlí, ale funkční hodnota nalezeného minima může mít větší hodnotu.

- **Účelová (kriteriální) funkce**

Účelová funkce je jednou z nejdůležitějších částí obou optimalizačních metod. Tato funkce přiřazuje konkrétně navrženému transformátoru reálnou hodnotu, která reprezentuje „kvalitu“ navrženého transformátoru. Tvar této funkce je pro obě optimalizační metody stejný a závisí na konkrétním typu řešené úlohy.

Například u problému identifikace parametrů náhradního schématu reálného elektrotechnického zařízení je tvar této funkce podle vztahu (2.1.1) nebo (2.1.2).

$$\varepsilon = k_1 \cdot \text{abs}(G_{01} - G_1) + \dots + k_n \cdot \text{abs}(G_{0n} - G_n) \quad (2.1.1)$$

n	<i>počet parametrů kriteriální funkce</i>
k	<i>váhový koeficient příslušného parametru</i>
G_0	<i>požadovaná hodnota parametru kriteriální funkce</i>
G_1	<i>skutečná hodnota parametru kriteriální funkce</i>

$$\varepsilon = k_1 \cdot (G_{01}^2 - G_1^2) + \dots + k_n \cdot (G_{0n}^2 - G_n^2) \quad (2.1.2)$$

Nejen tvar, ale především výběr vlastností a parametrů této funkce je pro úspěšnost optimalizace klíčový. Při optimalizaci transformátoru je tato funkce reprezentována vybranými vlastnostmi a konstrukčními parametry popisovaného transformátoru, které jsou následující:

- V [dm³] objem aktivních částí transformátoru
- C [Kč] cena aktivních částí transformátoru
- ε_{I1} [%] součet absolutních hodnot chyb proudu měřicí části pro 100% a 25% jmenovitého břemene
- ε_{n1} [-] Chyba skutečného nadproudového čísla měřicího jádra
- ε_{I2} [%] součet absolutních hodnot chyby proudu pro *jmenovitý proud* a celkové chyby transformátoru pro *jmenovitý nadproud* jistícího jádra
- ε_{a2} [%] chyba úhlu proudu jistícího jádra

a tvar této funkce je podle vztahu (2.1.3)

$$\varepsilon = k_V \cdot V + k_C \cdot C + k_{I_1} \cdot \varepsilon_{I_1} + k_{n_1} \cdot (n_0^2 - n^2) + k_{I_2} \cdot \varepsilon_{I_2} + k_{\alpha_2} \cdot \varepsilon_{\alpha_2} \quad (2.1.3)$$

kde

n skutečné nadproudové číslo měřicí části transformátoru

n_0 požadované nadproudové číslo měřicí části transformátoru

ε_{α_2} chyba úhlu jisticí části transformátoru pro 100% Z_n a 100% I_{2n} podle vztahu (2.32)

ε_{I_1} chyba proudu měřicího jádra pro 100% jmenovitého břemene Z_n podle vztahu (2.31)

$$\varepsilon_{I_1} = \sum abs(\varepsilon_{i1k}) + \sum abs(\varepsilon_{i2k}) \quad (2.1.4)$$

ε_{I_2} chyba proudu měřicího jádra pro 25% jmenovitého břemene Z_n podle vztahu (2.5.31)

k označuje procentuelní část jmenovitého proudu I_{2n} pro kterou se chyba počítá

$$\varepsilon_{I_2} = I_{20} + \varepsilon_i \quad (2.1.5)$$

I_{20} celková chyba jisticího jádra transformátoru pro jmenovitý nadproud nI_{2n} . Podle vztahu (2.35)

ε_i chyba proudu jisticího jádra transformátoru pro 100% Z_n a 100% I_{2n} podle vztahu (2.31)

Vliv každého parametru na celkovou chybu optimalizace se ovlivňuje nastavením hodnoty příslušného váhového koeficientu k . Pokud je požadavek na výraznější optimalizaci jedné vlastnosti (např. ceny), je příslušný váhový koeficient (v našem případě k_c) zvětšen a tím dojde k znevýhodnění ostatních parametrů. Nastavení těchto koeficientů je dalším klíčovým problémem celého optimalizačního procesu.

Protože reálné hodnoty chyb jednotlivých vlastností jsou řádově rozdílné, muselo být provedeno tzv. *normování* jednotlivých parametrů kriteriální funkce. Podstata této normalizace spočívá v podílu hodnoty konkrétního parametru hodnotou maximální, kterou tento parametr může nabývat. Touto úpravou se hodnota chyby pohybuje v intervalu (0,1). Zjištění maximálních hodnot některých parametrů principiálně není možné, proto byly tyto hodnoty nahrazeny hodnotami odhadnutými na základě zkušeností získaných při práci s programem pro výpočet transformátoru bez optimalizace.

- **Nerovnicová omezení**

Protože některá konstrukční řešení navrhnutá optimalizační metodou jsou principiálně nepřijatelná (např. chyba proudu překročila dovolené meze stanovené třídou přesnosti specifikované v příslušné normě), byla zavedena tzv. *nerovnicová omezení*, která při překročení určených hranic toto řešení znevýhodní umělým zvýšením chyby (funkční hodnoty kriteriální funkce). Takováto konstrukční varianta potom není optimalizačním algoritmem přijata jako možné řešení.

2.1.2 Optimalizace přístrojového transformátoru proudu

Před započítáním samotné optimalizace přístrojového transformátoru proudu vybranými optimalizačními metodami (GA a SA) je zapotřebí provést návrh

konstrukční řady měřicích transformátorů proudu. Návrh této řady prováděný obvyklým způsobem je důležitý zejména pro porovnání výsledků dosažených při optimalizaci a posouzení výhodnosti jednotlivých algoritmů.

2.1.2.1 Návrh konstrukční řady transformátorů

Při návrhu konstrukční řady se vycházelo z postupu popsáném v předchozí kapitole. Byl vytvořen počítačový program provádějící výpočty jednotlivých částí transformátorů v závislosti na vstupních volbách konstruktéra pro měřicí i jistící část transformátoru. Pro tento návrh byla zvolena konstrukční řada transformátorů s rozsahem primárního proudu 100-400 A, jejichž vstupní parametry doplněné o hodnoty parametrů kriteriální funkce jsou zahrnuty v tab. 2.1.2.

2.4. Dosažené výsledky

2.4.1 Optimalizace pomocí genetického algoritmu

Při práci s optimalizačním programem byla prováděna optimalizace s různými nastaveními parametrů genetického algoritmu. Vliv na rychlost poklesu chyby a na rychlost konvergence algoritmu ke globálnímu minimu měla velikost populace (VP) a počet mutací (PM), větší velikost populace měla za následek snížení počtu generací potřebných k nalezení minima, ale rychlost výpočtu jedné generace výrazně vrostla. Snížení VP mělo za následek opačný efekt. Přijatelný poměr mezi VP a rychlosti výpočtu bylo nastavení $VP=150$ a počet mutací na $PM=140$. Toto nastavení bylo použito u většiny optimalizací.

Optimalizace konstrukční řady transformátoru

Při optimalizaci konstrukční řady transformátorů byla požadována minimální cena (popřípadě objem) aktivních materiálů transformátorů (cenou se rozumí cena materiálu magnetického jádra, vodičů použitých na primární a sekundární vinutí) při dodržení požadavků stanovených třídou přesnosti. Daná třída přesnosti udává toleranční pásma pro chybu proudů měřicího jádra, chybu proudu jistícího jádra, chybu úhlu jistícího jádra a nadproudové číslo měřicího jádra, jejichž konkrétní hodnoty jsou specifikovány v normě IEC 185.

- Optimalizace celé řady na nejmenší **cenu aktivních materiálů**

Při optimalizaci na nejmenší cenu byl váhový koeficient příslušný ceně nastaven na hodnotu $k_c=20$. Ostatním koeficientům byla ponechána hodnota 1. Nastavení genetického algoritmu a dosažené výsledky po optimalizaci jsou shrnuty v tab. 2.4.1.

Porovnáním hodnot neoptimalizovaných (tab. 2.3.2) a hodnot optimalizovaných na minimální cenu aktivních materiálů (tab. 2.4.1) bylo zjištěno, že cena **poklesla** v průměru o **19,17 %** na jeden transformátor. Pokles ceny je však doprovázen zhoršením hodnot ostatních parametrů kriteriální funkce. Tyto parametry však setrvávají v požadovaných mezích, čímž byla norma ČSN dodržena a optimalizace byla úspěšná.

- Optimalizace celé řady na nejmenší **objem aktivních materiálů**

Při optimalizaci na nejmenší objem byl váhový koeficient příslušný objemu rovněž nastaven na hodnotu 20. Ostatním koeficientům byla ponechána hodnota 1. Nastavení genetického algoritmu a dosažené výsledky po optimalizaci jsou shrnuty v (tab. 2.4.2).

TRAFO	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	
I _{ln} [A]	10	15	20	25	30	40	50	60	75	100	150	200	250	300	400	
I _{thn} [kA]	6,3	10	16	16	25	31,5	31,5	31,5	31,5	31,5	40	40	40	50	63	
F1 [Az]	500	510	500	600	510	560	700	720	900	900	1050	800	1000	900	800	
U _{rs} [kV]	12	12	12	12	12	12	12	12	12	12	12	12	12	12	12	
Měřicí jádro	P _n [VA]	10	10	10	15	10	15	15	15	15	15	15	15	20	20	20
	n [-]	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5
	T _p [-]	0,5	0,5	0,5	0,5	0,5	0,5	0,5	0,5	0,5	0,5	0,2	0,5	0,2	0,5	0,5
	I _{2n} [A]	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5
	%P _y [%]	35	35	35	20	35	35	20	40	15	10	30	20	20	30	10
	kor. [z]	0,5	0,5	0,5	0,6	0,5	0,5	0,5	0,5	0,5	0,5	0,5	0,5	0,5	0,5	0,5
	h [mm]	20	20	20	30	20	20	20	20	20	20	20	20	20	20	30
	Jistící jádro	P _n [VA]	10	10	10	15	10	15	15	15	20	20	15	20	20	20
n [-]		10	10	10	5	10	5	10	10	10	10	10	10	10	10	10
T _p [-]		5P	5P	5P	5P	5P	5P	5P	5P	5P	5P	5P	5P	5P	5P	5P
I _{2n} [A]		5	5	5	5	5	5	5	5	5	5	5	5	5	5	5
%P _y [%]		0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
kor. [z]		0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
h [mm]		64	56	50	37	49	25	49	49	66	66	49	66	49	49	49
Vypočtené hodnoty jednotlivých parametrů kritériální funkce																
Cena [Kč]	1540	1887	1911	1671	2175	2235	2021	2005	1682	1263	1274	898	873	979	750	
Objem [dm ³]	6,004	7,308	7,360	6,722	8,554	8,806	8,518	7,504	7,069	5,672	5,174	3,875	3,717	3,860	3,256	
ε _{I 1} [%]	22,359	23,238	24,090	25,060	25,086	24,849	25,702	15,333	18,902	19,921	10,978	14,765	11,975	11,965	15,641	
n ₁ [-]	5,391	5,478	5,391	5,443	5,478	5,463	5,411	5,496	5,428	5,235	5,139	5,406	5,427	5,388	5,421	
ε _{I 2} [%]	4,936	5,182	5,291	4,496	5,530	5,522	4,008	3,716	2,842	2,625	2,254	2,574	2,077	2,365	2,287	
ε _{α 2} [min]	6,845	7,256	7,337	3,503	7,743	4,092	5,523	5,140	4,031	3,780	3,415	3,530	2,916	3,229	3,250	

Tab. 2.3.2 Vstupní parametry konstrukční řady transformátorů doplněné o hodnoty parametrů kritériální funkce (navrhované hodnoty jsou zvýrazněny)

TRAFO	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Nejlepší vstupní hodnoty generované genetickým algoritmem															
F1 [Az]	460	435	360	650	480	600	600	540	600	600	900	600	1000	900	800
korekce_1 [z]	0,7	0,7	0,5	0,8	0,6	0,9	0,8	0,7	0,7	0,7	0,6	0,6	0,6	0,6	0,5
h_1 [mm]	18	15	37	16	18	27	15	14	14	14	16	14	17	16	18
%Py [%]	10	20	25	5	25	5	10	15	5	5	15	5	5	5	5
korekce_2 [z]	0,5	0,8	0,6	0,9	0,8	1,0	0,8	0,6	0,8	0,5	1,6	0,5	0,5	0,5	0,7
Hodnoty parametrů kritériální funkce															
Cena [Kč]	1178	1520	1578	1518	1894	1872	1690	1398	1209	964	1020	729	747	733	677
Objem [dm³]	5,226	6,764	5,771	7,159	7,629	8,047	8,014	6,472	5,969	4,843	4,550	3,765	3,693	3,801	3,315
ε_{I1} [%]	34,102	35,024	32,975	29,925	30,190	33,700	31,630	29,813	29,430	27,313	15,478	25,167	14,906	17,505	18,407
n_1 [-]	5,458	5,475	5,413	5,498	5,348	5,466	5,462	5,470	5,465	5,465	5,299	5,464	5,440	5,433	5,500
ε_{I2} [%]	4,475	5,556	5,540	3,714	5,146	4,118	4,258	4,183	3,824	3,342	2,833	3,106	1,867	2,121	2,345
ε_{α} [min]	6,823	7,957	8,499	3,437	7,617	3,689	6,125	6,084	5,136	4,766	3,590	4,391	2,921	3,229	3,277
Nastavení genetického algoritmu															
Velikost populace	150	150	150	150	150	150	150	150	150	150	150	150	150	150	150
Počet mutací	140	140	140	140	140	140	140	140	140	140	140	140	140	140	140
Počet kroků GA	350	350	350	350	350	350	350	350	350	350	350	350	350	350	350
k_c	20	20	20	20	20	20	20	20	20	20	20	20	20	20	20
Ostatní váhy	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
Celková chyba	28,435	35,785	36,498	35,250	42,981	42,926	39,125	32,687	28,753	23,338	23,183	18,155	17,437	17,442	16,293

Tab. 2.4.1 Výsledky optimalizace konstrukční řady transformátorů na minimální cenu
(Optimalizované hodnoty cen jsou uvedeny v rámečku)

TRAFO	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Nejlepší vstupní hodnoty generované genetickým algoritmem															
F1 [Az]	340	285	360	450	240	440	450	540	375	500	450	600	750	900	800
korekce_1 [z]	0,4	0,3	0,3	0,5	0,2	0,5	0,3	0,6	0,3	0,4	0,2	0,4	0,4	0,6	0,5
h_1 [mm]	33	43	37	46	60	47	41	29	49	33	46	28	30	21	27
%Py [%]	30	55	50	30	65	30	55	20	55	35	55	30	30	5	15
korekce_2 [z]	0,4	0,3	0,3	0,7	0,3	0,8	0,4	0,5	0,4	0,4	0,5	0,8	0,5	0,4	0,4
Hodnoty parametrů kritériální funkce															
Cena [Kč]	1321	2055	1976	1605	2687	1935	2370	1481	2060	1289	1553	970	950	745	779
Objem [dm³]	4,675	5,332	5,880	5,356	5,909	6,544	6,403	5,657	5,015	4,173	3,906	3,553	3,356	3,686	3,244
ε_{I1} [%]	31,004	23,572	22,127	24,634	22,409	27,039	16,181	24,698	16,761	17,796	13,951	15,726	12,571	16,671	14,723
n_1 [-]	5,478	5,460	5,411	5,440	5,468	5,442	5,458	5,491	5,499	5,493	5,401	5,400	5,449	5,433	5,466
ε_{I2} [%]	5,499	6,843	5,819	4,384	8,065	4,804	4,616	3,696	4,593	3,408	3,796	3,100	2,272	2,071	2,086
ε_{α} [min]	8,142	9,598	8,406	3,639	11,178	4,025	6,622	5,603	6,427	4,924	5,552	4,162	3,411	3,180	3,221
Nastavení genetického algoritmu															
Velikost populace	150	150	150	150	150	150	150	150	150	150	150	150	150	150	150
Počet mutací	140	140	140	140	140	140	140	140	140	140	140	140	140	140	140
Počet kroků GA	350	350	350	350	350	350	350	350	350	350	350	350	350	350	350
k_0	20	20	20	20	20	20	20	20	20	20	20	20	20	20	20
Ostatní váhy	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
Celková chyba	27,998	31,508	33,796	30,962	34,749	37,482	36,170	32,377	28,973	24,061	22,616	20,413	19,072	20,924	18,553

Tab. 2.4.2 Výsledky optimalizace konstrukční řady transformátorů na minimální objem
(Optimalizované hodnoty objemů jsou uvedeny v rámečku)

Porovnáním hodnot neoptimalizovaných (tab. 2.3.2) a hodnot optimalizovaných na minimální objem aktivních materiálů (tab. 2.4.2) bylo zjištěno, že objem **poklesl** v průměru o **22,18 %** na jeden transformátor. Pokles objemu je rovněž doprovázen zhoršením hodnot ostatních parametrů kritériální funkce. Tyto parametry, stejně jak u optimalizace na nejmenší cenu, stále setrvávají v požadovaných mezích a tím je opět dodržen požadavek na příslušnou normu.

2.4.2 Optimalizace pomocí algoritmu simulovaného žíhání

Při práci s optimalizačním programem využívajícím algoritmus simulovaného žíhání byla prováděna optimalizace s různým nastavením parametrů algoritmu SA. Parametry, které byly u tohoto algoritmu měněny byl *počet akceptovaných stavů* (PAS), který měl vliv na rychlost ukončení algoritmu, a *míra poklesu žihací teploty* (MPT), která ovlivňuje rychlost poklesu teploty. Při rostoucí velikosti těchto parametrů roste i přesnost hledání globálního minima, ale rychlost ukončení algoritmu výrazně klesá. Jako vhodný kompromis mezi rychlostí a přesností optimalizace se projevila volba $PAS=6000$ a $MPT=10000$, která byla použita pro všechny prováděné optimalizace s tímto algoritmem.

2.4.3 Zhodnocení výsledků

Porovnání výsledků SA a GA se nedá jednoznačně určit, který algoritmus je při této optimalizační úloze úspěšnější, protože jejich výsledky jsou téměř shodné. Ve třech případech (při optimalizaci na minimální cenu, při optimalizaci na minimální objem a při současné optimalizaci na minimální cenu a objem) došlo k nalezení shodných minim kritériální funkce oběma algoritmy. Z toho lze usuzovat na to, že tyto vlastnosti závisí na většině optimalizovaných parametrů a proto má kritériální funkce jedno velice výrazné minimum. U ostatních optimalizací, kdy nedošlo k nalezení totožných minim, lze předpokládat závislost parametrů kritériální funkce na menším počtu optimalizačních parametrů.

3 OPTIMALIZACE ASYNCHRONNÍHO MOTORU

3.1 Konstrukční návrh asynchronního motoru (ASM)

Konkrétní návrh asynchronního motoru obvykle vychází z požadavků jednotlivých zákazníků, kteří konkrétně definují parametry, které má navržený stroj splňovat. Pro stejný výkon stroje potom můžeme získat různá provedení více či méně vyhovující jednotlivým podmínkám. Je možno požadovat pouze kvalitu jednoho parametru za cenu zhoršení parametrů jiných. Budeme se zabývat návrhem motorů o výkonech řádově (0,6 - 200)kW. Motory jsou navrhovány na trvalé zatížení a při zadání projektu jsou požadovány tyto vstupní hodnoty :

Výkon stroje P_n [kW], napětí U_{1n} [V], spojení vinutí Y/D , počet pólů $2p$ nebo otáčivá rychlost n [min^{-1}], kmitočet sítě f [Hz], účinnost η [%], účinník $\cos\varphi$, třída izolace, provedení IP a tvar stroje.

Jedná se o motory s kotvou nakrátko v uzavřeném provedení s kostrou a chladicími žebry. Klec rotoru je litá, hliníková. Při návrhu jsou potřebné údaje,

jako např. rozměry vodičů, drážek či magnetizační charakteristiky odečítány z tabulek a grafů, které jsou dány normou nebo měřením výrobce. Vlastní návrh potom spočívá v nalezení kompromisu mezi jednotlivými konstrukčními parametry takovými, aby výsledný stroj měl co možná nejlepší pracovní charakteristiky při dokonalém tepelném a materiálovém využití. Konkrétní návrh motoru je naznačen v následující kapitole.

3.2.2 Jmenovité hodnoty motoru

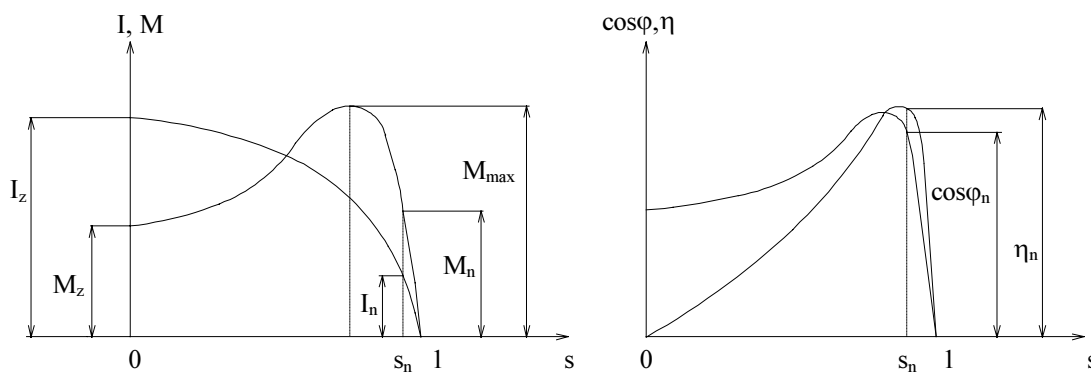
Tyto hodnoty jsou pro každý motor specifické a jsou hlavním kriteriem pro posouzení kvality návrhu. Počítají se z hodnot náhradního schématu a jsou uvedeny v tab. 3.5.

Název parametru	Veličina	Rozměr
Jmenovité napětí	U_{1n}	V
Jmenovitý proud	I_{1n}	A
Jmenovitý skluz	s_n	-
Jmenovité otáčky	n_n	min^{-1}
Jmenovitý příkon	P_{1n}	W
Jmenovitý výkon	P_n	W
Jmenovitý moment	M_n	Nm
Jmenovitý účinník	$\cos\varphi$	-
Jmenovitá účinnost	η	-
Maximální moment	M_{\max}	Nm

Tab. 3.5 Jmenovité hodnoty motoru

3.2.3 Charakteristiky motoru

K nejběžnějším charakteristikám, které se na asynchronním motoru měří, patří měření motoru naprázdno, nakrátko a při zatížení (tzv. momentová charakteristika). Někdy se u motoru měří také pracovní charakteristiky, které vyjadřují závislost momentu, příkonu, proudu, účinníku, účinnosti a skluzu na výkonu motoru. Pro posouzení návrhu motoru jsou nejdůležitější rozběhové charakteristiky, které vyjadřují závislost momentu a proudu na skluzu případně otáčkách motoru, obr. 3.5a) a charakteristiky účinníku a účinnosti na skluzu, především v oblasti jmenovitých hodnot, obr. 3.5b).



Obr. 3.5 Rozběhové charakteristiky asynchronního motoru

Při návrhu motoru se snažíme, aby rozběhové charakteristiky dosahovaly co nejlepšího průběhu, odpovídajícího teoretickým předpokladům. Snahou je co nejmenší jmenovitý skluz motoru, kdy jmenovité otáčky se nejvíce přibližují otáčkám synchronním. Pro rozběh motoru je důležitý co největší záběrný moment M_z , při co možná nejmenším záběrném proudu I_z . Při chodu motoru je potom nutné, aby při zvětšeném momentu zátěže nedošlo k překročení maximálního momentu motoru M_{max} , kdy se motor dostává do nestabilní oblasti. Tento fakt se při návrhu respektuje tzv. momentovou přetížitelností $m_p = M_{max}/M_n$, která se u dobře navržených motorů pohybuje v intervalu $(1,5 \div 2,5)$. Snahou celého návrhu je tedy dosažení dobrého průběhu momentové a proudové křivky, to vše pak při maximálních hodnotách účinníku a účinnosti motoru zejména v oblasti jmenovitého zatížení. Motor s malou hodnotou účinníku $\cos\phi$ nepříznivě působí na napájecí síť. V poslední době je však největší důraz kladen na vysokou hodnotu účinnosti, která především u středních a velkých strojů podstatně ovlivňuje jejich spotřebu elektrické energie. Typický zákazník tedy požaduje co nejlevnější stroj s vysokou hodnotou účinnosti, nehlučný, s průměrnými hodnotami ostatních provozních parametrů. Ve speciálních případech se potom upřednostňuje kvalita jednoho parametru na úkor ostatních podle předpokládaného použití motoru v provozu.

3.3 Posouzení klasického návrhu ASM

Návrh asynchronního motoru, pokud by byl prováděn ručně, představuje stovky výpočtů, které mohou trvat i zkušenému konstruktérovi řádově desítky hodin. V poslední době, kdy téměř do všech odvětví pronikly počítače, existuje řada programů, které dialogovou formou spolupracují s konstruktérem a značně urychlují výpočet. Na ústavu výkonové elektrotechniky a elektroniky FEI VUT v Brně je např. k dispozici program „MOTOR“, který byl vytvořen studenty v rámci diplomových prací.

I přes nesporné výhody tohoto návrhu je třeba si uvědomit, že existuje značné množství různých konstrukčních variant daného stroje, které více či méně splňují požadované provozní vlastnosti stroje, tedy více či méně se blíží ke globálnímu minimu účelové funkce, která kvalitu návrhu hodnotí.

Tak vznikla myšlenka pokusit se s využitím některé optimalizační metody sestavit program, který by prohledával celý stavový prostor všech možných řešení a vybral takovou variantu, která je nejvíce poplatná hodnotící účelové funkci (požadovaným vlastnostem motoru). Byla vybrána stochastická evoluční metoda genetický algoritmus, protože nejlépe prohledává celý stavový prostor všech možných řešení.

3.4. Popis programu

3.4.1 Úvod k programu

Pro výpočet asynchronního motoru bylo použito procedur a funkcí z již zmíněného programu „MOTOR“. Byl vytvořen program, který pro náhodně vygenerované konstrukční parametry a zadané vstupní hodnoty provede návrh asynchronního motoru, který zhodnotí vytvořenou kritériální funkcí. Tento výpočet se provádí pro každý genetický řetězec, jenž představuje sadu

vygenerovaných parametrů. Počet těchto genetických řetězců GR v jednom cyklu programu (populaci) se zadává jako všechny vstupní hodnoty ve vstupním souboru. Celý cyklus se neustále opakuje, dokud nedojde k ukončení běhu programu. Podmínkou ukončení algoritmu je pokles chyby nejlepšího řešení poslední populace pod hodnotu požadované chyby nebo proběhnutí programu požadovaným počtem opakování. Snahou je nalezení takového řešení motoru, které odpovídá vlastnostem popsaným v kapitole 3.2 (Charakteristiky ASM) při dobrém tepelném využití a minimalizaci jeho objemu.

Vstup programu

Po spuštění programu „ONAMGA.exe“ se objeví základní obrazovka s obecnými údaji. Stisknutím „Enter“ se uživatel přepne do další obrazovky, kde je možné zvolit způsob zadání programu, případně program ukončit. Lze vybrat dvě možnosti zadání :

1. Zadání ze souboru

V případě této volby jsou vstupní hodnoty zadány za souboru „VSTUP.txt“, který má pevně stanovenou formu zápisu a je možno ho přepsat v některém z editačních programů, např. editací v programu Norton Comander. Program se po načtení hodnot přepne do pracovní obrazovky, kde zůstane až do doby ukončení programu.

2. Zadání z klávesnice

Pokud uživatel zvolí druhý způsob zadávání z klávesnice jsou hodnoty načteny ze vstupního souboru, ale je možno je změnit právě zadáním z klávesnice. Je mu nabídnuta další obrazovka pro změnu zadání, která obsahuje následující volby :

1. Zadání motoru
2. Nastavení GA
3. Váhové koeficienty
4. Meze generovaných parametrů
5. Konstrukční parametry
6. Esc) Konec zadání

3. Zadání mezi generovaných parametrů

V této části se zadávají meze jednotlivých generovaných parametrů, tedy minimální a maximální hodnoty, kterých mohou nabývat.

4. Volené konstrukční konstanty

Zde se nastaví volené konstrukční hodnoty, jako např. tvar drážek, typ vinutí, druh drátu, tloušťky izolací, volené konstanty, hodnoty různých činitelů a podobně.

3.4.2 Popis řešené úlohy

Generované parametry

Při výběru optimalizačních parametrů byl proveden rozbor úlohy a byly vybrány ty parametry, které nejvíce ovlivňují výsledné vlastnosti motoru. Jedná se především o parametry, které se při klasickém návrhu volí a mohou nabývat

hodnot v širokém intervalu. Snahou bylo nalézt takový počet parametrů, aby úloha byla dostatečně popsána a současně byl jejich počet co nejmenší z důvodu časové náročnosti výpočtu. Konečný počet parametrů byl stanoven na 11 a jsou uvedeny včetně popisu a krajních mezí v následující tabulce 3.4.1.

Změnu počtu parametrů případně záměnu parametru za jiný je možno provést pouze zásahem do zdrojového textu programu. Hodnoty mezí parametrů se nastavují ve vstupním souboru „VSTUP.txt“ a lze je modifikovat podle druhu a velikosti motoru. Hodnoty uvedené v tabulce jsou pouze doporučené a pro motory o výkonech do 200kW většinou mezní. Meze průměrů D_e a D ze vstupního souboru jsou uvažovány pouze v případě, požadujeme-li návrh motoru bez ohledu na normalizovanou osovou výšku. V případě zadání normalizované osové výšky se tyto meze počítají. Meze ideální délky rotoru je vhodné zadat co nejužší podle velikosti motoru, z důvodu rychlejší konvergence programu k hledanému minimu. Není to však podmínkou. Obecně platí, že čím menší je interval jednotlivých parametrů, tím rychleji úloha konverguje ke globálnímu minimu a počet lokálních minim je menší.

Název parametru	Symbol	Rozměr	Dolní mez	Horní mez
Vnější průměr statoru	D_e	mm	volí uživatel	volí uživatel
Vnitřní průměr statoru	D	mm	volí uživatel	volí uživatel
Ideální délka železa	l_i	mm	volí uživatel	volí uživatel
Indukce ve vzduchové mezeře	B_δ	T	0,5	1,0
Plnění drážky statoru	k_{dr1}	-	0,6	0,75 (0,8)
Velikost vzduchové mezery	δ	mm	0,2	0,4
Proudová hustota statoru	σ_1	A/mm ²	3,0	15,0
Proudová hustota tyče rotoru	σ_t	A/mm ²	2,0	6,0
Proudová hustota kruhu rotoru	σ_k	A/mm ²	2,0	4,0
Magnetická indukce v zubu	B_z	T	1,6	2,0
Počet drážek na pól a fázi statoru	q_1	-	2,0	5,0

Tab. 3.4.1 Seznam generovaných parametrů a nastavení jejich mezí

Účelová (kriteriální) funkce

Účelová funkce je nejdůležitější částí genetického algoritmu. Obecně představuje funkci, která hodnotí kvalitu návrhu právě počítaného řešení a přiřazuje mu reálné číslo, které je potom mírou této kvality. Čím větší je hodnota tohoto čísla, tím větší chybu má aktuální řešení a tím více je vzdáleno od globálního minima této funkce. Na rozdíl od vlastního genetického algoritmu, který je stejný pro všechny optimalizované úlohy, má kriteriální funkce konkrétní tvar.

3.5. Dosažené výsledky

3.5.1 Popis návrhu motoru 5,5 kW, 380 V

Během sestavování a ladění programu byla provedena optimalizace na níže zadaném motoru a je tedy vhodné popsat výsledky a problémy, se kterými jsme se setkali, právě na jeho hodnotách. Použité symboly a veličiny, které nejsou blíže

vysvětleny, byly buď použity v předcházejícím textu nebo jsou uvedeny v seznamu použitých veličin.

Zadání motoru

Název veličiny	Symbol	Rozměr	Hodnota
Jmenovitý výkon	P_n	W	5500
Jmenovité napětí	U_{1n}	V	380
Požadovaný účinník	$\cos\varphi$	-	0,81
Požadovaná účinnost	η	-	0,86
Kmitočet sítě	f	Hz	50
Výška osy motoru	H	mm	132
Počet pólových dvojic	p	-	3
Tepelná třída izolace	TT	-	F
Momentová přetížitelnost	m_p	-	2

Tab. 3.5.1 Vstupní hodnoty motoru 5,5kW, 380V

Návrh byl prováděn s různým nastavením hodnot GA a byly měněny hodnoty váhových koeficientů u jednotlivých optimalizovaných proměnných tak, aby bylo dosaženo optimálního řešení motoru s kompromisem mezi optimalizovanými hodnotami. Během návrhů byly konstrukční hodnoty zadávané v páté části vstupního souboru stejné. Pouze se měnil typ vinutí (jednovrstvé / dvouvrstvé) a počet paralelních větví a_1 , pro který musí platit podmínky:

$$p / a_1 = \text{celé číslo} \dots \dots \text{jednovrstvé vinutí}$$

$$2p / a_1 = \text{celé číslo} \dots \dots \text{dvouvrstvé vinutí}$$

3.5.1.2 Souhrnné výsledky

Z fyzikálního principu plyne, že optimalizované veličiny spolu úzce souvisí. Zvýšení váhy u některého z nich znamená znevýhodnění ostatních. Z prováděných optimalizací je možné usuzovat na existenci dvou druhů motorů, podle množství železa a mědi v nich obsažených :

1. Motor s převládajícím množstvím železa, s vysokou proudovou hustotou ve statoru, s dobrou hodnotou účinníku za cenu horší účinnosti motoru a s mírně horší hodnotou momentové přetížitelnosti oproti druhému druhu motoru.

2. Motor s vysokým obsahem mědi s naopak malou hodnotou proudové hustoty ve statoru, má vysokou účinnost a horší hodnotu účinníku. Momentová přetížitelnost je dobrá.

Druh motoru je tedy dán nastavením vah váhových koeficientů. Součet chyb teploty a účinníku na jedné straně působí proti součtu chyb objemu a účinnosti na straně druhé. Hodnota momentové přetížitelnosti může být dobrá pro oba typy motorů.

V následující tabulce 3.5.8 jsou uvedeny výsledky jednotlivých optimalizací zadaného motoru seřazeny podle velikosti objemu od nejmenšího po největší. Podle velikosti váhových koeficientů byly získány různé varianty téhož motoru.

číslo	V [dm ³]	ϑ [K]	cosφ [-]	η [-]	m _p [-]	Adresář
1	3,96	88,1	0,798	0,834	1,72	Motor1
2	4,20	86,9	0,818	0,843	1,90	Motor2
3	4,31	74,9	0,787	0,865	1,77	Motor3
4	4,32	88,8	0,836	0,817	1,78	Motor4
5	4,33	75,1	0,690	0,973	1,07	Motor5
6	4,50	89,0	0,836	0,834	1,79	Motor6
7	4,51	86,8	0,818	0,818	1,93	Motor7
8	4,54	90,0	0,884	0,812	1,98	Motor8
9	4,56	84,6	0,857	0,816	1,74	Motor9
10	4,58	86,5	0,836	0,817	1,77	Motor10
11	4,63	68,2	0,792	0,858	2,10	Motor11
12	4,69	88,4	0,862	0,808	1,80	Motor12
13	4,70	73,4	0,845	0,830	2,25	Motor13
14	4,73	61,0	0,799	0,871	1,90	Motor14
15	4,78	78,1	0,853	0,858	1,67	Motor15
16	4,78	71,0	0,767	0,870	1,80	Motor16
17	4,81	70,6	0,703	0,934	1,28	Motor17
18	4,97	54,5	0,804	0,883	1,90	Motor18
19	5,08	55,5	0,762	0,877	2,20	Motor19
20	5,12	88,2	0,879	0,806	2,05	Motor20
21	5,96	44,0	0,784	0,870	2,55	Motor21
22	6,35	42,4	0,803	0,882	2,69	Motor22
23	6,40	87,5	0,887	0,853	2,27	Motor23
24	6,57	59,0	0,747	0,956	1,16	Motor24
25	7,05	42,3	0,793	0,865	3,00	Motor25
26	7,39	52,9	0,714	0,986	1,03	Motor26

Tab. 3.5.8 Seznam řešení motoru P=5,5kW, U=380V, bez omezení generovaných parametrů

Dále byla provedena optimalizace motoru vždy pouze s jedním optimalizovaným parametrem, kdy váhy ostatních jsem položil rovny nule.

3.6 Zhodnocení výsledků

Metoda byla aplikována na konstrukční návrh asynchronního motoru, kdy snahou bylo optimalizovat motor podle konkrétních požadavků tak, aby bylo dosaženo kompromisu mezi jeho provozními parametry a materiálovým využitím stroje. Bylo vybráno 11 konstrukčních parametrů, které ovlivňují výsledný návrh motoru. Mezi tyto generované parametry patří :

- Vnější průměr statoru D_e [mm]
- Vnitřní průměr statoru D [mm]
- Ideální délka železa l_i [mm]
- Indukce ve vzduchové mezeře B_δ [T]
- Plnění drážky statoru k_{dr1} [-]

- Velikost vzduchové mezery δ [mm]
- Proudová hustota statoru σ_1 [A/mm²]
- Proudová hustota tyče rotoru σ_t [A/mm²]
- Proudová hustota kruhu rotoru σ_k [A/mm²]
- Magnetická indukce v zubu B_z [T]
- Počet drážek na pól a fázi statoru q_1 [-]

Navržený motor byl poté ohodnocen podle následujících pěti optimalizačních parametrů, které kvalitu návrhu dostatečně popisují :

- Objem motoru V [dm³]
- Jmenovité oteplení ϑ [K]
- Jmenovitý účinník $\cos \varphi$ [-]
- Jmenovitá účinnost η [T]
- Momentová přetížitelnost m_p [-]

Objem stroje a jeho jmenovité oteplení zohledňují materiálové využití, ostatní tři parametry charakterizují provozní vlastnosti motoru.

4 ZÁVĚR

Předložená práce se zabývá možností použití algoritmů umělé inteligence při optimalizaci návrhu přístrojového transformátoru proudu a asynchronního motoru. Při optimalizaci přístrojového transformátoru proudu byla vybrána metoda genetického algoritmu a metoda simulovaného žihání. Po rozboru úlohy bylo vybráno pět konstrukčních parametrů, které významně ovlivňují výsledné vlastnosti a parametry navrženého transformátoru. Výsledky optimalizace provedené oběmi metodami jsou v podstatě shodné. Rozdíly zjištěné ve dvou případech jsou dány tím, že extrémy jsou ploché a metoda genetického algoritmu při přiblížení k plochému extrému konverguje pomalu. Při optimalizaci návrhu asynchronního motoru bylo použito metody genetického algoritmu. Bylo vybráno 11 konstrukčních parametrů, které ovlivňují výsledný návrh motoru. Navržený motor byl poté ohodnocen podle pěti parametrů, které kvalitu návrhu dostatečně popisují. Příklad optimalizace návrhu asynchronního motoru byl ověřen na školním programu, který je k dispozici pro výuku studentů v ústavu silnoproudé elektrotechniky a elektroniky. Takový postup by se použil například pro návrh stroje, který je vyráběn v jednom typu a malých sériích. Jako příklad lze uvést např. návrh stroje, který by měl mít např. v daném prostoru „který pro něj zbyl“ maximální výkon při největší možné účinnosti. Návrh stroje se neváže k žádným stávajícím investicím výrobce (vyrobené raznice pro plech, formy na odlitky atd.).

I když je postup návrhu z hlediska metodického i výpočtového správný, v praxi se spíše používají návrhové postupy, které musí respektovat existenci určitých standardních částí strojů, které odpovídají nabízené výkonové řadě. Např. do stejné kostry stroje (stejně vnější rozměry) se „dopočítají“ ostatní rozměry (např. délka svazku plechů, jiné vinutí atd.) tak., aby byly splněny uživatelem

zadané parametry. Optimalizace takovýchto návrhových postupů je prakticky stejná jako v předložené práci.

V současné době jsou výše popsané metody optimalizace ověřovány při návrhu elektrických strojů ve výrobním závodě SIEMENS ELECTRIC MACHINES s.r.o. DRÁSOV, při návrhu synchronních generátorů výkonové řady do 5MW a při návrhu asynchronních motorů výkonové řady 50 KW ÷ 2 MW.

5 SEZNAM POUŽITÉ LITERATURY

- [1] AARTS, E., KORST, J., Simulated Annealing and Boltzman Machines, John Wiley & Sons Ltd., 1989
- [2] HLAVÁČ, Z., Dynamická syntéza a optimalizace, Ediční středisko ZČU Plzeň, 1995
- [3] KRÁL, J., VANĚK, J., Elektromagnetické přístroje, Ediční středisko VUT Brno, 1988
- [4] Kopeček, J., DVOŘÁK, M., Přístrojové transformátory, Praha 1966, Academia
- [5] SLÁMA, L., Teze k rigorózní zkoušce, 1997
- [6] MAN, K., TANG, K., KWONG,S., Genetic Algorithms: Concepts and Applications, IEEE Transactions on Industrial Electronics, vol.43, no. 5, October 1996
- [7] KOHOUTEK, J., ODSTRČIL, M., Algoritmy hodnocení a optimalizace, Ediční středisko VUT Brno, 1988
- [8] OŠMERA, P., Genetické algoritmy a jejich aplikace, Inženýrská mechanika 5/1993, pH servis Brno
- [9] KRÁL, J., BŘEZINA,T., Genetic algorithms in solving of engineering problems, Inženýrská mechanika 5/1993, pH servis Brno
- [10] ŠTENCL, Z., Diplomová práce, VUT FEI Brno, UESP 1996
- [11] VEČERKA, J., Diplomová práce, VUT FEI Brno, UESP 1996
- [12] KREJČÍ, P., Dilpomová práce, VUT FS Brno, UMT 1998
- [13] CIGÁNEK, L., Stavba elektrických strojů, SNTL praha, 1958
- [14] KUTNOHORSKÝ, V., Návrh asynchronních motorů
- [15] MRAVEC, R., Elektrické stroje a přístroje I., ALFA Bratislava, 1978
- [16] OŠMERA, P., Genetické algoritmy a jejich aplikace, Inženýrská mechanika 5/1993, pH Service Brno
- [17] POKORNÝ, K., Stavba elektrických strojů II., Ediční středisko VUT Brno, 1987
- [18] ŠTENCL, Z., Posouzení možnosti optimalizace jednotlivých konstrukčních částí asynchronního motoru. Diplomová práce . UESP - FEI VUT Brno 1996

ABSTRACT

The habilitation thesis “Nonstandard Methods of Electrical Machines Optimization” deals with up-to-date interesting and important idea of using artificial intelligence, namely genetic algorithm and/or simulated annealing (GA/SA) for optimization of electrical machines design procedures. GA/SA were successfully applied for the design optimization of current measuring transformer and for the design optimization of a squirrel-cage induction motor as well. The goal was to receive such design parameters to get the required machine characteristics in minimum size and/or with minimum material cost. Any other design requirements should be included in design procedure.

The GA/SA are complete entities in which knowledge of this emerging technology can be integrated together to form the framework of a design tool for industrial engineers. The output of research work in this field has grown exponentially although the contributions have been, and are largely initiated from academic institutions world-wide. It is only very recently that some applications come from industry. Nevertheless, GA/SA development have now reached a stage of maturity, thanks to the effort made in the last few years by academics and engineers all over the world. It has blossomed rapidly due to the easy availability of low-cost but fast speed small computers. Those problems once considered to be “hard” or even “impossible” in the past are no longer a problem as far as computation is concerned. Therefore, complex and conflicting problems that require simultaneous solutions, which in the past were considered deadlocked problems, can be obtained with GA/SA algorithms.

Furthermore, the genetic algorithm is not considered a mathematically guided algorithm. The optima is evolved from generation to generation without rigid mathematical formulation such as the traditional gradient-type of optimizing procedure. In fact, genetic algorithm is much different in that context. It is merely a stochastic, discrete event and a nonlinear process. The optima is an end product containing the best elements of previous generations where the attributes of a stronger individual tend to be carried forward into the following generation. The rule of the game is “survival of the fittest will win”.