

METODOLOŠKI PRISTOP K VEČKRI- TERIJSKI OPTIMIZACIJI ELEKTRIČNIH STROJEV S PRAKTIČNIM PRIMEROM

Mitja Garmut, Martin Petrun

Izvleček:

V prispevku predstavljamo metodološki pristop k večkriterijski optimizaciji električnih strojev, ki vključuje opredelitev problema, izbiro ključnih kazalnikov uspešnosti ter omejitve, določitev prostora možnih rešitev, oblikovanje kriterijskih funkcij, modeliranje in pridobitev rešitev. Na primeru sinhronskega stroja s trajnimi magneti smo prikazali možnost hkratnega povečanja moči in zmanjšanja stroškov glede na referenčno zasnovo. V rezultatih smo prikazali učinkovitost pristopa, ki omogočajo izbiro optimalne zasnove glede na zahteve aplikacije.

Ključne besede:

električni stroj, ključni kazalniki uspešnosti (KPI-ji), večkriterijska optimizacija, Paretova krivulja

1 Uvod

Električni stroji so eden od temeljev sodobne družbe, saj proizvajajo električno energijo in poganjajo gospodinske aparate, električna orodja, električna vozila in industrijsko opremo [1, 2]. V zadnjih letih je bila velika pozornost namenjena sinhronskim strojem s trajnimi magneti (SSTM), ki izstopajo po svoji visoki gostoti moči in učinkovitosti [3]. Zmogljivost električnih strojev se meri s pomočjo ključnih kazalnikov uspešnosti (ang. Key Performance Indicators – KPI), kot so moč, izkoristek, stroški, masa, ... KPI-ji zagotavljajo celovit pregled nad delovanjem stroja in predstavljajo glavno vodilo pri izboljšavah obstoječih zasnov ali pri načrtovanju novih električnih strojev [4].

Da bi dosegli čim boljšo obstoječo zasnovo glede na izbrane KPI-je, je treba izvesti večkriterijsko optimizacijo, kot to prikazujejo [5, 6]. V takšnem postopku moramo obravnavati več kriterijev hkrati, vključevati različne omejitve in z ustrezno izbranimi parametri celovito zajeti prostor možnih rešitev.

Pomembno je zagotoviti povezavo med kriteriji v skladu s KPI-ji in geometrijskimi parametri v obliki kriterijskih funkcij. Najbolj natančen način za izra-

čun KPI-jev predstavlja numerični izračun z metodo končnih elementov (MKE), dopolnjen z različnimi postopki naknadne obdelave pridobljenih podatkov [7, 8]. Takšen pristop je mogoče razširiti tudi z vključitvijo termičnih in mehanskih modelov, kar omogoča večfizikalno oz. večdomensko vrednotenje in s tem celostno analizo električnih strojev [9, 10]. Ker pa je podrobna analiza modela MKE računsko zelo zahtevna, neposredna uporaba takšnih modelov v večkriterijski optimizaciji pogosto ni izvedljiva. Zato se v praksi uporabljajo nadomestni modeli oz. metamodeli, ki na podlagi omejenega števila analiz modela MKE omogočajo hitro oceno KPI-jev v danem prostoru možnih rešitev ter s tem bistveno pohitijo proces optimizacije [5, 11–13].

V nadaljevanju smo sistematično predstavili postopek priprave večkriterijske optimizacije električnih strojev, ki je na koncu ponazorjen s primerom optimizacije SSTM ter analizo pridobljenih rezultatov.

2 Optimizacija

Optimizacija je ključno orodje pri razvoju električnih strojev, saj omogoča doseganje najboljših možnih izkoristkov, moči in drugih ključnih lastnosti stroja [3, 14]. V nadaljevanju predstavljamo osnovne korake za uspešno optimizacijo električnega stroja:

- A. splošna opredelitev optimizacijskega problema,
- B. določitev KPI-jev in omejitev [15],
- C. formulacija optimizacijskega problema [16],
- D. določitev prostora možnih rešitev,
- E. modeliranje in
- F. pridobitev rešitve.

dr. Mitja Garmut, mag. inž. el, **izr. prof. dr. Martin Petrun**, univ. dipl. inž. el., oba Univerza v Mariboru, Fakulteta za elektrotehniko, računalništvo in informatiko



© The Authors 2025. CC-BY 4.0

<https://doi.org/10.5545/Ventil-31-2025-5.10>

Predstavljeni koraki si v splošnem sledijo eden za drugim, vendar se skozi postopek oblikovanja celotnega optimizacijskega problema iterativno nadgrajujejo in izboljšujejo.

2.1 Korak A – opredelitev optimizacijskega problema

V prvem koraku optimizacijskega postopka najprej podamo splošen pregled in jasno opredelimo glavni cilj problema. S tem postavimo trdne temelje za smiselno načrtovanje in učinkovito izvedbo vseh nadaljnjih korakov. Ker je ta korak tesno povezan s specifično naravo posameznega problema, ga moramo v vsakem primeru posebej prilagoditi. V poglavju 3 podrobno predstavimo obravnavani optimizacijski problem, pri čemer se osredotočimo na električni pogon – natančneje na zasnovo SSTM v kombinaciji z vodenjem pogona.

Primarni cilj optimizacije je izboljšati dva ali več KPI-jev, na primer povečati moč stroja in hkrati zmanjšati stroške. V praksi se večkriterijska optimizacija pogosto omeji na dva kriterija. Že pri dveh kriterijih se zahtevnost reševanja problema v primerjavi z enokriterijsko optimizacijo občutno poveča, pri več kot dveh pa eksponentno rasteta računska zahtevnost in čas optimizacije. Sekundarni cilj je oblikovati nabor optimalnih rešitev v obliki t. i. Paretove krivulje, ki prikazuje kompromisne rezultate med izbranimi KPI-ji. Tak pristop daje načrtovalcu strojev večjo fleksibilnost pri odločanju in možnost izbire najbolj primerne zasnove stroja glede na konkretne zahteve aplikacije.

2.2 Korak B – določitev KPI-jev in omejitve

Določitev ustreznih KPI-jev in omejitev je ključnega pomena za uspešno izvedbo optimizacijskega postopka. KPI-ji morajo zajemati tiste lastnosti stroja, ki najbolj odražajo njegovo zmogljivost, učinkovitost, zanesljivost in ekonomsko upravičenost. Pri tem jih je treba jasno definirati in natančno ovrednotiti, tako da celovito opisujejo obnašanje stroja v vseh relevantnih delovnih režimih. V kontekstu optimizacije električnih strojev so med najpogostejše uporabljeni KPI-ji naslednji [17]:

- ▶ m – skupna masa stroja, ki vpliva na skupno težo končnega izdelka,
- ▶ C – strošek uporabljenih materialov stroja, ki določa proizvodne stroške in konkurenčnost na trgu,
- ▶ η – izkoristek pretvorbe energije,
- ▶ P – termično stabilna moč, ki določa največjo termično stabilno izhodno moč,
- ▶ τ_e – povprečni elektromagnetni navor, ki vpliva na zmogljivost stroja pri določeni hitrosti in
- ▶ τ_Δ – valovitost navora, ki povzroča mehanske vibracije, hrup in pospešuje obrabo komponent.

Na drugi strani pa so za učinkovito optimizacijo enako ključne jasno opredeljene omejitve. Brez njih bi bil optimizacijski problem preveč kompleksen in pogosto nerešljiv. Omejitve na eni strani določajo fizikalne, tehnološke ali varnostne meje, znotraj katerih mora rešitev ostati, kar bistveno prispeva k realnosti in uporabnosti dobljenih rezultatov. Hkrati pa je treba že vnaprej ustrezno omejiti obseg problema, da zagotovimo njegovo rešljivost. V praksi to pomeni, da se optimizacija pogosto osredotoči le na izbrane podsisteme – na primer zgolj na električni stroj znotraj celotnega pogona – medtem ko druge fizikalne podsisteme, kot so hlajenje, baterijsko napajanje ali mehanski prenos, obravnavamo kot vnaprej definirane oziroma kot robne pogoje.

2.3 Korak C – formulacija optimizacijskega problema

Ko smo določili KPI-je in omejitve, smo pripravljeni oblikovati optimizacijski problem. Zaradi nasprotujočih si ciljev, kot sta večja moč in nižja cena, smo uporabili pristop večkriterijske optimizacije.

Večkriterijska optimizacija namesto ene funkcije obravnava več funkcij, pri čemer zagotovi množico optimalnih rešitev – t. i. Paretovo krivuljo. Večkriterijsko optimizacijo predstavimo z naslednjo formulacijo, dano z (1)

$$\min_{\mathbf{x}} F_i(\mathbf{x}), i = 1, \dots, N_F$$


$$\text{ob upoštevanju} \begin{cases} G_j(\mathbf{x}) \leq 0, j = 1, \dots, N_G \\ H_k(\mathbf{x}) = 0, k = 1, \dots, N_H \\ \mathbf{x}_l \leq \mathbf{x} \leq \mathbf{x}_u \end{cases} \quad (1)$$

kjer so $F_i(\mathbf{x})$ kriterijske funkcije, ki zagotavlja povezavo med KPI-ji in konstrukcijskimi parametri stroja $\mathbf{x}$, ki definirajo zasnovo stroja. $G_j(\mathbf{x})$ so funkcije nenakostnih omejitev in $H_k(\mathbf{x})$ so funkcije enakostnih omejitev. Prostor možnih rešitev je določen s spodnjo $\mathbf{x}_l$ in zgornjo mejo $\mathbf{x}_u$ konstrukcijskih parametrov stroja $\mathbf{x}$.

Večkriterijski optimizacijski pristop zahteva naprednejše optimizacijske algoritme, saj vključuje dodatna ovrednotenja kriterijskih in omejitvenih funkcij. Posledično so časi izračuna bistveno daljši v primerjavi z enokriterijskim pristopom. Zato je zmanjšanje časa, potrebnega za vrednotenje kriterijskih in omejitvenih funkcij, ključno v kontekstu večkriterijske optimizacije.

2.4 Korak D – določitev prostora možnih rešitev

Za uspešno optimizacijo moramo prostor možnih rešitev natančno določiti in ustrezno omejiti. Če je preozek, lahko spregledamo globalni optimum. Če je preširok, pa se čas računanja močno poveča. Pri optimizaciji električnih strojev se najpogosteje



Slika 1: Parametrični model referenčnega SSTM

osredotočamo na spreminjanje geometrije preseka železnega jedra statorja in rotorja, kot prikazuje slika 1, čeprav lahko vključimo tudi druge konstrukcijske parametre, kot je navitje.

Najpogostejše uporabimo parametrično geometrijo, kjer sta obliki oz. zasnovi rotorja in statorja opisani s pomočjo parametrov. Pri tem je pomembno, da ohranimo čim manjše število parametrov, ki pa še vedno omogočajo dovolj raznolikih rešitev, in zagotovimo, da sprememba posameznega parametra ne vpliva nekontrolirano na druge parametre.

Zelo priporočljivo je izvesti analizo občutljivosti, saj ta pokaže, kako posamezni parametri vplivajo na vrednosti KPI-jev in omejitev. Na podlagi rezultatov lahko nato izberemo najprimernejše parametre, ki se med optimizacijo spreminjajo [5, 18].

Neparametrična optimizacija geometrije pa predstavlja alternativo, kadar geometrija stroja ni vnaprej določena ali ko raziskujemo nove topologije. Ti pristopi temeljijo na strukturnih parametrih namesto na klasičnih geometrijskih dimenzijah ter pogosto uporabljajo metode, kot so binarna optimizacija [19].

2.5 Korak E – modeliranje

Za optimizacijo električnih strojev uporabljamo eksperimentalno preverjene modele, ki povezujejo parametre x z vrednostmi KPI-jev [20, 21]. V praksi pogosto uporabimo večfizikalne oz. večdomenske modele z ločeno elektromagnetno, termično in mehansko obravnavo [8, 22–24]. Šibka sklopitev ali vzporedna uporaba fizikalnih podsistemov omogoča dobro ravnovesje med točnostjo in računsko učinkovitostjo, kar omogoča njihovo uporabo v optimizacijskih algoritmihih – v nasprotju z močno sklopljenimi večfizikalnimi modeli, ki so pogosto preveč računsko zahtevni.

V številnih primerih se osredotočimo le na elektromagnetni podsistem, medtem ko termične in me-

hanske omejitve upoštevamo posredno, na primer omejitev največjega dovoljenega toka. Elektromagnetno analizo izvajamo z MKE, saj omogoča točno modeliranje nasičenja, izračun elektromagnetnega navora ter oceno izgub v železu, medtem ko so analitični modeli pogosto manj točni [25]. Termično analizo pogosto izvedemo z analitičnimi pristopi, kot so modeli s koncentriranimi parametri, kadar je primarni fokus na elektromagnetnem podsistemu [9]. Uporabiti je mogoče tudi termični MKE, združen z modeli fluidne dinamike, vendar je tak pristop računsko zelo zahteven in zato pogosto neprimeren za optimizacijske postopke.

Za celovito oceno električnega pogona je treba analizirati stroj skupaj z vodenjem in razsmernikom [26]. Čeprav neposredna povezava razsmernika z elektromagnetnim MKE omogoča visoko točnost, je tak pristop za optimizacijske namene pogosto preveč zahteven. Zato pri optimizaciji raje uporabimo MKE, ki vključuje vplive vodenja in razsmernika na delovanje stroja v poenostavljeni obliki.

2.6 Korak F – pridobitev rešitve

Pri iskanju optimalne rešitve uporabljamo deterministične (npr. gradientne metode) ali stohastične metode (npr. genetski algoritmi, diferencialna evolucija) [27]. Zaradi izrazite nelinearnosti pri analizi električnih strojev so stohastične metode pogosto primernejša izbira, saj se lahko izognejo lokalnim minimumom.

Metodologija načrtovanja poskusov (angl. Design of Experiments – DOE) se pogosto uporablja za oceno vpliva vhodnih parametrov x na vrednosti KPI-jev. Čeprav ne ponuja neposredne rešitve optimizacijskega problema, služi kot osnovna podatkovna zbirka za učenje nadomestnih modelov, ki so kasneje vključeni v optimizacijo [3, 11, 15].

Ker kriterijske funkcije običajno vključujejo računsko zahtevne simulacije MKE, za izboljšanje računске učinkovitosti uporabimo različne pristope:

- ▶ Simetrije: Z izkoriščanjem geometrijskih in elektromagnetnih simetrij zmanjšamo število potrebnih simulacij in velikost modelov MKE [8].
- ▶ Nadomestno modeliranje: Nadomestni modeli, trenirani na manjšem številu podatkov (pogosto pridobljenih z MKE), omogočajo hitro ocenjevanje vrednosti KPI-jev.
- ▶ Interpolacija: S pomočjo interpolacije ocenjujemo obratovalne točke, ki niso bile neposredno ovrednotene z analizo MKE [28].
- ▶ Paralelno računanje: Razdelitev računskih nalog na več jeder ali računalnikov bistveno pospeši optimizacijski proces ali zbiranje podatkov za treniranje nadomestnih modelov.

3 Rezultati

3.1 Predstavitev problema

Korak A

V okviru optimizacije smo obravnavali vektorsko voden SSTM, ki uporablja trifazno koncentrirano navitje, razporejeno v šest statorskih utorov, kot je prikazano na sliki 1. V rotorju so vgrajeni štirje notranji trajni magneti, kar omogoča generiranje tako magnetnega kot reluktančnega navora.

Stroj je bil sestavni del kompleksnega mehatronskega sistema, ki vključuje baterijo, napetostni pretvornik, vodenje s povratnima zankama za tok in položaj rotorja, mehanski reduktor ter hladilni sistem [29]. Zaradi visoke kompleksnosti celotnega sistema smo se pri optimizaciji osredotočili zgolj na izbrane podsisteme – torej na stroj v kombinaciji z njegovim vodenjem. Ker je bil sistem že vnaprej dobro definiran in uravnotežen, smo ključne parametre ohranili nespremenjene: delovno območje stroja (navor in hitrost) smo ustrezno omejili, hladilni podsistem smo ohranili, prav tako pa smo nespremenjen ohranili tudi napetostni nivo baterijskega napajanja.

Korak B, C in D

Glavni cilj optimizacije je bil povečati izhodno moč stroja P ob hkratnem znižanju stroškov C . Sekundarni cilj je bil pridobiti nabor optimalnih rešitev v obliki Paretove krivulje, ki omogoča izbiro med različnimi kompromisi med močjo in ceno.

Večkriterijsko optimizacijo smo formalno definirali z (2)

$$\min_x \begin{cases} -P(x) \\ C(x) \end{cases} \quad (2)$$

ob upoštevanju $\begin{cases} \frac{A_{\text{cool}}(x)}{A_{\text{cool,ref}}} - 1 \leq 0.1 \\ x_1 \leq x \leq x_u \end{cases}$

kjer smo hkrati minimizirali negativno vrednost največje izhodne moči stroja ter skupno ceno vseh aktivnih delov stroja (stator, rotor, magnet in navitje). Neenakostna omejitev je bila uporabljena z namenom zagotoviti, da hladilni presek A_{cool} pri optimalnih izvedbah stroja ne preseže 10 % referenčne vrednosti $A_{\text{cool,ref}}$. Ta omejitev skupaj z največjim dovoljenim statorskim tokom $I_{s,\text{max}}$ zagotovi termično stabilne zasnove. Slika 1 in Tabela 1 prikazujeta 8 parametrov x , ki so določili prostor možnih rešitev optimizacijskega problema in so parametrično spreminjali celotno geometrijo prereza statorskega in rotorskega jedra ter posledično navitje. $r_{s,\text{in}}$ je notranji premer statorja, $d_{r,q}$ je debelina mostička v q-osmi rotorja, $d_{r,y}$ določa pozicijo magnetov v rotorju, A_{pm} je površina trajnega magnetov, $d_{s,y}$ in $d_{s,t}$ sta debelini jarma in zoba statorja, $d_{s,x}$ je višina pola statorskega zoba in $\alpha_{s,v}$ je kot odprtine utora.

Tabela 1 : Parametri, ki definirajo presek železnega jedra statorja in rotorja SSTM

x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8
$r_{s,\text{in}}$	$d_{r,q}$	$d_{r,y}$	A_{pm}	$d_{s,y}$	$d_{s,t}$	$d_{s,x}$	$\alpha_{s,v}$

Korak E in F


Povezavo med parametri x in KPI-ji smo vzpostavili s pomočjo MKE. Geometrijo stroja smo prilagajali s parametri x , analiza na osnovi MKE pa je omogočala izračun magnetnih sklepov in navora v različnih delovnih točkah. Pridobljene vrednosti smo nato uporabili v analitičnih modelih za oceno največje izhodne moči stroja P . Stroški C in hladilni presek A_{cool} so bili neposredni rezultati parametričnega modela. Glavno orodje za oceno obratovanja stroja je bila analiza MKE, podrobnosti implementacije pa lahko najdete v [11, 14].

Za izvedbo optimizacije na osebнем računalniku smo uporabili več pristopov za zmanjšanje računskih zahtev. Najprej smo izkoristili geometrijsko simetrijo stroja in v modelih MKE simulirali le polovico modela. Nato smo za eno delovno točko analizirali zgolj 1/6 električne periode pri petih različnih električnih kotih, s čimer smo dodatno zmanjšali število potrebnih simulacij modelov MKE. Nadalje smo razvili nadomestne modele, osnovane na nevronske mrežah, ki smo jih trenirali z naborom podatkov, pridobljenih iz analiz MKE. Optimizacijo smo nato izvedli na nadomestnih modelih, ki so bili hkrati natančni in računsko učinkoviti, kar je omogočilo izvedbo večkriterijske optimizacije znotraj razumnega časa izvajanja. Model MKE je bil implementiran v simulacijskem orodju Ansys Maxwell, medtem ko so bile vse ostale naloge: od upravljanja modela in postprocesiranja do zbiranja podatkov, gradnje nadomestnih modelov in izvedbe optimizacije izvedene v Matlabu. Skupno je bilo za učenje nadomestnih modelov zbranih približno 1500 zasnov strojev. Ovrednotenje posamezne zasnove je trajalo približno 2–3 minute, kar pomeni okoli tri dni zbiranja podatkov na standardnem računalniku, pri čemer se lahko zbrani podatki ponovno uporabijo.

Uporabili smo večkriterijski genetski algoritem NSGA-II, ki omogoča hkratno iskanje kompromisnih rešitev med več kriteriji [30]. Največje število generacij smo določili na 250, velikost populacije na generacijo pa na 100. Sama optimizacija z nadomestnimi modeli je trajala približno 2–3 ure.

3.2 Rezultati optimizacije

Slika 2 prikazuje dobljeno Paretovo krivuljo optimalnih rešitev za predstavljeno večkriterijsko optimizacijo, dano z enačbo (2) skupaj z referenčno zasnovo in naborom podatkov, uporabljenih za treniranje nadomestnih modelov. Ciljna funkcija $-P$ je dala razpon rešitev, pri katerih se je moč povečala



Slika 2 : Oranžne točke predstavljajo Paretoovo krivuljo, tj. optimalne rešitve, ki so v obeh kriterijih ali vsaj v enem boljše od referenčne zasnove (modri kvadrat). Sivi krogi prikazujejo vrednosti KPI-jev zasnov strojev, ki smo jih uporabili za treniranje nadomestnih modelov.

za približno 9 % oziroma zmanjšala za več kot 55 % glede na referenčno zasnovo. Strošek C se je med rešitvami tudi spreminjal: povečal se je za 5,5 % ali zmanjšal za 18 %.

Vse rešitve na Paretovi krivulji niso izboljšale obeh kriterijev hkrati – nekatere so povečale moč, druge zmanjšale strošek, tretje pa so ponujale izboljšave v obeh kriterijih. Iz *slike 2* je jasno viden kompromis med obema ciljima funkcijama: povečanje moči pogosto vodi k višjim stroškom, medtem ko znižanje stroškov pomeni nižjo moč. Skrajne točke na fronti prikazujejo zasnove z minimalnimi stroški ali največjo močjo, medtem ko srednji del fronte predstavlja uravnotežene kompromisne rešitve. V primerjavi z referenčno zasnovo številne zasnove na fronti ponujajo očitne izboljšave, kar potrjuje učinkovitost uporabljenega optimizacijskega postopka.

Tovrstna analiza omogoča projektantu izbiro rešitve glede na prioritete, če je cilj povečanje moči, so ustrezne rešitve na levi strani fronte, če je cilj minimizacija stroškov, so bolj primerne rešitve na desni.

4 Zaključek

Metodološki pristop k večkriterijski optimizaciji električnih strojev, ki smo ga predstavili, omogoča sistematično obravnavo problema od izbire KPI-jev in omejitev do oblikovanja kriterijskih funkcij, določitve prostora možnih rešitev, modeliranja in pridobitve rešitev.

Na praktičnem primeru SSTM smo prikazali, da predstavljena metodologija omogoča učinkovito iskanje optimalnih rešitev. Z dobljeno Paretoovo krivuljo smo pokazali, da se moč stroja lahko poveča za

približno 9 % ali pa zmanjša strošek do 18 %. Hkrati pa smo pridobili nabor rešitve, ki hkrati izboljšajo oba KPI-ja v primerjavi z referenčno zasnovo

Viri

- [1] I. Husain et al., "Electric Drive Technology Trends, Challenges, and Opportunities for Future Electric Vehicles," *Proceedings of the IEEE*, vol. 109, no. 6, pp. 1039–1059, 2021-06-01 2021, doi: 10.1109/jproc.2020.3046112.
- [2] S. Zheng, X. Zhu, Z. Xiang, L. Xu, L. Zhang, and C. H. T. Lee, "Technology trends, challenges, and opportunities of reduced-rare-earth PM motor for modern electric vehicles," *Green Energy and Intelligent Transportation*, vol. 1, no. 1, p. 100012, 2022/06/01/ 2022, doi: <https://doi.org/10.1016/j.geits.2022.100012>.
- [3] G. Bramerdorfer, J. A. Tapia, J. J. Pyrhonen, and A. Cavagnino, "Modern Electrical Machine Design Optimization: Techniques, Trends, and Best Practices," (in English), *Ieee Transactions on Industrial Electronics*, vol. 65, no. 10, pp. 7672–7684, Oct 2018, doi: 10.1109/Tie.2018.2801805.
- [4] V. Parekh, D. Flore, and S. Schops, "Deep Learning-Based Prediction of Key Performance Indicators for Electrical Machines," *Ieee Access*, vol. 9, pp. 21786–21797, 2021-01-01 2021, doi: 10.1109/access.2021.3053856.
- [5] X. Sun, Z. Shi, G. Lei, Y. Guo, and J. Zhu, "Multi-Objective Design Optimization of an IPMSM Based on Multilevel Strategy," *IEEE Transactions on Industrial Electronics*, vol. 68, no. 1, pp. 139–148, 2021-01-01 2021, doi: 10.1109/tie.2020.2965463.
- [6] V. Parekh, D. Flore, and S. Schops, "Variational Autoencoder-Based Metamodeling for Multi-Objective Topology Optimization of Electrical Machines," *IEEE Transactions on Magnetics*, vol. 58, no. 9, pp. 1–4, 2022-09-01 2022, doi: 10.1109/tmag.2022.3163972.
- [7] M. Garmut, S. Steentjes, and M. Petrun, "Optimization of an IPMSM for Constant-Angle Square-Wave Control of a BLDC Drive," *Mathematics*, vol. 12, no. 10, p. 1418, 2024-05-07 2024, doi: 10.3390/math12101418.
- [8] G. Y. Sizov, D. M. Ionel, and N. A. O. Demerdash, "Modeling and Parametric Design of Permanent-Magnet AC Machines Using Computationally Efficient Finite-Element Analysis," *IEEE Transactions on Industrial Electronics*, vol. 59, no. 6, pp. 2403–2413, 2012-06-01 2012, doi: 10.1109/tie.2011.2163912.
- [9] E. A. Grunditz, T. Thiringer, J. Lindström, S. Tidblad Lundmark, and M. Alatalo, "Thermal capability of electric vehicle PMSM with different slot areas via thermal network analysis," *eTransportation*, vol. 8, p. 100107, 1 May 2021, doi: <https://doi.org/10.1016/j.etrans.2021.100107>.
- [10] M. Garmut, S. Steentjes, and M. Petrun, "Eva-

- luating the thermal stability of an interior permanent magnet synchronous machine through iterative multi-physics simulation," *International Journal of Numerical Modelling: Electronic Networks, Devices and Fields*, vol. 37, no. 5, 2024-09-01 2024, doi: 10.1002/jnm.3294.
- [11] M. Garmut, S. Steentjes, and M. Petrun, "Computationally efficient multi-objective optimization of an interior permanent magnet synchronous machine using neural networks," *Engineering Applications of Artificial Intelligence*, vol. 160, p. 111753, 2025-11-01 2025, doi: 10.1016/j.engappai.2025.111753.
- [12] W. D. Zhao, X. J. Wang, C. Gerada, H. Zhang, C. Liu, and Y. L. Wang, "Multi-Physics and Multi-Objective Optimization of a High Speed PMSM for High Performance Applications," (in English), *IEEE Transactions on Magnetics*, vol. 54, no. 11, Nov 2018, doi: Artn 810640510.1109/Tmag.2018.2835504.
- [13] S. Doi, H. Sasaki, and H. Igarashi, "Multi-Objective Topology Optimization of Rotating Machines Using Deep Learning," *IEEE Transactions on Magnetics*, vol. 55, no. 6, pp. 1-5, 2019-06-01 2019, doi: 10.1109/tmag.2019.2899934.
- [14] M. Garmut, "Integrating Multi-Physics Modeling within Multi-Objective Optimization to Enhance the Performance and Efficiency of Permanent Magnet Synchronous Machines," Doctoral dissertation, Fakulteta za elektrotehniko, računalništvo in informatiko, University of Maribor, Maribor, 2025. [Online]. Available: <https://dk.um.si/IzpisGradiva.php?id=91651&lang=slv>
- [15] V. Parekh, D. Flore, and S. Schöps, "Deep Learning-Based Meta-Modeling for Multi-Objective Technology Optimization of Electrical Machines," *IEEE Access*, vol. 11, pp. 93420-93430, 2023-01-01 2023, doi: 10.1109/access.2023.3307499.
- [16] W. Li, T. Zhang, R. Wang, S. Huang, and J. Liang, "Multimodal multi-objective optimization: Comparative study of the state-of-the-art," *Swarm and Evolutionary Computation*, vol. 77, p. 101253, 2023-03-01 2023, doi: 10.1016/j.swevo.2023.101253.
- [17] G. Bramerdorfer, A. Cavagnino, and S. Vaschetto, "Cost-optimal machine designs fulfilling efficiency requirements: a comparison of IMs and PMSMs," (in English), 2017 *IEEE International Electric Machines and Drives Conference (IEMDC)*, 2017. [Online]. Available: <Go to ISI>://WOS:000426933000065.
- [18] G. Bramerdorfer and A.-C. Zavoianu, "Surrogate-Based Multi-Objective Optimization of Electrical Machine Designs Facilitating Tolerance Analysis," *IEEE Transactions on Magnetics*, vol. 53, no. 8, pp. 1-11, 2017-08-01 2017, doi: 10.1109/tmag.2017.2694802.
- [19] S.-W. Jung, J. Ro, and H.-K. Jung, "A Hybrid Algorithm Using Shape and Topology Optimization for the Design of Electric Machines," *IEEE Transactions on Magnetics*, vol. 54, no. 3, pp. 1-4, 2018-03-01 2018, doi: 10.1109/tmag.2017.2764753.
- [20] B. Bilgin et al., "Modeling and Analysis of Electric Motors: State-of-the-Art Review," *IEEE Transactions on Transportation Electrification*, vol. 5, no. 3, pp. 602-617, 1 September 2019, doi: 10.1109/tte.2019.2931123.
- [21] J. Pyrhonen, T. Jokinen, and V. Hrabovcova, *Design of rotating electrical machines*. Chichester, West Sussex, United kingdom: John Wiley & Sons, 2013.
- [22] S. P. Wu, X. J. Huang, C. C. Tian, and P. J. Zhang, "Multi-Physical Field Optimization Analysis of High-Speed Permanent Magnet Synchronous Motor Based on NSGA-II Algorithm," (in English), *Int C Electr Mach Sy*, pp. 879-884, 2019. [Online]. Available: <Go to ISI>://WOS:000537504800166.
- [23] D. A. Staton and A. Cavagnino, "Convection Heat Transfer and Flow Calculations Suitable for Electric Machines Thermal Models," *IEEE Transactions on Industrial Electronics*, vol. 55, no. 10, pp. 3509-3516, 1 October 2008, doi: 10.1109/tie.2008.922604.
- [24] I. Kleilat, K. E. K. Benkara, G. Friedrich, S. Vivier, N. Moubayed, and R. Dib, "Comparison of Two Analytical Methods for Calculating the Maximum Mechanical Stress in the Rotor of High-Speed-Assisted Synchronous Reluctance Machines," *IEEE Transactions on Industry Applications*, vol. 57, no. 2, pp. 1344-1353, 2021-03-01 2021, doi: 10.1109/tia.2020.3040946.
- [25] M. Nell et al., "Complete and accurate modular numerical computation scheme for multi-coupled electric drive systems," *IET Science, Measurement & Technology*, vol. 14, no. 3, pp. 259-271, 2020-05-01 2020, doi: 10.1049/iet-smt.2019.0413.
- [26] M. Garmut, S. Steentjes, and M. Petrun, "Parameter identification for MTPA control based on a nonlinear d-q dynamic IPMSM model," *COMPEL - The international journal for computation and mathematics in electrical and electronic engineering*, vol. 42, no. 4, pp. 846-860, 20 June 2023, doi: 10.1108/compel-09-2022-0331.
- [27] S. Touati, R. Ibtouen, O. Touhami, and A. Djerdir, "Fast multi objective optimization of an automotive PMSM using mixed BEM with genetic algorithms," in 2010 *IEEE Vehicle Power and Propulsion Conference*, 1-3 Sept. 2010 2010, pp. 1-4, doi: 10.1109/VPPC.2010.5728995.
- [28] G. Weidenholzer, S. Silber, G. Jungmayr, G. Bramerdorfer, H. Grabner, and W. Amrhein, "A flux-based PMSM motor model using RBF interpolation for time-stepping simulations," in 2013 *International Electric Machines & Drives Conference*, Westin O'Hare, Chicago, IL, 12-15 May 2013: IEEE, doi: 10.1109/iemdc.2013.6556323. [Online]. Available: <https://ieeexplore.ieee.org/document/6556323>.
- [29] M. Garmut, S. Steentjes, and M. Petrun, "A Comparative Study of Meta-Modeling Appro-

aches for IPMSM Performance Prediction with Neural Networks," in 2025 IEEE International Electric Machines & Drives Conference (IEMDC), 2025-05-18 2025: IEEE, pp. 152-156, doi: 10.1109/iemdc60492.2025.11061145.

[30] K. Deb, A. Pratap, S. Agarwal, and T. Meyarivan, "A fast and elitist multiobjective genetic algorithm: NSGA-II," IEEE T Evolut Comput, vol. 6, no. 2, pp. 182-197, 2002, doi: 10.1109/4235.996017.

Methodological Approach to Multi-Objective Optimization of Electrical Machines with a Practical Case Study

Abstract:

This paper introduces a structured approach to the multi-objective optimization of electrical machines. The process covers the key steps: defining the problem, identifying the most relevant key performance indicators and constraints, setting the design space, formulating objective functions, and then modeling and evaluating the results. Using a permanent magnet synchronous machine as an example, the study shows that it is possible to achieve up to 9% higher output power or reduce the overall cost by as much as 18% compared with the reference design. These results highlight the value of the proposed method and provide a solid basis for choosing the most suitable design for a given application.

Keywords:

electrical machine, key performance indicators (KPIs), multi-objective optimization, Pareto front

Zahvala

To delo je bilo podprto s strani Javne agencije za znanstvenoraziskovalno in inovacijsko dejavnost Republike Slovenije (ARIS) v okviru projekta P2-0115 in projekta J7-3152



SPLAČA SE BITI NAROČNIK



ZA SAMO 50€ DOBITE:

- celoletno naročnino na revijo IRT3000 (10 številke)
- strokovne vsebine na več kot 140 straneh
- vsakih 14 dni e-novice IRT3000 na osebni elektronski naslov
- možnost ugodnejšega nakupa strokovne literature
- vsak novi naročnik prejme majico in ovratni trak



ZA SAMO 20€ DOBITE:

- celoletno naročnino na revijo IRT3000 (4 številke)
- strokovne vsebine na več kot 200 straneh
- vsakih 14 dni e-novice IRT3000 na osebni elektronski naslov
- možnost ugodnejšega nakupa strokovne literature
- vsak novi naročnik prejme majico in ovratni trak

Revija v
hrvaškem
jeziku

DIGITALNA NAROČNINA



Na voljo tudi naročnina na digitalno različico revije za uporabo **V BRSKALNIKU** in **NA MOBILNIH NAPRAVAH**

BUTIK IRT3000



Naša ekskluzivna spletna trgovina kakovostnih izdelkov s prepoznavnim dizajnom vaše priljubljene revije za inovacije, razvoj in tehnologije.

NAROČITE SE!



051 322 442



info@irt3000.si



www.irt3000.si/narocilo-revije

WWW.IRT3000.COM