

A kriging asszisztens algoritmus hatékonyságának vizsgálata különböző tesztfeladatokon

Examining the effectiveness of the kriging assistant algorithm on different test tasks

Istenes György^a, Dr. Horváth Zoltán^b

^aSzéchenyi István Egyetem – Járműipari Kutatóközpont
istenes.gyorgy@ga.sze.hu

^bSzéchenyi István Egyetem – Matematika és Számítástudomány Tanszék
horvathz@sze.hu

Absztrakt: A matematikai optimalizáció területén gyakran előfordul, hogy az optimum kellő mértékű megközelítéséhez sok költséges számítást kell elvégezni. Az olyan bonyolult feladatoknál, ahol az egyes kiértékelések elvégzéséhez pl. végeselemes szimuláció szükséges, fontos szempont a tényleges kiértékelések számának csökkentése. Erre egy jó módszer a bonyolult célfüggvény-kiértékelést valamilyen egyszerűbb (általában blackbox) modellel való helyettesítése. Ebben a cikkben a kriging elnevezésű statisztikai alapon működő asszisztensalgoritmus kerül bemutatásra és elemzésre. Két többcélú optimalizációs feladat elvégzése során a tényleges és az asszisztensalgoritmus által becsült eredmények kerülnek összehasonlításra. Az első vizsgálat egy nagyon egyszerű, analitikusan megoldható tesztfeladat, míg a második már egy jóval bonyolultabb, végeselemes számításokon alapuló villamos motor optimalizáció. Mindkét tesztben a MATLAB többcélú genetikusan algoritmus volt alkalmazva. A célkitűzés annak a vizsgálat, hogy a viszonylag egyszerű tesztfeladatokon kapott tapasztalatok mennyire hasznosíthatóak egy jóval bonyolultabb feladat paraméterezése során.

Kulcsszavak: többcélú optimalizáció, villamos motor modellezés, kriging

Abstract: In the field of mathematical optimization it often happens that many costly calculations have to be carried out in order to approach the optimum sufficiently. In the case of complex tasks where to perform individual evaluations - e.g. finite element simulation is necessary - an important aspect is to reduce the number of actual evaluations. A good way to do this is to replace the complicated objective function evaluation with a simpler (usually blackbox) model. In this article the statistical assistant algorithm called kriging is presented and analyzed. During the completion of two multi-objective optimization tasks the actual results and those estimated by the assistant algorithm are compared. The first test is a very simple test

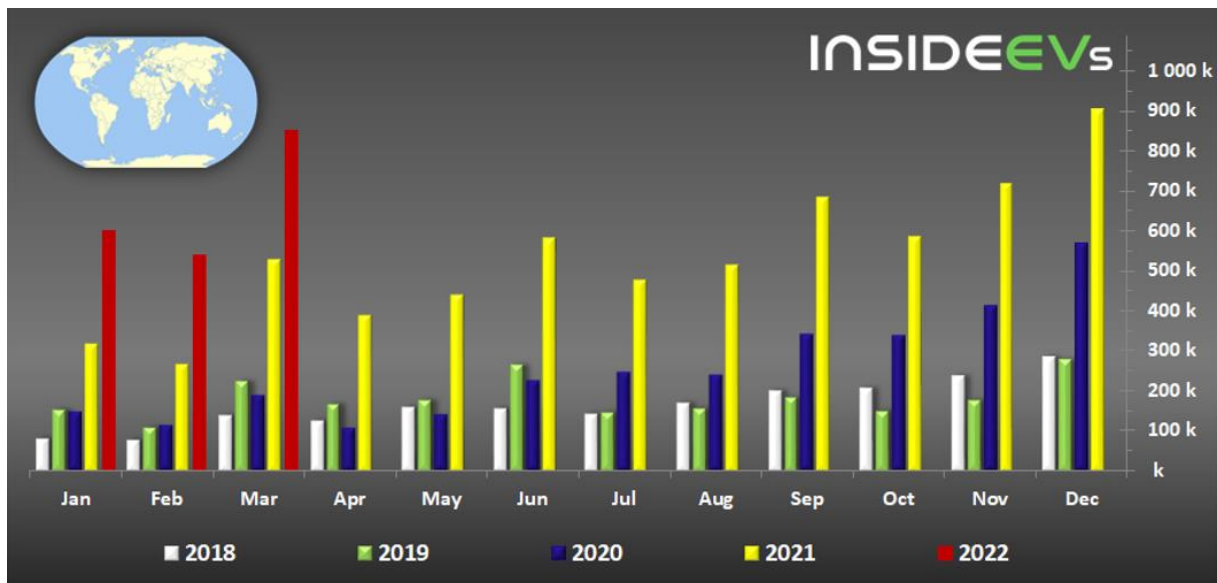
task that can be solved analytically while the second is a much more complicated electric motor optimization based on finite element calculations. In both tests the multi-objective genetic algorithm of MATLAB was used. The objective is to examine how well the experience gained from relatively simple test tasks can be utilized during the parameterization of a much more complicated task.

Keywords: multiobjective optimization, modelling of electric motors, kriging

Bevezetés

Sok ország kormánya világszerte támogatja az elektromos járművek elterjedését a kőolaj felhasználás csökkentése és a környezetvédelem érdekében. Az egyre emelkedő tüzelőanyagárak miatt manapság már nem csak a tömegközlekedésben és az áruszállításban válik jelentőssé az elektromos járművek száma, hanem a magánfelhasználásban is [1].

Az 1. ábra az elmúlt 5 év elektromos és tölthető hibrid (plug-in hybrid) személyautók eladási statisztikáit mutatja be.




1. ábra: Az elmúlt 5 év elektromos és tölthető hibrid (plug-in hybrid) személyautók eladási statisztikái. [1]

Ebben a cikkben egy állandómágneses szinkronmotorok (Permanent Magnet Synchronous Motor PMSM) többcélú optimalizációjára alkalmas szoftverkeretrendszer részeként működő statisztikai alapú becslő algoritmus (kriging) vizsgálata kerül bemutatásra. Erre az asszisztens algoritmusra azért van szükség, mert az optimalizáció során a célfüggvény kiértékelésekre alkalmazott végelelemes szimuláció egy nagyon bonyolult és költséges számítási módszer,

ugyanakkor ez szolgáltat megfelelően pontos eredményeket az optimalizációs algoritmus számára.

Az asszisztensalgoritmus működése

Az asszisztensalgoritmus képes a meglévő eredmények alapján statisztikai becslést adni az újabb kiértékelések eredményeire, amelyekhez szolgáltat egy megbízhatósági tartományt is. Amennyiben ez a tartomány nem érinti az optimum vagy optimumok területet, nincs szükség a tényleges kiértékelésre. Ez egyben azt is jelenti, hogy minél több tényleges kiértékelés történt egy adott optimalizáció során, annál szűkebb tartományban képes becslést adni az algoritmus. Asszisztensrendszerként a MATLAB Kriging toolbox DACE (Design and Analysis of Computer Experiments) rendszer került alkalmazásra. Működését tekintve ez egy statisztikai kiértékeléseken alapuló asszisztensalgoritmus, ami a ténylegesen kiszámított célfüggvényértékekre a tervezési paraméterek függvényében egy interpolációs függvényt illeszt, majd a ténylegesen kiszámolt pontok távolságától függően normáleloszlású sűrűségfüggvények segítségével egy alsó és egy felső határt számít. A működése egy tervezési változó és egy célfüggvény esetén a 2. ábrán látható: [2]



2. ábra: A kriging működése. [2]

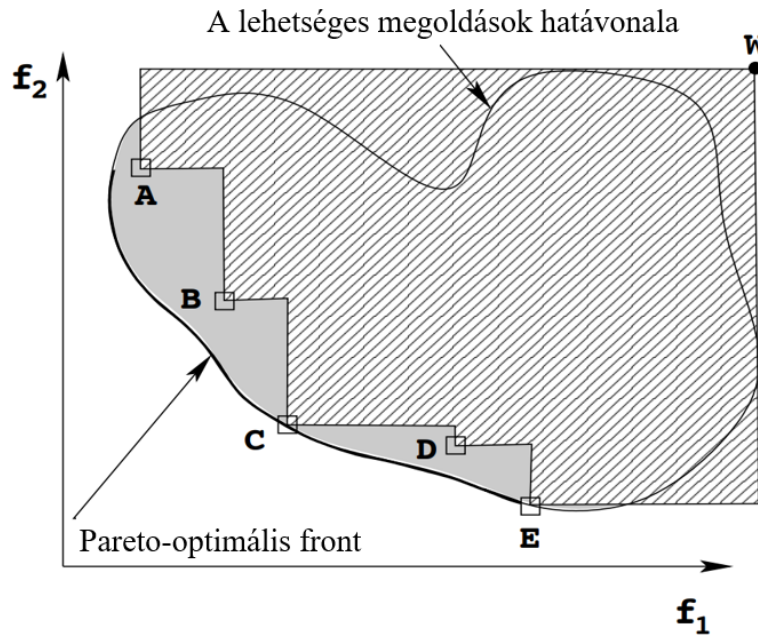
A használata tehát olyan esetekben előnyös, ha a célfüggvény kiértékelés az asszisztens futási időtartamánál lényegesen kevesebb (a motoroptimalizáció során ez az arány több nagyságrendű) és a megfelelő optimum megtalálásához sok (>100) célfüggvénykiértékelés szükséges.

Az optimalizációs algoritmus bemutatása

A matematikai optimalizáció olyan problémák megoldására szolgál, amelyeket analitikus módszerekkel nem lehet megoldani, tehát amikor olyan egy- vagy többváltozós térben kell megtalálnunk a paraméterek optimális kombinációját, ahol a célfüggvényünk értéke minimális. Ebben az alkalmazásban egy globális optimalizációs algoritmus lett felhasználva, a MATLAB szoftver Global Optimization Toolboxának többcélú genetikus algoritmus (Multiobjective Genetic Algorithm MOGA) [3].

A többcélú optimalizáció

Ha egynél több célfüggvényt kell optimalizálni, nem minden esetben lehetséges a megoldások között egyértelmű rangsort felállítani. Ezek kezelésének legegyszerűbb módja, ha a problémát egy egycélú optimalizációs problémára vezetjük vissza a célfüggvény-értékek súlyozott átlagával. Egy másik megközelítésben a kiértékelt eredmények két részre oszthatók, a dominált és a nem dominált egyedekre. Egy többcélú optimalizációs probléma esetén egy egyed csak akkor lehet egyértelműen jobb a többinél, ha annál nincs minden célfüggvény szerint jobb megoldás, ezek a nem dominált egyedek. A nem dominált egyedeket az optimalizáció pareto-optimalis frontjának nevezzük. Az optimalizáció eredményét az optimalizáció végén felírt pareto-optimalis front egyedei alkotják. Erre látható egy példa a 3. ábrán [3].



3. ábra: Egy példa a pareto-optimális frontra két célfüggvény esetén. [3]

A tesztfeladatok leírása

Az analitikusan megoldható tesztfeladat bemutatása

Az első tesztfeladat egy analitikusan megoldható többcélú optimalizációs probléma. A feladat két célfüggvényt és két tervezési változót tartalmaz. A Binh and Korn function bemutatása [4].

A célfüggvények:

$$f_1(x) = 4x_1^2 + 4x_2^2 \quad (1.1)$$

$$f_2(x) = (x_1 - 5)^2 + (x_2 - 5)^2 \quad (1.2)$$

A kényszerek:

$$g_1(x) = (x_1 - 5)^2 + x_2^2 \leq 25 \quad (1.3)$$

$$g_2(x) = (x_1 - 8)^2 + (x_2 + 3)^2 \geq 7,7 \quad (1.4)$$

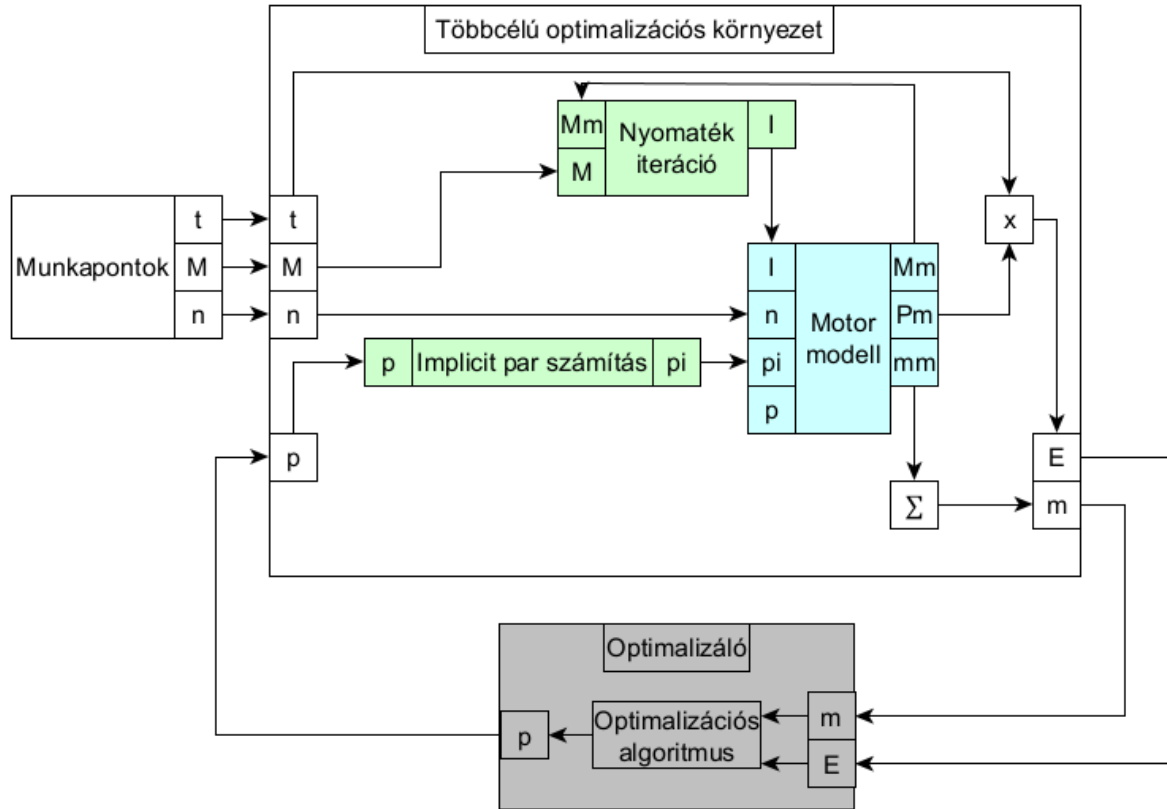
A paraméterek határai:

$$0 \leq x_1 \leq 5 \quad (1.5)$$

$$0 \leq x_2 \leq 3 \quad (1.6)$$

A motoroptimalizációs keretrendszer bemutatása

Az optimalizálási keretrendszer megkapja az optimalizáló algoritmustól az új tervezési változókat. Ezek és a munkaponti adatok alapján a szoftver-keretrendszer elvégzi a célfüggvények kiértékelését. A munkapontoknak a nyomatékigény és a fordulatszám mellett van még egy időszűrés paramétere is, ezáltal figyelembe lehet venni az egyes munkapontokban történő üzem időarányát a menetciklusra vetítve. Ezáltal nem veszteségteljesítményeket, hanem a menetciklusra vonatkozó veszteségenergia kerül kiszámításra célfüggvény-értékként. A motor tömegét és ohmikus veszteségeit analitikus modell, míg a vasveszteségeket és a sarokmunkapontra vonatkozó kényszert (a motor elvárt maximális nyomatéka és fordulatszáma adott áram és feszültségkorlát mellett) egy végelelemes modell számítja ki. A végelelemes modell bemenete a gerjesztőáram és a fordulatszám, ezért szükséges egy belső iteráció is, ami képes kiszámítani az adott nyomatékhoz szükséges fordulatszámot. A 4. ábrán a többcélú optimalizációs keretrendszer felépítése látható.



4. ábra: A többcélú optimalizációs keretrendszer felépítése.

Ezt a tesztfeladatot összesen 13 tervezési változó, az ezekhez tartozó határértékek és lineáris valamint nemlineáris kényszerek alkotják. A tervezési változók a menetszám kivételével mind folytonos geometriai paraméterek.

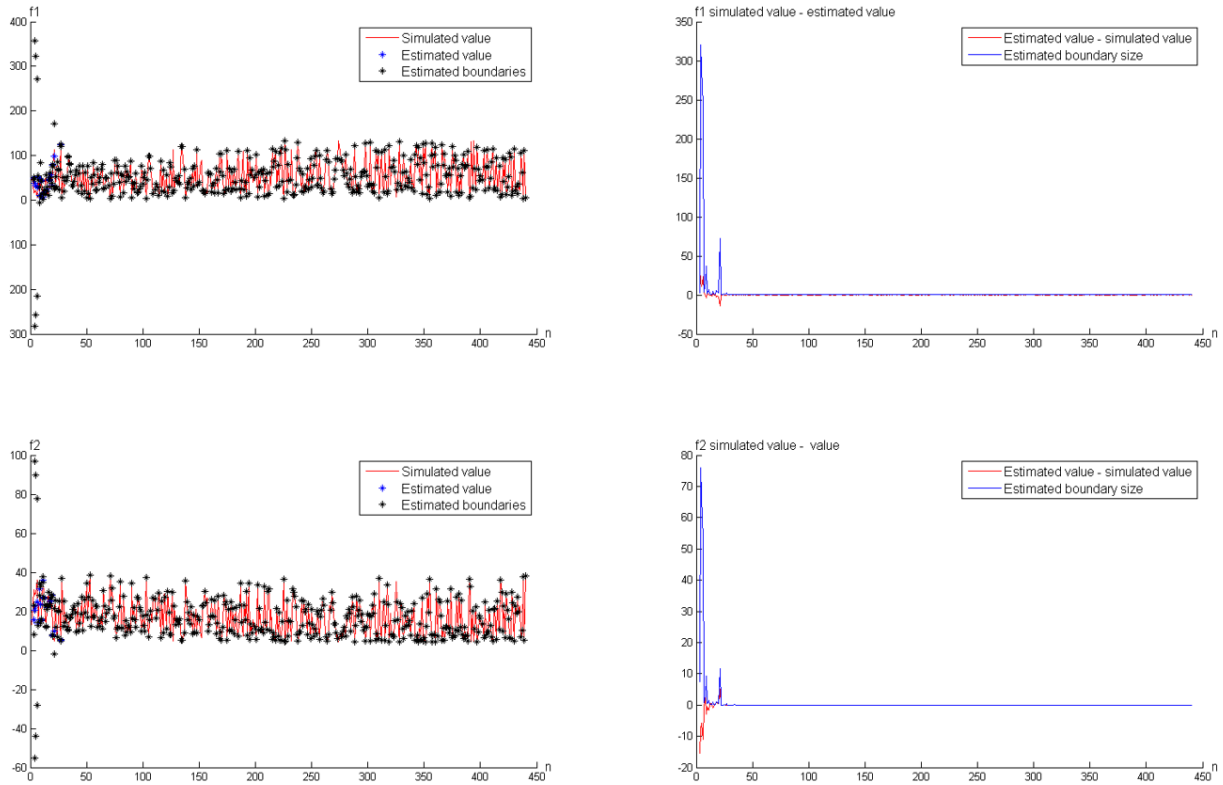
Az eredmények bemutatása

Az első tesztfeladat során 440 paraméterkombináció lett kiszámítva, ezek többségéhez készült becslés az asszisztens által. Azért nem mindegyikhez készült becslés, mert legalább két kiszámított pont kell az asszisztensrendszer megfelelő működéséhez. Az első tesztfeladat eredményei alapján lettek megállapítva a második tesztfeladat paraméterei.

Az első tesztfeladat eredményeinek bemutatása

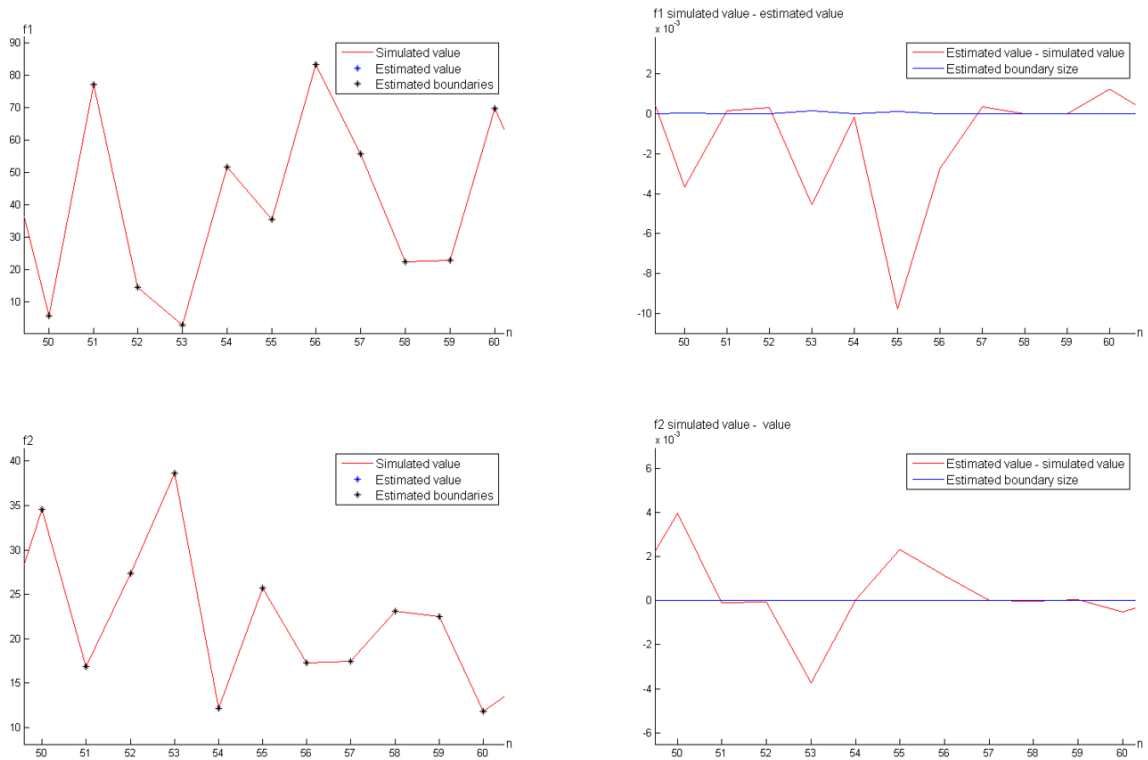
Az 5. ábra baloldali részén az egyes célfüggvények ténylegesen kiszámított értékei (piros vonal), az asszisztens rendszer várható értékei (kék csillagok) és a becslés határai (fekete csillagok) láthatóak. A jobb oldali részén a kiszámított és a becsült eredmények különbsége

(piros vonal) és a szimmetrikus határok abszolútértéke (tehát a szórási tartomány fele) vannak ábrázolva.



5. ábra: Az első tesztfeladat eredményei.

A 6. ábrán ugyan ez látható megfelelő nagyítással.

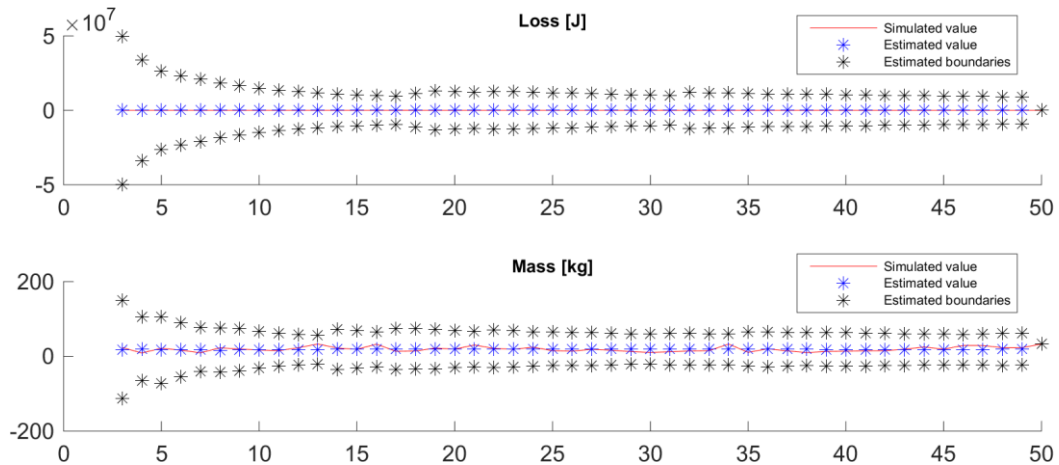


6. ábra: Az első tesztfeladat eredményei (nagyított).

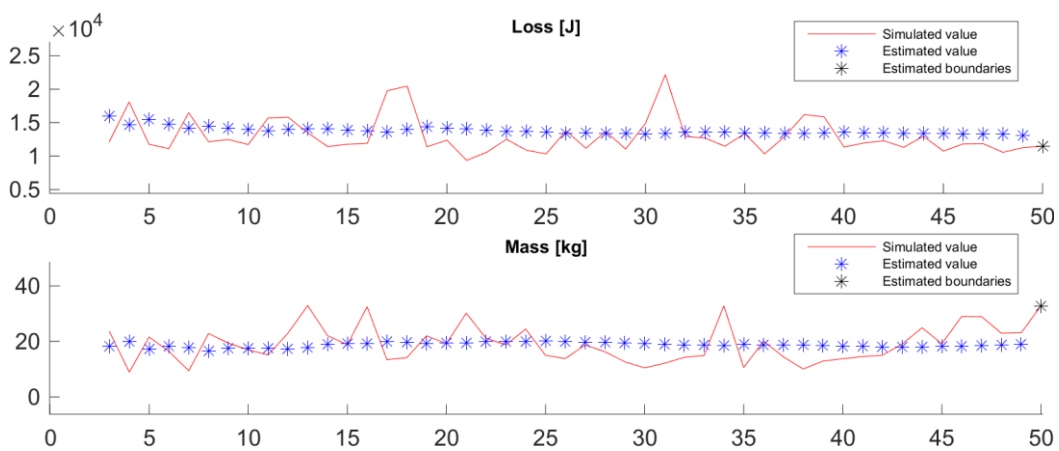
Látható, hogy az asszisztensrendszer már a 30-40. paraméterkombinációtól kezdve nagyon pontos becslést adott a célfüggvényekről.

A második tesztfeladat eredményeinek bemutatása

A második tesztfeladat során az asszisztensrendszer a motoroptimalizáló keretrendszerrel lett összekapcsolva.



7. ábra A második tesztfeladat eredményei.



8. ábra: A második tesztfeladat eredményei (nagyított).

A 7. és 8. ábrákon látszik, hogy két esetben a határok több nagyságrenddel nagyobbak voltak a célfüggvényértékeknél, egy esetben pedig a becslés volt túl pontatlan.

Összegzés

A bemutatott eredményekből jól látszik, hogy a tesztfeladat nem volt megfelelő a kriging asszisztensalgorithmus megfelelő felparaméterezéséhez egy ilyen rövid motoroptimalizációs kiértékelés során. Természetesen minél több valós kiértékelésből áll a motoroptimalizáció, az asszisztensalgorithmus annál pontosabb lesz, mivel annál több adatból képes statisztikai

becsléseket adni. Elmondható az eredmények alapján, hogy a paraméterezés pontosságának a tényleges optimalizáció korai szakaszában van jelentősége, viszont ehhez megfelelő helyettesítő problémára van szükség, ami a legtöbb esetben nem adott.

Köszönetnyilvánítás

A TKP2021-NKTA-48 számú projekt az Innovációs és Technológiai Minisztérium Nemzeti Kutatási, Fejlesztési és Innovációs Alapból nyújtott támogatásával, a TKP2021-NKTA pályázati program finanszírozásában valósult meg.

Irodalomjegyzék

- [1] K. Abkememier and A. Mize.: Hybrid and Electric Vehicles The Electric Drive Gains Traction, *Hybrid and electric vehicle implementing agreement, International Energy Agency*, 226, 2013
- [2] F. Bittner and I. Hahn.: Kriging-Assisted Multi-Objective Particle Swarm Optimization of Permanent Magnet Synchronous Machine for Hybrid and Electric Cars, *IEEE International Electric Machines and Drives Conference*, Chicago, 2013, pp. 1-8
- [3] K. Deb.: Multi-Objective Optimization using Evolutionary Algorithm, *Chichester, United Kingdom, John Wiley & Sons*, 2001.
- [4] T. Binh and U. Korn.: A Multiobjective Evolution Strategy for Constrained Optimization Problems, *Proceedings of the Third International Conference on Genetic Algorithms*, Czech Republic, 1997, pp. 176–182.