

A mesterséges intelligencia módszereinek helye a szimuláció alapú mérnöki optimalizálási feladatok megoldásában

The application of artificial intelligence techniques to simulation-based engineering optimization tasks

Dr. HURI Dávid¹, Dr. MANKOVITS Tamás²

¹adjunktus, Debreceni Egyetem, Műszaki Kar, Gépészmérnöki Tanszék, 4028 Debrecen,
Ótemető utca 2-4., huri.david@eng.unideb.hu

²tanszékvezető egyetemi docens, Debreceni Egyetem, Műszaki Kar, Gépészmérnöki Tanszék, 4028 Debrecen,
Ótemető utca 2-4., tamas.mankovits@eng.unideb.hu

Abstract

Using an optimization process in place of a trial-and-error-based mechanical engineering design method can help a company stay competitive in the market if the iteration process can be automated. Numerical simulation software makes it possible to do this iteration process even before the product is manufactured, which saves a significant amount of money and time. This article aims to outline the potential applications of artificial intelligence tools for simulation-based engineering optimization tasks which is a further automation option that boosts innovation and the design cycle.

Keywords: artificial intelligence, numeric simulation, engineering optimization, metaheuristic search algorithms, surrogate model

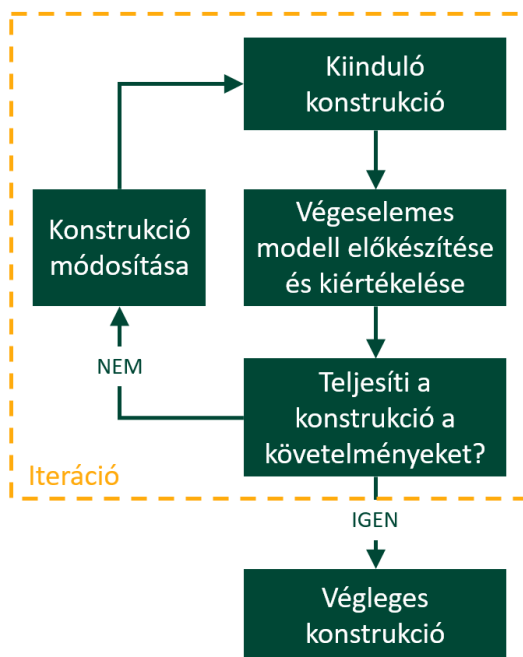
Kivonat

Ha lehetőség van az iterációs folyamat automatizálására, a próbálgatáson „what if” alapuló gépészeti tervezési módszer helyett, optimalizáló eljárás implementálásával lehet versenyképes maradni a piacon. A numerikus szimulációs eljárásoknak köszönhetően ezt az iterációs folyamatot már a késztermék legyártása előtt el lehet végezni, így jelentős időt, költséget és mérnöki munkaórát megtakarítva. Jelen cikk célja a szimuláció alapú mérnöki optimalizálási feladatokra ismertetni, a mesterséges intelligencia eszközeinek integrálási lehetőségeit. Az így adódó további automatizálási lehetőség felgyorsítja a tervezési ciklust és növeli az innovációt.

Kulcsszavak: mesterséges intelligencia, numerikus szimuláció, mérnöki optimalizáció, metaheurisztikus kereső eljárások, helyettesítő modell

1. BEVEZETÉS

A vevői elvárások alapján egy tervezőmérnöknek egyre bonyolultabb feladatokkal kell megküzdenie, melyre a rendelkezésére álló idő egyre inkább rövidül. Ahhoz, hogy ezek megoldása továbbra is időben tervezhető legyen módszeres gépészeti tervezést és azokba integrált számítógéppel segített tervezési eljárásokat kell használni. Ha lehetőség van az 1. ábrán látható iterációs folyamat automatizálására, a próbálgatáson „what if” alapuló gépészeti tervezési módszer helyett, optimalizáló eljárás implementálásával lehet versenyképes maradni a piacon. A numerikus szimulációs eljárásoknak köszönhetően ezt az iterációs folyamatot már a késztermék legyártása előtt el lehet végezni, így jelentős időt, költséget és mérnöki munkaórát lehet megtakarítani. A végeles elemes modellen alapuló célfüggvény hívása perctől akár napokig is tarthat, emiatt feladatspecifikus mérnöki optimalizálási módszereket kutatnak jelenleg is. A mesterséges intelligenciában (MI; *Artificial Intelligence*, AI) rejülő automatizálási lehetőség önmagában felgyorsítja a tervezési ciklust és növeli az innovációt. Jelen cikk célja a szimuláció alapú mérnöki optimalizálási feladatokra ismertetni, az MI eszközeinek integrálási lehetőségeit.



1. ábra. Végeselemes szimuláció alapú feladatok iterációs tervezési folyamata

2. MESTERSÉGES INTELLIGENCIA HELYE A MÉRNÖKI OPTIMALIZÁCIÓBAN

Az MI az 1950-es években jelent meg, mint az egyetemes tudomány fejlődésének egy új részterülete. A mesterséges intelligencia intelligens entitások építésének tudománya, melynek eredményeként emberi módon és/vagy racionálisan cselekvő és gondolkodó rendszerek létrehozása a cél. Ha a megközelítés központjában a racionalitás áll, akkor a rendszer tudásához viszonyítva helyesen cselekszik, melyhez mérnöki és matematikai tudományokat használ [1]. A XX. században számos kutatás történt melynek eredményeként új tudományos eredmények és megközelítések születtek az MI területén és feladatspecifikus megoldások alakultak ki. Az MI módszerei közé tartoznak például a természet ihlette metaheurisztikus optimalizáló algoritmusok [2] és a gépi tanuló (*Machine Learning*, ML) eljárások [3], [4]. A globális optimum közelítésére alkalmas metaheurisztikus kereső eljárások közé tartozik a genetikus algoritmus (*Genetic Algorithm*, GA) [5], a differenciális evolúció (*Differential Evolution*, DE) [6], vagy a szimulált hűtési eljárás (*Simulated Annealing*, SA) [7]. A gépi tanuló eljárások közé tartoznak a tartóvektor gépek (*Support Vector Regression*, SVR) [8], vagy a neurális hálózatok (*Neural Network*, NN) [9]. A XXI. század első évtizedében a számítási kapacitás és az egyre nagyobb mennyiségben rendelkezésre álló adatok lehetőséget biztosítottak a gépi tanulás széleskörű akadémiai és ipari alkalmazására. Az elmúlt egy évtizedben a nagymennyiségű adathalmazt igénylő mélytanuló (*Deep Learning*, DL) [10] rendszerek dominanciája figyelhető meg, mely egy meghatározó technológia a jelenleg is zajló negyedik ipari forradalomban [11], [12].

Szerkezetoptimalizálásról beszélünk olyan összetett mérnöki feladatok esetén melyek megkövetelik, hogy a viselkedés leírására a szerkezetanalízis numerikus eszközeit, míg az optimális konstrukció kiválasztására az elérhető matematikai eljárásokat alkalmazzuk [13]. A kiválasztás a tervezési változók terén adott válaszok alapján számított mérőszám segítségével történik, amit célfüggvénynek hívunk. A célfüggvény tulajdonságai a különböző problémák esetén eltérő [14]. Ha az analízis futtatási idejének hossza megengedi az optimalizáló algoritmus futtatását közvetlenül a modellen, számos lokális és globális kereső eljárás áll rendelkezésre [15]. Ha a célfüggvényről kevés információ áll rendelkezésre, akkor a feladatról keveset feltételező globális optimum kereső eljárások használata javasolt. Ide tartoznak a természet ihlette metaheurisztikus kereső eljárások, melyek megfelelő beállításokkal garantálják a globális optimum egy kellően jó környezetének megközelítését. Azonban ezen algoritmusok számos paramétert tartalmaznak, melyek megválasztása feladatspecifikusan, ezért tapasztalati úton történik.

2.1. Az optimalizáló módszer kiválasztásának szempontjai


Szimuláció alapú optimalizálási feladat megoldása során egy tervezőmérnök több – az 1. táblázatban felsorolt – problémával is szembesülhet, melyekre az elérhető megoldási módszerek napjainkban is aktívan kutatott területek. Ezek közül jól láthatóan több is az MI eszközei közé tartozik.

Numerikus szimuláció alapú optimalizálási feladat során alkalmazható módszerek a felmerülő problémák megoldására

1. táblázat

Probléma	Kutatási terület, módszer
Jobb megoldás elérése rövidebb idő alatt	Helyettesítő modell alapú optimalizálás: statisztikai mintavételezés (DoE); válaszfelület módszer (RSM); gépi tanulás (ML)
Ismeretlen viselkedésű célfüggvény optimalizációja	Globális optimum kereső eljárások: genetikus algoritmus (GA), szimulált hűtés (SA)
Automatizálás növelése, feladat összetettségétől független adaptálhatóság	Mesterséges intelligencia eszközei

Az optimalizáló módszer kiválasztását mutatja a 2. ábra mely három szempont alapján történhet, a hatékonyság, a robusztusság és a pontosság. Azonban egy jól kidolgozott eljárás esetén is csak két szempont elégíthető ki kellő mértékben. A tervezés alatt az innovációt és piaci versenyképességet szem előtt tartva napról napra újabb műszaki követelményeket kell kielégíteni, így ilyen feladatok esetén az optimalizálási feladat és annak célfüggvénye is változik. Emiatt csak olyan robusztus eljárás jöhet szóba, mely a feladat típusától függetlenül képes az optimum megközelítésére. Így az optimalizáló módszer kiválasztásakor a pontosságot vagy a hatékonyságot előtérbe helyezve az alábbi két alfejezetben bemutatott eljárások alkalmazhatóak, melyek ismertetésekor az MI-t is alkalmazó módszerekre koncentráltunk.



2. ábra. Az optimalizáló módszer kiválasztásának szempontjai

2.2. Helyettesítő modell alapú optimum becslés

Ha a szimuláció futásideje hosszú, vagy a számítási kapacitás korlátozott, akkor kézenfekvő megoldás helyettesítő modell (metamodell, *surrogate model*) [16] alapú eljárást választani. Ehhez elsőként mintavételezésre van szükség, amelyre a helyettesítő modell illeszthető, majd azon egy kereső eljárást futtatva becsülhető az eredeti feladat optimuma. A tanításhoz szükséges adathalmaz generálására különböző statisztikai mintavételezéseken alapuló kísérletterv (*Design of Experiment*, DoE) [17] használható. Helyettesítő modellként számos kutatás esetén [18]–[21] a gépi tanuláson alapuló regressziós eljárásokat használják, ilyen a lineáris regresszió, a neurális háló, a regressziós döntési fák, a tartóvektor gépek vagy a Kriging. A numerikus szimuláció területén használt helyettesítő modelleket és trendeket áttekintő irodalomban a gépi tanuláson alapuló eljárások dominanciája figyelhető meg az elmúlt években publikált kutatások során [22]. Nagy mennyiségű tanító adathalmazra és számítási kapacitásra van szükség a mélytanuló eljárások esetén, ezért azok alkalmazásának kerülése javasolt szimuláció alapú eljárások esetén. Egy ajtótomítás alakoptimalizálási feladát neurális modellel helyettesítették [23]-ban ahol a helyettesítő modell alapú optimum 7,9 [%]-os eltérést mutatott a meghatározott kialakításra futtatott végeselemes analízis eredményétől. Megállapítható, hogy a helyettesítő modell alapú optimum becslés esetén a pontosság a háttérbe szorul és így a globális optimum megtalálása sem garantált.

2.3. Globális optimum kereső eljárások

Amennyiben pontosabb eredményt kívánunk garantálni a robusztusság megtartásával akkor a magasabb függvényhívás számot igénylő ezáltal kevésbé hatékony globális optimum kereső eljárásokat célszerű választani. A kereső eljárásokat két nagy csoportra sorolhatjuk melyek a determinisztikus és heurisztikus módszerek. Utóbbin belül találhatóak a mesterséges intelligencia eszközei közé tartozó természet ihlette metaheurisztikus kereső eljárások. Ezen eljárások a mindennapjaink része, gondoljunk csak az útvonaltervezőkre de az ipari alkalmazások köre is jelentősen bővül. Számos irodalom elérhető ahol globális optimalizálási algoritmusokat alkalmaztak a numerikus szimuláció alapú tervezésben, mint például egy gumipersely alakoptimalizálása differenciális evolúcióval [24], egy rezgéscsillapító többcélú optimalizálása részecskeraj és tömegvonzás algoritmusok hibrid implementálásával [25] vagy a mérnöki szerkezetoptimalizálási feladatok megoldására implementált különböző szimulált hűtési eljárások [26]–[29]. Ezen eljárások előnye, hogy a szimulációk során előforduló futtatási hibák esetén a kereső eljárás sztochasztikus működéséből adódóan tovább futtathatóak egy másik megoldható pontból. A feldolgozott irodalmak alapján megállapítható, hogy az algoritmusok képesek a globális optimum egy kellően jó környezetének megközelítésére, ha az algoritmus paraméterei előzetes próbálgatásokkal kerültek meghatározásra.

3. KONKLÚZIÓ

Az analitikusan meghatározott célfüggvényekhez képest, a numerikus szimuláció alapú optimalizálási feladat hívása költséges, ezért célszerű helyettesítő modell alapú optimalizálási eljárás alkalmazni, mely esetben gépi tanuló eljárást választva feladat függetlenül elvégezhető a regressziós probléma megoldása. Amennyiben rendelkezésre áll elég idő és erőforrás, érdemes közvetlenül a szimulációs modellen futtatni a kereső eljárást, melyek közül több metaheurisztikus kereső eljárás is garantálja az optimum egy kellően jó környezetének megközelítését. Egyik mű esetén sem foglalkoztak a kereső algoritmusok hiperparamétereinek automatizált beállításával. A gépi tanuló eljárásokkal ennek a folyamatnak az automatizáltsági foka növelhető lenne. A mesterséges intelligencia eszközeinek kombinálásával tovább csökkenthető a számítási igény és növelhető az innováció a költséges mérnöki optimalizálási feladatok esetén.

KÖSZÖNETNYILVÁNÍTÁS

A kutatás a kulturális és innovációs minisztérium ÚNKP-23-4-II. kódszámú új nemzeti kiválóság programjának a nemzeti kutatási, fejlesztési és innovációs alapból finanszírozott szakmai támogatásával készült.

IRODALMI HIVATKOZÁSOK

- [1] P. Norvig and S. J. Russell, *Mesterséges intelligencia modern megközelítésben*, 2nd ed. Budapest, HU: Panem Kiadó Kft., 2005.
- [2] B. Chopard and M. Tomassini, *An Introduction to Metaheuristics for Optimization*. Cham: Springer International Publishing, 2018. doi: 10.1007/978-3-319-93073-2.
- [3] A. Burkov, *The Hundred-Page Machine Learning Book*. 2019.
- [4] M. Kubat, *An Introduction to Machine Learning*. Cham: Springer International Publishing, 2017. doi: 10.1007/978-3-319-63913-0.
- [5] David E. Goldberg, *Genetic Algorithms in Search, Optimization and Machine Learning*. Boston, MA, USA: Addison-Wesley Longman Publishing Co., Inc., 1989.
- [6] S. Das and P. N. Suganthan, “Differential Evolution: A Survey of the State-of-the-Art,” *IEEE Trans. Evol. Comput.*, vol. 15, no. 1, pp. 4–31, Feb. 2011, doi: 10.1109/TEVC.2010.2059031.
- [7] S. Kirkpatrick, C. D. Gelatt, and M. P. Vecchi, “Optimization by Simulated Annealing,” *Science (80-.)*, vol. 220, no. 4598, pp. 671–680, May 1983, doi: 10.1126/science.220.4598.671.
- [8] H. Drucker, C. J. C. Burges, L. Kaufman, A. Smola, and V. Vapnik, “Support Vector Regression Machines,” in *Advances in neural information processing systems*, 1997, pp. 155–161. Accessed: Feb. 15, 2020. [Online]. Available: <https://papers.nips.cc/paper/1238-support-vector-regression-machines>
- [9] R. E. Neapolitan and X. Jiang, “Neural Networks and Deep Learning,” in *Artificial Intelligence*, Chapman and Hall/CRC, 2018, pp. 389–411. doi: 10.1201/b22400-15.
- [10] S. Skansi, *Introduction to Deep Learning*. Cham: Springer International Publishing, 2018. doi: 10.1007/978-3-319-73004-2.
- [11] T. Kotsiopoulos, P. Sarigiannidis, D. Ioannidis, and D. Tzovaras, “Machine Learning and Deep Learning in smart manufacturing: The Smart Grid paradigm,” *Comput. Sci. Rev.*, vol. 40, p. 100341, May 2021, doi: 10.1016/j.cosrev.2020.100341.

- [12] S. Khan and T. Yairi, "A review on the application of deep learning in system health management," *Mech. Syst. Signal Process.*, vol. 107, pp. 241–265, Jul. 2018, doi: 10.1016/j.ymssp.2017.11.024.
- [13] C. Erdősné Sélley, G. Gyurecz, J. Janik, and G. Körtélyesi, *Mérnöki Optimalizáció*. Budapest, HU: Typotex Kiadó, 2012.
- [14] P. Y. Papalambros and D. J. Wilde, *Principles of Optimal Design*. Cambridge: Cambridge University Press, 2017. doi: 10.1017/9781316451038.
- [15] M. J. K. T. A. Wheeler, *Algorithms for Optimization*. The MIT Press, 2019.
- [16] A. I. J. Forrester, A. Sóbester, and A. J. Keane, *Engineering Design via Surrogate Modelling*. Oxford, UK: Wiley, 2008. doi: 10.1002/9780470770801.
- [17] K. Hinkelmann, *Design and Analysis of Experiments*, vol. 3. Hoboken, NJ, USA: John Wiley & Sons, Inc., 2012. doi: 10.1002/9781118147634.
- [18] Q. Li, J. Zhao, B. Zhao, and X. Zhu, "Parameter Optimization of Rubber Mounts Based on Finite Element Analysis and Genetic Neural Network," *J. Macromol. Sci. Part A*, vol. 46, no. 2, pp. 186–192, Dec. 2008, doi: 10.1080/10601320802594923.
- [19] L. Guo *et al.*, "Fatigue optimization of rotary control head rubber core based on steady sealing," *Eng. Fail. Anal.*, vol. 132, p. 105935, Feb. 2022, doi: 10.1016/j.engfailanal.2021.105935.
- [20] C. Cernuda, I. Llavori, A.-C. Zavoianu, A. Aguirre, A. Zabala, and J. Plaza, "Critical Analysis of the Suitability of Surrogate Models for Finite Element Method Application in Catalog-Based Suspension Bushing Design," in *2020 25th IEEE International Conference on Emerging Technologies and Factory Automation (ETFA)*, Sep. 2020, vol. 1, pp. 829–836. doi: 10.1109/ETFA46521.2020.9212166.
- [21] L. Li, B. Sun, M. He, and H. Hua, "Analysis of the Radial Stiffness of Rubber Bush Used in Dynamic Vibration Absorber Based on Artificial Neural Network," *NeuroQuantology*, vol. 16, no. 6, pp. 737–744, Jun. 2018, doi: 10.14704/nq.2018.16.6.1643.
- [22] J. Kudela and R. Matousek, "Recent advances and applications of surrogate models for finite element method computations: a review," *Soft Comput.*, pp. 1–25, Jul. 2022, doi: 10.1007/s00500-022-07362-8.
- [23] W. Zhu, J. Wang, and P. Lin, "Numerical analysis and optimal design for new automotive door sealing with variable cross-section," *Finite Elem. Anal. Des.*, vol. 91, pp. 115–126, 2014, doi: 10.1016/j.finel.2014.06.012.
- [24] N. Kaya, "Shape Optimization of Rubber Bushing Using Differential Evolution Algorithm," *Sci. World J.*, vol. 2014, pp. 1–9, 2014, doi: 10.1155/2014/379196.
- [25] F. Hejazi, H. Farahpour, N. Ayyash, and T. Chong, "Development of a volumetric compression restrainer for structures subjected to vibration," *J. Build. Eng.*, vol. 46, p. 103735, Apr. 2022, doi: 10.1016/j.jobe.2021.103735.
- [26] M. Sobótka, "Shape optimization of flexible soil-steel culverts taking non-stationary loads into account," *Structures*, vol. 23, pp. 612–620, Feb. 2020, doi: 10.1016/j.istruc.2019.12.010.
- [27] H. N. Ghafil and K. Jármái, "Dynamic differential annealed optimization: New metaheuristic optimization algorithm for engineering applications," *Appl. Soft Comput.*, vol. 93, p. 106392, Aug. 2020, doi: 10.1016/j.asoc.2020.106392.
- [28] J. Guo, W. Yuan, X. Dang, and M. S. Alam, "Cable force optimization of a curved cable-stayed bridge with combined simulated annealing method and cubic B-Spline interpolation curves," *Eng. Struct.*, vol. 201, p. 109813, Dec. 2019, doi: 10.1016/j.engstruct.2019.109813.
- [29] M. Akbulut and F. O. Sonmez, "Design optimization of laminated composites using a new variant of simulated annealing," *Comput. Struct.*, vol. 89, no. 17–18, pp. 1712–1724, Sep. 2011, doi: 10.1016/j.compstruc.2011.04.007.