

KORMÁNYMECHANIZMUS-GEOMETRIA OPTIMALIZÁLÁS GENERATÍV TERVEZÉS FELHASZNÁLÁSÁVAL

STEERING MECHANISM OPTIMIZATION USING GENERATIVE DESIGN TOOLS

*Dóka Tamás, PhD hallgató, Dr. Horák Péter, egyetemi docens
BME, Gépészmérnöki Kar, Gép- és Terméktervezés Tanszék*

ABSTRACT

In this paper, the advantages of generative design tools are demonstrated through a steering mechanism design process. With the help of generative design, in a correctly set up environment and with described desired goals, multiple equally good solutions could be discovered. First, the topic of generative design and the general problem of rack-pinion type steering mechanisms is presented, then the optimization process using a genetic algorithm and its result are evaluated. Finally, conclusions and possible future improvements and development possibilities are discussed.

1. BEVEZETÉS

A mai modern modellező és szimulációs technológiák megjelenése előtt különböző prototípusok előállítás, tesztelése és kiértékelése időigényes és rendkívül költséges folyamat volt. A számítógéppel támogatott modellező és vizualizációs technológiák segítségével a tervezett folyamatok, rendszerek fizikai megépítése, a szimulációs technológiák megjelenésével a tesztelés és kiértékelés időigényes folyamata vált helyettesíthetővé, ami nagy mértékben csökkentette a fejlesztés időtartamát és költségeit. A tervezési folyamatban így adott idő alatt sokkal több verziót lehet virtuálisan felépíteni és kipróbálni, ezáltal a fizikailag megvalósuló prototípusok már csak a bizonyítottan jobb megoldásokból készülnek el.

A tervezési feladatok nagy részében valamilyen paraméterhalmaztól függő problémát kell optimalizálnunk, mely paramétereit közötti viszonyrendszer általában nagyon összetett, így sok aspektust kell figyelembe venni a fejlesztés során. A projektek sok résztvevője és a változatos mérnöki területek miatt a tervezés egyes fázisaiban általában nem sikerül (sőt néha nem is lehetséges) hagyományos módszerekkel figyelembe venni az egyes döntések más területekre gyakorolt hatását (funkcionalitás, költségek, tervezési és előállítási idő), így még a rendelkezésre álló

szimulációs technológiák segítségével is nehéz meghatározni, hogy mi is lesz az optimális megoldás. Továbbá általában nem állnak rendelkezésre a pontos számításokhoz szükséges adatok, így a tervezés korai fázisában különböző koncepciókat kell elkészíteni, amely rendkívül időigényes, főleg a tapasztalatlanabb tervezők számára [1]. A hiányzó paramétereket becsléssel határozhatjuk meg, majd iteratívan közelíthetünk egy megfelelő megoldáshoz.

Egy újfajta megközelítésben a tervezés során egy konkrét megvalósításra való koncentráció helyett, a lehető legtöbb adatot összegyűjtve és egy átfogó követelményrendszert és tervezési teret (*design space*) létrehozva, optimalizáló algoritmusok vagy akár mesterséges intelligencia segítségével generálhatunk lehetséges alternatívákat, amelyek megfelelnek a követelményeinknek, ezt nevezzük generatív tervezésnek. Generatív tervezés segítségével a követelményrendszer módosításával, rövid idő alatt hozhatunk létre újabb megoldásjelölteket, amelyek egy megfelelően konfigurált optimalizáló algoritmus segítségével, jobb tulajdonságokkal rendelkezhetnek, mint amit emberek képesek lennének megtervezni, valamint a generált megoldások különböző módszerekkel és különböző szempontok szerint ki is értékelhetők, így megkönnyítve a közülük való választást. A generatív tervezés lehetővé teszi a tervező számára, hogy a hatalmas potenciális megoldástérből ne csak egy-egy megfelelő „pont” megtalálásán dolgozzon, hanem a probléma megfelelő körülírásával és a megoldó algoritmusok segítségével egyszerre párhuzamosan több, azonosan jó megoldás közül dönthessen.

A cikk célja, hogy egy egyszerűen kezelhető és ellenőrizhető tervezési problémára, a BME Fuse egyetemi versenycsapat elektromos koncepciójárművének fogaslécével működő kormánymechanizmusának kialakítására adjon megoldási javaslatokat generatív tervezési eszközök felhasználásával.



1. ábra - A BME Fuse egyetemi versenycsapat járművének integrált meghajtó modulja

2. GENERATÍV TERVEZÉS

A generatív tervező rendszerek parametrikusan felépített modelleket, szimulációs és optimalizációs eszközöket alkalmaznak, amelyek lehetővé teszik a tervező számára, hogy egy jól felépített modell esetén nagy számú generált változatot értékeljenek ki automatikusan. A probléma definícióját bemenetként megadva a generatív tervező rendszerek képesek megalkotni egy változatos megoldáshalmazt az adott problémára. [1] Így olyan megoldásokat is képes eredményezni, amiket emberként nem is tudnánk elképzelni. [2]



2. ábra - Generatív tervezéssel meghatározott kialakítású felni [2]

A kereskedelemben elérhető generatív tervező eszközök a gépészet területén jelenleg összetett alkatrészek optimalizálását teszik lehetővé mesterséges intelligencia és topológiai optimalizálás alkalmazásával, adott kényszerek és terhelésállapot esetén (2. ábra). Ezekkel a módszerekkel azonban csak terhelések és anyagfelhasználás szempontjából, a rendszerből kiemelve lehet optimalizálni, a teljes rendszerre gyakorolt hatások figyelmen kívül hagyásával. Ezt az optimalizáló módszert általánosságban nagyon nehéz lenne teljes rendszerekre alkalmazni, hiszen a rendszer elemeinek megváltozása az eredeti peremfeltételek megváltozását is jelenti, valamint így is rendkívül nagy számítási kapacitás szükséges egy-egy alkatrész generálásához is.

A gépészeti tervezés koncepciók fázisában azonban a legtöbb esetben ismeretlenek a pontos


peremfeltételek és terhelések, sőt függenek magától a konstrukciótól is, amit meg szeretnénk tervezni. Ezekben az esetekben általában egy konkrét kialakítás kerül meghatározásra tapasztalatok és feltételezések alapján, majd ennek a kialakításnak a méretezése és ellenőrzése történik és amennyiben az előre meghatározott határértékek között maradnak a definiált paraméterek, úgy elfogadják a megoldást. Ez a megközelítés a legtöbb esetben kielégítő megoldást eredményez azonban valószínűleg nem optimális a feladat szempontjából, valamint abban sem lehetünk biztosak, hogy pontosan ugyanennyi erőforrás ráfordításával nem tervezhetünk-e volna jobb konstrukciót. Ahhoz, hogy ezeket a „jobb” megoldásokat megtalálhassuk egy adott problémára, hagyományos módszerekkel nagyon sok időt, erőforrást kellene felhasználnunk minden egyes iterációs lépésben. Generatív tervezéssel azonban minden tervezési fázisban gyorsan, hatékonyan kaphatunk megoldásokat a tervezési térből.

A tervezési feladatok nagy részében a rendszer komponensei között zárt matematikai alakban nem meghatározható kapcsolat áll fent, ezért egy olyan algoritmusra van szükség, amely anélkül generál optimális megoldásokat, hogy a rendszer közvetlen működését ismerné [3]. Erre a feladatra megfelelőek az úgynevezett kereső algoritmusok, amelyek külső alkalmazásokat felhasználva tesztelik a megoldásokat, és ez alapján jutnak el a megoldáshoz ahelyett, hogy egy rejtett struktúrát építenének fel, mint a hagyományos neurális hálózatok. A kereső algoritmusok speciális fajtái a genetikai algoritmusok (GA), amelyek segítségével a tervezési térben található egyedek kombinálásával a kiértékelési szempontoknak leginkább megfelelő megoldásokat gyűjthetjük össze, ezekből pedig meghatározhatjuk a tervezési tér számunka releváns pontjait. Léteznek véletlenszerűen kereső, és a tervezési térben egyenletesen elosztott kereső módszerek is, kutatásukkal jelenleg több szerző is aktívan foglalkozik [1].

3. KORMÁNYMECHANIMUS OPTIMALIZÁCIÓS PROBLÉMA

A cikkben a generatív tervezés összeállítás szintű optimalizációs lehetőségeit a BME Fuse egyetemi versenycsapat négykerékű, elsőkerék-kormányzású járművének ideális kanyarodását lehetővé tévő kormánymechanizmus-geometria meghatározásával kapcsolatban mutatjuk be, adott futómű kialakítás mellett. A feladat célja, hogy a tervezés korai fázisában, amikor sok paraméter még ismeretlen vagy bizonytalan,


több, hasonlóan jó megoldás alternatívát kínálunk az ideális kanyarodás megvalósítására. Ideális, csúszásmentes kanyarodás akkor jön létre, ha a jármű kerekei egy közös középpontból húzott köríveken haladnak kanyarodás során (3. ábra – M pont). Ha csak elsőkerék-kormányzású a jármű, úgy a két hátsó kerék közös tengelye megszab egy egyenest, amin ez a közös középpont elhelyezkedhet. Minden egyes fordulókör sugár esetén, a külső köríven haladó kerék talppontjából a fordulókör sugarával húzott ív, és a hátsó tengely egyenesének metszéspontja kiadja a közös fordulókör középpontját. Ahhoz, hogy az ideális kanyarodás megvalósuljon, vagyis teljesüljön az Ackermann feltétel, a belső keréknek is ebből a középpontból húzott köríven kell haladnia, így minden fordulókör sugárhoz, adott lesz a külső- (δ_o), és a belső kerék elfordulási szög (δ_i), amelyek az egyenes haladási irányhoz képesti elfordulási szögek [4] (3. ábra).



3. ábra - Egy négykerékű jármű kerekeinek és a fordulókör középpontjának viszonya.

3.1 Kormánymű geometria

Az Ackermann feltétel teljesítésére a történelem során több különböző mechanizmust találtak fel, amelyek különböző előnyökkel és hátrányokkal rendelkeznek. [4] A közúti járművek legelterjedtebb kormánymű kialakítása az úgynevezett fogasléc – fogaskerék (*rack-pinion*) elrendezés (4. ábra).



4. ábra - Fogasléc – fogaskerék kormánymű kialakítás felülnézeti ábrázolása


Ebben a kialakításban a kormánykerék forgatásával egy fogaskerék kapcsolaton keresztül a fogasléc oldalirányban való lineáris mozgása a külső és belső kerék eltérő mértékű elfordulását eredményezi, így megfelelő geometria megválasztásával létrejöhethet az ideális kanyarodáshoz közeli állapot minden fordulókör sugár mellett. Az optimalizálás során egy adott tengelytáv, nyomtáv, valamint a futómű geometriából ismert kerék elfordulási tengely távolság (4. ábra – V és V' pontok távolsága) mellett határozzuk meg, a forgatókar (4. ábra V-U) és kormányösszekötő-rúd (4. ábra U-T) végpontjainak elhelyezkedését. További kritérium feltétel egy minimális fordulókör előírása is, hiszen matematikailag előfordulhat, hogy egy adott geometria mellett létrejön az ideális kanyarodás, de ha ez csak közel egyenes haladásra alkalmas, praktikus szempontból a megoldás haszontalan.

1. táblázat. A kormánymechanizmus-geometria optimalizáláshoz szükséges kötött paraméterek

tengelytáv	1900	mm
nyomtáv	1150	mm
V-V'	1030	mm
min. fordulókör	4000	mm

3.2 Változtatható paraméterek

Az optimalizáció során a valósághoz képest egyszerűsített, síkbeli modellt vizsgálunk. A kormánymechanizmus szimmetrikus elrendezését kihasználva a T és U pontok x és y koordinátáit változtatva generálhatjuk a megoldás jelölteket. A derékszögű koordináta-rendszer origóját az első tengely közepére helyezzük és az x irány a fogasléc tengelyével párhuzamos, az y irány pedig a menetiránnyal esik egybe (5. ábra).



5. ábra – Kormánymechanizmus egyszerűsített, síkbeli reprezentációja

A paraméterek értelmezési tartományát szűkíteni kell annak érdekében, hogy ne kapjunk fizikailag megvalósíthatatlan megoldásokat, így például a fogasléc bal végpontjának (T) és a bal kerék forgatókar végpontjának (U) is az y tengelytől balra kell esniük. Ezenkívül érdemes az y koordinátákat is határok között vizsgálni,

így a koordináták lehetséges tartományait a 2. táblázat tartalmazza.


2. táblázat - A T és U pontok koordinátáinak értelmezési tartománya

	min.	max.
TX	-500	-50
TY	-300	300
UX	-600	-50
UY	-300	300

3.2 Jelöltek kiértékelése

Minden koordináta kombináció esetén meg kell határozni a kanyarodás pontatlanságát. A koordináták az egyenes haladási iránynak megfelelő elrendezést adják meg, amelyből a fogaslécet kimozdítva kell meghatározni a kerekek elfordulási szögét. A fogasléc x irányú mozgástartományát az alapgeometria határozza meg, ezt a mozgástartományt azonos számú részre oszthatjuk minden esetben, így azonos felbontással kapjuk meg a kerekek elfordulási szögét a fogasléc mozgásának függvényében. A külső kerék elfordulása határozza meg a jármű fordulókörét, ennek megfelelően minden külső elfordulási szög (δ_o), esetén kiszámítható az Ackermann feltétel teljesülésével az ideális belső elfordulási szög is.

A vizsgált konfigurációkban a belső kerék valódi elfordulási szöge ($\delta_{i,actual}$) eltérhet az ideálistól ($\delta_{i,ideal}$).



6. ábra - A hibafüggvény ábrázolása különböző konfigurációk esetén

Az ideálistól való eltérés nagyságát a külső kerék elfordulásának függvényében ábrázolva kapjuk meg a konfigurációk hibafüggvényét (6. ábra). Az egyenes iránynak megfelelő nulla pozíciótól a minimális fordulókörnek megfelelő külső kerék elfordulási szög értékig (β) integrálva a hibafüggvényt megkapjuk a konfiguráció hibaértékét ($error$).

$$error = \int_0^{\beta} |\delta_{i,actual} - \delta_{i,ideal}| d\delta_o \quad (1)$$

Az optimalizálási feladat megoldott, ha ez a hibaérték eléri a nullát, vagy egy általunk előírt határ alá csökken, tehát a valódi elfordulás megközelíti az ideálisat és a feladatban meghatározott minimális fordulókör is biztosított.

4. OPTIMALIZÁLÓ ALGORITMUS

A bemutatott probléma optimalizálására léteznek nagyon jól működő optimumkereső algoritmusok, amelyek a megadott paraméter tartományokban különböző módszerekkel keresik a függvény szélsőértékét. Ezek az algoritmusok azonban amellet, hogy csak egyetlen megoldást adnak vissza, a paraméterek számának növekedésével csak jelentősen növekvő futásidő mellett képesek eredményt szolgáltatni. Ha a paraméterhalmazba több tényezőt (például: tömeg, anyag, szilárdsági tulajdonságok) is beemelünk, az a klasszikus szélsőérték kereső algoritmusok számára problémát jelenthet, ezért, hogy általános megoldást találhassunk a problémára, genetikus algoritmust (GA) alkalmazhatunk.


Az algoritmus működésének lényege, hogy a változtatható paraméterekből felépített megoldásjelöltek (egyedek) paramétereit (génjeit) sztochasztikus módon változtatva, kombinálva, az evolúció működését imitálva hoz létre minden generációban a kiértékelésnek egyre jobban megfelelő megoldásokat. A módszer előnyös, mivel a modell és a kiértékelés bonyolultsága is változtatható, nem folytonos paraméter tartományokon is megoldást szolgáltat és nem egyetlen megoldással, hanem egy megoldás halmazzal tér vissza.

A genetikus algoritmus alapjául a *pyeasyga* Python könyvtár szolgál, amelyet a tesztelés megkönnyítése érdekében diagnosztikai eszközökkel bővítettünk.

4.1 Egyedek

Az algoritmus populáció egyedeinek génjei a korábban említett T és U pontok x és y koordinátáinak értékei. A kezdeti populáció az értelmezési tartomány véletlenszerű mintavételezésével jön létre. Az egyedek rangsorolása az algoritmus fitness függvénye alapján történik meg. Az újabb generációk létrehozása során ezek az egyedek véletlenszerűen kereszteződnek, mutálódnak, majd a hasonló egyedek kiszűrését követően létrejön belőlük minden generációban az új populáció (7. ábra). Az új populáció létrehozásánál több stratégiát is követhetünk. Az

első megközelítés, hogy az új populáció kizárólag új egyedekből álljon. Ekkor a keresztezés és mutáció során létrejött új egyedekből képezzük a populációt. Ez a megközelítés magában hordozza annak a lehetőségét, hogy a legjobb egyedet elveszítjük, és csak rosszabb fitness értékű egyedek jönnek létre. Így dönthetünk úgy is, hogy az előző generáció legjobbját, vagy a legjobbak egy részét engedjük tovább az új populációba (elitizmus). Fennáll a lehetősége annak, hogy a legjobb megoldások egyetlen érték körül jelentkeznek, így a generációk számának növekedésével a populáció diverzitása csökken, és nem kapunk megfelelő képet arról, hogy milyen jó megoldások találhatóak a tervezési térben. Ennek a jelenségnek a kiküszöbölésére az új populáció létrehozásakor minden új egyed génjeit összehasonlítjuk az új populációba már felvett egyedek génjeivel, és ha az új egyed valamelyik már felvett egyeddel nagymértékű egyezést mutat, akkor eldobásra kerül. Az új egyedek létrehozását addig ismételjük, amíg az új populáció száma el nem éri az előírt értéket.



7. ábra - A genetikus algoritmus által generált populáció az eredeti tartományon (fent) és szűkített tartományon (lent). A legjobb egyedek kiemelve láthatóak (bal oldalon a T pont, jobb oldalon az U' pont értelmezési tartománya).

4.2 A fitness függvény


Az egyedek rangsorolása során több szempontot is figyelembe kell venni. A legfontosabb mérték a kormánymű ideálistól eltérő karakterisztikája, amit a konfiguráció hibaértéke (*error*) jellemez. Annál jobb egy kormánymechanizmus-geometria, minél kisebb

a hibaérték, így a fitness függvény értékét (*f*) a hibaérték reciprokával számíthatjuk első megközelítésben. Ha a hibaérték nagy, nullához közeli, ha nagyon kicsi, akkor végtelenhez közeli fitness értéket kapunk. A minimális fordulókörnél nagyobb fordulókör esetén is létrejöhet olyan egyed, ami összességében jó fitness értékkel rendelkezik, érdemes a populációban tartani. Azonban, ha a minimális fordulókörhöz tartozó határszögnél lényegesen kisebb szögben képes csak elfordulni, nem lesz megfelelő megoldás. Ezért a fordulókör esetében, amennyiben a megoldás az elvárthoz közel helyezkedik el, egy exponenciális lecsengéssel vesszük figyelembe a szögkülönbséget ($\Delta\beta$), ezzel csökkentve a fitness függvény értékét. Ugyanígy exponenciálisan lecsengő tényezővel szorozzuk meg a fitness értéket, ha a kapott egyed génjei közül valamelyik koordináta a kijelölt határokon kívül esne, és az eltérés mértéke Δd .

$$f = \frac{1}{error} \cdot e^{-\Delta\beta} \cdot e^{-\Delta d} \quad (2)$$

5. EREDMÉNYEK

A kormánymechanizmus-geometria optimalizálására a genetikus algoritmust a 3. táblázatban található adatokkal futtatva teljes tartományon, képet kaphatunk a legmegfelelőbb elhelyezésekről.




8. ábra - Az optimalizáló algoritmus által generált kormánymű kialakítások 3D modellbe ültetése.

Az eredményeket a parametrikus 3D modellbe beolvasva (8. ábra) a tervezési folyamatban rendkívül hasznos információkhoz jutunk, amelyek alapján a keresési tér tartományát szűkítve újabb keresést futtathatunk és iteratívan közelíthetünk a végleges megoldás felé úgy, hogy minden lépésben számos alternatívát kínál fel az algoritmus számunkra.

3. táblázat - A genetikus algoritmus futtatási adatai

Populáció egyedszám	100
Generációk száma	20
Kereszteződés valószínűsége	0.75
Mutáció valószínűsége	0.5
Elitizmus	igen

A futtatás eredménye függ a keresési tartománytól és a kezdeti véletlenszerűen felvett populációtól is. A megoldások matematikai szempontból nem feltétlenül jelentenek szélsőértéket, de mérnöki szempontból nagyon hasznosak, hiszen hasonlóan jó alternatívákat kínálnak. Minden generáció legjobb egyedének hibafüggvényét ábrázolva látható (9. ábra), hogy a konfigurációk hibája 0,1 fok alatti a teljes kanyarodási tartományon, így az egyszerűsített két-dimenziós modell képes az Ackermann feltételt jól közelítő megoldást szolgáltatni.



9. ábra – A genetikus algoritmus futtatása során a generációnkénti legjobb egyedek hibafüggvényei.

5.1 Fejlesztési lehetőségek

Az optimalizáló genetikus algoritmus rugalmas bővíthetőségének és skálázhatóságának köszönhetően a jelenlegi problémába bevonhatóak a kormánymű további paraméterei is, így nem csak a geometriai szempontok figyelembevételével, hanem alkatrész szintű optimalizálással is tervezhetünk. További fejlesztési lehetőség a kiértékelésbe közvetlenül bekapcsolt 3D CAD rendszer, hiszen így a kanyarodás során jelentkező térbeli hatásokat is

figyelembe lehet venni, ha a kiértékelő algoritmus közvetlenül képes vezérelni a CAD rendszeren belüli mozgásszimulációkat.

6. ÖSSZEFOGLALÁS

A generatív tervezés előnyeinek és hátrányainak áttekintése után bemutatásra került a fogasléc-fogaskerék (*rack-pinion*) elrendezésű kormánymechanizmusok működése, egyszerűsített síkbeli modellezése és a mechanizmust felépítő elemek paramétereinek hatása a kanyarodás közben fellépő, az ideális Ackermann feltételnek megfelelő állapothoz képesti hibára. Az optimalizációra alkalmas genetikus algoritmus (GA) működésének rövid összefoglalását követően az új generációk létrehozása és az egyedek rangsorolásának módja, végül a kapott eredmények hasznosítása és a jövőbeli fejlesztések felvázolása is bemutatásra került.

7. KÖSZÖNETNYILVÁNÍTÁS

A tanulmány alapjául szolgáló kutatást az Emberi Erőforrások Minisztériuma által meghirdetett Felsőoktatási Intézményi Kiválósági Program támogatta, a Budapesti Műszaki és Gazdaságtudományi Egyetem Mesterséges intelligencia (BME FIKP- MI) tématerületi programja keretében.

8. IRODALOM

- [1] Khan S. és Awan M.: A generative design technique for exploring shape variations. *Advanced Engineering Informatics*, 38, 712–724, 2018
- [2] Tyrrel M.: Autodesk generative design used on electric VB bus concept. *Production Engineering Solutions*, 2019. július 10.
- [3] Nagy D.: The Problem of Learning. medium.com/generative-design, 2017. január 23.
- [4] Jazar R.: *Vehicle Dynamics: Theory and Applications*. Springer, 2008