

# Válasz Prof. Kuczmann Miklós bírálatában megfogalmazott kérdésekre

## az *Analysis and Synthesis Methods for the Optimal Design of Control Systems in Automated Vehicles*

című MTA doktora cím elnyerésére benyújtott értekezés  
vonatkozásában.


Mindenek előtt szeretném megköszönni Professzor Kuczmann Miklós opponens munkáját, az elem tárt alapos és szakszerű bírálatát. A bírálatban feltett kérdésekre az alábbiakban szeretnék válaszolni.

### A 2. fejezethez kapcsolódó első kérdés

Kérem a Jelöltet, hogy a 2.2. vagy a 2.3. fejezetben megfogalmazott új tudományos eredmények illusztrálására mutasson be röviden egy egyszerű illusztratív példát.

### Válasz

A 2.3-as fejezetben vázolt irányítási megoldás működési elvének és hatékonyságának lényegét - a bírálói kérdésnek megfelelően - egy egyszerűsített robotikai alkalmazáson mutatom be. Ebben a példában az 1 ábrán látható mobil robot karjának szögállását szükséges egy előre adott referenciaértékre beállítani. Jelen megoldásban a neurális hálózat a visszacsatolási hurokban a szabályozási feladat elvégzésére került betanításra felügyelt tanulási eljárással. A rendszer modellje, illetve az irányítás tervezésének részletes bemutatása egy könyvfejezet publikációmban található meg [1].



1. ábra. Mobil robot illusztrációja.

Az alábbiakban a működés hatékonyságát szimulációs eredményekkel mutatom meg. Az irányítás megvalósítására elvégeztem a robotkar szabályozásának tanítási feladatát, illetve az LPV irányítás megtervezését. Ez utóbbit különböző beállításokkal végeztem el.

A disszertáció (2.40) optimalizálásban szereplő  $R$ ,  $D$  és  $T$  súlyokat az 2 táblázat szerint állítottam be, illetve a táblázat jobb oldalán lévő eredményekre vezetett az optimalizálás. Minden egyes iterációt  $\rho_{L,min} = 0.25$ ,  $\rho_{L,max} = 0.5$  kezdeti értékekkel végeztem el.

$R$	$D$	$T$	$\rho_{L,min}$	$\rho_{L,max}$	$\Delta_{L,min}$	$\Delta_{L,max}$	$E$ [%]	$\gamma$
3	5	0.1	0.4997	0.5104	-0.7855	0.7009	8.1	0.3886
3	5	0.5	0.01	1.13	-0.6380	1.7414	2.2	0.3898
3	5	1	0.01	1.5393	-3.4616	3.2791	0.7	0.4009

1. táblázat. Iteratív LPV tervezés eredménye

A szimulációs eredményeket a 2. és 3. ábrákon szemléltetem. Az összehasonlító elemzést két szimuláción végeztem el. Az 1. esetben a referenciajel abszolút értéke  $|r| \leq 0.5$  rad, a második esetben ez  $|r| \leq 0.9$  rad. Ennek jelentősége, hogy az első esetben olyan nagyságú referenciajelet kap a szabályozó, amelyek a neurális háló tanításának mintáiban is jelen voltak. A második esetben azonban az  $r$  értéke ezeken kívül is van. Az LPV szabályozó azonban  $|r| \leq 1$  nagyságú referenciajelek alapján került megtervezésre.

Az 1. eset szimulációs eredményei a 2. ábrán láthatók. A 2(a) ábra azt mutatja, hogy a csak neurális hálóval irányított rendszer is pontosan követi a referenciajelet kis hibával, amely a tanítás sikerességét mutatja. Hasonlóképpen, az LPV irányítással kiegészített szabályozó rendszerek is garantálják a követést, de a követési pontosságuk azonban eltérő. Az  $R = 3, D = 5, T = 1$  beállításokkal LPV irányítás esetén az  $u$  és  $u_L$  jelek közel azonosak. A  $T = 0.5$  és  $T = 0.1$  beállítású LPV irányításnál magasabb követési hiba jelenik meg:  $T = 0.5$  túllövéshez, míg a  $T = 0.1$  megnövekedett állandósult állapotú hibához vezet. Az irányítójelek és a kapcsolódó  $\rho_L, \Delta_L$  jelek a 2(b) ábrán láthatók. A  $T = 1$  beállítás esetén az  $u_L$  jelet alacsony hibával követi az  $u$  irányítójelet, ami a megnövekedett  $\rho_L, \Delta_L$  tartományok eredménye, amint az a 2(c),(d) ábrákon látható. Az  $u$  irányítójelet  $T = 0.5$  beállításnál szintén közel áll az  $u_L$ -hez, de a kisebb  $\rho_L, \Delta_L$  tartományok nagyobb különbséget eredményeznek. A  $T = 0.1$  beállítás esetén az  $u$  és az  $u_L$  közötti különbség jelentős (lásd a 2(b) ábrát), mivel a  $\rho_L$  és  $\Delta_L$  csak kis értéket vehet fel, azaz az LPV irányítás hatása érvényesül a működés nagyobb részében.


A 2. esethez kapcsolódó szimuláció a 3 ábrákon látható. A szimulációs eredmények azt mutatják, hogy a neurális háló szabályozó nem képes önmagában megfelelő követést biztosítani az egész szimuláció során, lásd 3(a) ábra. Ennek oka, hogy a 2. esetben a növelt nagyságú referenciajeltől nem tartalmazott mintát a tanítás. Az LPV-vel kiegészített irányítás azonban ebben az esetben is képes garantálni a követést egy előre definiált maximális követési hiba garantálása mellett. A szimulációk továbbá azt is mutatják, hogy a különböző  $T$  beállítás mellett az  $u$  és  $u_L$  különbözőképpen tér el egymástól, ami meghatározza a  $\rho_L$  és  $\Delta_L$  változását az egyes beállítások mellett. Például, az 52s után az  $u_L$  jelentős követési hibát okoz, amit azonban az LPV irányítással a  $\rho_{L,max}$  érték választása mellett el lehet kerülni, lásd a 3(c) ábrán. Továbbá a szimuláció azt is mutatja, hogy a  $T = 0.1$  beállítás a legsimább  $u$  jelhez vezet, amíg a  $T = 0.5$  és  $T = 1$  beállítások az  $u$  hirtelen változásaihoz vezet a nagyobb tartományban mozgó  $\rho_L, \Delta_L$  jelek miatt.

## A 2. fejezethez kapcsolódó második kérdés


A modell alapú tervezés bemutatása kellően mély. A tanuló módszerekről azonban bővebben nem értekeznek. Kérem, mutassa meg röviden, hogy kell elképzelni a módszerek alkalmazását a referenciajel és a beavatkozás előállításában.

Válasz







(a) Referenciajel ( $r$ ) követése



(b) Irányítójelek



(c) A  $\rho_L$  változása




(d) A  $\Delta_L$  változása


2. ábra. Szimulációs eredmények az 1. esetben.

A járműirányítás vonatkozásában felügyelt tanulási, illetve megerősítéses tanulási megoldásokat alkalmaztam.


- A felügyelt tanulás megvalósítása során visszaterjesztéses eljárást (backpropagation) alkalmaztam, a neurális háló egyes paramétereit Levenberg-Marquardt optimalizálással határoztam meg. A tanítás során szükséges réteg- és neuronszám meghatározást részben tapasztalati úton, egyes alkalmazásoknál pedig  $k$ -fold keresztvalidációs technikával végeztem el [2, 3]. A háló tanítási eredményére nézve egy példát mutatok a 4. ábrán. Itt egy olyan neurális háló tanításának eredménye látható, amelynek célja különböző mért jelek alapján az oldalirányú sebesség becslése [4]. A 4. ábra az első és második rejtett rétegeken különböző számú neuronok mellett ( $n_1, n_2$ ) mutatja a becslés eredményét. A neuronok számának növekedésével a becslés pontossága növelhető, azonban a túl sok neuron túltanuláshoz is vezethet, ami a háló általános használatának lehetőségét korlátozhatja. Ennélfogva a neuronok számát kellő körültekintéssel kellett megválasztanom.
- Megerősítéses tanulás alkalmazása esetén a modell nélküli online és off-policy típusú Deep Deterministic Policy Gradient (DDPG) eljárást használtam [5]. Ennek az eljárásnak a célja egy előre definiált jutalomfüggvény (reward) kumulatív értékének maximalizálása, amelyet a háló epizódonként, a tanítási környezetben történt futtatása által értékeltem ki. A jutalomfüggvény maximalizálása egy actor-critic struktúrában történik. Az actor maga az a neurális háló, amelyet majd a járműirányításba építettem be. A critic pedig az a másik ágens, amely megbecsli a jutalomfüggvény várható




(a) Referenciajel ( $r$ ) követése



(b) Irányítójelek




(c) A  $\rho_L$  változása



(d) A  $\Delta_L$  változása

3. ábra. Szimulációs eredmények a 2. esetben.



4. ábra. Neurális háló becslési tulajdonságának értékelése szimulációkkal.

értékét. A megerősítéssel tanulásban a jutalomfüggvény formájának a megválasztása kiemelten fontos, ugyanis ez segíti elő az irányítás által elérni kívánt performancia szint megvalósulását.

### A 3. fejezethez kapcsolódó kérdés

A 3.1.1. new result pontban miért nem fogalmazta meg, hogy a kidolgozott sebesség-profil energia-optimalis, miközben a 3.1. fejezet címe ezt mondja? A fejezetben ezt nem is hangsúlyozza, a 3.2.1. new result pont, azaz a 3.2. fejezet, végül a gondolatmenetet

befejezi a súlyok optimalizálásán keresztül.

#### Válasz

Egyetértek a kérdésben lévő állítással, a dolgozat 42. oldalán lévő 3.1.1 pontja valóban nem foglalja magában az energia-optimalis megfogalmazást. A 3.1-es fejezet célja egy modellalkotás, amely modell magában hordozza a jövőbeli útvonalhoz, sebességkorlátozásokhoz kapcsolódó súlyokat. Ezen súlyok a 3.2-es fejezetben az optimalizálás változóivá lesznek, amelyek kiszámítását a (3.16)-os összefüggés adja meg.

#### A 4. fejezethez kapcsolódó első kérdés

Hogy lehet figyelembe venni azt a járművet, amelyről nincs pozíció és sebesség információ, mert például nincs jármű-jármű kapcsolat? Ha jól értelmezem, az első módszerben ez nem működik, a második módszer erre alkalmas lehet.

#### Válasz

Mindkét általam felvázolt módszer számára szükséges, hogy információval rendelkezünk a környező járművek mozgásáról, azaz aktuális pozíciójáról és sebességéről. Amennyiben jármű-jármű (V2V) kommunikáció nem áll rendelkezésre, az automatizált járműnek a saját méréseit kell alkalmaznia az irányításban. A környező járművek jövőbeli mozgásának becslésére nézve egyszerűsített kinematikai mozgásmodelleket alkalmaztam. Ennek előnye, hogy kevés számú járműparamétert tartalmaz, azaz általánosan használható különböző típusú járművek rövidtávú mozgásának becslésére.

**A 4. fejezethez kapcsolódó második kérdés** Milyen számításigénnyel bírnak ezek a módszerek, ha a valósidejű megvalósítás is cél?

#### Válasz

A bemutatott irányítási eljárások esetében vizsgáltam, hogy a számítási idő mekkora a supervisor-ban lévő optimalizálás esetében, amely a legnagyobb erőforrást igényli az online megoldás során. Itt különösen is lényeges, hogy a környező járművek számának növekedése növelheti egy lépés számítási idejét. Ebben az esetben ugyanis a (6.12) optimalizálás korlátozó feltételeinek száma növekszik. Jelen kontextusban ez azt jelenti, hogy a felírt mixed-integer probléma egyre több térrészre esik szét, amelyen az optimalizálási feladatot meg kell oldani. Az általam vázolt megoldásban ennek a növekedésnek azzal lehet elejét venni, hogy az  $n_s$  paraméter értékét alacsonyan kell tartani a (6.12)-es optimalizálási feladatban. Az  $n_s$  ugyanis azt reprezentálja, hogy az adott automatizált jármű a környezetében hány további jármű mozgását veszi figyelembe.

$n_s$	1	2	3	4	5	6	7	8
$T_{comp}$ (s)	0.012	0.022	0.044	0.057	0.080	0.106	0.226	0.426
$n_s$	9	10	11	12	13	14	15	
$T_{comp}$ (s)	0.866	1.904	3.097	6.610	16.292	34.886	66.817	

2. táblázat. A supervisor mögött lévő algoritmus számítási idejének elemzése

A számítási idő ( $T_{comp}$ ) kiértékelését az 1. táblázat mutatja be különböző  $n_s$  értékek esetében. Jelen számításokat MATLAB 2020a programmal végeztem Intel Core i7 10<sup>th</sup> processzorral rendelkező számítógépen futtatva az algoritmusomat [6]. Az általam vázolt eredmények megerősítik az előzetes elképzelést, miszerint a figyelembe vett járművek számának növekedésével jelentősen növekszik a (6.12) optimalizálási feladat megoldási ideje. Figyelembe véve, hogy egy hosszirányú járműirányítási rendszerbe a szükséges beavatkozást hozzávetőlegesen 0.05s időközönként szükséges számítani, az  $n_s = 3$  értéknél nem

javaslok ezen feladat esetében magasabbat választani, azaz a jármű keresztesződésben való mozgását minden időpillanatban a legközelebbi három (vele konfliktushelyzetben lévő) jármű mozgása alapján szükséges meghatározni.

**A 4. fejezethez kapcsolódó harmadik kérdés** A Jelölt szerint mikorra várható, hogy az infrastruktúra kiépítettsége lehetővé teszi ilyen modern algoritmusok alkalmazását az utakon?

**Válasz**

A konkrét alkalmazás megvalósulásának lehetséges időtávját számos tényező befolyásolja. Irányításméleti oldalról az általam bemutatott megoldások tekintetében egy fontos tényezőre vonatkozó kérdést tudok ennek kapcsán megjelölni: a járművek koordinált irányításának struktúráját. Amennyiben az irányított járművek egy központosított (centralizált) struktúrában kerülnek irányításra, az egy magasabb informatikai biztonsági szintet igényel. A centralizált esetben ugyanis a járművek mozgáspályájának egy része nem az egyedi járműveken kerül kiszámításra, amely biztonsági kockázatokat jelent.

A 6. fejezetben bemutatott módszerem azonban például nem igényli ez a központosítást, itt a járművek mozgáspályájának kiszámítása és irányítása egyedileg történik meg. Ez segítheti az automatizált funkciók elterjedését. Ha azonban az irányított jármű nem (csak) saját mérést, hanem V2V kapcsolatot használ, kihívásként vetődik fel az adatvédelem kérdése, ugyanis a járművek egymás között adatokat kell, hogy megosszanak a mozgásukról. Az értekezésben bemutatott ezen megoldásaim egyes részei vezetéstámogató funkcióként akár már a jelenben, illetve a közeljövőben is alkalmazhatóak lennének, lásd pl. [7].

**Az 5. fejezethez kapcsolódó kérdés**

A fejezetben autópálya-szakaszokról mutatott eredményeket. A fejezet címe ennél általánosabb, emiatt adódik a kérdés, hogy az itt bemutatott módszereket hogy lehet átvinni a városi környezetben előforduló problémák megoldására?

**Válasz**

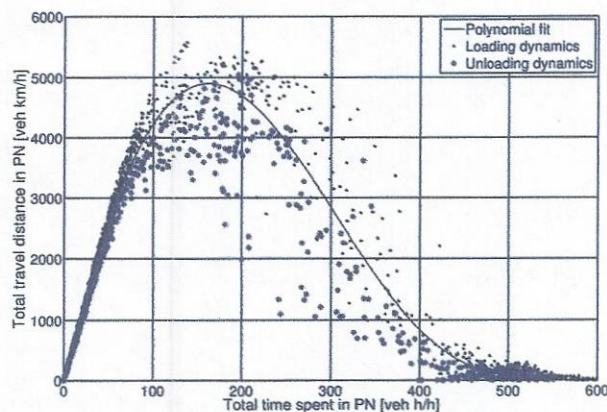
A bemutatott módszer alkalmas városi közlekedési környezetben történő analízisre és irányítástervezésre. Az általam alkalmazott makroszkopikus modellben szereplő fundamentális diagram paraméterezhető városi hálózatra nézve is, ld. [8]. Erre az 5. ábra mutat egy példát egy korábbi publikációból [9]. Ebben a tanulmányban az értekezésben közölt módszer alapján határoztam meg Sum-of-Squares (SoS) módszertannal a városi hálózatba a szabályozott kereszteszűdéseken beengedhető forgalom nagyságát.

**Végezetül, köszönöm még egyszer Professzor Kuczmann Miklós opponens munkáját és bírálatában megfogalmazott támogatását!**

Budapest, 2023.12.15.



Németh Balázs



5. ábra. Fundamentális diagram szemléltetése városi kontextusban [9].

## Hivatkozások

- [1] B. Németh and P. Gáspár, *Guaranteed Performances for Learning-Based Control Systems Using Robust Control Theory*. Cham: Springer International Publishing, 2021, pp. 109–142.
- [2] H. Demut, M. Hagan, and M. Beale, *Neural network design*. PWS Publishing Co, 1997.
- [3] S. Xu and L. Chen, „A novel approach for determining the optimal number of hidden layer neurons for fnn’s and its application in data mining,” *5th International Conference on Information Technology and Applications (ICITA 2008)*, pp. 683–686, 2008.
- [4] B. Németh, T. Hegedűs, and P. Gáspár, „Design framework for achieving guarantees with learning-based observers,” *Energies*, vol. 14, no. 8, 2021.
- [5] T. P. Lillicrap, J. J. Hunt, A. Pritzel, N. Heess, T. Erez, Y. Tassa, D. Silver, and D. Wierstra, „Continuous control with deep reinforcement learning,” *International Conference on Learning Representations*, 2016.
- [6] B. Németh and P. Gáspár, „Hierarchical motion control strategies for handling interactions of automated vehicles,” *Control Engineering Practice*, vol. 136, p. 105523, 2023.
- [7] B. Németh, M. Fazekas, Z. Bagoly, P. Gáspár, and O. Sename, „LPV-Based Control Design with Guarantees: a Case Study for Automated Steering of Road Vehicles,” in *2023 European Control Conference (ECC)*, 2023, pp. 1–6.
- [8] M. Keyvan-Ekbatani, A. Kouvelas, I. Papamichail, and M. Papageorgiou, „Exploiting the fundamental diagram of urban networks for feedback-based gating,” *Transportation Research Part B: Methodological*, vol. 46, no. 10, pp. 1393–1403, 2012.
- [9] B. Németh, A. Csikós, P. Gáspár, and I. Varga, „Analysis of the urban network gating problem: An SOS programming approach,” in *2015 European Control Conference (ECC)*, 2015, pp. 2652–2657.

