

Válasz Prof. Korondi Péter 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 Korondi Péter opponens munkáját, az elem tárt alapos és szakszerű bírálatát. A bírálatban feltett kérdésekre az alábbiakban szeretnék válaszolni.

Az 1. tézishez kapcsolódó első kérdés

Milyen esetekben lehet előnyös a javasolt módszer bizonyos szokásos MPC alapú módszerrel összevetve? Ez a kérdés akár nagyon messze vezethet, itt elegendő lenne néhány konkrét példát bemutatni.

Válasz

Köszönöm a bírálói kérdést, amely segít tisztázni az általam kidolgozott módszer különbözőségeit és előnyeit a Model Predictive Control (MPC) típusú megközelítésekhez képest.

Az értekezésben általam kidolgozott hierarchikus irányítás előnyös tulajdonságait az alábbi pontokban tudom összefoglalni:

- A kidolgozott struktúra egyes elemei között viszonylagosan kevés kapcsolat áll fenn, ami a tanulás alapú irányítási elem módosítását könnyen lehetővé teszi. A supervisor ugyanis ennek az irányítási elemnek csak a kimenetét használja, további jellemzőit nem. Ennélfogva, egy újratanítás esetén elegendő kicserélni a tanulásra épülő irányítási elemet, az irányítási kör többi része változatlanul maradhat.
- Ennek a tulajdonságnak egy következménye, hogy a módszer független a tanulásra épülő irányítási elem belső struktúrájától. Ennélfogva tetszőleges struktúrájú irányítási elem beépíthető ennek helyére, ami jelentős szabadságot biztosít az irányítás tervezésében. Például, a már gyakorlatban is bevált neurális hálókra épülő megoldások implementálhatók az általam kidolgozott irányítási megoldásokban a referencijel képzés, vagy a visszacsatolási hurok vonatkozásában. Az adat alapú MPC típusú irányítások azonban jellemzően egy zártabb, kevésbé rugalmas formalizmussal rendelkeznek az bennük megfogalmazott optimalizálásra nézve.
- A hierarchikus struktúra felépítésének egy további következménye, hogy a tanulásra épülő irányítási elem fizikailag szeparálható a supervisor és a robusztus irányítási elemektől. Például, az automatizált járművek vonatkozásában a supervisor-robusztus

irányítás kettős, amely alacsony számításigénnyel bír, elhelyezhető a jármű fedélzeten, míg a tanulásra épülő irányítási elem egy ettől független platformon, például felhőn. Azon irányítási megoldások, amelyek döntően egy optimalizálási feladat online megoldására épülnek, ezzel az előnyös tulajdonsággal jellemzően nem rendelkeznek.

- Végül egy további következmény, hogy az online számítást igénylő supervisor elem jelentősen alacsonyabb számításigényű, mint a hagyományos MPC, vagy a fejlettebb, adat-alapú (tanuló) MPC megoldások. Ennek oka, hogy a supervisor lényegesen kevesebb feladatot lát el, mint az MPC fő optimalizálási feladata. A járműmozgás dinamikája a robusztus irányítási elemekben került figyelembe vételre, a tanulási funkciók pedig a tanulásra épülő irányítási elemekben. Továbbá, a supervisorban nem szükséges egy hosszú horizonton történő optimalizálást végrehajtani, ugyanis a jövőbeli mozgásállapotokra való hatás a tanulási folyamatban figyelembe vételre kerül epizódokon történő futtatások, vagy előre adott minták által. Egy konkrét összehasonlítást készítettem az ún. Learning MPC (LMPC) megoldással, amelynél egy köridő minimalizálásra törekvő irányítás eredményét [1] vetettem össze a saját megoldás eredményével. Az analízis eredménye, hogy a cikkben közöl mintapéldát alapul véve az LMPC megoldással elért köridő 7.00 s volt, a saját megoldásé ehhez nagyon hasonló, 6.29 s. Egy számítási lépés átlagos ideje azonban az LMPC esetében 21.0 ms, míg a saját megoldás esetében 10.8 ms, amely jelentős időbeli nyereség az online számításidőt tekintve.

Az 1. tézishez kapcsolódó második kérdés

A felügyelő algoritmusban alkalmazott optimalizálás kiterjeszthető-e egy multi fidelity optimalizálással, amely a két ágens jellegének megbízhatóságát (felbontási pontosságát) is figyelembe veszi, különös tekintettel arra, hogy a gépi tanuláshoz mennyi és milyen minőségű adat áll rendelkezésre?

Válasz

Köszönöm a bírálóiban megfogalmazott kérdést és egyben a benne rejlő további kutatási lehetőséget a módszerem vonatkozásában!

A multi fidelity optimalizálás és ennek motivációja, a különböző forrásokból, ágensekből származó jelek megbízhatósága komplex rendszerek esetében különösen is fontos [2]. Azzal a problémával, hogy egy másik jármű által szolgáltatott, V2V kommunikációs forrásból érkező jelet nem feltétlenül fogad el a járműirányítás, az értekezésem 4. fejezetében érintőlegesen magam is foglalkozom. Az A.2 számú függelékben lévő példában a V2V kommunikációs csatornában jelentősebb időkésés állt be, ami miatt az automatizált járműnek az előzendő járműtől való távolság predikciója kevésbé pontos. Az általam bemutatott példában azonban a hangsúly azonban arra kerül, hogy az automatizált jármű ebben az esetben hogyan kezelje a biztonságkritikus közlekedési szituációt, ami a példa vonatkozásában azt jelenti, hogy az automatizált jármű a saját méréseire támaszkodik a másik járműtől származó jel helyett.

Az általam bemutatott járműirányítási struktúra multi fidelity optimalizálással való összekapcsolását a hierarchikus struktúra supervisor irányítási elemében látom megvalósíthatónak. Figyelembe véve, hogy ez az irányítási elem felelős a tanulásra épülő irányítási elemtől származó irányítójel javaslatok vizsgálatáért és esetleges elfogadásáért, a (2.31)-es optimalizálás multi fidelity szemléletű átalakítását tartom egy célravezető eljárásnak.

A 2. tézishez kapcsolódó első kérdés



Villamos hajtások energiafelhasználása esetén fontos kérdésnek tartom a visszatáplálást, amely számos technológiai kérdést vet fel. Hogyan vehető figyelembe a visszatáplálás, illetve az ezekhez kapcsolódó technológiai korlátozások?

Válasz

A visszatáplálás lehetősége közvetlenül nem lett figyelembe véve az általam bemutatott energia optimális sebességprofil tervezési eljárásban. Ennek oka, hogy olyan univerzális tervezési eljárást szerettem volna kidolgozni, amely a jármű hajtásláncának típusától függetlenül alkalmas a sebességprofil kiszámítására. A modularitást ennél a járműfunkciónál is kiemelten fontosnak tartottam: az energia optimális sebességprofil tervező algoritmus referencia sebesség jelet szolgáltat a járműirányítás számára és a hajtáslánc típusához való alkalmazkodás ennek feladata az irányítástervezés mögött lévő modell formalizálásán keresztül.

Mindazonáltal a visszatáplálás - amennyiben ez kiemelten fontos járműfunkció - a sebességprofil tervezésében is figyelembe vehető. Az eljárásom ugyanis hosszirányú erőkre épül fel, ahol a hajtás és a lassítás által igényelt energia csökkentésének igénye nincs elkülönítve. Visszatáplálás esetében a lassítás hatását más súlyokkal célszerű figyelembe venni, azaz a (3.5) formalizmusában ki kell emelni a visszatáplálás hatását.

Az értekezésben egy ponton azonban már jelenleg is figyelembe van véve közvetlenül is a visszatáplálás: az 5.1 fejezetben lévő (5.1) összefüggés kvázi-kinetikus energia esetében a $0 \leq \eta \leq 1$ paraméter ezt a funkciót tölti be: értéke minél nagyobb, annál nagyobb mértékben nyerhető vissza a keresztveződésben történő megálláshoz igényelt lassítási energia.

A 2. tézishez kapcsolódó második kérdés

A jármű miként tud alkalmazkodni nem csak az előtte haladó, hanem akár a mögötte/mellette/másik sávban haladó járműhöz?

Válasz

Az értekezés valóban nem tárgyalja ezt a kérdést, azonban az energia optimális mozgásprofil tervezés témájában írt [3] monográfiám 3. fejezete részletesen tárgyalja a kérdést.


Az általam kidolgozott megoldás lényege, hogy a (3.16) összefüggésben lévő R_1 súly értékét változtatom egy optimalizálási feladat keretein belül úgy, hogy a szabályozott jármű képes legyen alkalmazkodni a mögötte, vagy a másik sávban haladó jármű mozgásához. Ennek egy fontos lépése, hogy a másik jármű (follower vehicles) jövőbeli mozgását prediktálni szükséges (ld. az 1. ábra illusztrációját), és az irányított jármű (az ábrán: look-ahead vehicle) mozgását úgy kell megválasztani, hogy egy adott távolságon ne kerüljön belülré a követő jármű mozgása. Az R_1 érték csökkentése esetén az irányított jármű sebességprofilja a lehetséges sebességmaximum felé, növelése esetén pedig az energia optimális mozgásprofil felé mozdul el. A megoldásom hatása, hogy az irányított jármű a jövőbeli útvonalon lévő információk figyelembe vétele által képes a forgalmat kevésbé, vagy egyáltalán nem megzavaró mozgásprofil felvenni.

A 3. tézishez kapcsolódó első kérdés

A keresztveződésen túl más forgalmi helyzetben, pl. körforgalomra is alkalmazható-e a módszer?


Válasz

Igen, és ennek lehetőségét a 2. ábrán szemléltetem is. Az értekezés 6. fejezetében kidolgozott módszer alapja, hogy jármű-konfliktuspont kapcsolatokra építi fel a mozgást, amely kellően flexibilis alapot biztosít a különböző közlekedési szituációk kezeléséhez. A 2(a) ábra egy keresztveződésben egy jármű-jármű kapcsolatot mutat be - az értekezésben szereplő formulák erre az esetre nézve kerültek felírásra. A 2(b) ábra ennek átalakítását



1. ábra. Járműmozgás predikciójának szemléltetése.

mutatja be körforgalom esetére. A körforgalomba történő behajtás egy speciális kereszteződési esetként fogható fel (conflict point 1), a körforgalomban történő haladás pedig egy járműkövetési esetként, ahol az elől haladó jármű egy folyamatosan mozgó konfliktus pontot (conflict point 2) testesít meg.



(a) Kereszteződésben való haladás.

(b) Körforgalomban történő mozgás.

2. ábra. Közlekedési esetek illusztrációja.

A 3. tézishez kapcsolódó további kérdések

Sok esetben kereszteződések, különösen körforgalmak olyan közel vannak egymáshoz, hogy nem lehet azokat egymástól függetlenül vizsgálni. Mennyire terjeszthető ki a módszer ilyen esetekre is? A tanulási megoldások ennél a nagyobb léptékű problémánál hogyan alkalmazhatók?

Válasz

Városi környezetben valóban szükséges figyelembe venni az egyes közlekedési elemek egymás utáni jellegének hatását a jármű mozgására. Ennek kezelése jelenlegi kutatásaim tárgyát képezi.

A jelenlegi megközelítésmódban az értekezés 6. fejezetében lévő módszertan univer-



zális jellegét használom ki, azaz hogy a jármű-konfliktus pont kapcsolat sokfajta közlekedési helyzet leírására alkalmas a supervisor szintjén. Mintaképpen a ZalaZONE Autóipari Próbapálya Smart City pályarészének egy területét választottam ki, amelyben szabályozatlan és szabályozott kereszteződések, valamint körforgalom egyaránt előfordul, illetve szimulátorral virtuális járművek mozgását is modelleztem, amelyekkel szemben a biztonságos haladást biztosítani kell. Figyelembe véve a felépített környezeti modell komplexitását, a megerősítéssel tanítási folyamatnak a teljes epizódokon történő futtatása nagy számú virtuális járművek figyelembe vételével a gyakorlatban nem kivitelezhető. A tanítás gyakorlati megvalósítása során a városi pályának egy kisebb része, azaz egy körforgalom, egy kereszteződés és alacsonyabb számú jármű lett beleépítve a tanítás környezetébe. Az így megvalósított tanítás eredménye azonban a jelenlegi tapasztalataim szerint képes hatékonyan működni a nagyobb hálózaton, mert a tanítási célra használt környezeti modell jól reprezentálja a nagyobb hálózat legfontosabb tulajdonságait.

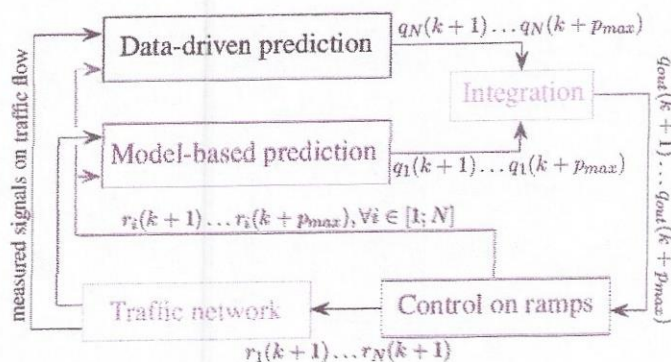
Az 4. tézishez kapcsolódó kérdés

Hogyan tehető hatékonyabbá a forgalom jövőbeli predikciója?

Válasz

Az általam kidolgozott adat-alapú megoldásokkal a forgalomáramlás nagyságának predikciója pontosítható a hagyományos, fundamentális diagram alapú forgalom modellekre épülő predikcióhoz képest. A kettő integrációjának vázlatát a 3. ábra mutatja meg [4]. Ebben a struktúrában a modell alapú predikció és az adat alapú predikció (az idézett publikációmban ez pace-regression eljárással készített ágens) az integrációs blokkban egyesül egy λ tényezőn keresztül.

Az integráció elve, hogy a lineáris pace regression rövid időtávon képes pontos predikciót biztosítani, hosszú távon (nagy időhorizonton) az illesztés lineáris jellege miatt azonban erre alkalmatlan. A fundamentális diagramra épülő modell azonban tartalmazza a folyamat nemlineáris jellegét, amely miatt nagyobb időhorizonton az erre épülő predikció pontosabb értéket szolgáltat. A λ tényező célja a két predikció integrálása úgy, hogy mindegyik predikciónak jellemzően az előnyei érvényesüljenek az időhorizonton, azaz az adat-alapú predikció a horizont elején, a modell-alapú predikció a horizont végén legyen nagyobb hatású. Az így létrejött predikció felhasználható a forgalom irányításában, azaz például a hálózatba befelé irányuló forgalom szabályozására (control on ramps).



3. ábra. A közlekedési folyamat irányításának vázlata.

Végezetül, köszönöm még egyszer Professzor Korondi Péter opponens munkáját és bírálatában megfogalmazott támogatását!

Budapest, 2023.12.15.



Németh Balázs

Hivatkozások

- [1] U. Rosolia and F. Borrelli, „Learning how to autonomously race a car: A predictive control approach,” *IEEE Transactions on Control Systems Technology*, vol. 28, no. 6, pp. 2713–2719, 2020.
- [2] P. Z. Korondi, M. Marchi, L. Parussini, and C. Poloni, „Multi-fidelity design optimization strategy under uncertainty with limited computational budget,” *Optimization and Engineering*, vol. 22, pp. 1039–1064, 2021.
- [3] P. Gáspár and B. Németh, *Predictive Cruise Control for Road Vehicles Using Road and Traffic Information*. Springer Verlag, 2019.
- [4] B. Németh, D. Fényes, Z. Bede, and P. Gáspár, „Optimal control design for traffic flow maximization based on data-driven modeling method,” *Energies*, vol. 15, no. 1, 2022.