

OPIS IZUMA**Područje izuma**

- 5 Izum se odnosi sustav upravljanja dinamikom električnog vozila koji uzima u obzir proračunana ograničenja za štićenje integriteta baterije vozila.

Opis

- 10 Općenito o elektroničkim sustavima za upravljanje dinamikom vozila:

U modernim automobilima često nalazimo elektroničke sigurnosne sustave koji su posljednjih godina postali sastavni dio automobilske industrije. To uključuje, na primjer, sustav protiv blokiranja kotača (ABS), kontrolu proklizavanja (TC), elektroničku kontrolu stabilnosti (ESC) i sustav aktivnog upravljanja. Osim ABS-a, TC-a i ESC-a, koji uglavnom imaju sigurnosne funkcije, aktivno se upravljanje često koristi za poboljšanje udobnosti vozača i/ili aspekta zabave u vožnji. Međutim, izvedba aktivnog upravljanja za poboljšanje upravljaljivosti i stabilnosti uvelike ovisi o bočnim silama pneumatika. U opsegu u kojem je bočna akceleracija relativno velika, a vozilo blizu granice upravljaljivosti, bočne sile postaju zasićene i tada aktivni sustavi upravljanja koji koriste isključivo bočne sile više ne mogu učinkovito kontrolirati vozilo. U takvim situacijama vozač može izgubiti kontrolu nad svojim vozilom zbog prevelikog kuta klizanja, zajedno s neravnotežom u trenutku skretanja vozila. Kako bi se prevladao ovaj problem, predložena je strategija koja koristi uzdužne sile guma za kontrolu bočnog kretanja vozila, poznata kao izravna kontrola momenta zakreta (DYC) (P. Lugner, Vehicle Dynamics of Modern Passenger Cars. Springer, 2019). DYC se može postići korištenjem elektrohidrauličkih kočnica ili takozvanim sustavom vektoriranja zakretnog momenta (TV), u kojem se zakretni moment zasebno raspoređuje na svaki kotač. Potonji se posljednjih godina široko koristi u električnim vozilima sa strukturom motora na kotačima, gdje se motorima može upravljati neovisno (M. Vignati, E. Sabbioni, and D. Tarsitano, "Torque vectoring control for IWM vehicles", International Journal of Vehicle Performance, vol. 2, no. 3, pp. 302–324, 2016; G. Park, K. Han, K. Nam, H. Kim, and S. B. Choi, "Torque vectoring algorithm of electronic-four-wheel drive vehicles for enhancement of cornering performance", IEEE Transactions on Vehicular Technology, vol. 69, no. 4, pp. 3668–3679, 2020).

- 30 Prediktivni TV algoritmi i problemi koji se pojavljuju:

Jedna od mogućih upravljačkih arhitektura za TV algoritam je modelsko prediktivno upravljanje (eng. *Model Predictive Control*, MPC). Osnovni koncept MPC-a je uporaba modela sustava za iterativno predviđanje njegova budućeg ponašanja i optimiziranje tog predviđanja odabirom najboljeg niza upravljačkih akcija. Prvi element niza se primjenjuje na sustav, i postupak se ponavlja. Glavni problem koji se rješava MPC-om je zadovoljavanje ograničenja (J. B. Rawlings and D. Q. Mayne, *Model predictive control: Theory and design*. Nob Hill Pub., 2009). Prediktivni regulator ima informacije o ograničenjima koja su uključena u njegov dizajn i tako pruža optimalnu raspodjelu momenata. Budući da su modeli dinamike vozila općenito nelinearni, uobičajeni pristup njihovom modeliranju je uporaba aproksimacije sustava zasnovane na linearnim vremenski promjenjivim (eng. *Linear Time Varying*, LTV) modelima (G. Palmieri, O. Barbarisi, S. Scala, and L. Glielmo, "A preliminary study to integrate LTV-MPC lateral vehicle dynamics control with a slip control", in Proceedings of the 48h IEEE Conference on Decision and Control (CDC) held jointly with 2009 28th Chinese Control Conference. IEEE, 2009, pp. 4625–4630).

U usporedbi s nelinearnim MPC-om (NMPC), LTV-MPC dovodi do kraćeg vremena računanja, ali NMPC točnije predviđa buduće ponašanje vozila (E. Mikuláš, M. Gulan, and G. Takács, "Model predictive torque vectoring control for a formula student electric racing car," in 2018 European Control Conference (ECC). IEEE, 2018, pp. 581–588; E. Siampis, E. Velenis, S. Gariuolo, and S. Longo, "A real-time nonlinear model predictive control strategy for stabilization of an electric vehicle at the limits of handling", IEEE Transactions on Control Systems Technology, vol. 26, no. 6, pp. 1982–1994, 2017).

50 Dobro je poznato da nelinearni modeli, kada se koriste u MPC-u, mogu dovesti do nekonveksnih optimizacijskih problema s više lokalnih optimuma. Prilikom rješavanja takvih problema teško je dati jamstva globalne optimalnosti rješenja. Dodatno, nelinearni optimizacijski problem teže je riješiti u ograničenom vremenu. Stoga je poželjna upotreba linearnih prikaza za predviđanje budućeg ponašanja sustava, iako to može dovesti do značajnih pogrešaka u predviđanju, posebno za veće predikcijske horizonte (S. Gros, et al. "From linear to nonlinear MPC: bridging the gap via the real-time iteration." International Journal of Control 93.1 (2020): pp. 62-80).

Temeljna ideja izuma:

60 Umjesto povećanja brzine nelinearnog MPC-a, moguće je povećati točnost linearног MPC-a. Predmetnim izumom se predlaže korištenje transformacije koja podiže dimenzionalnost originalnog prostora stanja (npr. Koopmanovog operatora) za identifikaciju linearног modela vozila i razvoj linearног MPC TV algoritma koristeći taj model. Osnovna

ideja je podići (ili ugraditi) nelinearnu dinamiku u prostor više dimenzije kroz niz nelinearnih transformacija. Ako su ove transformacije pravilno odabrane, evolucija sustava u prostoru više dimenzije (u teoriji beskonačno dimenzionalni prostor) bit će (približno) linearna (B. O. Koopman, "Hamiltonian systems and transformation in Hilbert space", Proceedings of the National Academy of Sciences of the United States of America, vol. 17, no. 5, p. 315, 1931).

5 Dodatno, tip ograničenja unutar algoritma pogodan je za ograničavanje potrošnje energije iz baterijskog paketa. Također je ključno da predmetni izum omogućava bolje iskorištavanje performansi vozila budući da je samim načinom dinamičkog zadavanja promjenjivih ograničenja duž predikcijskog horizonta sustav manje konzervativan i može na znatno učinkovitije u odnosu na navedeno prethodno stanje tehnike odrediti u kojem će koraku koristiti koliko snage. Drugim riječima, ideja predmetnog izuma je ograničiti ukupnu raspoloživu snagu i pustiti MPC algoritmu da odabere koliko će snage potrošiti u određenom koraku. To se uvelike razlikuje od postojećih rješenja koja koriste konstantna ograničenja snage (jednaka u svakom koraku predikcije), što je veoma konzervativno i nije primjereni za sve stilove vožnje, posebice u slučajevima kada je poželjno postići kompromis između perfomansi potrebnih za sportsku vožnju koju omogućavaju sportski automobili i integriteta baterije.

10 Primjeri mogućih algoritama za konkretizaciju izuma (ne ograničavaju izum, moguće su i druge metode):

15 Budući da je u praksi nemoguće raditi s beskonačno dimenzionalnim operatorima, istražene su razne numeričke metode kako bi se stvorila aproksimacija konačnih dimenzija. Standardni pristupi uključuju dinamičku modalnu dekompoziciju (DMD) i proširenu dinamičku modalnu dekompoziciju (EDMD) (M.O. Williams, I. G. Kevrekidis, and C. W. Rowley, "A data–driven approximation of the Koopman operator: Extending dynamic mode decomposition", Journal of Nonlinear Science 25.6 (2015): pp. 1307-1346), generaliziranu Laplaceovu analizu (GLA) (ponekad se naziva i metoda vlastitih funkcija) (M. Korda, and I. Mezić, "Optimal construction of Koopman eigenfunctions for prediction and control", IEEE Transactions on Automatic Control 65.12 (2020): pp. 5114-5129) i duboku dinamičku modalnu dekompoziciju (Deep-DMD) (E. Yeung, K. Soumya, and N. Hudas, "Learning deep neural network representations for Koopman operators of nonlinear dynamical systems", 2019 American Control Conference (ACC). IEEE, 2019), DMD i EDMD temelje se na rječniku osmotrivačih funkcija koji određuje korisnik, GLA koristi vlastite vrijednosti sustava i vlastite vektore za stvaranje vlastitih funkcija umjesto osmotrivačih, dok Deep-DMD koristi duboke neuronske mreže kako bi naučila i nelinearne transformacije i Koopmanov operator. EDMD i Deep-DMD najprikladnije su za praktičnu primjenu zbog svoje fleksibilnosti i izražajnosti. EDMD je računski učinkovita, ali pati od prokletstva dimenzionalnosti i zahtijeva da izlazi sustava linearno ovise o ulazima, dok se Deep-DMD dobro prilagodava višim dimenzijama i zahtijeva malo apriornog znanja, ali zahtijeva mnoštvo podataka (uzoraka) i računski je veoma složena.

20 Istraživanje sličnih metoda u polju dinamike vozila:

25 Na polju identifikacije dinamike vozila, Koopmanov operator korišten je u (V. Cibulka, T. Haniš, and M. Hromčík, "Data-driven identification of vehicle dynamics using Koopman operator", in Proceedings of the 2019 22nd International Conference on Process Control, PC 2019. IEEE, 2019, pp. 167–172) za identifikaciju jednostavnog bicikl modela vozila. Autori su primijenili dvije različite metode za odabir baznih funkcija: EDMD i metodu vlastitih funkcija. Isti pristup korišten je kasnije u (Cibulka, Vít, et al. "Model Predictive Control of a Vehicle using Koopman Operator". IFAC-PapersOnLine, 2020, 53.2: 4228-4233) za dizajn sustava upravljanja. Primjena Koopmanovog operatora za upravljanje dinamikom vozila može se naći i u (Y. Xiao, X. Zhang, X. Xu, X. Liu, and J. Liu, "A deep learning framework based on Koopman operator for data-driven modeling of vehicle dynamics", arXiv preprint arXiv:2007.02219, 2020) i Xiao, Yongqian. "DDK: A Deep Koopman Approach for Dynamics Modeling and Trajectory Tracking of Autonomous Vehicles". arXiv preprint arXiv:2110.14700, 2021) gdje je implementiran Deep-DMD. Predloženi model tada je iskorišten za razvoj linearne MPC-a koji upravlja zakretom volana i zaklopkom motora te je testiran koristeći model autonomnog vozila u simulacijskom okruženju visoke vjernosti. Prvi rezultati vezani za upravljanje dinamikom vozila pri čemu se direktno upravlja silama klizanjima kotača dani su u Švec, Marko; Ileš, Šandor; Matuško, Jadranko. "Model predictive control of vehicle dynamics based on the Koopman operator with extended dynamic mode decomposition". In: 2021 22nd IEEE International Conference on Industrial Technology (ICIT). IEEE, 2021. p. 68-73 i Švec, Marko; Ileš, Šandor; Matuško, Jadranko. "Predictive approach to torque vectoring based on the Koopman operator". In: 2021 European Control Conference (ECC). IEEE, 2021. p. 1341-1346.

30 Predmetni izum predstavlja značajan iskorak u odnosu na prethodno navedena rješenja stoga što u potpunosti generalizira njihove mogućnosti i iznenađujuće omogućava primjenu na stvarnim vozilima jer, za razliku od tih pristupa, predmetni izum omogućava direktno upravljanje momentima kotača i zakretnom volanu bez ograničavajućih pretpostavki koje spominju radovi iz prethodnog stanja tehnike (kao što su savršeno poznavanje zakreta volana vozila, rad vozila u linearnom području guma).

35 Detaljan opis izvodenja izuma

40 Kratki opis slike

Slika1. Model vozila s dvije trake

Slika 2. Dijagram sustava

Slika 3. Usporedba upravljanih stanja vozila između LTV-MPC i Koopman MPC algoritma

Slika 4. Usporedba kuteva klizanja vozila između LTV-MPC i Koopman MPC algoritma

1. NELINEARNI MODEL VOZILA

Oznake $\bullet \in \{f, r\}$ predstavljaju vrijednosti na prednjim, tj. stražnjim kotačima vozila, dok $\bullet \in \{l, r\}$ predstavljaju vrijednosti na lijevoj, tj. desnoj strani. Korišteni model primjer je tzv. modela s dvije trake (eng. two track) i prikazan je na Slici 1. Prijenos mase je zanemaren. Jednadžbe modela su:

$$mv_x = m\dot{\theta}_z v_y + F_{flx} + F_{frx} + F_{rlx} + F_{rrx}, \quad (2-1)$$

$$mv_y = -m\dot{\theta}_z v_x + F_{fly} + F_{fry} + F_{rly} + F_{rry}, \quad (2-2)$$

$$J_z \ddot{\theta}_z = l_f(F_{fly} + F_{fry}) - l_r(F_{rly} + F_{rry}) + w(-F_{flx} + F_{frx} - F_{rlx} + F_{rrx}), \quad (2-3)$$

$$J_w \dot{\omega}_{\star} = T_{\star} - r_w F_{\star x}^w. \quad (2-4)$$

U (2-1) – (2-4) v_x je longitudinalna brzina, v_y lateralna brzina, $\dot{\theta}_z$ kutna brzina automobile, a ω_{\star} kutne brzine pojedinih kotača. Momenti pogonskih kotača označeni su s T_{\star} . Parametri vozila su masa m , moment inercije oko z osi J_z , udaljenost centra mase od prednje osovine l_f , udaljenost centra mase od stražnje osovine l_r i polovica širine razmaka između lijevih i desnih kotača vozila w . Parametri kotača su radijus r_w i moment inercije J_w . Longitudinalne i lateralne sile koje djeluju na vozilo proračunate su iz sila kotača i kuta zakreta kotača δ_f kao

$$F_{f*x}^w = F_{f*x}^w \cos(\delta_f) - F_{f*y}^w \sin(\delta_f) \quad (2-5)$$

$$F_{f*y}^w = F_{f*x}^w \sin(\delta_f) + F_{f*y}^w \cos(\delta_f) \quad (2-6)$$

Općenite jednadžbe nelinearnog modela pneumatika mogu se zapisati kao

$$F_{\star x}^w = f_x(\alpha_{\star}, s_{\star x}, \mu_{\star}, F_{\star z}), \quad (2-7)$$

$$F_{\star y}^w = f_y(\alpha_{\star}, s_{\star x}, \mu_{\star}, F_{\star z}), \quad (2-8)$$

što naglašava činjenicu da sile pneumatika ovise o vertikalnoj sili F_{f*z} , koeficijentu trenja podloge μ_{\star} , koeficijentu longitudinalnog klizanja

$$s_{\star x} = \frac{r_w \omega_{\star}}{v_{\star x}^w} - 1, v_{\star x}^w \neq 0, \quad (2-9)$$

i kutu klizanja

$$\alpha_{\star} = \arctan\left(\frac{v_{\star y}^w}{v_{\star x}^w}\right). \quad (2-10)$$

Linearne brzine kotača u koordinatnom sustavu kotača jednake su

$$v_{f*x}^w = v_{f*x} \cos \delta_f + v_{f*y} \sin \delta_f, v_{r*x}^w = v_{r*x}, \quad (2-11)$$

$$v_{f*y}^w = -v_{f*x} \sin \delta_f + v_{f*y} \cos \delta_f, v_{r*y}^w = v_{r*y}, \quad (2-12)$$

pri čemu su brzine u koordinatnom sustavu vozila

$$v_{flx} = v_x - w\dot{\theta}_z, v_{fly} = v_y + l_f\dot{\theta}_z, \quad (2-13)$$

$$v_{frx} = v_x + w\dot{\theta}_z, v_{fry} = v_y + l_f\dot{\theta}_z, \quad (2-14)$$

$$v_{rlx} = v_x - w\dot{\theta}_z, v_{rly} = v_y - l_r\dot{\theta}_z, \quad (2-15)$$

$$v_{rrx} = v_x + w\dot{\theta}_z, v_{rry} = v_y - l_r\dot{\theta}_z. \quad (2-16)$$

Vertikalne sile koje djeluju na kotače (uz zanemaren prijenos mase) dane su kao

$$F_{f*z} = \frac{mgl_r}{2(l_f + l_r)}, F_{r*z} = \frac{mgl_f}{2(l_f + l_r)}. \quad (2-17)$$

2. ZAPIS MODELA VOZILA U PROŠIRENOM PROSTORU STANJA

Nelinearni model vozila (2-1)-(2-17) moguće je sažeto zapisati kao

$$\dot{x}(t) = f(x(t), u(t)), \quad (3-1)$$

$$y(t) = g(x(t)) \quad (3-2)$$

pri čemu je vektor stanja jednak $x(t) = [v_y, v_x, \dot{\theta}_z, \omega_{fl}, \omega_{fr}, \omega_{rl}, \omega_{rr}]^T$ a upravljačka veličina jednaka $u = [\delta_f, T_{fl}, T_{fr}, T_{rl}, T_{rr}]^T$. Kontinuirani nelinearni model (3-1) – (3-2) može se diskretizirati i izraziti kao

$$x_{k+1} = f_d(x_k, u_k), \quad (3-3)$$

$$u_k = u_{k-1} + \Delta u_k, \quad (3-4)$$

$$y_k = g(x_k), \quad (3-5)$$

gdje je $x_k \in \mathbb{R}^n$ trenutno stanje sustava, $x_{k+1} \in \mathbb{R}^n$ sljedeće stanje sustava, a $u_k \in \mathbb{R}^m$ trenutni iznos upravljačke veličine. Definirajmo prošireno stanje dobiveno konkateniranjem postojećeg vektora stanja i upravljačkog vektora kao $\chi_k = [x_k \ u_k]^T$. Evolucija proširenog stanja može se odrediti sljedećim izrazom:

$$\chi_{k+1} = h(\chi_k) = \begin{bmatrix} f_d(x_k, u_o) \\ Su_k \end{bmatrix}, \quad (3-6)$$

pri čemu je S operator pomaka $Su_k = u_{k+1}$, Koopmanov operator K povezan s dinamikom (23-5) definiran je kao

$$\psi(\chi_{k+1}) = K\psi(\chi_k) = \psi(h(\chi_k)), \quad (3-7)$$

za svako preslikavanje $\psi: \mathbb{R}^n \times \mathbb{R}^m \rightarrow \mathbb{R}$ koje je invarijantno pod djelovanjem Koopmanovog operatara. To se preslikavanje često naziva osmotrivom funkcijom (engl. *observable*).

Proširena modalna dinamička dekompozicija:

Proširena modalna dinamička dekompozicija (engl. Extended Dynamic Mode Decomposition; EDMD) jedan je od algoritama kojima je moguće dobiti numerički opis Koopmanovog operatara, tj. linearne aproksimacije nelinearnog sustava u prostoru stanja veće dimenzije. Aproksimacija sustava određuje se rješavajući sljedeći optimizacijski problem:

$$\min_{A, B} \sum_{j=1}^{N_K} \left\| \phi(x_{k+1}^j) - A\phi(x_k^j) - Bu_k^j \right\|_2^2, \quad (3-8)$$

gdje je $z_k^j = \phi(x_k^j) = [\phi_1(x_k^j) \dots \phi_{n_\phi}(x_k^j)]^T \in \mathbb{R}^{n_\phi}$ vektor baznih funkcija (drugi naziv za osmotrive funkcije u ovom slučaju), a u_k^j upravljački vektor za j -ti uzorak. Stanja x_k i x_{k+1} dobivena su ili sakupljanjem podataka sa stvarnog sustava ili simuliranjem nelinearnog modela sustava, dok je N_K broj sakupljenih uzoraka. Na jednak način moguće je dobiti model koji povezuje izlaz y_t i stanja proširenog sustava kao

$$\min_{A, B} \sum_{j=1}^{N_K} \left\| y_t^j - C\phi(x_t^j) \right\|_2^2. \quad (3-9)$$

Konačan linearni model dobiven opisanom metodom moguće je zapisati na sljedeći način:

$$z_{k+1} = Az_k + Bu_k \quad (3-10)$$

$$y_k = Cz_k. \quad (3-11)$$

Bazne funkcije su nelinearne i biraju se „po osjećaju“ pa shodno tome kvaliteta predikcije u ovome slučaju uvelike ovisi o iskustvu inženjera koji ih definira. Postoje i razne druge metode identifikacije sustava i konceptualno nije bitno koja se koristi sve dok je razina predikcijske pogreške u odnosu na nelinearni model, tj. stvarni sustav dovoljno malena.

Također je bitno uvidjeti prednost koju nam ova ideja donosi, a to je da proizvoljni nelinearni model (3-1) – (3-2) opišemo linearnim modelom (3-10)–(3-11). Osim toga, moguće je kreirati preslikavanje koje će kao ulaz primati i neke paremetre poput trenja podloge (ili neke druge) i na temelju toga imati cijeli skup tako razvijenih linearnih modela, pri čemu svaki vrijedi za određene vrijednosti tih parametara. Za razliku od ostalih metoda identifikacije linearnih modela, koje ovise o radnoj točki i vrijede u njenoj neposrednoj blizini, ovaj linearan model vrijedi u cijelom skupu iz kojega su uzorkovani podaci korišteni za identifikaciju. Naravno, uz pretpostavku dobrog odabira baznih/osmotrivoih funkcija i numerički stabilnog algoritma za rješavanje optimizacijskih problema (3-8) – (3-9), ali to ovisi implementaciji i specifičnoj primjeni.

U nastavku dokumenta dan je primjer koji potvrđuje da je navedeni pristup izvediv.

3. MPC ALGORITAM KOJI KORISTI LINEARNI MODEL U PROŠIRENOM PROSTORU STANJA

Modelsко предiktivно upravljanje je način upravljanja gdje se model sustava koristi kako bi se predvidjelo buduće vladanje sustava na konačnom predikcijskom horizontu. U svakom koraku rješava se optimizacijski problem kako bi se dobila optimalna upravljačka sekvenca koja osigurava optimalno vladanje sustava na horizontu. Prvi element iz optimalne upravljačke sekvence se primjenjuje i cijeli postupak se ponavlja. Najveća prednost ovog načina upravljanja je što se na 10 sustavan način uzima u obzir dinamički model sustava, kao i njegova ograničenja te se omogućava postizanje kompromisa između često suprotstavljenih zahtjeva kroz formiranje ispravne funkcije cilja.

Formulacija MPC regulatora je

$$\min_{U_t, E_t} J(x_t, Y_t^{ref}, U_t, E_t) \quad (4-1)$$

$$\text{tako da } z_{k+1} = Az_k + Bu_k, \quad (4-2)$$

$$y_k = Cz_k, \quad (4-3)$$

$$F_k u_k \leq f_k, k = t, \dots, t + N - 1, \quad (4-4)$$

$$G_k \Delta u_k \leq g_k, k = t, \dots, t + N - 1, \quad (4-5)$$

$$H_k y_{k+1} \leq h_k + \varepsilon_k, k = t + 1, \dots, t + N - 1, \quad (4-6)$$

$$\varepsilon_k \geq 0, k = t + 1, \dots, t + N - 1, \quad (4-7)$$

$$z_t = \psi(x(t)), \quad (4-8)$$

pri čemu je $U_t = [u_t, u_{t+1}, \dots, u_{t+N-1}]$ niz upravljačkih vektora, ε_t predstavlja proširnu varijablu (engl. *slack variable*) u trenutku t , a $E_t = [\varepsilon_t, \varepsilon_{t+1}, \dots, \varepsilon_{t+N-1}]$ predstavlja niz proširnih varijabli preko cijelog predikcijskog horizontalnog Y_t^{ref} je sekvenca referentnih vrijednosti.

Pojedini dijelovi optimizacijskog problema (4-1)- (4-7) su kako slijedi:

- Funkcija cijene (engl. *cost function*) J predstavlja cilj optimizacije, tj. ono što optimizacijski algoritam minimizira. Ona može biti izražena na razne načine, a jedan od primjera je
- $J = Q_1(v_{xk} - v_{xk}^{ref})^2 + Q_2(\dot{\theta}_{zk} - \dot{\theta}_{zk}^{ref})^2 + \Delta u_k^T R \Delta u_k + p \varepsilon_k^T \varepsilon_k$
- Navedena funkcija penalizira odstupanje vozila od referentne longitudinalne brzine v_x i referentne kutne brzine $\dot{\theta}_z$ minimizirajući pritom promjene upravljačkog signala Δu_k i proširne varijable ε_k
- Jednadžbe dinamike sustava (4-1) i (4-2) opisane su modelom dobivenim koristeći metodu aproksimacije iz poglavlja 3
- Ograničenja upravljačkog signala (4-3) i promjene upravljačkog signala (4-4) osiguravaju da navedene veličine nikada ne premaše zadane granice. Ograničenja su dana kao politopski skupovi (matrične nejednadžbe) i podrazumijeva se da su promjenjivi u vremenu (tj. u svakome koraku optimizacije mogu biti različiti). Ovo je upravo dio algoritma pomoću kojega osiguravamo da će biti zadovoljena ograničenja zadana od strane sustava koji kontrolira stanje baterijskog paketa. Nadzorni algoritam baterijskog paketa proslijedi ograničenja u politopskom obliku, što upravo odgovara pretpostavci, tj obliku ograničenja unutar danog algoritma. Ograničenja su dana dinamički preko predikcijskog horizonta. To znači da u svakom koraku predikcije raspoloživa snaga ovisi o tome što je odlučeno u prethodnom koraku, tj da je ograničena ukupna snaga duž cijelog horizonta. Time se osigurava da iznosi momenata kotača zadani od strane algoritma koji upravlja vozilom budu zadani na način koji štiti dinamička stanja baterijskog paketa ukoliko to zahtijeva nadzorni sustav baterijskog paketa, a da je istovremeno algoritam u mogućnosti iskoristiti snagu za upravljanje dinamičkim ponašanjem vozila bolje nego što bi to bio slučaj s konstantnim ograničenjima.
- Ograničenja izlaza sustava (4-5) osiguravaju da stanja sustava budu unutar željenog skupa kad god je to moguće. Naime, za razliku od upravljačkih veličina koje su strogo ograničene budući da ih algoritam odabire, stanja vozila ne ovise samo o algoritmu, već i o okolini i raznim poremećajima. Stoga nije uvijek moguće osigurati da stanja poštuju zadana ograničenja. Kršenje tih ograničenja omogućeno je korištenjem proširnih varijabli ε_k koje forsiramo da budu što je manje moguće (penalizacija istih u funkciji cijene), ali također želimo da budu nenegativne (4-6). Ova ograničenja također mogu biti vremenski promjenjiva.
- Proširenje prostora stanja (4-7) kao što je objašnjeno u poglavlju 3.

MPC regulator radi kako je opisano sljedećim koracima:

1. Mjere se ili estimiraju stanja vozila
2. Rješava se optimizacijski problem (4-1) – (4-7) koji kao rješenje daje sekvencu optimalnih upravljačkih akcija.

3. Prvi vektor iz optimalne sekvence odabire se kao stvarna upravljačka akcija i primjenjuje na vozilo
 4. Povratak na korak 1 i izvršavanje istih koraka iznova.

4. DIJAGRAM KOJI OPISUJE RAD PREDLOŽENOG SUSTAVA

Dijagram sustava prikazan je na Slici 2. Tipičan put signala za vrijeme rada sustava opisan je sljedećim koracima:

0. Vozilo se nalazi u nekom dinamičkom stanju u trenutku t .
1. Mjere se fizičalne veličine vozila i baterije (koje je moguće izmjeriti).
2. Različitim estimacijskim algoritmima određuju se stanja vozila x_t i stanja baterijskog paketa x_{bt} na temelju poznatih matematičkih modela i dostupnih mjerjenih veličina.
3. Na temelju estimacije stanja vozila x_t , kreira se novo stanje u prostoru više dimenzije z_t , koristeći prethodno definirano preslikavanje čiji je opis dan u poglavlju 3.
4. Dano prošireno stanje vozila z_t i ograničenja snage baterije ulaze kao parametri u prediktivni regulator opisan u poglavlju 3. Prediktivni regulator na temelju tih podataka i na temelju poznatog modela vozila računa optimalnu raspodjelu momenata na kotačima tako da se zadovolji dinamičko ponašanje zadano referentnim signalima i samim dizajnom algoritma, ali da se pritom poštuju sva ograničenja koja sustavu nalaže estimator ograničenja baterijskog paketa (BMS).
5. Nakon što je dobivena optimalna sekvenca upravljačkih varijabli, prva od njih primjenjuje se na pogonske kotače vozila.
6. Povratak na točku 0. Cijeli postupak kreće ponovo.

5. DOKAZ FUNKCIONALNOSTI SUSTAVA

Ovdje su dani grafovi i tablica koji pokazuju kako je jedna verzija implementacije ovog algoritma superiorna implementaciji koja koristi LTV model vozila, dok istovremeno omogućava kreaciju iste klase optimizacijskog problema (kvadratni problem s linearnim ograničenjima) i rješavanje koristeći isti optimizacijski paket (engl. *solver*). Sustav je testiran koristeći modificiranu verziju tzv. *Sine with dwell* manevra (F. Bruzelius, "A theoretical justification of the sine with dwell manoeuvre," Vehicle System Dynamics, vol. 53, no. 4, pp. 493-505, 2015).

	LTV MPC	Koopman MPC
Funkcija cijene	2.374e8	1.8622e8
Funkcija cijene (%)	100 %	78.44 %
Prosječno trajanje optimizacije u jednom koraku (sekunde)	0.1413	0.024
Prosječno trajanje optimizacije u jednom koraku (%)	100 %	16.99 %

TABLICA 1. Odnos iznosa funkcija gubitaka i prosječnih trajanja simulacije za postojeći sustav (LTV-MPC) i jednu od mogućih verzija izuma (Koopman MPC)

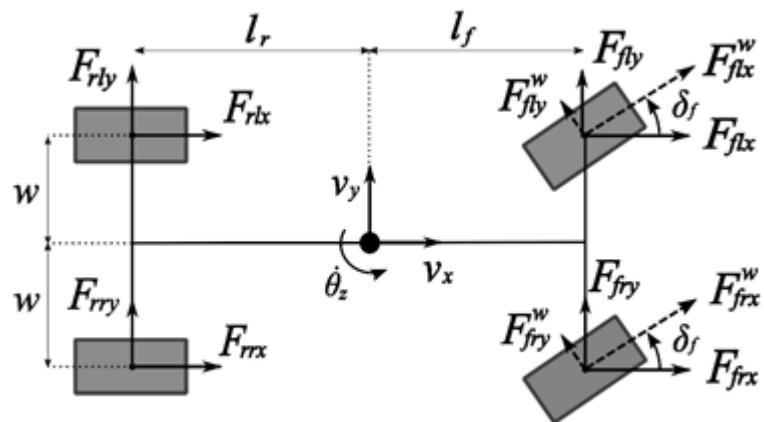
Tablica 1. pokazuje kako predloženi sustav daje bitno bolje rezultate u usporedbi s jednim od standardnih postojećih pristupa, što se najbolje vidi promatranjem relativnih vrijednosti funkcija cijene i prosječnog trajanja koraka optimizacije, gdje predmetni izum rezultira poboljšanjem od otprilike 21 % u slučaju funkcije cijene i čak 83 % bržim izvođenjem algoritma. Simulacije su provedene na istom računalu, koristeći isti simulacijski model vozila, s jednakim funkcijama cilja, ograničenjima sustava i koristeći isti rješavač (engl. *solver*) za rješavanje zadanog optimizacijskog problema.

Iste rezultate potkrepljuju i grafovi na Slici 3 i 4. Primjer je dan za vozilo kojemu kut volana određuje vanjski sustav (npr. algoritam autonomne vožnje ili vozač). Vidi se kako je odziv svih veličina skoro jednak, s razlikom da LTV-MPC lošije prati referencu longitudinalne brzine i vozilo nepotrebno ubrzava. Oba algoritma (Koopman MPC i LTV-MPC) moguće je podesiti da rade bolje i to ovisi o specifičnoj primjeni i iskustvu projektanta. Međutim, zbog numeričkih karakteristika, to je mnogo teže učiniti za LTV-MPC nego ako se koristi model sustava predložen predmetnim izumom. Drugim riječima, osim što donosi poboljšanje performansi vozila i ubrzava izvođenje algoritma, predmetni izum također olakšava podešavanje parametara upravljačkog algoritma zbog povećane numeričke stabilnosti u odnosu na LTV-MPC s kojim je uspoređen.

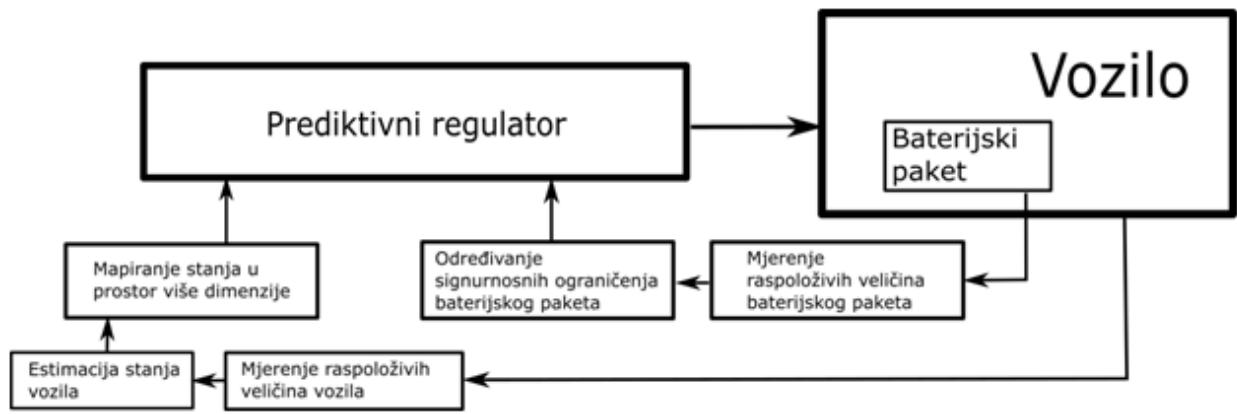
PATENTNI ZAHTJEVI

1. Računalno implementirani postupak za upravljanje dinamikom električnog vozila, **naznačen time**, da obuhvaća sljedeće korake:
 - a) određivanje dinamičkog stanja vozila u trenutku t ;
 - b) mjerjenje fizičalnih veličina vozila i baterije;

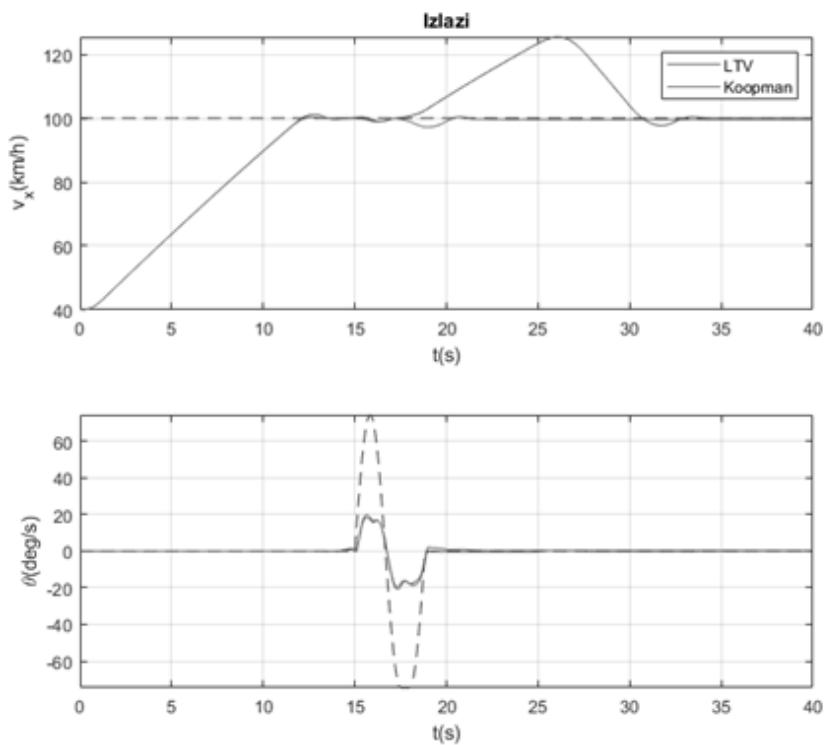
- c) određivanje stanja vozila x_t i stanja baterijskog paketa x_{bt} putem estimacijskih algoritama;
- d) kreiranje novog stanja u prostoru više dimenzije z_t , na temelju estimacije stanja vozila x_t , uporabom nelinearnog preslikavanja, nakon čega se model sustava u proširenom prostoru stanja koristi za predikciju ponašanja vozila u prediktivnom regulatoru;;
- 5 e) korištenje ograničenja snage baterije u prediktivnom regulatoru koji upravlja dinamikom vozila gdje su ograničenja definirana duž predikcijskog horizonta, pri čemu je prediktivnom regulatoru prepuštena odluka koji postotak te snage će koristiti u određenom koraku predikcije;
- f) korištenje prediktivnog regulatora za dobivanje optimalne raspodjele momenata na kotačima tako da se zadovolji dinamičko ponašanje zadano referentnim signalima i dizajnom algoritma uz poštivanje svih ograničenja koja sustavu nalaže estimator ograničenja baterijskog paketa;
- 10 g) izračunavanje sekvene upravljačkih varijabli;
- h) korištenje prve od dobivenih varijabli u koraku g) za primjenu na pogonske kotače vozila;
- i) povratak na korak a).



Slika 1

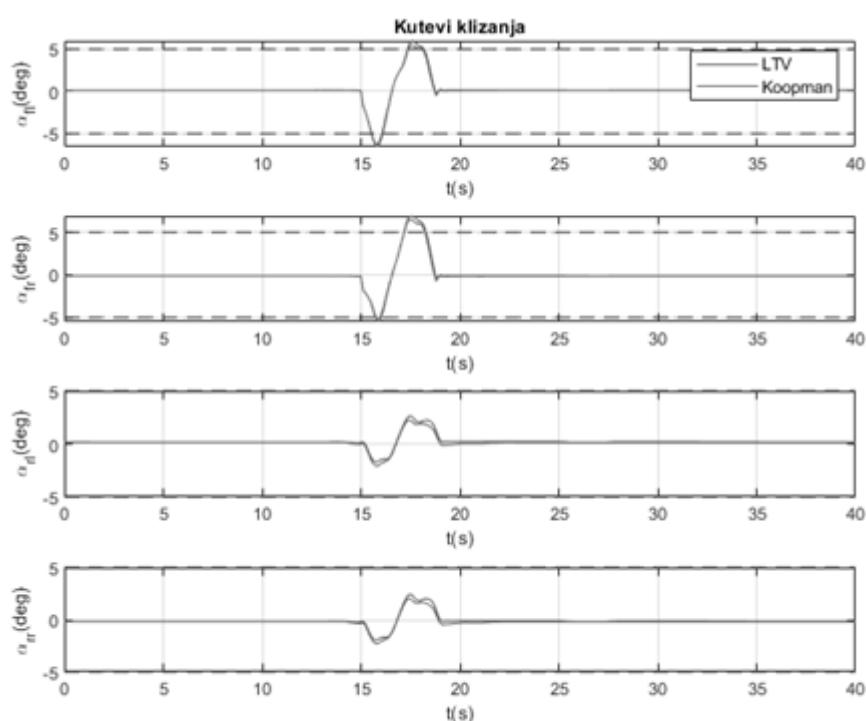


Slika 2



Slika 3

HR P20220282 B1



Slika 4