AVTOMATLASHTIRILGAN TIZIMLARNI IDENTIFIKATSIYALASH VA BOSHQARISH JARAYONLARINI SUN'IY INTELLEKT YORDAMIDA MODELLASHTIRISH

Mo'ydinov Dostonbek Mirkomil o'g'li
Namangan davlat texnika universiteti "Axborot tizimlari va texnologiyalari" kafedrasi stajor o'qituvchisi
kelajak054@gmail.com

ANNOTATSIYA

Maqolada avtomatlashtirilgan tizimlarni identifikatsiyalash va boshqarish jarayonlarini sun'iy intellekt vositalari yordamida modellashtirishning uslubiy asoslari ko'rib chiqiladi. Tadqiqotning maqsadi nochiziqli dinamik ob'yektni chiziqli ARX modeli hamda ARX va ko'p qatlamli perseptron (MLP) asosidagi gibrid model yordamida identifikatsiyalash aniqligini taqqoslash, shuningdek, olingan modelga tayanuvchi prognozlovchi boshqaruvni (NN-MPC) an'anaviy PID rostlagich bilan solishtirishdan iborat. Metodologiya sifatida o'lik zona, quruq ishqalanish va og'irlik momentiga ega doimiy tok dvigateli asosidagi pozitsion servotizimning kompyuter modeli qo'llanildi; modellar uch xil o'lchash shovqini darajasida va turli hajmdagi o'quv tanlanmalarida sinovdan o'tkazildi. Natijalarga ko'ra, past shovqinda gibrid model 25 qadamli bashoratda ARX modeliga nisbatan xatolikni 10,5 % ga kamaytirdi, biroq shovqin oshganda bu ustunlik barqaror bo'lmadi, modelning ustunligi uchun kamida 4000 ta o'quv namunasi talab etildi. Simulyatsiyada NN-MPC aniqlik bo'yicha PID rostlagichdan ustun kelmadi. Olingan natijalar sun'iy intellekt usullarini qo'llashdan oldin ma'lumot hajmi, o'lchash shovqini va hisoblash xarajatlarini baholash zarurligini ko'rsatadi. Maqola natijalari texnika yo'nalishidagi talabalarni tayyorlashda laboratoriya mashg'uloti sifatida foydalanilishi mumkin.

Kalit so‘zlar: sun’iy intellekt, identifikatsiya, avtomatlashtirilgan tizim, neyron tarmoq, ARX, prognozlovchi boshqaruv, PID rostlagich, modellashtirish.

ABSTRACT

The article examines methodological foundations for modelling the identification and control of automated systems using artificial intelligence. The aim is to compare the accuracy of a linear ARX model and a hybrid model that combines ARX with a multilayer perceptron (MLP) when identifying a nonlinear dynamic plant, and to compare model-based predictive control built on the identified model (NN-MPC) with a conventional PID controller. A computer model of a DC-motor position servo with dead zone, Coulomb friction and gravity torque was used. The models were tested at three measurement-noise levels and with different training-set sizes. At low noise the hybrid model reduced the 25-step-ahead prediction error by 10,5 % relative to the ARX model, but this advantage was not stable as noise increased, and at least 4000 training samples were needed. In the simulations NN-MPC did not outperform the PID controller in tracking accuracy. The results show that data volume, measurement noise and computational cost should be assessed before applying artificial intelligence methods. They can be used as a laboratory exercise in training engineering students.

Keywords: artificial intelligence, system identification, automated system, neural network, ARX, model predictive control, PID controller, modelling.

KIRISH

Zamonaviy ishlab chiqarish, energetika, transport va robototexnika tizimlarida avtomatlashtirish darajasi ortib borishi bilan boshqarish ob’yektlarining matematik modellariga qo‘yiladigan talablar ham kuchaymoqda. Boshqarish tizimining sifati, eng avvalo, ob’yekt dinamikasi qanchalik to‘g‘ri tavsiflanganiga bog‘liq. Real ob’yektlarda esa ishqalanish, o‘lik zona, to‘yinish, yuklama o‘zgarishi va eskirish kabi nochiziqli hamda vaqt bo‘yicha o‘zgaruvchan omillar mavjud bo‘lib, ularni faqat birlamchi fizik qonunlar asosida aniq tavsiflash ko‘pincha

murakkab yoki iqtisodiy jihatdan maqsadga muvofiq bo‘lmaydi (Ljung, 1999; Nelles, 2001).

Identifikatsiya, ya’ni ob’yektning kirish va chiqish signallarini o‘lchash natijalariga tayanib uning matematik modelini qurish usullari bu muammoning klassik yechimi hisoblanadi. So‘nggi o‘n yilliklarda sun’iy neyron tarmoqlar va ma’lumotlarga asoslangan usullar nochiziqli identifikatsiyada keng qo‘llanila boshlandi (Narendra & Parthasarathy, 1990; Sjöberg va boshq., 1995; Brunton va boshq., 2016). Biroq amaliyotda neyron tarmoq asosidagi modellar har doim chiziqli modellardan afzal bo‘lavermaydi: ularning samaradorligi o‘quv ma’lumotlarining hajmi va sifatiga, o‘lchash shovqiniga hamda modelning rekursiv bashorat paytidagi barqarorligiga bog‘liq. Bu holat modellarni faqat bir qadamli bashorat bo‘yicha emas, balki ko‘p qadamli bashorat va yopiq konturli boshqaruv sharoitida ham baholash zarurligini ko‘rsatadi.

Tadqiqotning **maqsadi** nochiziqli avtomatlashtirilgan ob’yektni identifikatsiyalash va boshqarish jarayonlarini sun’iy intellekt vositalari yordamida modellashtirish hamda chiziqli va neyron tarmoq asosidagi yondashuvlarni takrorlanuvchan hisoblash tajribasida taqqoslashdan iborat. Maqsadga erishish uchun quyidagi vazifalar belgilandi: (1) nochiziqli pozitsion servotizimning kompyuter modelini yaratish; (2) ARX va gibrid ARX+MLP modellarini identifikatsiyalash aniqligini turli shovqin darajasida va o‘quv tanlanma hajmida baholash; (3) identifikatsiyalangan modelga tayanuvchi prognozlovchi boshqaruvni (NN-MPC) model asosida sozlangan PID rostlagich bilan solishtirish; (4) natijalarning o‘quv jarayonida qo‘llanilish imkoniyatlarini aniqlash.

Maqolaning ilmiy-amaliy ahamiyati shundaki, unda sun’iy intellekt usullarining afzalliklari bilan bir qatorda cheklovlari ham real hisoblash natijalari asosida ochiq ko‘rsatiladi. Bu esa kelajak muhandis va informatika o‘qituvchilarida modelni mezonli baholash, ya’ni “eng murakkab model eng yaxshi model” degan tasavvurdan voz kechish malakasini shakllantirishga xizmat qiladi.

ADABIYOTLAR TAHLILI VA METODOLOGIYA

Adabiyotlar tahlili

Tizimlar identifikatsiyasi nazariyasining asosiy qoidalari Ljung (1999) tomonidan bayon etilgan bo‘lib, unda parametrik modellar (ARX, ARMAX, Box–Jenkins), eng kichik kvadratlar usuli va modelni validatsiya qilish tamoyillari tizimlashtirilgan. Nochiziqli identifikatsiya bo‘yicha Sjöberg va boshq. (1995) “qora quti” modellarining yagona nazariy tavsifini taklif etgan; Hornik va boshq. (1989) esa ko‘p qatlamli to‘g‘ri tarqalish tarmoqlarining universal approksimatsiya xususiyatini asoslagan. Dinamik tizimlarni neyron tarmoq yordamida identifikatsiyalash va boshqarish g‘oyasini Narendra va Parthasarathy (1990) hamda Chen va boshq. (1990) ishlarida NARX tuzilmasi misolida ko‘rish mumkin.

Boshqarishda PID rostlagichlar sanoatda eng keng tarqalgan bo‘lib qolmoqda va ularning sozlash usullari Åström va Hägglund (2006) asarida batafsil yoritilgan. Prognozlovchi boshqaruv (MPC) esa ob’yekt modeli yordamida cheklovlarni hisobga olgan holda optimal boshqarish ketma-ketligini hisoblash imkonini beradi (Camacho & Bordons, 2007). Ma’lumotlarga asoslangan modellarni MPC bilan birlashtirish bo‘yicha zamonaviy sharh Hewing va boshq. (2020) tomonidan berilgan bo‘lib, unda o‘rganilgan modelning noaniqligi xavfsizlik va barqarorlik nuqtai nazaridan asosiy muammo sifatida ko‘rsatilgan. Mazkur adabiyotlar tahlili shuni ko‘rsatadiki, neyron tarmoq asosidagi identifikatsiya va boshqaruvning real afzalliklari hamda cheklovlarini bir xil sharoitda, bir xil o‘lchovlar bilan taqqoslovchi sodda, takrorlanuvchan hisoblash tajribalariga ehtiyoj saqlanib qolmoqda. Ushbu tadqiqot aynan shu ehtiyojga qaratilgan.

Tadqiqot ob’yekti va uning matematik modeli

Tadqiqot ob’yekti sifatida doimiy tok dvigateli yuritadigan, yelkali yuklamali pozitsion servotizim tanlandi. Ob’yekt dinamikasi quyidagi tenglamalar bilan tavsiflanadi:

$$d\theta/dt = \omega, \quad (1)$$

$$J \cdot d\omega/dt = K \cdot u_d - b \cdot \omega - F_c \cdot \tanh(\omega/\varepsilon) - g \cdot \sin\theta, \quad (2)$$

$$u_d = u - \mathrm{sat}(u; -u_0, u_0), \quad u = \mathrm{clip}(u_{buyruq}, -5, 5), \qquad (3)$$

bu yerda θ – burilish burchagi (rad); ω – burchak tezligi; u – dvigatelga berilgan kuchlanish (V); J – inersiya momenti; b – yopishqoq ishqalanish koeffitsiyenti; K – kuchaytirish koeffitsiyenti; F_c – quruq (Kulon) ishqalanish; g – og‘irlik momenti koeffitsiyenti; u_0 – o‘lik zona chegarasi. Ob’yektning o‘lchanadigan chiqishi burchak θ bo‘lib, unga o‘rtacha kvadratik og‘ishi σ bo‘lgan Gauss shovqini qo‘shiladi. Tenglamalar Eyler usuli bilan (har bir o‘lchash davrida 4 ta ichki qadam) sonli integrallandi. Model parametrlari 1-jadvalda keltirilgan; o‘lchov birliklari shartli, ya’ni tadqiqotda muayyan jismoniy qurilma emas, tipik tartibdagi parametrlarga ega kompyuter modeli ishlatilgan.

1-jadval. Ob’yekt modelining parametrlari

Parametr	**Belgi**	**Qiymati**
Inersiya momenti	J	0,05
Yopishqoq ishqalanish	b	0,10
Kuchaytirish koeffitsiyenti	K	1,0
Quruq ishqalanish	F_c	0,40
Og‘irlik momenti koeffitsiyenti	g	1,20
Ishqalanish silliqlash parametri	ε	0,05
O‘lik zona (kuchlanish bo‘yicha)	u_0	±0,4 V
Kuchlanish chegarasi (to‘yinish)	u_{max}	±5 V
O‘lchash davri	T_s	0,02 s
O‘lchash shovqini (o‘rtacha kvadratik og‘ish)	σ	0,002; 0,01; 0,05 rad

Identifikatsiya modellari

Identifikatsiya uchun o‘quv ma’lumotlari ob’yektga ochiq konturda, qadamma-qadam o‘zgaruvchi tasodifiy kirish signali berish orqali olindi: amplituda

[−4; 4] V oralig‘ida bir tekis taqsimlangan, har bir sath 10–50 o‘lchash davri (0,2–1,0 s) davomida ushlab turildi. O‘quv tanlanmasi 8000 ta (160 s), validatsiya tanlanmasi esa mustaqil ravishda olingan 4000 ta (80 s) namunadan iborat bo‘ldi. Modellar sifati validatsiya tanlanmasida, shovqinsiz “haqiqiy” chiqishga nisbatan baholandi.

1-model (ARX). Chiziqli ARX(2,2) modeli quyidagi ko‘rinishda tanlandi:

$$\hat{y}(k) = \theta_1 \cdot y(k-1) + \theta_2 \cdot y(k-2) + \theta_3 \cdot u(k-1) + \theta_4 \cdot u(k-2), \quad (4)$$

bunda parametrlar eng kichik kvadratlar usuli bilan topildi: $\theta = (\Phi^T\Phi)^{-1}\Phi^T Y$ (Ljung, 1999).

2-model (gibrid ARX+MLP). Ikkinchi modelda ARX qismi asosiy chiziqli dinamikani, ko‘p qatlamli perseptron esa ARX qoldig‘ini, ya’ni chiziqli model tushuntira olmagan nochiziqli qismni o‘rganadi:

$$\hat{y}(k) = \hat{y}_{ARX}(k) + s \cdot N(\psi(k)), \quad \psi(k) = [y(k-1 \ldots k-3), u(k-1 \ldots k-3)]^T, \quad (5)$$

bu yerda $N(\cdot)$ – 6–16–8–1 tuzilmali, yashirin qatlamlarida giperbolik tangens faollashtirish funksiyasiga ega neyron tarmoq; s – qoldiqni me’yorlashtirish koeffitsiyenti. Tarmoq Adam algoritmi (Kingma & Ba, 2015) bilan o‘qitildi, L2-regulyarizatsiya ($\alpha = 0{,}01$), erta to‘xtatish (validatsiya ulushi 15 %) va kirish regressorlariga standart og‘ishning 2 % miqdoridagi shovqin qo‘shish (kirish shovqini bilan regulyarizatsiya) qo‘llandi. Hisoblashlar Python, NumPy, SciPy va scikit-learn kutubxonalarida bajarildi (Harris va boshq., 2020; Pedregosa va boshq., 2011; Virtanen va boshq., 2020). Dastlabki sinovlarda sof NARX-MLP modeli (ARX qismisiz) bir qadamli bashoratda yaxshi natija bergan bo‘lsa-da, rekursiv bashoratda beqaror bo‘lib qoldi; shu sababli gibrid tuzilma tanlandi.

Baholash mezoni. Ob’yekt integrallovchi xususiyatga ega bo‘lgani uchun uzoq erkin (ochiq konturli) simulyatsiyada xatolik fizik jihatdan to‘planib boradi. Shu sababli modellar k qadamli bashorat bo‘yicha (k = 1, 10 va 25, ya’ni 0,02; 0,2 va 0,5 s) o‘rtacha kvadratik xatolik (RMSE) orqali baholandi. Taqqoslash uchun

“doimiylik” bazaviy bashorati ham keltirildi, unda chiqish oxirgi o‘lchangan qiymatda o‘zgarmaydi deb hisoblanadi.

Boshqarish algoritmlari

PID rostlagich. Klassik yondashuvga muvofiq PID rostlagich ob’yektning ARX modeli bo‘yicha sozlandi: koeffitsiyentlar Nelder–Mid usuli bilan modeldagi og‘ishlarning mutlaq qiymati integrali va boshqaruv energiyasidan iborat mezonni minimallashtirish orqali topildi. Natijada $K_p = 18{,}5$, $K_i = 0{,}014$, $K_d = 1{,}46$ qiymatlari olindi. Integral qismda to‘yinishga qarshi (anti-windup) shartli integrallash qo‘llandi.

NN-MPC. Prognozlovchi boshqaruvda har bir o‘lchash davrida identifikatsiyalangan gibrid model yordamida $H = 15$ qadamga bashorat qilinib, quyidagi mezon minimallashtirildi:

$$J = \Sigma_{h=1}^{H} [\, (r(k+h) - \hat{y}(k+h) - d(k))^2 + \lambda \cdot (u(k+h-1) - u(k+h-2))^2 \,], \qquad (6)$$

bunda r – berilgan qiymat (kelgusi o‘zgarishlar oldindan ma’lum deb olingan), $\lambda = 0{,}001$, d(k) – modelning siljishini hisobga oluvchi tuzatish: $d(k) = 0{,}95 \cdot d(k-1) + 0{,}05 \cdot [y(k) - \hat{y}(k|k-1)]$. Optimallashtirish tasodifiy qidiruv (random shooting) yordamida amalga oshirildi: har bir davrda $M = 400$ ta nomzod ketma-ketlik tekshirildi (yarmi $[-5; 5]$ V oralig‘idagi doimiy sathlar, yarmi esa oldingi yechimning siljitilgan nusxasiga $\sigma = 1{,}5$ V shovqin qo‘shilgan variantlar). Birinchi elementi ob’yektga berildi, qolganlari keyingi davrda boshlang‘ich yaqinlashish sifatida ishlatildi.

Boshqaruv tajribasi. Berilgan qiymat 12 s davomida quyidagicha o‘zgartirildi: boshida 0 rad, 1-sekundda 1 rad, 6-sekundda −0,5 rad. Ikkala rostlagich uch sharoitda sinaldi: (a) nominal parametrlar; (b) inersiya momenti 50 % ga oshirilgan ($J = 0{,}075$); (c) quruq ishqalanish 1,5 marta, og‘irlik momenti 1,3 marta oshirilgan ($F_c = 0{,}60$; $g = 1{,}56$). Modellar (b) va (c) holatlarda qayta o‘qitilmadi, ya’ni bu tajriba parametrlar o‘zgarishiga chidamlilikni tekshiradi. Sifat ko‘rsatkichlari sifatida og‘ishlarning mutlaq qiymati integrali (IAE), turg‘un

holatdagi xatolik, maksimal o‘ta rostlash (overshoot) va boshqaruv energiyasi ($\int u^2 dt$) olindi.

NATIJALAR

Identifikatsiya natijalari

2-jadvalda modellarning validatsiya tanlanmasidagi bashorat xatoliklari keltirilgan. Bazaviy “doimiylik” bashorati 25 qadamda 5,20 rad xatolik beradi; past shovqinda (σ = 0,002 rad) ikkala model ham bu ko‘rsatkichni taxminan 5 marta kamaytiradi, σ = 0,05 rad da esa kamayish taxminan 2 martani tashkil etadi. Eng past shovqin darajasida (σ = 0,002 rad) gibrid model ARX modeliga nisbatan 10 qadamli bashoratda xatolikni 6,8 %, 25 qadamli bashoratda esa 10,5 % ga kamaytirdi. Shovqin σ = 0,01 rad bo‘lganda esa gibrid model 25 qadamda ARXdan 4,5 % yomonroq natija berdi, σ = 0,05 rad da yana 6,7 % ustunlikka erishdi. Demak, neyron tarmoq qismining foydasi shovqin darajasiga monoton bog‘liq bo‘lmadi va bu farqlar kichik, shu sababli ularni ehtiyotkorlik bilan talqin qilish lozim.

2-jadval. Bashoratning o‘rtacha kvadratik xatoligi (RMSE, rad) o‘lchash shovqini darajasiga bog‘liqligi

Shovqin σ, rad	Model	k = 1	k = 10	k = 25
0,002	Doimiylik bazasi	0,219	2,168	5,205
	ARX(2,2)	0,008	0,290	1,085
	Gibrid ARX+MLP	0,008	0,270	0,971
0,010	Doimiylik bazasi	0,219	2,168	5,205
	ARX(2,2)	0,023	0,319	1,122
	Gibrid ARX+MLP	0,023	0,328	1,173
0,050	Doimiylik bazasi	0,224	2,168	5,204
	ARX(2,2)	0,101	1,054	2,755
	Gibrid ARX+MLP	0,100	0,993	2,570

1-diagrammada σ = 0,002 rad sharoitida validatsiya tanlanmasining bir qismi uchun 25 qadamli (0,5 s) bashoratlar ob'yektning haqiqiy chiqishi bilan taqqoslangan. Ikkala model ham umumiy dinamikani aniq takrorlaydi; farq asosan tezlik yo'nalishi o'zgargan paytlarda, ya'ni ishqalanish va o'lik zona ta'siri kuchli bo'lgan joylarda namoyon bo'ladi.

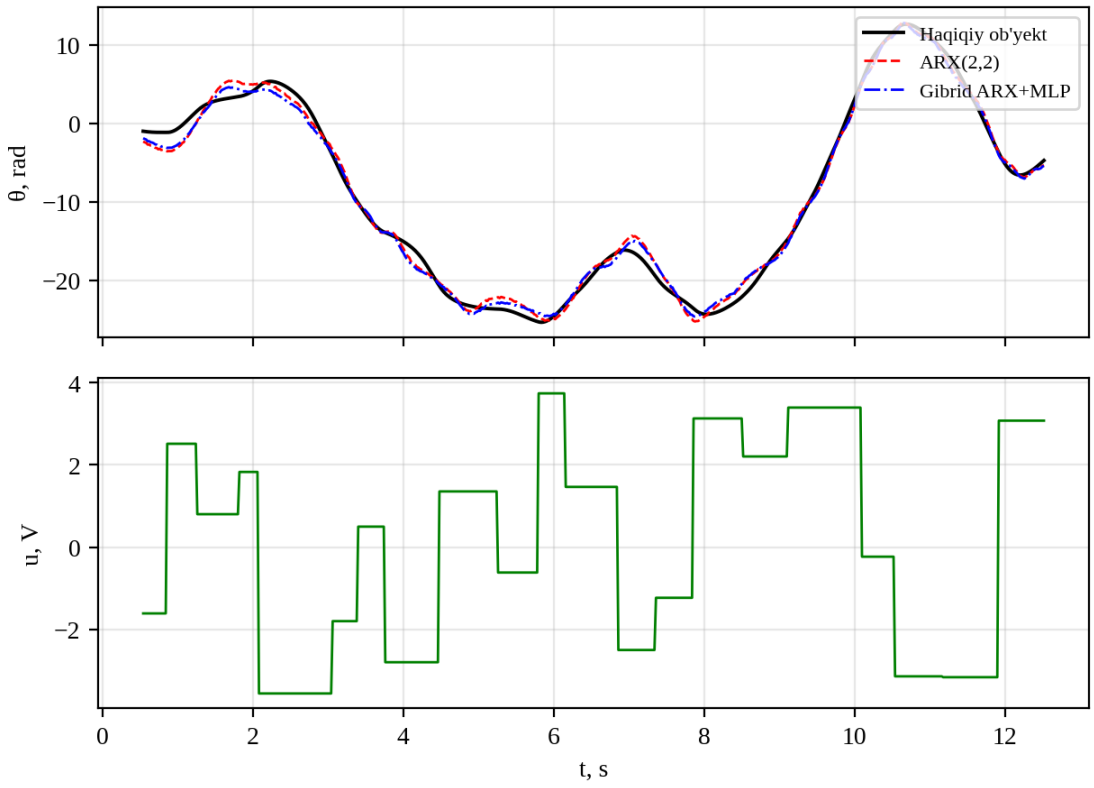

1-diagramma. 25 qadamli bashorat natijalari (σ = 0,002 rad): yuqorida – chiqish burchagi, pastda – kirish kuchlanishi

O'quv tanlanma hajmining ta'siri 3-jadvalda ko'rsatilgan. 500 ta namunada gibrid model deyarli foydasiz bo'lib (25 qadamda 4,24 rad, bazaviy 5,20 rad), 4000 ta namunaga qadar xatolik keskin kamaydi (0,98 rad); undan keyin 8000 tagacha deyarli o'zgarmadi (0,97 rad). Taqqoslash uchun 8000 ta namunada o'qitilgan ARX modelining 25 qadamli xatoligi 1,08 rad ni tashkil etdi. Shunday qilib, gibrid modelning chiziqli modeldan ustunligi uchun kamida taxminan 4000 ta namuna (80 s o'lchash) zarur bo'ldi.

3-jadval. Gibrid modelning bashorat xatoligi (RMSE, rad) o‘quv tanlanmasi hajmiga bog‘liqligi (σ = 0,002 rad)

O‘quv namunalari soni	k = 1	k = 10	k = 25
500	0,021	0,938	4,237
1000	0,011	0,477	2,043
2000	0,010	0,402	1,707
4000	0,008	0,272	0,978
8000	0,008	0,270	0,971
ARX (8000 namuna)	0,008	0,290	1,085

Boshqaruv natijalari

2-diagrammada nominal sharoitda ikkala rostlagichning o‘tish jarayonlari ko‘rsatilgan. Har ikki rostlagich ham berilgan qiymatga yaqinlashdi, biroq o‘lik zona va quruq ishqalanish tufayli to‘liq nol xatolikka erishilmadi, ya’ni 2 % li chegaradagi turg‘unlashish vaqtiga ikkala holatda ham erishilmadi. 4-jadvaldan ko‘rinadiki, nominal sharoitda PID rostlagichning IAE ko‘rsatkichi 0,99, NN-MPC niki 1,08, ya’ni PID taxminan 9 % aniqroq; turg‘un holatdagi xatolik ham PID da kichikroq (0,062 rad va 0,137 rad). Boshqaruv energiyasi bo‘yicha farq deyarli yo‘q (23,2 va 23,5).

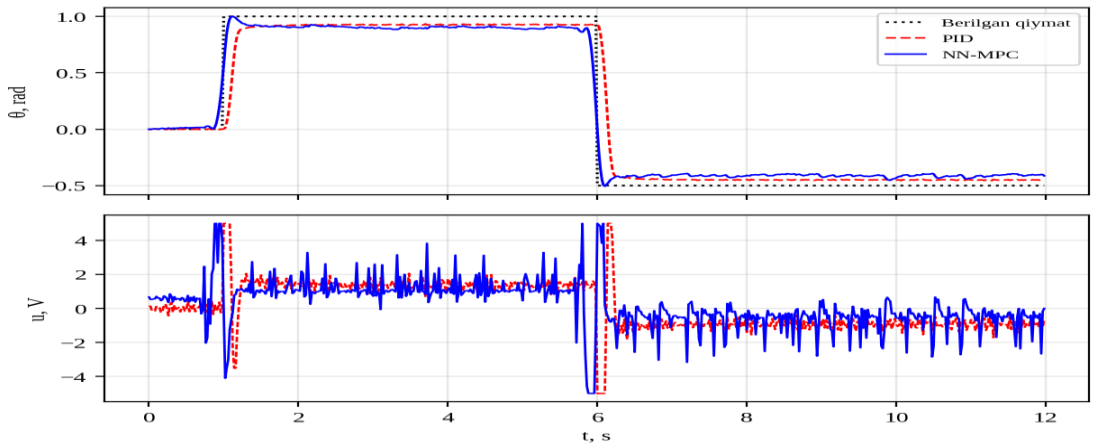

2-diagramma. Nominal sharoitda PID va NN-MPC rostlagichlarining o‘tish jarayonlari: yuqorida – burchak, pastda – boshqaruv signali

NN-MPC ning o‘tish jarayoni vizual jihatdan tezroq boshlanadi, buning bir sababi prognoz gorizontida berilgan qiymatning o‘zgarishi oldindan ma’lum deb olinganidir (1-sekunddagi o‘zgarishga rostlagich undan sal oldin reaksiya bildiradi). Shuningdek, tasodifiy qidiruvga asoslangan optimallashtirish natijasida NN-MPC ning boshqaruv signali PID nikiga qaraganda ancha “shovqinli” bo‘lib, bu amalda aktuatorning eskirishiga olib kelishi mumkin.

4-jadval. Boshqaruv sifati ko‘rsatkichlari

Sharoit	**Rostlagich**	**IAE**	**Turg‘un xatolik, rad**	**Maks. o‘ta rostlash, %**	**Energiya $\int u^2 dt$**
Nominal	PID	0,988	0,062	0,0	23,2
	NN-MPC	1,080	0,137	0,9	23,5
J + 50 %	PID	0,985	0,062	3,8	23,9
	NN-MPC	1,112	0,127	7,8	25,6
F_c ×1,5; g ×1,3	PID	1,123	0,073	0,0	29,7
	NN-MPC	1,179	0,142	0,0	27,7

Parametrlar o‘zgargan sharoitlarda ham tartib saqlanib qoldi. Inersiya momenti 50 % ga oshganda PID ning IAE ko‘rsatkichi 0,99, NN-MPC niki 1,11 bo‘ldi; maksimal o‘ta rostlash mos ravishda 3,8 % va 7,8 % ni tashkil etdi. Ishqalanish va og‘irlik momenti oshirilganda IAE 1,12 va 1,18 bo‘ldi. Ikkala algoritm ham modelni qayta sozlamasdan barqaror ishladi, parametrlar o‘zgarishi sifatni sezilarli darajada yomonlashtirmadi (3-diagramma).

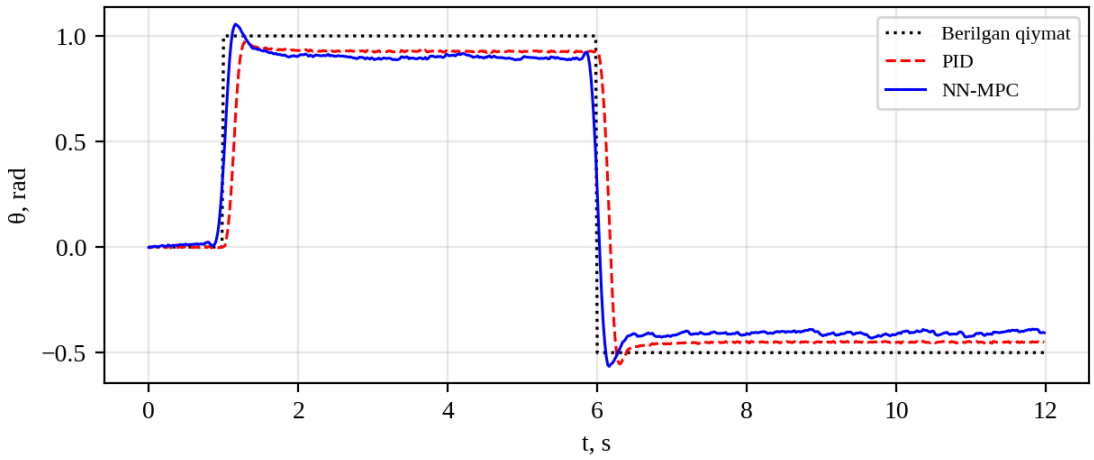

3-diagramma. Inersiya momenti 50 % ga oshirilgan sharoitda o‘tish jarayonlari

MUHOKAMA

Natijalarning talqini

Olingan natijalar sun’iy intellekt usullarini avtomatlashtirishda qo‘llash bo‘yicha ikki muhim xulosani asoslaydi. Birinchidan, neyron tarmoq qismi nochiziqli dinamikaning bir qismini (ishqalanish, o‘lik zona ta’siri) real ravishda tutib oladi, biroq bu ustunlik kam namuna va yuqori shovqin sharoitida yo‘qoladi. Bu holat neyron tarmoq usullarining ma’lumot hajmiga sezgir ekanligi haqidagi umumiy kuzatuvlarga mos keladi (Sjöberg va boshq., 1995; Hewing va boshq., 2020). Ikkinchidan, identifikatsiya aniqligining ma’lum darajada oshishi avtomatik ravishda boshqaruv sifatining oshishiga olib kelmadi: PID rostlagich ARX modeli asosida sozlangan bo‘lsa ham, NN-MPC dan biroz aniqroq ishladi. Buning mumkin bo‘lgan sabablari: bashorat xatoligining farqi kichikligi, MPC ning tasodifiy qidiruv bilan taqribiy optimallashtirilishi hamda turg‘un holatdagi xatolikka asosiy hissani ob’yektning o‘lik zonasi qo‘shishi (ikkala rostlagichda ham bor).

Shuningdek, dastlabki sinovlarda sof neyron tarmoqli NARX modelining rekursiv bashoratda beqaror bo‘lishi, hamda chiziqli ARX qismni saqlab qolgan gibrid tuzilma barqaror ishlashi amaliy jihatdan muhim kuzatuv hisoblanadi: neyron tarmoq faqat chiziqli model tushuntira olmagan qismni o‘rgansa, model kam ma’lumot sharoitida ham xavfsizroq bo‘ladi. Bu natija Hewing va boshq. (2020)

tomonidan ta’kidlangan o‘rganilgan modelning noaniqligi muammosi bilan mos keladi.

Tadqiqotning cheklovlari

Tadqiqot natijalarini talqin qilishda quyidagi cheklovlarni hisobga olish zarur. Birinchidan, barcha natijalar kompyuter simulyatsiyasi asosida olingan, haqiqiy jismoniy qurilmada eksperiment o‘tkazilmagan; ob’yekt modeli bitta, parametrlar tanlovi muallif tomonidan belgilangan. Ikkinchidan, shovqin va tanlanma hajmi bo‘yicha natijalar bitta tasodifiy o‘quv-validatsiya bo‘linmasi uchun olingan, takroriy tajribalar bo‘yicha statistik ishonch oralig‘i hisoblanmagan, shu sababli kichik farqlar (masalan, 10 % atrofidagi) statistik ahamiyatli deb tasdiqlanmaydi. Uchinchidan, neyron tarmoq giperparametrlari to‘liq optimallashtirilmagan, NN-MPC da esa tasodifiy qidiruv qo‘llanilgan; gradientga asoslangan yoki ketma-ket kvadratik dasturlash usullari natijani o‘zgartirishi mumkin. To‘rtinchidan, NN-MPC har bir davrda 400×15 ta model chaqiruvini talab qiladi, bu esa PID ga nisbatan hisoblash yuklamasini sezilarli oshiradi va ichki tizimlarda (mikrokontrollerlarda) qo‘llanilishini cheklaydi.

Pedagogik ahamiyati

Tajriba tuzilmasi o‘quv jarayonida laboratoriya mashg‘uloti sifatida ishlatilishi mumkin: talabalar bir xil ob’yektda chiziqli va nochiziqli modellarni qurib, tanlanma hajmi, shovqin va bashorat gorizonti ta’sirini mustaqil o‘rganadi, so‘ngra identifikatsiyalangan modelni boshqaruvda sinab, “yaxshi model” va “yaxshi boshqaruv” tushunchalari har doim ham mos kelmasligini amalda ko‘radi. Bunday yondashuv bo‘lajak informatika va texnologiya o‘qituvchilarida ma’lumotlar bilan ishlash, modelni tanqidiy baholash va natijani ochiq talqin qilish kompetensiyalarini rivojlantiradi. Hisoblash eksperimenti xavfsiz va arzon bo‘lgani uchun uni maktab va oliy ta’lim darajasida robototexnika hamda sun’iy intellekt kurslariga moslashtirish mumkin.

XULOSA

Tadqiqot natijalariga ko‘ra, nochiziqli pozitsion servotizimni identifikatsiyalashda ARX asosiga ko‘p qatlamli perseptron tuzatishini qo‘shuvchi gibrid model past shovqin sharoitida ($\sigma = 0{,}002$ rad) 25 qadamli bashoratda chiziqli ARX modeliga nisbatan xatolikni 10,5 % ga kamaytirdi. Biroq bu ustunlik shovqin darajasiga barqaror bog‘liq bo‘lmadi ($\sigma = 0{,}01$ rad da gibrid model 4,5 % yomonroq natija berdi) va kamida taxminan 4000 ta o‘quv namunasini talab qildi.

Gibrid model asosidagi prognozlovchi boshqaruv (NN-MPC) sinalgan sharoitlarning barchasida model asosida sozlangan PID rostlagichdan aniqlik bo‘yicha ustun kelmadi (nominal sharoitda IAE 1,08 ga nisbatan 0,99), ammo ikkala algoritm ham parametrlar o‘zgarganda barqaror ishladi. Demak, identifikatsiya aniqligining oshishi o‘z-o‘zidan boshqaruv sifatining yaxshilanishini kafolatlamaydi; sun’iy intellekt vositalarini qo‘llashdan oldin ularning ma’lumot hajmi, shovqin va hisoblash xarajatlari bo‘yicha ehtiyojini baholash lozim.

Kelgusi tadqiqotlarda natijalarni real jismoniy qurilmada tekshirish, takroriy tajribalar asosida statistik baholash, neyron tarmoq giperparametrlarini optimallashtirish, gradientli MPC optimallashtirgichlaridan foydalanish hamda modelni onlayn moslashtirish usullarini qo‘shish rejalashtirilmoqda. Taklif etilgan tajriba tuzilmasi texnika va informatika yo‘nalishidagi talabalar uchun laboratoriya mashg‘uloti sifatida tavsiya etiladi.

ADABIYOTLAR RO‘YXATI (REFERENCES)

Åström, K. J., & Hägglund, T. (2006). *Advanced PID control*. ISA – The Instrumentation, Systems, and Automation Society.

Brunton, S. L., Proctor, J. L., & Kutz, J. N. (2016). Discovering governing equations from data by sparse identification of nonlinear dynamical systems. *Proceedings of the National Academy of Sciences, 113*(15), 3932–3937. https://doi.org/10.1073/pnas.1517384113

Camacho, E. F., & Bordons, C. (2007). *Model predictive control* (2nd ed.). Springer.

Chen, S., Billings, S. A., & Grant, P. M. (1990). Non-linear system identification using neural networks. *International Journal of Control, 51*(6), 1191–1214.

Harris, C. R., Millman, K. J., van der Walt, S. J., Gommers, R., Virtanen, P., Cournapeau, D., ... Oliphant, T. E. (2020). Array programming with NumPy. *Nature, 585*(7825), 357–362. https://doi.org/10.1038/s41586-020-2649-2

Hewing, L., Wabersich, K. P., Menner, M., & Zeilinger, M. N. (2020). Learning-based model predictive control: Toward safe learning in control. *Annual Review of Control, Robotics, and Autonomous Systems, 3*, 269–296.

Hornik, K., Stinchcombe, M., & White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural Networks, 2*(5), 359–366.

Kingma, D. P., & Ba, J. (2015). Adam: A method for stochastic optimization. *Proceedings of the 3rd International Conference on Learning Representations (ICLR 2015)*.

Ljung, L. (1999). *System identification: Theory for the user* (2nd ed.). Prentice Hall.

Narendra, K. S., & Parthasarathy, K. (1990). Identification and control of dynamical systems using neural networks. *IEEE Transactions on Neural Networks, 1*(1), 4–27.

Nelles, O. (2001). *Nonlinear system identification: From classical approaches to neural networks and fuzzy models*. Springer.

Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... Duchesnay, É. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research, 12*, 2825–2830.

Sjöberg, J., Zhang, Q., Ljung, L., Benveniste, A., Delyon, B., Glorennec, P.-Y., Hjalmarsson, H., & Juditsky, A. (1995). Nonlinear black-box modeling in system identification: A unified overview. *Automatica, 31*(12), 1691–1724.

Virtanen, P., Gommers, R., Oliphant, T. E., Haberland, M., Reddy, T., Cournapeau, D., ... SciPy 1.0 Contributors. (2020). SciPy 1.0: Fundamental algorithms for scientific computing in Python. *Nature Methods, 17*(3), 261–272. https://doi.org/10.1038/s41592-019-0686-2