

Udruženje naučnika  
 Elektrotehnički fakultet  
 Kraljevača, 51000 Srebreni

UČENJE I KORISNOŠĆI SIMBOLIČKE REPRIZENTACIJE INVERZNE  
 DINAMIKE SISTEMATA

LEARNING AND USEFULNESS OF SYMBOLIC REPRESENTATIONS OF  
 INVERSE SYSTEM DYNAMICS

SAŽETAK - U radu je predstavljen metod i algoritam, koje se veruje da su novi, za učenje i korišćenje simboličke reprezentacije inverzne dinamičke sistema. Prezentiran je algoritam i eksperimenti kojima je poređena njegove performanse sa metodama na osnovi neuronskih arhitektura. Rezultati ukazuju na značajne prednosti predloženog metoda u odnosu na brzinu i kvalitet učenja.

ABSTRACT - In this work we propose a method and an algorithm, believed to be novel, for learning and use (for control purposes) of inverse systems dynamics. We present the algorithm and some experiments that compare its performance with proposals based on neural network architectures. Results indicate considerable advantage of the method proposed here, in terms of learning speed and accuracy.

1. UVOD

Tradicionalni postupci sinteze upravljača robotima stvaraju tri posebna problema: 1) potrebni su tačni matematički modeli kinematike i dinamike robotika, 2) potrebni određivanje prednastavaka, perzencera, tj. često neopuđe, i 3) kodove interakcije sa okolinom, tj. teško uklopiti u model. Usled toga se sve veća pažnja posvećuje metodama automatskog učenja za akviziciju znanja o modelima sistema i strategijama kontrolisanja, posebno u kontekstu neuronskih arhitektura [1], [2]. Izvestan napredak je postignut u korišćenju vektornih višedimenzijalnih mreža [3] za simulaciju interakcije između robotičke ruke i okoline [4]. Dodatno uočene su i određene slabosti: sporost učenja, nedostatak efektivnih metoda za proveru konvergenције postupaka, i, napravnije, "nepredvidivost" naučenog znanja, reprezentovanog u obliku skupa adaptivnih koeficijenata.

U ovom radu opisuemo novi metod učenja nelinearnih preslikavanja koje definišu modele dinamičkih sistema. Metod se oslanja na

particioniranju prostora primera i orijentovanju particija u strukturu koja sadrži grupacije primera. Zajedno sa pridruženom strukturom podataka koja definiše interpolacionu shemu. Upravljanje se postiže upotrebom ulaznih vrednosti i vektora stanja da se adresira odgovarajuća particija; izlazni vektor se formira interpolacijom između susjednih primera. Metod je uspešno primenjen na problem učenja inverzne dinamike robota; posebno je interesantno poređenje performansi sa jednom neuronornom arhitekturom na istom problemu [1], gde je predloženi metod pokazao veću brzinu i tačnost učenja za nekoliko redova veličine [5].

Rad je organizovan na sledeći način: u odeljku 2 dat je osnovnu arhitekturu upravljanja za "inteligentne" dinamičke sisteme. Onaj metod je prezentiran u odeljku 3. Naredni odeljak opisuje eksperimente koji omogućavaju poređenje metoda sa jednom neuronornom arhitekturom. Na kraju diskutujemo o mogućim primenama i daljem radu na metodu.

## 2. KONCEPT UPRAVLJANJA SISTEMIMA ZASNOVAN NA UČENJU INVERZNIH MODELA

Na slici 1 predstavljen je opeti koncept fleksibilnog, "inteligentnog" upravljanja dinamičkim sistemima (posebno inteligentnih robota). Modul za planiranje kreira reprezentaciju plana akcija, na osnovu informacija od procesa na višim nivoima (npr. simboličkih planera ili ekspertnih sistema): rezultata prethodnih akcija. Moduli upravljanja u otvorenoj petlji i povratnoj vezi generiraju komandne signale  $x_{ff}(t)$  i  $x_{fb}(t)$ , respektivno, čime se generiše odgovarajući odziv sistema. Kontroler u otvorenoj petlji implementira inverznu dinamiku sistema  $x(t) = F^{-1}(y_n(t))$ ; problem se sastoji u pronalaženju metoda učenja za akviziciju modela inverzne dinamike.

Postoje predloženi postupci za realizaciju svih kontrolera u obliku kaskadnih neuronskih mreža, modifikacijom sinaptičkih veza prema algoritmu za povratnu propagaciju greške [3] posle prezentacije parova ulazno-izlaznih vektora  $\langle y_n(t), x(t) \rangle$ . Neuronska mreža razvija aproksimaciju nelinearnog preslikovanja koje definiše inverznu dinamiku, dok greška praćenja  $z(t) = y(t) - y_n(t)$  postepeno opada. To ima za posledicu preuzimanje generisanja komandnog signala od strane kontrolera u otvorenoj petlji i ubrzanje odziva sistema. Međutim, tipični nedostaci neuronornih sistema su prisutni: sporo učenje, problematična konvergencija ka konačnoj internoj reprezentaciji i neprozirnost naučene reprezentacije.

## 3. NOVI METOD UČENJA KONTINUIRANIH PRAVNIH IZRAZIJA

Soština predložene metode za učenje (u vidu konstrukcije interne reprezentacije) nelinearne inverzne dinamične sistema je u konstruisanju particije  $\Pi$  nad prostorom  $Y$  ulaznih vektora  $y$ , zajedno sa pridruženom strukturom podataka koja definiše interpolacioni sistem. Particija  $\Pi = \{\pi_k\} = \{\bigcap_{j=1}^p \pi_{kj}\}$  se sastavlja od  $p$  hiperplana  $\pi_k$ , koje su definisane presečnim hiperplanom  $h_k = \{y \in Y \mid \min_{j=1, \dots, p} y_j \leq y_{jmax} \}$  za sve  $i \in \{1, \dots, p\}$ ,  $y_j \in [0, 1]$  i  $y_{jmax}$  je  $i$ -ta komponenta podvektora  $y$  u prostoru vektora  $Y$ . Svaki takav podvektor se razlaže u funkcije  $h_{kj}$  i izvorne funkcije  $g_{kj}(y)$ . Struktura se koristi za određivanje za svaki ulazni

1. Za svaki ulazni vektor  $y_k$  pronalazi se odgovarajuća particija.

2. Odredi se odgovarajuća susjedna težina  $w_k$  i njome radius uključuje  $y_k$ .

3. Izlazni vektor se formira kao:

$$x = \sum_k w_k (y_k \odot g_k) / \sum_k w_k (y_k)$$

gde težinski koeficijenti  $w_k$  zavise od rastojanja  $d_k = \|y - y_k\|$  i radiusa uticaja  $R_k$ .

Gornji izraz se zasniva na modificiranom Sheppard-ovom metodu interpolacije.

Na taj način "učenje" u ovom metodu zapravo se u konstrukciji interne reprezentacije (s) na particiju  $\Pi$  i specifikaciji parametara  $R_k$  i  $g_k$ . Osnovni algoritam učenja je:

Ulaz: Datoteka ulazno-izlaznih parova  $(y, x)$ , koji parcijalno definišu inverzno dinamično preslikavanje  $x = f^{-1}(y)$ .

Izlaz: Struktura podataka koja reprezentira particiju  $\Pi$  ulaznog prostora  $Y$ , zajedno sa radiusima uticaja  $R_k$  i koeficijentima kojima su definisane izvorne funkcije  $g_k$ .

**Korak 1:** Formiranje particije  $\Pi$  i razmeštanje svakog ulaznog vektora  $y$  u odgovarajuću oblast  $\pi_k$ .

**Korak 2:** Za svaki  $y_k \in Y$ :

- odredi se radius uticaja  $R_k$  vektora  $y_k$  tako da

uključuje  $N_q$  najbližih tačaka ( $N_q$  je neuristički parametar;

- odrede se koeficijenti čvorne funkcije  $Q_k$  rešavanjem regresione matrice za metod najmanjih kvadrata, po metodi QR-dekompozicije

#### 4. EKSPERIMENTALNI REZULTATI

Predloženi algoritam je eksperimentalno testiran na nekoliko zadataka akvizicije interne reprezentacije nelinearnih preslikavanja kojima su definisane funkcije inverzne dinamike sistema. Posebno je interesantna komparacija sa metodom koji je predložen u [2], gde je kaskadna neuronska mreža korišćena za učenje preslikavanja između pravougaonih i polarnih koordinata  $(x, y) \rightarrow (r, \varphi)$ . Primenjen je metod učenja pomoću povratne propagacije greske, a korišćena je datoteka od 9 primera (tačke označene kružićima na Sl. 2a, u oblasti  $[0, 10] \times [0, 10]$ ). Na Sl. 2a, 2b i 2c predstavljene su i konture greske učenja  $\epsilon^2 = \|x - x_d\|^2$  za metod iz [2], naše modifikacije [5], i metoda predložene u ovom radu. Vidi se da predloženi metod proizvodi gotovo savršeno preslikavanje, sa greškom približno za dva reda veličine manjom od metoda povratne propagacije greške u neuronskoj mreži (uporediti Sl. 2c i Sl. 2a). Ove veličine su dobijene posle 1000 prezentacija cele baze primera za Sl. 2a i 2b (u trajanju od oko 120 min), dok predloženi metod uči internu simboličku reprezentaciju u jednom prolazu, za oko 10 sec.

Slika 2b prikazuje srednji kvadrat greske  $\epsilon^2$  u funkciji broja prezentacija cele datoteke primera. Uočava se da greška kod metoda iz [2] nepredvidljivo varira sa brojem iteracija (neprekidana linija) i da se stabilizuje tek sa brojem iteracija  $> 1000$ . Nasuprot tome naša modifikacija pokazuje brzu stabilizaciju i konstantno manje greške (puna linija). Daleko bolje performanse pokazuje, međutim, predloženi metod koji na ovom primeru u jednoj jedinog iteraciji postiže grešku praktično jednaku nuli.

Ovaj algoritam upotrebili smo i za akviziciju modela inverzne dinamike uprošćenog modela ruke, sa realnim vrednostima parametara. Pokazalo se da je naučena interna reprezentacija u stanju da upravlja izvršenjem zadate trajektorije sa velikim stepenom tačnosti.

Iz takvog eksperimenta utvrđeno je da žanje pravilno izvedenog pokreta u horizontalnoj ravni između tačaka A(0,1, 0,15) i B(0,1, 0,15) (a) sa trouglašnim profilom brojeva. Baza primere je formirana usvajanjem 40 vrednosti  $\alpha_1, \alpha_2, \alpha_3, \alpha_4$  od ukupno 100 vrednosti. Kaskadna greška sa 5 glaznih, s dodatnošću i izlazna elementa oblikovana je programom DFFN na osnovu originalnog metoda autora. Tačnost i sposobnost generalizacije međineg modula testirani su na koeficijent modula na reprodukciju celokupnog modula (svih 100 uzoraka). Glavni kritični performansi je srednja normalizovana greška  $\epsilon_1, \epsilon_2$  i  $\epsilon$ , izlazi ukupna normalizovana greška  $\epsilon$ :

$$\epsilon = \sqrt{(\sum_{i=1}^p \|v^k - v_i^k\|) / (\sum_{i=1}^p \|v_i^k - v_i^k\|)}$$

gde je  $p$  - broj uzoraka,  $x^k$  - ulazni vektor,  $v^k$  - izlazni vektor,  $v_i^k$  - nominalna (zadata) vrednost izlaznog vektora,  $i$  - njegova srednja vrednost.

Poređenje tih performansi i CPU vremena potrebnog za utjanje između ovog metoda i metoda predloženog u radu (program RSVB) date je u Tabeli 1; evidentna je prednost programa RSVB.

TABELA 1. Poređenje performansi metoda u rekonstrukciji DFFN i RSVB

	Broj iterac.	Srednja greska			CPU vreme [s]
		$\epsilon_1$	$\epsilon_2$	$\epsilon$	
DFFN	13	0,009	0,116	0,147	174e
RSVB	1	0,00017	0,000029	0,000057	1315

Iz particija  $\pi$  prostora ulaznih vektora  $x$ , koje su definirane produktom intervala  $\prod_{i=1}^n [x_{i \min}^k, x_{i \max}^k]$ , mogu se dobiti i sledeća pravila za opisivanje algoritma upravljanja:

```
IF ( $x_{i \min}^k < x_i$ ) AND ( $x_i < x_{i \max}^k$ ) AND ...
.. AND ( $x_{i \min}^k < x_i$ ) AND ( $x_i < x_{i \max}^k$ )
THEN Akcija k
```

gde Akcija  $k$  podrazumeva rutinu za konstruisanje izlaznog vektora pomoću interpolacije. Gornji oblik predstavlja standardnu simboličku reprezentaciju znanja u ekspertnim sistemima.

## 5. ZAKLJUČAK

Razvili smo novi metod za učenje iz primera na osnovi originalnog algoritma koji kombinira simboličke i numeričke postupke. Metod je uspešno primenjen na učenje simboličkih internih reprezentacija nelinearnih kontinualnih preslikavanja koji karakterišu funkcije inverzne dinamike sistema (posebno robotskih manipulatora). Dosadašnje eksperimentalne provere pokazale su daleko bolje performanse predloženog metoda nad metodom učenja neuronskih mreža povratnom propagacijom greske.

Činjenicu da je jedna metoda učenja koja konstruiše simboličku reprezentaciju uspešno primenjena u domenu za koji se smatralo da se može obrađivati samo novim neuromorfnim arhitekturama, smatramo posebno značajnom zbog mogućnosti automatske konstrukcije sistema zasnovanih na znanju za upravljanje složenim sistemima. Kod takvih sistema će primarni problem biti reprezentacija, metode učenja i metode transformacije različitih tipova znanja. Naše dalje istraživanje i razvoj ovog metoda biće usmereni u tom pravcu.

## 6. LITERATURA

- [1] Bullock D, Grossberg S.: "Neural Dynamics of Planned Arm Movements", Psych. Rev., u štampi.
- [2] Psaltis et al.: "A Multilayered Neural Network Controller", IEEE Cont. Syst. Magazine, Apr. 1988, 17-21.
- [3] Rumelhart D, Hinton G, Williams R.: "Learning Representations by Back-Propagating Errors", Nature (323), 1986, 533-536.
- [4] Kawato M.: "Learning Control of Voluntary Movement by Multilayer Neural Network", Proc. Japan-China Bilateral Symposium on Biophysics, 1988.
- [5] Zografski Z.: "An Improved Neural Network Architecture for Learning Control", rad prihvaćen za Simpozijum o informacionim tehnologijama, Sarajevo 1989.
- [6] Michalski, R.S.: "Understanding the Nature of Learning", u: MACHINE Learning 2 (Michalski, Carbonnel & Mitchell, Eds.). Palo Alto: Morgan Kaufmann, 1986.

## 6. ZAKLJUČAK

Každili smo novi metod za učenje i kontrolu na osnovu originalnog algoritma koji kombinira simboličke i numeričke postupke. Metod je uspešno primenjen na učenje simboličkih interakcijskih reprezentacija nelinearnih kontinualnih kretnjavanja kod karakterističnije inverzine dinamičke sistema i posebno nepodiznih predstavljivanja. Obednašnje eksperimentalne provere pokazale su daleko bolji performansu predložene metode nad metodom učenja i kontrole kroz direktnu propagaciju grešaka.

Očekujem da je ovaj metod učenje i kontrolu kroz simboličku reprezentaciju uspešno primenjen u sistemima koji se smatraju da se nije obradivati samo novim neuroničnim shemama turina i shemama posebno značajnom zbog mogućnosti učenja i kontrole u sistemima korenovanih na energiji za obradivanje simboličkih predstava. Jedan od problema će primarni problem biti reprezentacija metode učenja i metode transformacije različitih tipova energija. Naša dalje istraživanja u ovom ovom metoda biće usmerena u tom pravcu.

## 6. LITERATURA

- [1] Burdick D., Grossberg S.: "Neural Dynamics of Hierarchical Arm Movements", Psych. Rev., u štampi.
- [2] Psaltis et al.: "A Multilayered Neural Network Controller", IEEE Cont. Syst. Magazine, Apr. 1988, 17-21.
- [3] Rumelhart D., Hinton G., Williams R.: "Learning Representations by Back-Propagating Errors", Nature (1986), 1989, 537-539.
- [4] Kawato M.: "Learning Control of Voluntary Movement by Multilayer Neural Network", Proc. Japan-China Bilateral Symposium on Biophysics, 1988.
- [5] Zografski I.: "An Improved Neural Network Architecture for Learning Control", rad prihvađen za Simpozijum o Informacionim Tehnologijama, Sarajevo 1989.
- [6] Michalek, R.S.: "Understanding the Nature of Learning", in *Artificial Learning*, Michalek, R., Samuel, J. (Eds.), John Wiley & Sons, Morgan Kaufmann, 1986.





