

Renata Zupanc, Tanja Urbancic  
 Institut "Jozef Stefan"  
 Jamova 39, 61111 Ljubljana

POSKUS UPRAVLJANJA PREFROSTEGA DINAMICNEGA SISTEMA Z METODAMI  
 UMETNE INTELIGENCE

AN EXPERIMENT IN SIMPLE DYNAMIC SYSTEM CONTROL USING  
 ARTIFICIAL INTELLIGENCE METHODS

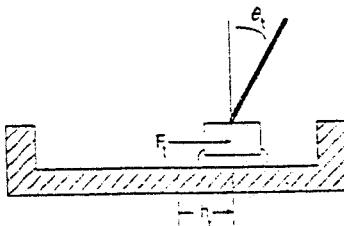
**POVZETEK** - Reprezentativen primer dinamičnega sistema je invertirano nihalo (vrtljivo vpeta palica na vozišku), ki se ga poskušali krmiliti s klasičnimi analitičnimi metodami, pa tudi z uporabo nekaterih metod umetne inteligence. V referatu je podano upravljanje sistema z uporabo metode preiskovanja prostora stanj, dobljenega iz modela sistema na osnovi intervalske aritmetike. Na generiranih kontrolnih pravilih smo uporabili sistema za induktivno učenje ASSISTANT 86 in GINESYS PC. Rezultati kažejo, da dosefemo precej dobro upravljanje že s preprostim modelom. Kritičen je problem razbitja parametrov na intervale. Upravljanje se pri večji globini preiskovanja prostora stanj presenetljivo poslabša - vzrok za to je, v večanju napak z globino pri intervalski aritmetiki.

**ABSTRACT** - The pole-balancing task is often used as an example of the inherently unstable dynamic system. It has been used to demonstrate modern and classical control-engineering techniques. This paper describes an experiment of controlling the pole-cart system. We use a method of searching a state-space, derived from the model based on interval arithmetic. In addition two inductive learning systems, ASSISTANT 86 and GINESYS PC were used to build decision rules from generated control rules. The results show that even with a simple model a rather good control can be achieved. The problem of partitioning of parameter values into intervals is critical. Surprisingly the control gets worse with deeper search because errors due to interval arithmetic grow with increasing search-depth.

## 1. UVOD

Problem balansiranja palice je primer nestabilnih dinamičnih sistemov, ki se kažejo v številnih primerih balansiranja (npr. pri hoji, usmerjanju rakettrega izpuha itd.). Problem ni trivialen in je analitično rešljiv. Med balansiranjem palice in bolj uporabnimi problemi, kot je na primer satelitska kontrola, obstaja precej podobnosti. Zato tudi posvečajo temu problemu toliko pozornosti [3].

Problem voziček-palica je opisan takole: Na ravnem tiru stojijo dve deli sistema: voziček in palica. Voziček je na katerem je pritrjeni vodoravni sistem, ki je gibljiva le okoli vodoravne osi, pravokotne na tircice. Na voziček delujemo s silo  $F$  konstantne velikosti, ki ji lahko v rednih časovnih presledkih (0.02 s) spremenimo predznak. Vozilku je potrebno voditi tako, da ostane na tircicah in da palica ne pada [4].



Slika 1: Preprosta predstavitev sistema, ki ga kontroliramo

Kvalitativno modeliranje - za razliko od klasičnega analitičnega - opisuje delovanje naprav na intuitiven, človeku razumljiv način, ob uporabi preprostega fizikalnega znanja.

V modelu so kvantitete predstavljene z majhno množico kvalitativnih, simboličnih vrednosti in njihovimi ordinalnimi relacijami. Ni točnih funkcijskih odvisnosti. Zvezne so približne (npr. monotonost) in ponavadi v obliki predikatov.

Klasične metode delujejo bolje od kvalitativnih, kadar imamo dosegljiv analitični model. Kjer imamo opravka s problemi, ki so prekompleksni za klasično kontrolo (parametri, ki se spremenijo s časom, nelinearni sistemi, ali če ne poznamo točnih numeričnih vrednosti parametrov oziroma njihovih medsebojnih odvisnosti - npr. pri fizioloških sistemih), pa se odločimo za preprostejšo, a morda manj zanesljivo kvalitativno kontrolo. Dodatna prednost kvalitativnega pristopa je možnost razlage avtomatsko generiranih odločitev za kontrolne akcije.

## 2. MODELIRANJE SISTEMA VOZICEK-PALICA

### 2.1 Analitični model

Sistem določajo štirje parametri: položaj vozička ( $X$ ), hitrost vozička ( $V$ ), naklon palice ( $F_i$ ) in kotna hitrost palice ( $F_{iV}$ ). Sama dinamika sistema je določena s sistemom dveh diferencialnih enačb drugega reda [1, 5].

### 2.2 Kvalitativni model

Iz analitičnega modela smo izpeljali verjetnostni kvalitativni model. Vrednosti parametrov so enake, kot jih navaja Anderson v [1]. Le-te v kvalitativnem modelu niso realna števila temveč intervali na realni osi. Sistem je modeliran na treh različnih nivojih podrobnosti. Nivoji se ločijo po tem, na koliko

intervalov je razdeljeno dovoljeno območje za posamezni parameter. Model povezuje trenutno stanje sistema (vektor štirih parametrov), akcijo, novo stanje in verjetnost prehoda v novo stanje. Akcija je lahko pozitivna ali negativna (glede na smer sile na vtiček).

### 2.3 Računanje verjetnosti prehodov z intervalsko aritmetiko

Pri nematanem informaciji (intervalne vrednosti parametrov) je stopnja nedeterminizma veliko večja. Isteremu kvalitativnemu stanju v trenutku  $T$  lahko pri isti akciji sledijo v času  $T + \Delta t$  različna nova kvalitativna stanja. Stopnja nedeterminizma lahko zmanjšam: s tem, da za vsako od možnih novih stanj povemo verjetnost, da se bo sistem znašel v njem. Vsakemu prehodu vrednosti parametrov je pridružena ocena verjetnosti za to vrednost. Obeno verjetnosti za prehod celotnega stanja ( $X, V, F_i, F_iV$ ) v novo stanje dobimo kot produkt ocen verjetnosti za prehode vrednosti posameznih parametrov, čeprav kolikšne niso nesčivne. Pri izračunu verjetnosti za posamezne parametre predstavim v intervalski aritmetiki njihovo enakomerne porazdelitev. Upoštevamo le tiste prehode, katerih verjetnost je večja od 0.01.

Vrednosti posameznih parametrov novega kvalitativnega stanja so torej izračunajo po enačbah dinamike sistema z intervalsko aritmetiko. Za primer si oglejmo računanje vrednosti novega položaja. Izhajamo iz znane Eulerjeve enačbe

$$x(t + \Delta t) = x(t) + D t \dot{x}(t)$$

Dobiti želimo  $XN$  kot vsoto  $X$  in  $DX$ , pri čemer je  $DX$  produkt  $Dt$  in  $V$ :

$$XN = X + Dt V$$

$X, V, DX$  in  $XN$  so intervali,  $Dt$  pa konstanta. Torej

```

x(X, V, Dt, XN\|P) :-  

    mult_int_c(V, Dt, DX),          % množenje intervala s konstanto  

    plus_int(X, DX, XN\|P)         % sestevanje dveh intervalov  

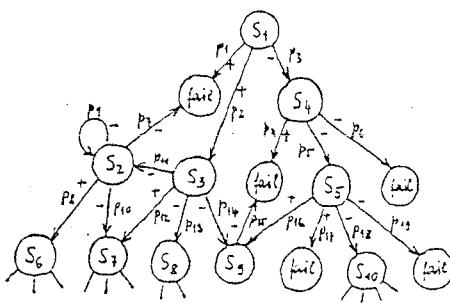
    P >= 0.01.                      % verjetnost zanj več kot 0.01

```

Ker imamo opravka s funkcijami, ki so na danih intervalih monotone, se intervalska aritmetika prevede na dokaj enostavno računanje vrednosti mej intervalov. Poskrbeti je treba, da nova vrednost parametra ni kar poljuben interval, temveč ena od možnih kvalitativnih vrednosti za ta parameter (eden izmed določenih intervalov). Ker lahko več kvalitativnih vrednosti pokriva izračunani interval, je skupna ocena verjetnosti (ki je enaka 1) medjne razdeljena v razmerju dolžin njihovih presekov z izračunanim intervalom (predpostavka enakomerne porazdelitve verjetnosti).

### 2.4 Prostor stanj

S simulacijo kvalitativnega modela s silo velikosti 1 N in 10 N smo generirali vsa možna naslednja stanja s pripadajočimi verjetnostmi, pri znanem trenutnem stanju in akciji, na izbranem nivoju natančnosti. Na ta način smo dobili  $2 \times 3 = 6$  grafov prehajanja stanj. Vsak graf predstavlja prostor stanj.



Slika 2: Del grafa prehajanja stanj

### 3. GENERIRANJE KONTROLNE STRATEGIJE NA PODLAGI VERJETNOSTNEGA KVALITATIVNEGA MODELA

Na osnovi preiskovanja tako dobljenega grafa smo izpeljali kontrolna pravila tako, da se v vsakem stanju algoritem odloči za akcijo, pri kateri je matematično upanje preko vseh stanj ugodnejše glede na izbrani kriterij. Izbrali smo naslednji kriterija: maksimizirati ocenjeno dobo preživetja (to strategijo imenujemo KAPA) in maksimizirati ocenjeno verjetnost preživetja N korakov (strategija IOTA).

Doba preživetja je ocenjena z rekurzivno funkcijo:

$$\text{kapa}(S, 0) = \begin{cases} 0 & \text{če terminal}(S) \\ 1 & \text{sicer} \end{cases} \quad (1)$$

$$\text{kapa}(S, N) = \begin{cases} \max_{\{i \in \{1, 2, \dots, 10\} : S_i \text{ naslednik} S\}} (1 + \sum_{A \in \{A_1, A_2, \dots, A_{10}\}} P_i \text{kapa}(S_i, N-1)) & \text{če non-terminal}(S) \\ 0 & \text{če terminal}(S) \end{cases}$$

Kjer četverka  $t(S, A, S_i, p_i)$  označuje i-tega naslednika stanja S z verjetnostjo  $p_i$  pri akciji A. Terminalna stanja so stanja, pri katerih vsaj eden izmed parametrov pada izven dovoljenega območja. Vsa ostala stanja so neterminalna stanja.

Verjetnost preživetja N korakov je ocenjena s podobno rekurzivno funkcijo:

$$\text{iota}(S, 0) = \begin{cases} 0 & \text{če terminal}(S) \\ 1 & \text{sicer} \end{cases} \quad (2)$$

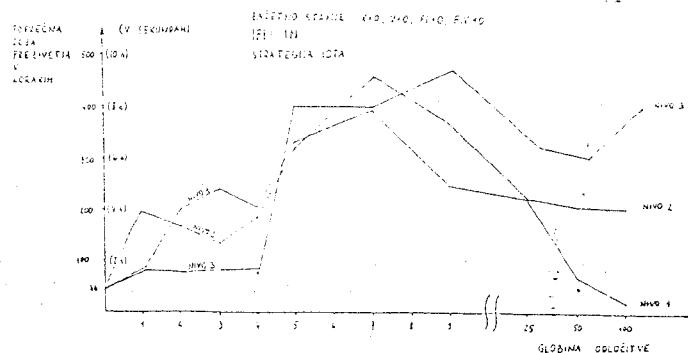
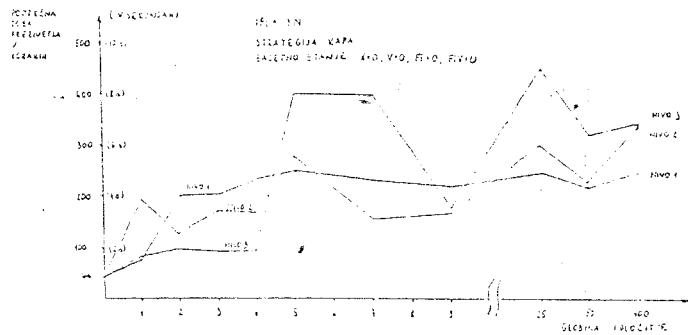
$$\text{iota}(S, N) = \begin{cases} \max_{\{i \in \{1, 2, \dots, 10\} : S_i \text{ naslednik} S\}} \sum_{A \in \{A_1, A_2, \dots, A_{10}\}} P_i \text{iota}(S_i, N-1) & \text{če non-terminal}(S) \\ 0 & \text{če terminal}(S) \end{cases}$$

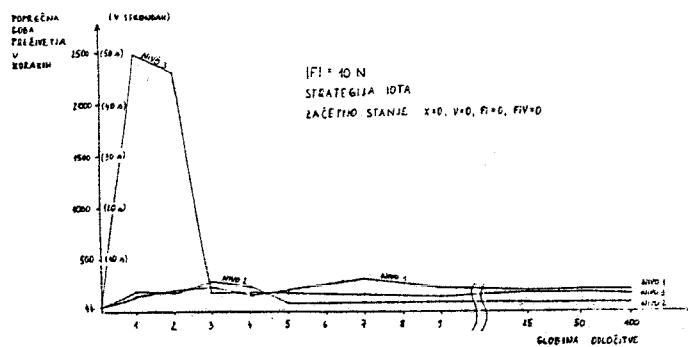
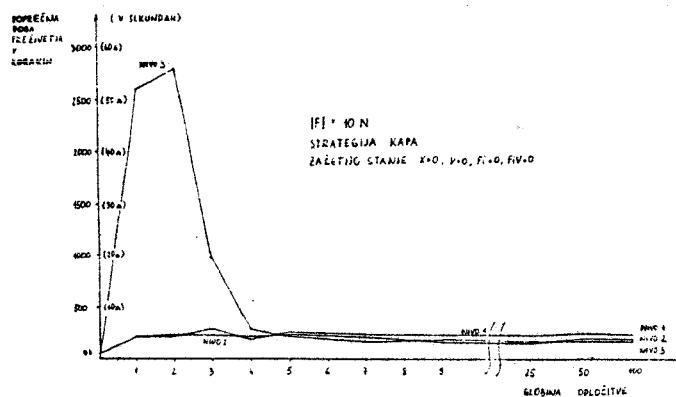
Pri teh občah ocenah je pomemben parameter globina preiskovanja grafa. Izbrali smo deset globin: 1, 2, 3, 4, 5, 7, 9, 23, 50 in 100. Z uporabo običnih kriterijev na vseh šestih grafih (dve sili, trije nivoji) dobimo  $10 \times 2 \times 6 = 120$  kontingenčnih pravil (tabelje stanje-akcija).

#### 4. REZULTATI TESTIRANJA KONTINGENČNIH PRAVIL

Namesto dejanske naprave smo uporabili numerični simulator, ki uporablja eksplizivne analitične enačbe dinamičkega sistema. Vs. pravila so testirana s silo 1 N na fiksniem naboru 16 izbranih zadetnih stanj. Za vsaj eden od teh stanj se izračunata tudi poprečna doba preživetja in standardna deviacija.

Poprečno dobo preživetja v odvisnosti od globine preiskovanja grafa prikazujejo diagrami na sliki 3a, b, c, d:





Slika 3a, b, c, d: Poprečna doba preživetja v odvisnosti od globine odločitve

Iz diagramov smo ugotovili naslednje:

- Izbira intervalov: pravilna izbira števila intervalov in njihovih mej za posamezni parameter je kritična pri sili 10 N in majhni globini preiskovanja; krmiljenje na nivoju tri prečivi 10 do 16 krat dolje kot na nivoju ena ali dva; kontrola na nivoju era se ne razlikuje signifikantno od kontrole na nivoju dva - pri obeh se kvaliteta kontrole res spreminja z globino preiskovanja.
- Stabilnost kvalitete upravljanja: Pri sili 10 N se kvaliteta upravljanja pri gledanju vec kot štiri korake naprej stabilizira in je približno dvakrat boljša od naslednjene strategije.
- IOTA : KAPA: Razlike med strategijama IOTA in KAPA pri sili 10 N niso velike
- Pretiravanje s silo: dobijena s silo 10 N so primerna tudi za kontrolu s silo 1 N (na nivoju tri pri velikih globinah preiskovanja celo bolj kot kontrolna pravila dobijena s silo 1 N), kar kaže na določeno robustnost sistema.
- Maksimum: Pri globini pet do osem je pri strategiji IOTA opazen maksimum kvalitete obnašanja (najbolj izrazit za nivo ena; na nivoju tri komaj opaten). Velika globina preiskovanja grafa ima za posledico kvečjemu slabšu rezultate pri kontroli. Zakaj?
  - \* napake se pri intervalski aritmetiki z globino večajo (intervali povečujejo napake pri izračunavanju verjetnosti),
  - \* potrebno je sprejeti kompromis med napakami pri izračunavanju (intervalska aritmetika) in globino preiskovanja grafa (na nivoju tri je kvaliteta upravljanja na globinah 1 in 2 znatno boljša - faktor 10 do 15 - od kvalitete upravljanja na večjih globinah). Verjetnosti v grafu prehodov so brezpogojne, pri gledanju v globino pa bi morali upoštevati pogojne verjetnosti (zgodovino).

## 5. ODLOCITVENA PRAVILA, DOBLJENA S SISTEMOMA ZA INDUKTIVNO UCENJE ASISTENT 86 IN GINESYS PC

Sistema za induktivno učenje, ASISTENT 86 in GINESYS PC, smo uporabili na nekaj izbranih tabelah stanje-akcija iz poglavja tri. Vsak element tabele stanje-akcija je učni primer. Iz primerov ASISTENT 86 zgradi odločitveno drevo, GINESYS PC pa odločitveno pravilo, sestavljeno iz več IF-THEN pravil [2, 3].

Analiza odločitvenih dreves in pravil pa pokare:

- Kompleksnost: Odločitvena drevesa so bolj kompleksna od pravil, ki jih generira GINESYS PC, in tudi bolj asimetrična.
- Enostavni in sestavljeni pogoji:
  - \* pri vrhu drevesa so pokrite oditne situacije, ki jih je potrebno neposredno krmiliti. Enako velja za pravila na vrhu celodictvenega pravila, ki so si podobna. Primer:  
 $(FiV = Pos) \Rightarrow Pos\_Act$   
 Če se palica giblje v pozitivni smeri, izvrši pozitivno akcijo.
  - \* pri sili 10 N v pravilih nastopajo skoraj izključno enostavni pogoji, pri sili 1 N pa imamo večinoma konjunktivno sestavljeni pogoji. Taki sestavljeni pogoji pokrivajo bolj zapletene situacije, na primer:  
 $(Fi = Near\_Pos) \& (FiV = Neg) \Rightarrow Neg\_Act$   
 Če je palica malo nagnjena od navpičnice in se giblje proti njej, je je potrebno zaustaviti.

- Krmiljenje položaja: Položaj vozička je mogoče krmiliti šele pri veliki globini preiskovanja prostora stanj. Parameter X nastopa le pri dnu dreves oz. na dnu hierarhije pravil.
- Simetrija pravil: Zgornji del hierarhije pravil je simetrišen za vsako pravilo obstaja "zrcalno" pravilo, kjer v poravnanih nastopajo parametri z nasprotno predznačenimi kvalitativnimi vrednostmi in ki pokrivajo nasprotno predznačeno akcijo kot prvotno pravilo.

## 6. ZAKLJUČEK IN RAZPRAVA

Raziskovanje v smeri preiskovanja prostora stanj v globino je koristno, ker lahko iz poskusov povzamemo več zanimivih ugotovitev. Obstaja kompromis med globino preiskovanja in napaka zaradi intervalske aritmetike. Precej dobro upravljanje doseže že s preprostim modelom. Položaj vozička postane pomemben. Šele pri večji globini preiskovanja prostora stanj. Pretiranje s silo je koristno (generirana pravila s silo velikosti 10, upravljanje s silo velikosti 1).

Za nadaljnje delo bi bilo zanimivo preučiti vpeljavo aposteriornih verjetnosti prehodov stanj, ki bi jih dobili z večkratnim krmiljenjem, in jih primerjati z apriornimi. Verjetno se da dosti pridobiti z opustitvijo predpostavke enakomerne porazdelitve verjetnosti po intervalih ter z upoštevanjem pogornih verjetnosti oziroma zgodovine, pa tudi s planiranjem in učenjem na podlagi izkušenj. Raziskave v teh smereh so že v teku.

## LITERATURA

- [1] Anderson, C. W. (1987) Strategy Learning with Multilayer Connectionist Representations, v Langley, P. (ur.), Proceedings of the 4th International Workshop on Machine Learning, Morgan Kaufmann
- [2] Karalić, A. (1988) Implementacija sistema GINESYS PC, diplomska naloga, Fakulteta za elektrotehniko, Ljubljana
- [3] Kononenko, I. (1985) Razvoj sistema za induktivno učenje ASISTENT, magistrsko delo, Fakulteta za elektrotehniko, Ljubljana
- [4] Michie, D. & Chambers, R. A. (1971) Boxes: An Experiment In Adaptive Control, Machine Intelligence 2, Edinburgh University Press, stran 137-152
- [5] Sammut, C. (1988) Experimental Results from an Evaluation of Algorithms that Learn to Control Dynamic Systems, Proceedings of 5th International Machine Learning Conference, Ann Arbor, Michigan, Morgan Kaufmann