

Златко Зографски  
 Електротехнички факултет  
 Универзитет "Кирил и Методиј"  
 Карпош II, 91000 Скопје

Proglašen za najbolji  
 rad u komisiji.

## ЕДНА НОВА МЕТОДА НА АВТОМАТНО УЧЕЊЕ И НЕЈЗИНА ПРИМЕНА ВО МОДЕЛТРАЊЕ И СИМУЛАЦИЈА НА ДИНАМИЧКИ СИСТЕМИ

**Резиме -** Во трудот е изложена една нова метода на автоматно учење и описана е нејзината примена во доменот на сложени динамички системи. Со алгоритмот се конструира репрезентација на динамичките равенки на системот тако нов вид на асоцијативна меморија заснована на локална интерполациска схема и брз алгоритам за пребарување. Експериментите во примена на методата при учење на динамичкиот модел и системот на инвертирано нишало и при употребувањето на добиленото знаење во предикција на еволуцијата на системот ја демонстрираат ефикасноста на алгоритмот и ги верифицираат теоретски изведените поставки за неговата временска и просторна комплексност.

### A NOVEL MACHINE LEARNING METHOD AND ITS USE IN THE MODELLING AND SIMULATION OF DYNAMICAL SYSTEMS

**Abstract -** In this paper a new method of machine learning is presented, and its application in the domain of complex dynamical systems is described. The learning algorithm constructs a representation of the model of system's dynamics in a new form of associative memory which features a local interpolation scheme for approximating nonlinear mappings and fast geometric searching algorithms. Experiments with the acquisition of the dynamics model of the well-known pole balancing system demonstrate the efficiency of the learning method and verify theoretical results with regard to its time and space complexity.

#### 1. УВОД

Со трудот на Michie и Chambers [6] почнува применувањето на методите на вештачка интелигенција во управувањето со физички процеси. Методите се интересни затоа што класичната теорија на управување е понекогаш неприменивa за определен процес, поради непознавањето на детален модел, неговите параметри и влијанието на околнината. Постојат мислења дека методологијата на автоматско учење од примери може да биде полезна во овие случаи; таквиот пристап резултира со некои интересни резултати во врска со термоморфно ([2], [3], [10]) и индуктивно учење [8].

Сличен е и проблемот на креирања на еволуцијата на системот при зададена почетна состојба. Клучен концепт, што ги покажуваат проблемите, е мемориски модел на динамиката на системот, како апроксимација на егзактните равенки (кои често пати се практично невозможно да се добијат). Доволно точен модел, добиен преку процес на учење од примери на состојбите на системот и неговите одзиви, би можел да се употреби за предвидување на следната состојба на системот (доколку се подиза сегашната состојба и именитот масив), и со тоа ефективно да се изврши интеграција на неговите равенки на движење како ниникадаматичка форма е непозната.

Во овој труд прав драме кус преглед на една нова метода за автоматско учење ([5], [6], [7]). Потоа ја описуваме нејзината применица проблемот на аквизиција на динамиката на инвертирано нишало

на подвижна количка. Се дискутираат перформансите на методата, а се даваат и сугестиии за понатамошно истражување.

## 2. МОДЕЛ ЗА УЧЕЊЕ НА НЕЛИНЕАРНИ ДИНАМИЧКИ ПРЕСЛИКУВАЊА

Разгледуваме динамички систем:

$$\frac{dy}{dt} = F(y) \quad (1)$$

каде секој  $y = (y_1, y_2, \dots)$  претставува вектор на состојба на системот и може да се набљудува како точка во соодветен фазен простор  $S$  ( $S \subseteq \mathbb{R}^n$ ). Така векторското поле  $F(y)$  е нелинеарен оператор врз точки од  $S$  (ако  $S \subseteq \mathbb{R}^n$ , тогаш  $F: \mathbb{R}^n \rightarrow \mathbb{R}^n$ ); оду, во момент  $t$  може да се определи  $y_{t+1}$  во  $t + dt$ :

$$y_{t+1} = y_t + F(y) \cdot \Delta t \quad (2)$$

Често пати аналитичкиот израз за  $F(y)$  не е познат, меѓутоа, позната е низа на измерени величини на векторот на состојба и неговите изводи  $\{(dy/dt)\}_i = f_i$ . Проблемот на предвидувањето на системот  $F$  така се сведува на проблем на мултидимензионална интерполяција, и тоа кон конструкција на функција  $\Phi: \mathbb{R}^n \rightarrow \mathbb{R}^n$ , така што  $\Phi(y_i) = f_i$  за сите  $i$  во секвенцата на набљудувања.

Проблемот може да се формулира и како парадигма на автоматно учење: од дадено множество на примери  $L$  на релации влез/излез  $\{(y_i, f_i)\}, i=1, 2, \dots, N$  (каде  $y_i$  и  $f_i$  се реали  $n$ -вектори, да се конструира мемориски модел  $M$  на нелинеарното пресликување  $\Phi$  кое ги вклучува паровите од множеството на примери. Откако моделот  $M$  е конструиран, од него се добива излезниот вектор  $f_i$  при индексирање со соодветниот влезен вектор  $y_i$ . Во овој контекст, генерализацијата се однесува на способност да се произведе "прифатлив" одзив  $\varphi_i$  и на влезови  $y_i$  кои не биле презентирани во учењето; овој поим може да се прецизира преку дефиницијата на нормализираната грешка  $\epsilon$ :

$$\epsilon = \left( \sum_{i=1}^{P_1} \|\varphi_i - \varphi_a\|^2 / \sum_{j=1}^{P_1} \|\varphi_j - \langle \varphi_j \rangle\|^2 \right)^{1/2} \quad (3)$$

каде  $(y_i, \varphi_i), i=1, 2, \dots, P_1$  е колекција на тест-примери (неупотребени во учењето). За секој вектор  $y_i$  излезниот вектор  $\varphi_i$  што се добива од  $M$  се споредува со очекуваниот (точен) вектор  $\varphi_a$ ;  $\langle \varphi_j \rangle$  е средниот излезен вектор (над сите тест-вектори).

## 3. АСОЦИЈАТИВНА ИНТЕРПОЛИРАЧКА МЕМОРИЈА: МОДЕЛ И АЛГОРИТМ ЗА УЧЕЊЕ

Репрезентацијата на множеството на примери во вид на множество на влезно-излезни парови на вектори може да се смета и како нов тип на асоцијативна меморија [12], наречена AICAM. Излезниот вектор за пример од пресликувањето може да се добие со пребарување и делумно поклопчување помеѓу влезниот вектор (употребен како клуч за адресирање) и меморираните примери. Задачата на учење се состои во алгоритмичка конструкција на оваа мемориска репрезентација за барањот пресликување од множеството на примери. Подетален опис на методата и алгоритмот, скицирани подолу, може да се најде во [11] и [12].

За множество на  $N$  точки  $\{y\}$  со придружени вредности на функцијата  $\{f\}$ , дефинираме функција од две променливи (експозицијата на методата е за 2-D случај; генерализацијата за повеќедимензионални случаи е единственава)  $F \in C(\mathbb{R})$  таква што  $F(y_i) = f_i$  за  $i = 1, 2, \dots, N$ . Функцијата  $F$  е дефинирана со сумата:

$$F(y) = \sum_{k=1}^N W_k(y) \cdot Q_k(y) / \sum_{j=1}^N W_j(y) \quad (4)$$

каде  $Q_k$  се функции за кои важи  $Q_k(y_k) = f_k$ , додека тежинските кофициенти  $W_k$  се определуваат со функцијата на инверзно растојание  $W_k(y) = (R_w - d_k)_+^2 / R_w^2 d_k^2$ , каде  $(R_w - d_k)_+ = (R_w - d_k)$  ако  $d_k < R_w$  и  $(R_w - d_k)_+ = 0$  ако  $d_k \leq R_w$ ,  $d_k$  е Евклидското растојание помеѓу интерполирачката точка  $(y)$  и

memoriрана точка  $(y_k)$ , и  $R_w$  е радиусот на влијание околу точката  $(y_k)$ . Јасно е оти податокот  $f_k$  алијас само врз интерполирачки вредности во радиус  $R_w$ . Функциите  $Q_k$  се дадени со изразот:

$$Q_k(y) = \alpha_{11}(y_1 - y_{1k})^2 + \alpha_{12}(y_1 - y_{1k})(y_2 - y_{2k}) + \alpha_{13}(y_2 - y_{2k})^2 + \alpha_{14}(y_1 - y_{1k}) + \alpha_{15}(y_2 - y_{2k}) + f_k \quad (5)$$

во кој коефициентите  $\alpha_{ij}$  се определени со минимизација на изразот (6) според методата на најмали квадрати:

$$\sum_{j=1, j \neq k}^N \omega_j(y_k) [\alpha_{11}(y_{1j} - x_{1k})^2 + \dots + f_k - f_j]^2 \quad (6)$$

во кој

$$\omega_j(y) = (R_q - d_j)^2 / R_q^2 d_j^2 \quad (7)$$

$R_q$  е радиус на влијание околу точката  $(y_k)$ , додека  $d_j$  е растојанието помеѓу  $(y_j)$  и интерполираната точка  $(y)$ . Од (6) следи дека во определувањето на  $Q_k$  придонесуваат само оние точки чии радиуси го вклучуваат  $(y_k)$ , дефинирајќи ја локално. Значи, определувањето на функциите на јазли  $Q_k$  поѓа од определувањето на радиусите  $R_q$  следено од формирањето и решавањето на системот (6). Радиусите  $R_q$  и  $R_w$  се бираат така да опфаќаат  $N_q$  и  $N_w$  точки, респективно, за фиксни, empirиски определени вредности на  $N_q$  и  $N_w$ .


Значи, горе описанниот алгоритам на учење врз основа на модифицираната Shepard-ова метода [11], се состои од три фази:

1. Фаза на "memoriрање" на примерите, во која решетка од  $O(N)$  просторни клетки се постава на множеството од  $N$  податочни точки (примери), и секоја точка се придржува кон определена клетка.
2. Пребарување на околината на секоја податочна точка  $(y_k)$  за да се определи подредена низа од  $N_w$  најблиски соседи на секоја од нив, и според тоа радиус на влијание  $R_w$ .
3. Определување на коефициентите  $\alpha_{ij}$  за функциите  $Q_k$  според (6), со вклучување на најблиските  $N_q$  точки на секоја податочна точка  $(y_k)$  и решавање на соодветната регресиона матрица со декомпозиција по сингуларните вредности.

Што се однесува до просторната комплексност на методата, за 2-D случај се потребни  $3N$  локации за сместување на  $(y_i)$  и  $f_i$ . За коефициентите  $\alpha_{ij}$  за функциите на јазли  $Q_k$  и радиусите  $R_w$  за секоја податочна точка потребни се уште  $6N$  локации. Кон ова треба да се додадат и  $4N/3$  локации за сместување на решетчестата податочна структура. Така алгоритмот (фазите на конструкција и евалуација) бара  $O(N)$  мемориски локации. Во [11] се покажува дека средното време на конструкцијата е линеарно ( $O(N)$ ), додека на евалуацијата е константно ( $O(1)$ ). Во [11] е исто така покажано дека методата лесно се обопштува за  $n$ -димензионален проблем.

#### 4. АКВИЗИЦИЈА НА ДИНАМИЧКИОТ МОДЕЛ НА ИНВЕРТИРАНОТО НИШАЛО

Проблемот на балансирање на инвертирано нишало досега неколку пати бил разгледуван во врска со алгоритми што учат закони на управување на динамички системи ([2], [3], [6], [8]). Системот е пример на инхерентно нестабилен мултидимензионален динамички систем, какви што се сретнуваат при управување со двоножно одење (како и ориентација на сателит). Системот се состои од нишало приврстено за количка што може да се движи долж шина (Сл. 1); движенето на нишалото е ограничено на вертикалната рамнина. Задачата е да се балансира нишалото во определени граници, движејќи ја количката долж шината со аплицирање на секвенца на сили со фиксна величини во дискретни моменти.



Сл. 1. Системот на инвертирано нишало

Оваа задача на учење на стратегија на управување е сложена поради непостоење на *a priori* информација за динамиката на системот. Единствената информација е векторот на состојба во момент  $t$ :

$x_t$  ..... хоризонталната позиција на количката, [m]

$\dot{x}_t$  ..... хоризонталната брзина на количката, [m/s]

$\varphi_t$  ..... аголот меѓу нишалото и вертикалата, [rad]

$\dot{\varphi}_t$  ..... аглова брзина на нишалото, [rad/s]

и "сигналот на неуспех"  $r$  кој добива вредност 1 ако аголот  $\varphi_t$  ја надмине вредноста  $\pm 12^\circ$  или количката излезе надвор од лимитот на шината.

Употребени се равенки на движење и вредности на параметрите како во [1] поради полесна споредба на резултатите:

$$\ddot{\varphi}_t = \frac{g \sin \varphi_t + \cos \varphi_t [-F_t - m_p \dot{\varphi}_t^2 \sin \varphi_t]}{(m_c + m_p)} / (m_c + m_p) \quad (8)$$

$$\ddot{x}_t = \left[ F_t + m_p (\dot{\varphi}_t^2 \sin \varphi_t - \ddot{\varphi}_t \cos \varphi_t) \right] / (m_c + m_p) \quad (9)$$

Системот е симулиран со интегрирање на равенките на движење (4) и (5) со Euler-овата метода со чекор  $\Delta t = 0.02\text{s}$ , при што управувачката сила во секој чекор е определена со правилото добиено со индуктивно учење како во [8].

Задачата во експериментот е да се научи од примери модел на преиспликувањето

$$\ddot{\varphi}_t = f_1(\varphi_t, \dot{\varphi}_t, F) \quad (10)$$

$$\ddot{x}_t = f_2(\varphi_t, \dot{\varphi}_t, F) \quad (11)$$

Независните променливи  $\varphi_t, \dot{\varphi}_t, F$  се избрани поради физичката природа на проблемот, а и поради погодност. Јасно,  $F$ , изведена според правило од информацијата за векторот на состојба, вушност е зависна од  $(x_t, \dot{x}_t, \varphi_t, \dot{\varphi}_t)$ . Меѓутоа, информацијата за сигналот  $F$  е директно достапна на системот и затоа е поприродно да се изрази  $\dot{\varphi}_t$  во зависност од  $F$ ; (имплицитната) зависност на  $\dot{\varphi}_t$  и  $\ddot{x}_t$  од целокупниот вектор на состојба притоа е осигурена преку зависноста од  $F$ . Со тоа се решуира димензионалноста на

проблемот на учење: векторот на примери има само 3 компоненти ( $\varphi_t, \dot{\varphi}_t, F$ ) наместо 4 (доколку беше употребен векторот на состојба).

## 5. ЕКСПЕРИМЕНТАЛНИ РЕЗУЛТАТИ И ДИСКУСИЈА

Првиот експеримент се однесува на брзината и точноста на учењето. Пет множества на примери беа употребени,  $L_1, \dots, L_5$  со 200, 160, 120, 80, и 40 примери ресpektивно. (Секој пример е чифт на влезно-излезни вектори  $\{(\varphi_t, \dot{\varphi}_t, F); (\dot{\varphi}_t, \ddot{x}_t)\}$ ). Овие примери беа добиени со регуларно земање на одбирачи од излезната датотека (за првите 500 чекори) при симулацијата на системот со употребување на равенките на Andersonia и правилото на управување на Sammut ([8]), и униформна редукција на бројот на примерите на соодветните вредности. Множествата  $L_1, \dots, L_5$  потоа се употребени како влезови на две верзии на алгоритмот за учење, наречени  $RL$  и  $RQ$ . Времето на учење  $T_L$  (CPU sec.) беше забележено за секој обид. По извршеното учење системот беше тестиран за точност на репродукција на првите 1000 чекори (еволуцијата на системот се одвива под истите услови како погоре), земајќи ја нормализираната грешка е дефинирана со (3) и пресметана за точно пресметаната секвенца  $\{(\dot{\varphi}_t, \ddot{x}_t)\}$  и за приближната секвенца  $\{(\dot{\varphi}_t^*, \ddot{x}_t^*)\}$  ресpektивно (за целиот интервал од 1000 чекори). Резултатите се прикажани на Слика 2 и тие го потврдуваат заклучокот за линеарната временска комплексност на овој алгоритам за учење во зависност од бројот на примерите (vide supra). Исто така се гледа дека варијантата  $RL$  е типично двојно поспора отколку варијантата  $RQ$ , но се одликува со поголема точност.




Fig. 2 Time complexity vs. sample size

Графикот на нормализираната грешка на генерализација при процесот на репродукција на првите 1000 чекори од еволуцијата на системот е прикажан на Сл. 3. Се гледа дека грешката на генерализација е останува практично константна (типично доста под 10 %) при редукција на бројот на примерите, се додека не се дојде до критична минимална вредност (40 примери во овој случај). Во тој момент грешката рашцедираше до 62 %. Сепак, резултатите укажуваат дека дури и толку "слаб" мемориски модел може да се употреби за симулација во проблемот на инвертираното нишало.

Интересно е да се повлечат некои споредби меѓу карактеристиките на оваа метода и резултатите од други истражувања. Учењето на нелинеарни пресликувачи е моќне истражуван проблем и во областа на вештачките неурални мрежи ([10], [5]). И покрај тоа што се развиени успешни методи, вклучувајќи и наши ([11], [13]), тие типично баарат големи мрежи и долго време на учење ([5]). Наспроти тоа, овој алгоритам во некои експерименти со учење на модел на динамика на работ




Fig. 3 Generalisation accuracy vs sample size

PUMA 560 се покажа подобар од најдобрите неурални методи во однос на брзината и точноста на учењето, како и способноста за генерализација ([11] и [12]).

Најпосле, интересно е да се одбележи дека овој тип на асоцијативна меморија може да се структурира и во вид на  $k$ - $d$  стебло, со мала модификација на алгоритмот за учење. Репрезентациите на сензоримоторното знаење во вид на стебло, конструирано со учење, го предизвикуваат вниманието и на други истражувачи [8]. Со таква реформулација, нашата метода може да се поврзе и спореди со методите за индуктивно симболичко учење [7].

## 6. ЗАКЛУЧОК

Во овој труд е презентирана нова метода за учење на нелинеарни пресликувања од примери. При учењето се формира репрезентација на примерите во вид на посебен тип на асоцијативна меморија (наречена AICAM), адресабилна според содржината. Методата беше применета за учење на модел на нелинеарен динамички систем и за употреба на научениот модел во симулација на еволуцијата на системот. Теориски изведените заклучоци за комплексноста на алгоритмот без и експериментално потврдени. Посебно, беше покажано дека: а) временската комплексност на алгоритмот за учење е линеарна во зависност од бројот  $N$  на примерите за учење, б) мали множества на примери се доволни за формирање на многу точни модели кои можат ефективно да се употребат наместо експлицитните, математички модели во симулацијата.

Овие резултати водат кон заклучокот дека оваа метода, како и воопшто и други геометрски репрезентации и алгоритми слични на неа (или изведени од неа) можат да бидат ефективен алат за аквизиција на знаење во комплексни интелигентни системи. Наша цел во понатамошните истражувања ќе биде разработка на овие резултати во неколку насоки, а посебно во воспоставувањето на врски помеѓу неуралните, алгоритмичко-геометриските и симболичките методи на автоматно учење во контекстот на динамичките системи.

## 7. ЛИТЕРАТУРА

- [1] C. Alkeson and D. Renckensmeyer: "Using content-addressable memories to control robots", In *Proceedings of the IEEE International Conference on Robotics and Automation, Scottsdale, AZ, 1989.*
- [2] C. W. Anderson: "Strategy learning with multilevel connectionist representations", *Proceedings of the 4th International Workshop on Machine Learning, 1987.*
- [3] A Barto et al.: "Neuronlike elements that can solve difficult control problems", *IEEE Trans. SMC, Vol. 13, pp. 835-846, July 1983.*
- [4] J. D. Farmer and J. J. Sidorowich: "Predicting chaotic time series", *Physical Review Letters, Vol. 59, pp. 845-848, August 1987.*
- [5] M. Kawato: "Computational schemes and neural network models for formation and control of multijoint arm trajectory", in *Proceedings of the NSF Workshop on Applications of Neural Networks to Robotics and Control, New Hampshire, 1989.*
- [6] D. Michie D. and R. Chambers: "Boxes: An experiment in adaptive control", in *Machine Intelligence 2 (E. Dale and D. Michie, Eds.). Edinburgh: Oliver and Boyd, 1968.*
- [7] J. R. Quinlan: "Induction of decision trees", *Machine Learning, Vol. 1, pp. 81-106, 1986.*
- [8] C. Sammut: "Experimental results from an evaluation of algorithms that learn to control dynamical systems", in *Proc. 5th Int'l Machine Learning Workshop, San Francisco, CA, 1988.*
- [9] C. Stanfill and D. Waltz: "Toward memory-based reasoning", *Comm. ACM, Vol. 29, pp. 1213-1228, December 1986.*
- [10] B. Widrow and M. A Lehr: "Thirty years of adaptive neural networks", *Proceedings of the IEEE, Vol. 78, pp. 1415-1443, September 1990.*
- [11] Z. Zografski: *Neuromorphic, Algorithmic, and Logical Models for the Automatic Synthesis of Robot Action, DSc Thesis, University of Ljubljana, Yugoslavia, 1989.*
- [12] Z. Zografski: "A learning method for the construction of associative interpolating memory models of robot inverse dynamics", in *Proc. Int'l Workshop on Sensorial Integration for Industrial Robots, Zaragoza, Spain, 1989, pp. 306-310.*
- [13] Z. Zografski: "Efficient learning of robot dynamics in a neuromorphic system", in *Proc. Int'l Neural Networks Conf., Paris. Dordrecht: Kluwer Academic Publishers, 1990, pp. 217-220.*

