

MOŽNOSTI ZA VODENJE SISTEMOV S POMOČJO METOD UMETNE INTELIGENCE

INFORMATICA 4/91

Keywords: control of dynamic systems
artificial intelligence, qualitative modelling

Tanja Urbančič
Institut Jožef Stefan

Pri vodenju dinamičnih sistemov se srečujemo s problemi tako pri načrtovanju kot pri nadzorovanju vodenja. Članek utemeljuje potrebo po alternativnih pristopih k reševanju teh problemov. Opisuje možnosti, ki jih pri tem nudijo metode umetne inteligence, zlasti avtomatsko učenje in kvalitativno modeliranje.

TOWARDS CONTROLLING DYNAMIC SYSTEMS USING AI METHODS

Two kinds of problems arise when a dynamic system is to be controlled: designing control and supervising the controlled system. In the paper, the need of alternative approaches to solving these problems is shown. Perspectives given by artificial intelligence methods are surveyed, especially those of machine learning and qualitative modelling.

1 Uvod


Vodenje dinamičnih sistemov je zahtevno področje, na katerem se kljub desetletja dolgemu razvoju teorije in akumulaciji izkušenj pojavljajo problemi, ki so s klasičnimi metodami nerešljivi. Pri tem mislimo predvsem na vodenje sistemov, ki jih zaradi njihove zapletenosti ali kompleksnosti ne moremo dovolj natančno predstaviti z matematičnim modelom. Težave nastopijo tudi, če je sprotno zagotavljanje tako natančnih numeričnih vrednosti, kot jih zahtevajo klasične metode, predrago, predolgotrajno ali sploh nemogoče. Namesto čimvečje natančnosti prihaja v ospredje potreba po robustnosti in adaptivnosti, vse bolj pa tudi po razumljivosti vodenja sistemov. Izkazalo se je namreč, da se popolna avtomatizacija nadzora procesa v praksi ne obnese najbolje. Operaterji si želijo predvsem orodje, ki opravlja rutinske operacije in reagira v najkrajšem možnem času, kadar je treba zagotoviti varnost, sicer pa prepušča končno odločitev človeku, pri čemer mu pomaga z interpretacijo opazanj in s predlogi za ukrepanje. Proučiti

želimo, kako je na tem področju možno izkoristiti metode umetne inteligence, predvsem metode avtomatskega učenja (Bratko 1989) in kvalitativnega modeliranja (Weld & de Kleer 1990).

2 Identifikacija problemov

Za lažjo identifikacijo problemov si najprej ogledimo grobo poenostavljen prikaz klasično vodenega sistema (slika 1). Sistem (S), ki ga želimo voditi, je skupaj z regulatorjem (R) zaprt v zanko. V tej regulacijski zanki se na podlagi reference (r) in dejanskega odziva (y) računa napaka (e), nato pa se določa in izvaja kontrolna akcija (u). Obstaja več vrst klasičnih regulatorjev, med njimi npr. preprost in široko uporaben PID-regulator, ki upošteva trenutno napako (P-člen), integral napake (I-člen) in predikcijo na osnovi odvoda napake (D-člen):

$$u(t) = k_P e(t) + k_I \int_0^t e(t) dt + k_D e'(t)$$



Slika 1: Regulacijska zanka z operaterjevim nadzorom

Sistem nadzoruje operater. Pogosto se dogaja, da zaradi neustrezne izbire oziroma nastavitve regulatorja ali pa zaradi spremenjenih okoliščin delovanja vodenje sistema ni zadovoljivo. V takih primerih je treba ukrepati. Obstajajo zapletene matematične metode za doseganje robustnosti in adaptacijo, kljub temu pa se zaenkrat pojmuje, da je pri nadzoru in ukrepanju človek nepogrešljiv. Znano je, da je človek sposoben "ročno" voditi tudi dokaj zapletene sisteme. To je možno zaradi njegove sposobnosti *kvalitativnega sklepanja*. Pri tem je bistvena zmožnost opazovanja in interpretacije pojavov v kvalitativnem smislu, pogosto pa ima velik pomen tudi *upoštevanje izkušenj*. Vendar pa je treba upoštevati, da je delo operaterja podvrženo psihofizičnim faktorjem, kot so nemotiviranost, utrujenost ali stres zaradi kritičnosti situacije. Problem je lahko tudi kratek čas, v katerem je treba interpretirati veliko število hkratnih informacij in se odločiti za ukrepanje. Zato je pri tem delu pomoč računalnika lahko zelo dragocena.

Ocenjujemo, da lahko metode umetne inteligence pomagajo reševati probleme pri ključnih fazah, potrebnih za vodenje sistemov:

- pri *načrtovanju klasičnega vodenja* (npr. Pang 1989), zlasti pri določanju numeričnih parametrov regulatorja in morda celo pri sintezi pravil za nastavljanje parametrov,
- pri *adaptivnem vodenju* za sprotno prilagajanje parametrov regulatorja spremembam v

procesu (Litt 1991),

- pri *načrtovanju kvalitativnega vodenja* (t.j. vodenja na osnovi kvalitativnih informacij o sistemu), kadar ne moremo uporabiti klasičnih metod, ker ne moremo razviti matematičnega modela, ki bi dovolj dobro odražal realnost (npr. Sammut & Michie 1991),
- pri *nadzorovanju* vodenega procesa: s podporo pri ugotavljanju stanj in dinamičnih tendenc sistema, ki bi lahko privedle do nedopustne degradacije delovanja sistema, ter z nasveti za ukrepanje (Dvorak 1987).

3 Kvalitativno vodenje

Ena izmed možnosti za kvalitativno vodenje sistema je uporaba takoimenovanega *površinskega znanja*, ki je vzorčno vodeno in je ponavadi izraženo s preprostimi pravili oblike

če situacija S, potem akcija A

Tovrstno znanje je zelo operativno. Vodenje z njim je preprosto in včasih zadošča. Lahko pa se zgodi, da naletimo na težave pri izgradnji in preverjanju takšne baze znanja. Predvideti in eksplicitno navesti je namreč treba vse možne primere, kar je pri kompleksnejših sistemih seveda vprašljivo. Če se sistem znajde v stanju, ki ga nismo predvideli, je program povsem nemočen. Tudi v primerih, ko je vodenje uspešno, pa lahko nudi le šibko razlago.

Problem izgradnje baze znanja rešujemo z metodami za *avtomatsko sintezo znanja*. Znanje za vodenje sistemov je možno sintetizirati na dva v osnovi različna načina. Pri prvem sintetiziramo znanje neposredno iz poskusov s sistemom, tako da se učimo iz njihovih izidov. Bistvene so numerične evaluacije uspešnosti posameznih kontrolnih odločitev, ki vplivajo na morebitno spremembo kontrolnih odločitev v nadaljevanju poskusov. Na tem principu delujejo znani programi za avtomatsko učenje vodenja sistemov, kot so BOXES (Michie & Chambers 1968), AHC (Barto in sod. 1983; Selfridge in sod. 1985) in CART (Connel & Utgoff 1987). Kot ugotavljamo v članku (Urbančič 1990), so prednosti teh pristopov v tem, da ne potrebujejo poznavanja dinamike sistema in da so zmožni adaptacije

tudi v precej spremenjenih pogojih delovanja. Obravnavali smo tudi njihove pomanjkljivosti, kot npr. netransparentnost zaradi ad hoc izbranih numeričnih parametrov, (pre)dolgotrajno eksperimentiranje in nezanesljivost naučenih pravil. Tem težavam se skušamo izogniti z drugim načinom, pri katerem znanje za vodenje izpeljemo s pomočjo znanja o sistemu, ki ga želimo voditi. O tem govori naslednji razdelek.

4 Kvalitativni modeli in vodenje sistemov


Novejši ekspertni sistemi uporabljajo tudi *globoko znanje*, ki je kompaktnejše ter odraža strukturo in globlje principe problemskega področja. V zvezi s tem se postavljata vprašanji, kako globoko znanje predstaviti in kako ga uporabiti za reševanje problemov.

Globoko znanje lahko predstavimo s *kvalitativnimi modeli*. Ti opisujejo delovanje sistemov in naprav na enostaven simboličen način, ki je blizu človekovemu načinu mišljenja. Natančne numerične vrednosti niso potrebne: vse vrednosti spremenljivke, ki dajo kvalitativno isto vedenje sistema, združimo v eno samo kvalitativno vrednost. Spremenljivke so vezane z relacijami in ne z enačbami kot pri klasičnih modelih. Relacije imajo lahko obliko omejitvenih enačb, neenačb ali logičnih izjav. Podrobnejši pregled področja najdemo v knjigi (Weld & de Kleer 1990).

Končni cilj predstavitve znanja je seveda njegova uporaba. Za razliko od matematičnih modelov, pri katerih rešujemo enačbe in računamo vrednosti funkcij v danih točkah, postanejo kvalitativni modeli operativni s *kvalitativnim sklepanjem*. Spremenljivkam določamo kvalitativne vrednosti tako, da je zadoščeno relacijam v modelu.

Kvalitativni modeli določajo relacije med vhodi v sistem, kvalitativnimi stanji sistema in izhodi. Najpogostejši in "najnaravnejši" način sklepanja začne z znanim začetnim stanjem in vhodi v sistem, nato pa v skladu z modelom razvija nadaljnje vedenje sistema. V tem primeru govorimo o *kvalitativni simulaciji* (npr. Kuipers 1986). Z njo je možno neposredno reševati probleme, kot so na primer napovedovanje vedenja sistema, verifikacija načrtov, izpeljava vseh možnih stanj sistema in prehodov med njimi (envisioning).

Reševati želimo tudi drugačne probleme, ki so v nekem smislu obratni prejšnjim: izhajamo iz podanega vedenja sistema in ugotavljamo, kako lahko do njega pride. Kadar gre za diagnostiko, izhajamo iz manifestiranega nezaželenega vedenja in iščemo stanja, ki so ga povzročila. Pri problemu vodenja sistema je podano zaželeno vedenje, poiskati pa je treba zaporedje vhodov (akcij), ki pri danem začetnem stanju tako vedenje zagotovijo. Za neposredno reševanje takih problemov z modelom je potrebno *uzvratno sklepanje*.



Slika 2: Avtomatska sinteza pravil za vodenje, pristop z izčrpno kvalitativno simulacijo

Učinkovitost sklepanja pri tovrstnih problemih lahko povečamo na različne načine. Eden od njih je modeliranje na različnih nivojih podrobnosti in upoštevanje hierarhij pri sklepanju (Mozetič in sod. 1990): rezultati na manj podrobnem nivoju usmerjajo sklepanje na bolj podrobnem. Druga možnost je uporaba izčrpnih simulacij za generiranje enostavnih površinskih pravil, s katerimi je možno hitro reševati probleme na nivoju natančnosti modela. Postopek je ponazorjen na sliki 2 in smo ga že uporabili za avtomatsko sintezo pravil za vodenje inverznega nihala (Urbančič 1991). Če je problemsko področje preobsežno za izčrpno simulacijo in iz ogromne množice možnih primerov velika večina dejansko nikoli ne nastopi, je smiselno uporabiti kombinacijo površinskega in globokega znanja. Za pogoste situacije vgradimo plitvo operativno

znanje, v izjemnih situacijah pa izpeljemo rešitev neposredno iz modela in tako dobljeno pravilo naknadno vključimo v plitvo bazo znanja. Seveda se moramo pred uporabo te metode prepričati, da kritičnost in hitrost procesov to dopuščata.

Medtem ko so se kvalitativni modeli na nekaterih tehničnih področjih kmalu izkazali kot primerno orodje za reševanje problemov, npr. pri diagnostiki (Davis 1984; Genesereth 1984), so možnosti njihove uporabe na področju vodenja sistemov še relativno neraziskane (Franklin 1990). Nekateri rezultati pa vendarle tudi tukaj kažejo na obetavnost kvalitativnega pristopa:

- kvalitativne modele je možno uporabljati za načrtovanje vodenja (npr. Leitch & Francis 1986; Bratko 1991; Urbančič 1991),
- v posebnih primerih (linearni modeli) je možno na podlagi kvalitativnega modela izvesti analizo perturbacij in določiti, kako s perturbacijo vhodnih parametrov dosežemo željeno vedenje sistema (de Mori & Prager 1989),
- kvalitativni modeli lahko pripomorejo k inteligentnemu monitoringu, zaenkrat predvsem v kontekstu diagnostike (Forbus 1987; Dvorak & Kuipers 1989),
- rezultate kvalitativne simulacije lahko uporabimo za analizo stabilnosti vodenih sistemov (Fouche & Kuipers 1991).

Obetavne so tudi študije primerov (npr. Bratko in sod. 1989; Bratko in sod. 1991; Varšek 1991), ki kažejo, da lahko avtomatsko učenje učinkovito uporabimo pri avtomatizirani gradnji kvalitativnih modelov iz opazovanega vedenja sistema.

Vendarle pa še ni bila dosežena stopnja širše praktične uporabnosti. Eden izmed razlogov je gotovo težek problem prevajanja kvantitativnih opažanj v kvalitativni jezik ter kvalitativnih zaključkov v kvantitativne vrednosti kontrolnih akcij. Razen tega je treba poskrbeti za delovanje v realnem času, za upoštevanje različnih tipov znanja (npr. vzročno znanje o sistemu, nujne akcije za zagotavljanje varnosti, verjetnost za posamezne okvare v sistemu in na senzorjih) ter za obvladovanje kompleksnosti. Niso namreč redki sistemi z nekaj tisoč komponentami.

5 Zaključek

Poudariti želimo, da pri razvoju alternativnih metod za vodenje sistemov ne gre za tekmovanje s klasičnimi, kvantitativno orientiranimi pristopi, pač pa za smiselno dopolnjevanje:

- Če je možno sistem v sprejemljivem času res ustrezno predstaviti z matematičnim modelom in so izpolnjene predpostavke za klasične postopke načrtovanja vodenja, bo tako dobljeno vodenje seveda zmeraj natančnejše od kakršnegakoli kvalitativnega pristopa. Veliko prednost predstavljajo tudi teoretično podprte metode za obravnavanje pomembnih vprašanj, kot npr. določanje območja kontrolabilnosti, stabilnosti ipd., ki jih je v takih primerih možno uporabiti. Kvalitativne pristope je v tem kontekstu smiselno uporabiti le kot dopolnilo zaradi zagotavljanja razlage oziroma transparentnosti vodenja ter zaradi nudenja pomoči operaterju pri nadzorovanju procesa.
- Če ustreznega matematičnega modela v sprejemljivem času ne moremo razviti ali pa le-ta (od samega začetka ali pa čez čas, ko se razmere spremenijo) ne odraža dovolj verno realnosti, je treba iskati kompromis med natančnostjo rešitve in hitrostjo oziroma ceno, ki je za to potrebna. Problem bi lahko formulirali kot iskanje konceptualno jasnih, čeprav manj natančnih rešitev, ki bi se obnesle v praksi ne le zaradi razumljivosti, pač pa nenazadnje tudi zaradi nižje cene.

Literatura

- Barto, A.G., Sutton, R.S., Anderson, C.W. (1983) Neuronlike Adaptive Elements That Can Solve Difficult Learning Control Problems. *IEEE Transactions on Systems, Man and Cybernetics*, Vol. SMC-13, No.5, 834-846.
- Bratko, I. (1989) *Machine Learning*. V knjigi K.J. Gilhooly (ur.) *Human and Machine Problem Solving*, Plenum Press, New York.
- Bratko, I., Mozetič, I., Lavrač, N. (1989) *KAR-DIO: A study in deep and qualitative knowledge for expert systems*. Cambridge, MA: MIT Press.
- Bratko, I. (1991) *Qualitative Modelling: Learning and Control*. Sixth Czechoslovak Conference on

Artificial Intelligence, Prague, June 1991.

Bratko, I., Muggleton, S., Varšek, A. (1991) Learning qualitative models of dynamic systems. Inductive Logic Programming Workshop 91, Viana de Castelo, Portugal, March 1991. A short version also in Proc. Machine Learning 91, Morgan Kaufmann.

Connel, M.E., Utgoff, P.E. (1987) Learning to Control a Dynamic Physical System. In Proceedings of the 6th National Conference on Artificial Intelligence, Morgan Kaufmann, 456-459.

Davis, R. (1984) Diagnostic Reasoning Based on Structure and Behavior. Special Volume on Qualitative Reasoning about Physical Systems, Artificial Intelligence, 24(1-3), 347-410.

Dvorak, D.L. (1987) Expert Systems for Monitoring and Control. Technical Report AI 87-55, Artificial Intelligence Laboratory, The University of Texas at Austin.

Dvorak, D., Kuipers, B. (1989) Model-Based Monitoring of Dynamic Systems. In Proceedings of the Eleventh International Joint Conference on Artificial Intelligence, August 20-25, Detroit, MI, 1238-1243.

Forbus, K.D. (1987) Interpreting Observations of Physical Systems. IEEE Transactions on Systems, Man and Cybernetics, Vol. SMC-17, No.3, 350-359.

Fouche, P., Kuipers, B. (1991) Introducing Energy into Qualitative Simulation. First European Workshop on Qualitative Reasoning about Physical Systems, Genova, January 1991.

Franklin, J.A. (1990) What is Qualitative Reasoning, and Can We Use it for Control? Proceedings of the 29th IEEE Conference on Decision and Control, Dec. 1990, Honolulu, HI.

Genesereth, M.R. (1984) The Use of Design Descriptions in Automated Diagnosis. Special Volume on Qualitative Reasoning about Physical Systems, Artificial Intelligence, 24(1-3), 411-436.

Kuipers, B. (1986) Qualitative Simulation. Artificial Intelligence 29, 289-338.

Leich, R., Francis, J.C. (1986) Towards Intelligent Control Systems. In Mamdani, A., Efstathiou, J. (eds.) Expert Systems and Optimisation in Process Control. Gower Technical Press, Aldershot, England, 62-73.

Litt, J. (1991) An Expert System to Perform On-

Line Controller Tuning. IEEE Control Systems Magazine, Vol.11, No.3, 18-23.

Michie, D., Chambers, R.A. (1968) BOXES: An experiment in adaptive control. In Dale, E., Michie, D. (eds.) Machine Intelligence 2, Edinburgh University Press, 137-152.

de Mori, R., Prager, R. (1989) Perturbation Analysis with Qualitative Models. In Proceedings of the Eleventh International Joint Conference on Artificial Intelligence, August 20-25, Detroit, MI, 1180-1186.

Mozetič, I., Bratko, I., Urbančič, T. (1991) Varying level of abstraction in qualitative modelling. V knjigi J.E.Hayes, D.Michie, E.Tyugu (eds.) Machine Intelligence 12, Oxford University Press, 259-280.

Pang, G. (1989) Knowledge engineering in the computer-aided design of control systems. Expert Systems, Vol.6, No.4, 250-262.

Sammut, C., Michie, D. (1991) Controlling a "Black Box" Simulation of a Space Craft. AI Magazine, Vol.12, No.1, 56-63.

Selfridge, O.G., Sutton, R.S., Barto, A.G. (1985) Training and Tracking in Robotics. In Proceedings of the 9th International Conference on Artificial Intelligence. Morgan Kaufmann, 670-672.

Urbančič, T. (1990) Avtomatsko učenje vodenja dinamičnih sistemov. Informatica, letnik 14, št. 4, 39-48.

Urbančič, T. (1991) Automatic model-based synthesis of control rules for inverted pendulum. First European Workshop on Qualitative Reasoning about Physical Systems, Genova, January 1991.

Varšek, A. (1991) Qualitative model evolution. International Joint Conference on Artificial Intelligence, Sydney, September 1991.

Weld, D.S., de Kleer, J. (eds.) (1990) Readings in Qualitative Reasoning about Physical Systems. Morgan Kaufmann, San Mateo, CA.