

Tomislav Grladinović<sup>1</sup>, Jože Kropivšek, Leon Oblak<sup>2</sup>

# Suvremeno upravljanje proizvodnjom i poslovanjem u preradi drva i proizvodnji namještaja

## Modern production and business management in wood processing and furniture manufacture

### Pregledni rad • Review paper

Prispjelo – received: 2. 3. 2007.

Prihvaćeno – accepted: 12. 6. 2007.

UDK: 684.4; 658.5.012.4:004.8

**SAŽETAK** • Razvoj suvremenih tehnologija i uvođenje visokog stupnja automatizacije proizvodne opreme, od numerički upravljanih strojeva preko obradnih centara do fleksibilnih tehnoloških linija, s već realiziranim rješenjima automatiziranih tvornica, pridonio je porastu značenja funkcije upravljanja proizvodnjom. S obzirom na to da se dio dosadašnjih, isključivo proizvodnih funkcija (davanje naloga za početak rada, provjera mjere i odabir početnih parametara, uključivanje i izbor glavnih i pomoćnih zahvata, a time i režima obrade i sl.) prenosi i rješava u funkciji upravljanja proizvodnjom i poslovanjem, sve je veće značenje upravljanja proizvodnjom i njezin utjecaj na djelotvornost proizvodnje i poslovanja tvrtke za preradu drva i proizvodnju namještaja. Sve to potiče na nov pristup u upravljanju proizvodnjom i poslovanjem s drvom: sustavni pristup, sustavna potpora odlučivanju, ekspertni sustavi, heuristika, neuralne mreže, logističko prognoiranje, modeliranje za učenje, simuliranje, teorija kaosa te informacijski sustavi podržani softverskim paketima za povećanje djelotvornosti pojedinih funkcija računalom integrirane proizvodnje. Upotrebljivi zajednički imenitelj je umjetna inteligencija. Konceptijama je zajedničko da se na temelju sposobnosti razumijevanja, zaključivanja, učenja, primjene znanja i informacijskih tehnologija, opažanja i prepoznavanja događaja i objekata mogu koristiti u smislu savjetodavne inteligentne potpore procesima odlučivanja i upravljanja. Te se koncepcije međusobno dopunjuju i čine opću logističku koncepciju, koja u preradi drva i proizvodnji namještaja može poprimiti različite oblike, od tzv. smisao-znanje tehnologije do informacijske tehnologije, bez obzira na to o kakvoj je koncepciji riječ. Ona mora davati suvisle odgovore te rješavati situacije u opsegu u kojemu smo je opskrbili znanjem o proizvodnji i poslovanju tvrtke za preradu drva i proizvodnju namještaja. Takvo savjetodavno svojstvo prikazanih koncepcija čvrst je oslonac u okolini koja zbunjuje.

**Ključne riječi:** prerada drva i proizvodnja namještaja, umjetna inteligencija, ekspertni sustavi, sustavi za potporu odlučivanju, inteligentni proizvodni sustavi

**ABSTRACT** • The development of modern technologies with high-tech automated equipment, such as numerically controlled machines, processing centres, or flexible technological lines, with already realised solutions of automated factories, has contributed to increased significance of the production management function. Considering that

<sup>1</sup> Autor je izvanredni profesor Šumarskog fakulteta Sveučilišta u Zagrebu, Hrvatska. <sup>2</sup> Autori su docenti Biotehničkog fakulteta Sveučilišta u Ljubljani, Slovenija.

<sup>1</sup> The author is associate professor at the Faculty of Forestry, University of Zagreb, Croatia. <sup>2</sup> The authors are assistant professors at the Biotechnical Faculty, University of Ljubljana, Slovenia.

one part of the present exclusively production functions (issuing work orders; measurement checking and choice of initial parameters; introduction and choice of main and subordinate operations; processing regime, etc.) is being transferred and solved in the function of production and business management, the significance of production management and its impact upon the effectiveness of wood processing and furniture manufacturing firms is on constant increase. Thus, a new approach to the production and business management in wood processing will be initiated by applying the following: system approach; system decision support; expert systems; heuristics; neural networks; logistic programming; modelling for learning; simulation; theory of chaos, and information systems supported by software packages for efficiency increase of individual functions of computer-aided integrated production. The applicable common nominator is artificial intelligence. Various concepts have a common feature: based on the capability of understanding, making conclusions, learning, application of knowledge and information technologies, observation and recognition of events and objects, different concepts can be used as intelligent support to the processes of decision making and management. These concepts are interactive, forming a general logistic concept, which can adopt different forms in wood processing and furniture manufacture. It must be capable of giving reasonable answers, and solving issues in accordance with the degree of knowledge we have supplied it. Such advisory property of the presented concepts is a firm support in a perplexed environment.

**Key words:** wood processing and furniture manufacture, decision support systems, intelligence production system, expert systems, artificial intelligence

*... mi poznajemo podatke, ne realnost. Zato se moramo baviti 'svijetom' podataka. Moramo proučiti obilježja tog svijeta prije no što budemo mogli pravilno razumjeti njegove zakone i projektirati informacijske sustave koji će ih odražavati. Ima li prostor podataka inherentnu (vlastitu) organizaciju ili je samo podložan organizaciji prema našem htijenju (izboru)? Koja je dimenzionalnost prostora podataka? Može li prostor podataka biti samoorganizirajući? Koji se tipovi procesa odvijaju u prostoru podataka?...*

R. R. Korfhage i sur. Data Physics –  
An Unorthodox View of Data and  
its Implications in Data Processors,  
Syracuse University, kolovoz 1978.

## 1. UVOD 1 INTRODUCTION

Čovjekove su sposobnosti percepcije i reagiranja na događaje ograničene. Potrebno mu je računalo koje će nadzirati i voditi procese te upravljati njima. Nužan mu je i robot koji će umjesto njega obavljati opasne i neugodne poslove, kao i poslove koji zahtijevaju preciznost, ponavljanje i kvalitetu. Razvoj elektronike donosi automatizaciju proizvodnje, koja prvi put omogućuje postizanje planirane količine proizvoda.

Proizvodnju je potrebno dobro i kvalitetno pripremiti, ali i precizno planirati kako bi se svi poslovi obavili najbrže, uz optimalni utrošak svih proizvodnih resursa: materijala, rada, novca, informacija, instrumentarija i energije. Konkurencija proizvođača sve je jača i automatizacija prerasta u automaciju. Nije više dovoljno samo raditi i planirati, nego to treba činiti na mudar način.

Međutim, iako su se uvjeti odvijanja proizvodnje umnogome poboljšali i humanizirali, a sam rad više nije tako opasna i prljava aktivnost (kao nekad), čovjek nije zadovoljan. Znanost, istraživanje, umjetnost, šport, putovanja, zabava i ostale razonode čine se primjerenima čovjeku.

Prvi put čovjek ima takav tehničko-tehnološki instrumentarij uz pomoć kojega mu se čini mogućim ostvariti svoje zamisli. Po uzoru na nj izgrađuje sustave koji se neupućenome promatraču čine inteligentnima,

koji djeluju baš onako kako bi djelovao taj promatrač u istoj toj situaciji (što bi radio, kako bi razmišljao).

Roboti zaobilaze prepreke, obavljaju izbor dijelova koje treba postaviti na stroj ili prenijeti na određeno mjesto, odlučuju kojim redosljedom obavljati niz zadanih poslova i još mnogo toga što su do jučer radili ljudi. Fleksibilni proizvodni sustavi autonomno odlučuju o tome što, koliko, kada i kako proizvoditi. Osim tehničko-tehnoloških preduvjeta, za takvo što potrebno je koncipirati, osmisliti, teorijski razraditi, ispitati i provjeriti logičke, matematičke i fizičke modele i metode. Svi ti modeli i metode, a posebno matematički i logički, koji se izravno ili neizravno primjenjuju u proizvodnji, potječu od operacijskih istraživanja koja povezuju stručnjake tehničkih, prirodnih i društvenih znanosti. Samo je na takav cjelovit i sveobuhvatan način moguće najbolje riješiti postavljene zadatke (Benić, 1995).

## 2. DOSADAŠNJE SPOZNAJE 2 PREVIOUS KNOWLEDGE

### 2.1. Umjetna inteligencija 2.1 Artificial Intelligence

Kao i sami korijeni tzv. treće industrijske revolucije, operacijska su istraživanja izravna posljedica Drugoga svjetskog rata. Tijekom vremena neka su se područja teorije i primjene, koja su u početku bila unutar operacijskih istraživanja, osamostalila i razvila kao za-

sebna i ravnopravna. Danas se za neka od njih upotrebljava zajednički imenitelj *umjetna inteligencija* (*artificial intelligence*). Brojne su definicije koje na manje ili više precizan način pojmovno objašnjavaju što je umjetna inteligencija. U ovim ćemo se razmatranjima osloniti na jednu, koja je, čini se, najpraktičnija za primjene što ih u ovom tekstu razmatramo (\*\*\*, 1990).

Umjetna je inteligencija proces proučavanja ideja koje računalima omogućuju inteligenciju.

Međutim, postavlja se pitanje što je inteligencija. Čovjeku se, kada se spomene taj pojam, najčešće javljaju različite asocijacije, kao što su:

- sposobnost razumijevanja i zaključivanja
- sposobnost učenja i primjene znanja
- sposobnost opažanja i prepoznavanja fizičkih objekata.

Sigurno je da sve te sposobnosti čine ono što se obično razumijeva pod pojmom inteligencije, no ipak sama definicija inteligencije, u uobičajenom smislu značenja tog pojma, ostaje nedorečena. Inteligencija je ujedno i sposobnost primanja, obrade, prikazivanja i uporabe informacija, a to je sposobnost ugrađena u mnoge računalne programe namijenjene specifičnim primjenama. Bez obzira na sve to, osnovni ciljevi primjene umjetne inteligencije jesu:

- učiniti računala korisnijima pri obavljanju zadanih poslova
- razumjeti temeljna načela koja čine inteligenciju.

To pak treba pridonijeti učinkovitijem rješavanju problema. U svemu onome što se danas razumijeva pod pojmom umjetne inteligencije zamjetne su neke, isključivo općeljudske osobine, koje moraju biti standardni atributi sustava što "posjeduju" inteligenciju (\*\*\*, 1990). To su:

1. jezik razumijevanja (komunikacije); sustav tim jezikom može komunicirati s okolinom, najčešće s čovjekom,
2. kreiranje opisa novih situacija; sustav može definirati nove pojmove i relacijske odnose među njima, i to međusobno i u odnosu prema postojećim pojmovima,
3. prikupljanje i izbor informacija; sustav mora biti sposoban kontinuirano prikupljati informacije, analizirati ih i izabrati bitne među njima,
4. kreiranje modela za zadanu okolinu; na osnovi poznatih i/ili zadanih podataka sustav kreira model (kvantitativni, kvalitativni) za danu okolinu,
5. simboličko razumijevanje i zaključivanje; s obzirom na to da se podaci jednom takvom sustavu zadaju na simbolički način, sustav ih mora moći razumjeti i iz njih izvesti svrhovite i realne zaključke,
6. interpretacija dobivenih rezultata; sustav mora znati autonomno interpretirati i objasniti dobivene rezultate - simbole vlastitog zaključivanja na čovjeku jasan i blizak način,
7. rješavanje problema i bez uporabe numeričkih algoritama; poželjno je tu funkciju (ako je ikako moguće) ugraditi u sustav,
8. učenje; sustav akumulira nove činjenice radi razvoja znanja,

9. manipulacije velikom količinom podataka; brzo i djelotvorno pretraživanje dinamičke baze znanja (baza znanja čiji opseg podataka s vremenom raste),
10. planiranje i priprema akcija za postizanje cilja; za neki unaprijed zadani cilj, na osnovi postojećeg znanja i stanja, sustav treba moći i znati autonomno pripremiti i isplanirati sve akcije potrebne za njegovo ostvarenje,
11. manipulacija ambicioznim i/ili nesigurnim znanjem; sustav mora moći raditi s podacima koji imaju deterministički ili stohastički karakter.

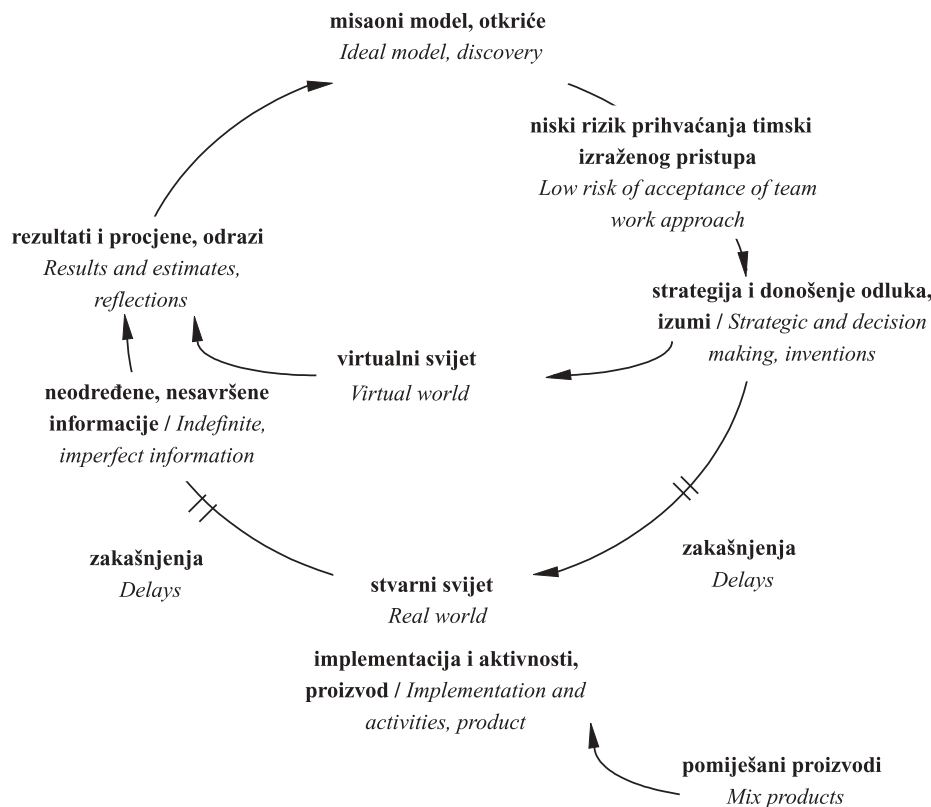
Sve navedene sposobnosti omogućit će sustavu da autonomno djeluje i da se prividno ponaša kao inteligentni sustav. Tih jedanaest načela u današnjim su uvjetima prilično visoko postavljeni zahtjevi za nešto što će se proglasiti inteligentnim autonomnim sustavom. Objektivno razmatrajući te zahtjeve, nijedan današnji sustav koji djeluje u praksi ne posjeduje baš sve navedene zahtjeve, već samo većinu njih. No to i nije važno jer je čovjek u tome ionako tek na početku (Benić, 1995).

Odgovor na te visoke zahtjeve i jedno od rješenja jesu sustavi za potporu odlučivanju (*decision support*). Modeliranje za učenje (*modelling as learning*) novi je put kojim se želi napraviti proboj u budućnost. I već se čini da bi i praktični rezultati mogli biti primjereniji aktualnoj situaciji. Logičko programiranje (*logical programming*), utemeljeno na reagiranju na događaj kao osnovni motiv neke akcije, mnogo obećava. Čini se da je to prirodan način rješavanja problema - tako to rade i priroda i čovjek. Prethodnu generaciju deklarativno usmjerenih računalnih jezika istiskuje nova, na objekte usredotočena generacija tih istih programskih jezika. No danas su oni redefinirani na načelu deklarativno-aritmetičkoga i vizualnog programiranja bliskoga čovjeku. Čini se da su računala već pomalo dorasla tome da u realnom vremenu mogu kreirati virtualne svjetove (*virtual reality*), koji bi kao inkarnacija istinske primjene računalne grafike inteligentnim autonomnim sustavima trebali omogućiti uvjerljivost u komunikaciji s čovjekom, te holografskoj prezentaciji znanja i rješenja dobivenih proceduralnom i logičkom analizom problema (sl. 1). Sve je to moguće jer se čini (a je li uistinu tako?) da je već otprije skupljena dovoljna kritična količina znanja (formalnih postupaka, metoda i modela) koja mora rezultirati novim probojima. U šumi novih pojmova, područja i pristupa rješavanju problema rađa se i teorija kaosa (*chaos theory*), koja nastoji razmrsiti (naizgled) zapetljanu situaciju. Cilj joj je stvoriti opći svjetski model zbivanja, kako bi se njegovim proučavanjem razumjele i nove spoznaje (Benić, 1995).

## 2.2. Neka motrišta umjetne inteligencije u industrijskoj proizvodnji

### 2.2 Some views of artificial intelligence in industrial production

Suvremena industrijska proizvodnja i, posebice, CIM (*Computer Integrated Manufacturing* - računalom integrirana proizvodnja) koncepcija pogodno su tlo za primjenu svega onoga što danas obuhvaća umjetna inte-



**Slika 1.** Virtualni svijet - okruženje učenja (Forrester, 1992)  
**Figure 1** Virtual world – learning environment (Forrester, 1992)

ligencija. Suvremeni trendovi u razvoju i implementaciji umjetne inteligencije u industrijsku proizvodnju jesu:

- razumijevanje kontinuiranoga govora
- razvoj i realizacija sustava za planiranje vremena (rokovi izrade), planiranje postupaka obrade, dijagnozu opreme, nadzor i upravljanje industrijskim procesima, automatsko generiranje planova rada, izbor instrumentarija i opreme (znanstveno upravljanje, *scientific management*) (Katalinić, 1992).

Osim navedenih, aktualni su i trendovi prepoznavanja i izbora dijelova-pozicija-predmeta, što je i preduvjet primjene robota i manipulatora u mnogim područjima tehnologije. Sve bi to pak trebalo omogućiti da CIM kao koncepcija jednog dana zaživi u stvarnosti.

Suvremena je industrijska proizvodnja nezamisliva bez organizacije proizvodnje. Preduvjet djelotvornog ostvarivanja takve proizvodnje u CIM koncepciji jest sustav planiranja i vođenja proizvodnje - PPS (*Production Planning System*), utemeljen na osnovnim logističkim načelima. Logistika se kao istoznačnica onoga što se naziva organizacijom proizvodnje može definirati kao znanstvena disciplina koja proučava i rješava probleme planiranja, pripreme, opskrbe, raspodjele, kontrole, praćenja i upravljanja svim resursima i njihovim tijekovima s ciljem optimizacije ukupnih troškova u procesima proizvodnje (Grladinović, 1999).

Današnje suvremene koncepcije logistike i pristup primjeni umjetne inteligencije u industrijskoj se proizvodnji očituju uključivanjem ovih metoda i načina rješavanja problema:

- ekspertnih sustava u klasičnom smislu (*expert systems*)

- sustava za potporu odlučivanju (*decision support systems*)
- modeliranja za učenje (*modelling for learning*).

Osim samih koncepcija, umjetna inteligencija razumijeva i niz specifičnih i općih metoda što ih te koncepcije trebaju oživotvoriti. Spomenimo samo neke specifične:

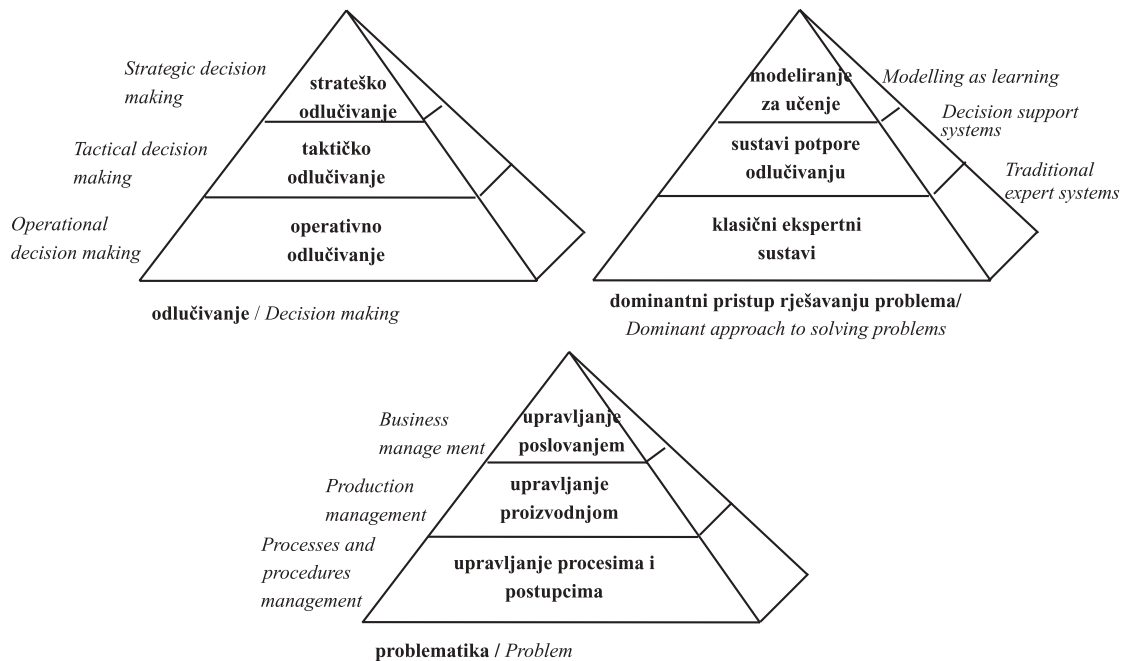
- računalno učenje (*machine learning*)
- heuristika (*heuristics*)
- logičko programiranje (*logical programming*)
- neuralne mreže (*neural networks*)
- teorija kaosa (*chaos theory*) (Benić, 1995).

Pri tome je osnovni cilj razviti inteligentne sustave koji bi trebali preuzeti nadzor i upravljanje proizvodnjom. Njihova je konkretna zadaća primjena u:

- inteligenciji informacijskog sustava
- potpori poslovnom odlučivanju
- dijagnostici (prepoznavanju oblika, predmeta, mjerenju)
- oblikovanju proizvoda
- projektiranju tehnoloških postupaka
- projektiranju proizvodnih procesa i sustava
- planiranju i praćenju proizvodnje (\*\*\*, 1990).

Na slici 2. u obliku triju piramida konceptualno je i relacijski predočena paradigma povezanosti koncepcija primjene umjetne inteligencije, razine odlučivanja te vrste problema koji treba riješiti u tipičnoj industrijskoj tvrtki (Benić, 1995).

Najniža razina problematike sa stajališta logistike svake industrijske tvrtke jest upravljanje postupcima i procesima s kojima se susrećemo na razini operativnog odlučivanja. Zbog prirode problema što ih treba riješiti,




**Slika 2.** Hijerarhijske piramide rješavanja problema u industrijskoj tvrtki (Benić, 1995)  
**Figure 2** Hierarchy pyramids of problem solution in industrial companies (Benić, 1995)

u tim se slučajevima obično primjenjuje klasični ekspertni sustav. Na temelju baze znanja i mehanizma isključivanja, takvi sustavi brzo i učinkovito rješavaju probleme dijagnostike u najširem smislu te riječi.

Na višoj taktičkoj razini odlučivanja treba riješiti probleme upravljanja proizvodnjom. Za takve se tipove problema u današnje vrijeme uobičajila uporaba sustava za potporu odlučivanju. Na temelju proceduralno ugrađenog znanja i pristupa bazama podataka, prethodni sustavi, kao inteligentno djelujući programi, imaju ulogu čovjekova pomoćnika i savjetnika.

Modeliranje za učenje dominantan je pristup rješavanju problema poslovanja. Kako industrijska tvrtka djeluje u zadanoj okolini, modeliranje mora biti prilagodljivo zahtjevima te okoline, a ujedno mora moći utjecati na zahtjeve okoline. Zbog toga je potrebno izgraditi model poslovanja tvrtke u koji treba uklopiti sve bitne čimbenike okoline. Na taj način, na razini strateškog odlučivanja, primjenom sustavske dinamike simulacija i prognoziranja, u interakciji s neuralnom mrežom, treba istražiti i predvidjeti scenarij budućnosti te prilagoditi tvrtku zahtjevima koje donosi budućnost (Benić, 1995).



**Slika 3.** Ekspertni sustav (Grladinović, 1999)  
**Figure 3** Expert systems (Grladinović, 1999)

### 2.3. Ekspertni sustavi

#### 2.3 Expert systems

Klasična koncepcija ekspertnog sustava temelji se na računalnom programskom sustavu koji objedinjuje bazu znanja sa svom potrebnom i nužnom radnom okolinom, koja mu treba omogućiti autonomno djelovanje unutar unaprijed zadanih okvira. Zato takav sustav mora imati:

- bazu znanja - tipičnu bazu podataka obično smještenu na hardverskim resursima računalnog sustava ili lokalne kontrolne mreže
- radnu memoriju - memorijski prostor rezerviran za razvoj rekurzivnih logičkih i (prema potrebi) numeričkih operacija
- mehanizam zaključivanja - programski okviri (*frames*) unutar kojih su već definirana pravila povezivanja
- modul za prikupljanje podataka - programski modul koji prikuplja i obrađuje podatke s unaprijed zadanih i privremeno dostupnih uređaja, senzora
- korisničko sučelje - programski modul koji treba omogućiti vezu čovjek-ekspertni sustav i ima višestruku ulogu (dopuna i/ili izmjena baza znanja, dopuna i/ili izmjena frameova zaključivanja, reorganiziranje modula za prikupljanje podataka).

U biti, ekspertni su sustavi namijenjeni dijagnostici, jer se pomoću njih naizgled lako mogu dobiti dijagnostički odgovori. Na temelju vidljivih znakova neke pojave neupućeni korisnik može utvrditi o čemu je uistinu riječ, te je zbog toga njihova uloga u industriji ponajprije savjetodavna.

### 2.4. Sustavi za potporu odlučivanju

#### 2.4 Decision support systems

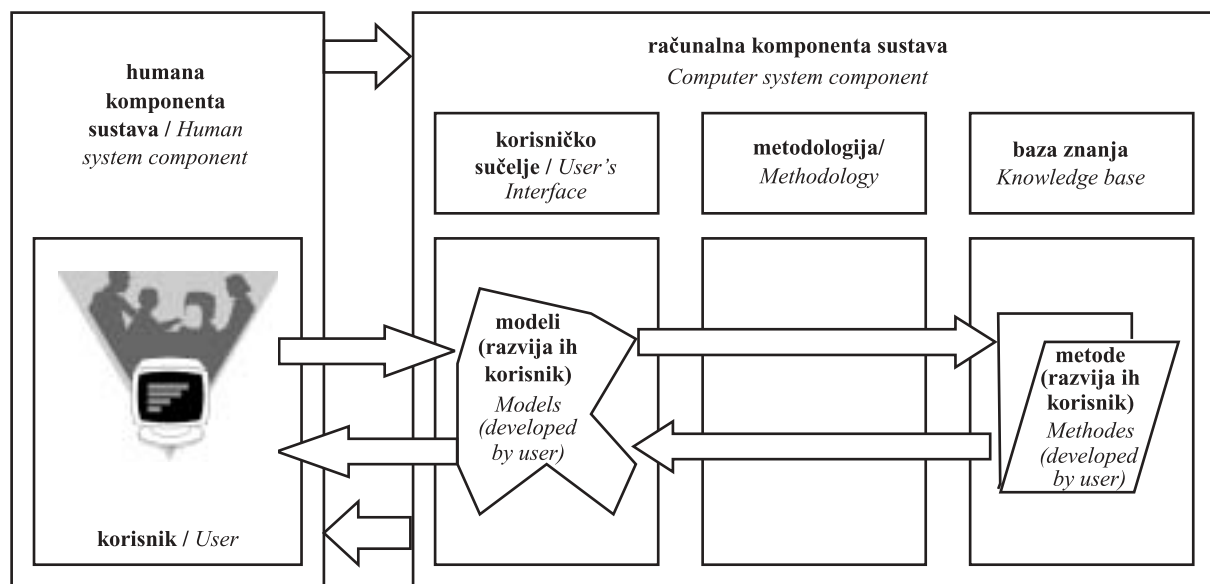
Pri detaljnijoj raščlambi industrijske proizvodnje uočava se da koncepcija sustava za potporu odlučivanju (*DSS - Decision Support System*) ima značajnu primjenu. Ta se koncepcija unekoliko razlikuje od klasične

koncepcije ekspertnog sustava, iako u biti i ti sustavi na neki način pripadaju univerzalnim ekspertnim sustavima (sl. 4). Sustavi za potporu odlučivanju danas su metafora za računalno orijentirane i inteligentno koncipirane programske sustave koji isključivo služe kao potpora za racionalno donošenje odluka u složenim situacijama i nedovoljno strukturiranim problemima (*fuzzy logic*). Za razliku od čistoga ekspertnog sustava, koji je logički strukturiran, sustav za potporu odlučivanju usmjeren je ponajprije na procese - postupke, odnosno na njihovu primjenu u rješavanju specifičnih problema. Temeljno obilježje takvih sustava jest postojanje interakcije između baza:

1. modela i korisnika (komunikacijska veza) - sposobnost interaktivne komunikacije između sustava i korisnika koja se odnosi na prikaz poznatih (postojećih) modela,
2. modela i metoda (interpretacijska veza) - sposobnost dinamičke analize i interpretacije modela na temelju točno specificiranih zahtjeva korisnika,
3. metoda i korisnika (integracijska veza) - sposobnost primjene metoda i informacija na osnovi rezultata dobivenih iz njihove primjene kako bi se korisniku na dinamičan i konkretan način predočilo rješenje s kompletnom pripadajućom analizom (Grladinović, 1999).

Logičko zaključivanje (rezolucija) može biti sastavnica takvih sustava, no ono nije njihovo dominantno obilježje. Naime, u samoj se proizvodnji ljudi stalno susreću s novim nepoznicama, a ni neki osnovni problemi još nisu riješeni na zadovoljavajući način (Forrester, 1992). Sustave za potporu odlučivanju obilježavaju ova svojstva:

1. interaktivni su,
2. služe kao potpora odlučivanju,
3. rješavaju nestrukturirane probleme,
4. koriste se podacima,
5. kreiraju modele.



Slika 4. Paradigma sustava za potporu odlučivanju (Benić, 1995)

Figure 4 Paradigme of decision support system (Benić, 1995)

Da bi mogli ostvariti navedene zahtjeve, takvi sustavi u svojoj praktičnoj programskoj realizaciji moraju imati:

- bazu podataka (npr. iz klasičnoga MRP II sustava)
- bazu modela s pripadajućim rješenjima
- programe (metode, algoritme) koji omogućuju odlučivanje.

## 2.5. Baza podataka sustava za potporu odlučivanju

### 2.5 Data base for decision support systems

Baza podataka sustava za potporu odlučivanju ponajprije ovisi o namjeni sustava. Ako je riječ o sustavu koji služi kao potpora proizvodnji (planiranju tehnoloških procesa, proizvodnih procesa ili proizvodnje), tada je baza podataka ono što se pod time razumijeva kada se govori o programskim paketima potpore proizvodnji. To je klasična relacijska (u novije vrijeme objektna) baza podataka s tablicama osnovnih entiteta. Svaki slog (zapis) u tablici jedan je podatak koji se sastoji od atributa, a tablice su međusobno povezane relacijskim vezama (indeksi).

## 2.6. Program sustava za potporu odlučivanju

### 2.6 Program for decision support systems

Program sustava za potporu odlučivanju može se služiti podacima iz tablice (prikupljati ih, selektirati i analizirati). Za to se koristi unaprijed ugrađenim algoritmima – postupcima - metodama. Na osnovi rezultata prethodne selekcije i analize, sustav prema unaprijed zadanim logičkim i proceduralnim pravilima automatski razvija model kako bi se nekim od prikladnih postupaka riješio zadani problem. Zadavanje problema prethodi generiranju modela te može (ovisno o koncepciji) biti nametnuto kao vanjski nalog operatera ili kao zadani cilj ugrađen u programsko rješenje. Svaki novi model, kao i njegovo rješenje, zapisuje se u bazu modela.

## 2.7. Programi za odlučivanje

### 2.7 Decision programs

Programi za odlučivanje srž su takvog sustava. Pri tome takvom sustavu prije svega odgovaraju proceduralno orijentirani programi, a manje oni koji se temelje na čistoj logici. Oni mu omogućuju pojedine funkcije: manipulaciju bazom podataka, prikupljanje, analizu i selekciju bitnih podataka, izgradnju i analizu modela, rješavanje zadanog problema (u cjelini ili u pojedinim njegovim segmentima). Takav sustav može imati i programe (objekte) zadužene za logističku analizu problema, pri čemu mu unaprijed moraju biti zadani okviri djelovanja i načini zaključivanja (Benić, 1995).

## 2.8. Modeliranje za učenje

### 2.8 Modelling for learning

Modeliranje za učenje jedna je od koncepcija kojom se na čovjeku prikladan način može rješavati mnoštvo problema. Bez obzira na bitne razlike od dosad opisanih koncepcija (ekspertnih sustava i sustava za potporu odlučivanju), obje koncepcije imaju nešto zajedničko. To je model. Model je *conditio sine qua non* svakog zaključivanja i učenja, bez obzira na to kako ga mi zvali. Osnovni aspekti računalnog učenja

jesu automatsko programiranje, umjetnička kreativnost, sažimanje podataka, optimiranje te traženje i izgradnja teorija (Forrester, 1992).

Za sve prethodne aspekte bitan je model. Model je:

- pojednostavnjena slika realnog sustava
- pojednostavnjena i vjerna slika procesa u nekom realnom sustavu
- struktura učinka sustava ( $E_u$ ), ovisna o nepoznanicama i parametrima koji se mogu ( $x_i$ ) i/ili ne mogu ( $y_i$ ) kontrolirati:

$$E_u = f(x_i, y_i) \quad (1)$$

a modeliranje je:

- postupak kojim se procesi u realnom sustavu (realnom problemu) preslikavaju u sustav - model kojemu je cilj proučavanje ponašanja prethodnoga realnog sustava
- funkcija koja uspostavlja odnos između učinaka sustava te varijabli i parametara koji djeluju u sustavu.

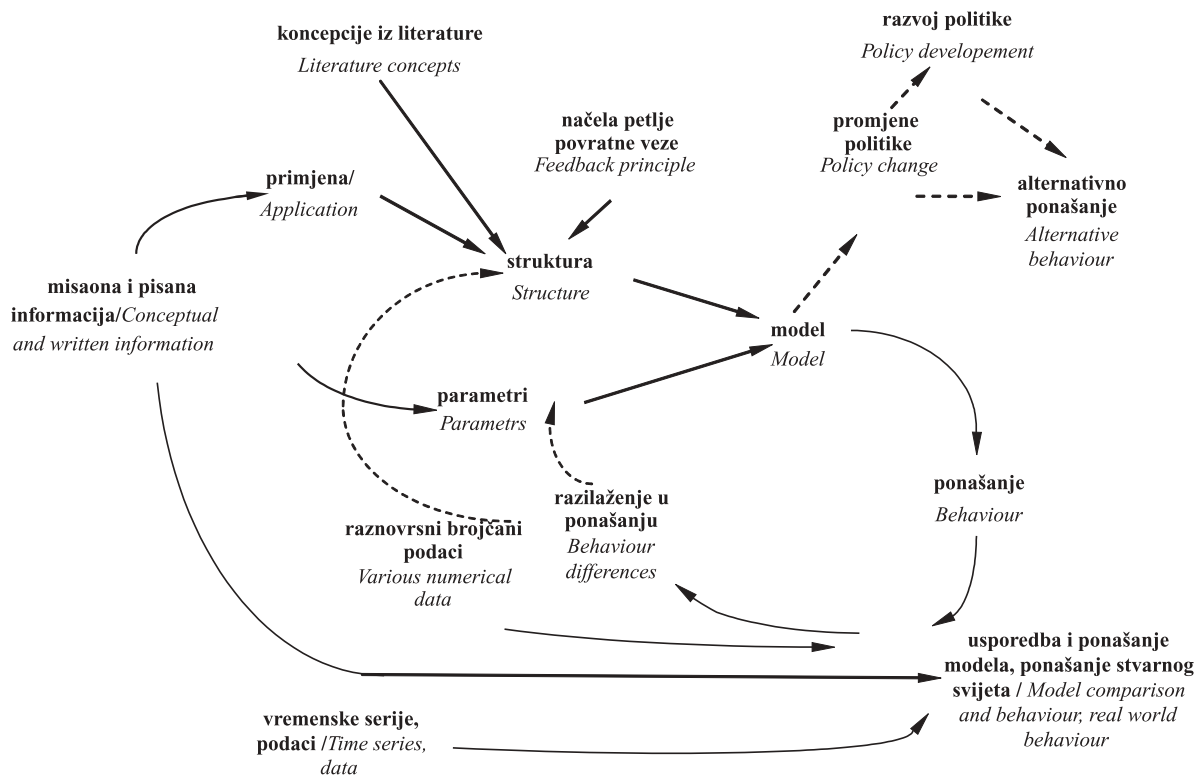
Modeliranje za učenje, kao disciplina koja nedostaje, danas označava suvremenu koncepciju u izgradnji i verifikaciji teorija, posebice onih vezanih za ponašanje poslovnih sustava (organizacija je u širem smislu takav sustav). Modeliranje učenja proizlazi izravno iz teorije odlučivanja (Lane, 1992).

Modeliranje za učenje savjetodavna je metodologija potpore odlučivanju koja se koristi analitičkim instrumentarijem i bliskim asocijacijama. Kako savjetnik ima ulogu katalizatora u zajedničkom procesu odlučivanja, njegova je zadaća pripremiti interaktivni okvir za korisnikove ideje i pretpostavke koje moraju biti čvrsto utemeljene, lako razumljive i realno izvedive prikladnim analitičkim instrumentarijem. Rezultirajući model omogućuje korisniku provjeru koherentnosti ideja te razmatranje dosljednosti tih ideja i posljedica što ih one prouzročuju. Model je poslovni sustav na kojemu se tada jednostavno mogu izvoditi pokusi u kojima se primjenjuju različite poslovne strategije. Cilj procesa je razvijanje smisla za prikladno poslovno razmišljanje, usmjeravanje diskusije prema razvoju novih opcija i ideja koje poboljšavaju donošenje odluka.

Kako je riječ o poslovnom odlučivanju, teži se:

- pronalaženju općeg modela prema kojemu priroda djeluje (i, sukladno tome, rješava probleme)
- razvoju novih i inkorporiranju postojećih teorija i metodologija kako bi modeli mogli u realnom vremenu (obično vrlo brzo) i na odgovarajući način oponašati najstroža zbivanja u prirodi (ISO 9000, 1994).

Modeliranje procesa radi njihova proučavanja u biti je kompilacija mnogih već poznatih modela i polazišta u rješavanju problema, a svi izravno potječu iz operacijskih istraživanja. U toj su kategoriji: 1. teorija igara, 2. teorija odlučivanja i primjena vjerojatnosti, 3. sustavska dinamika, 4. računalne simulacije (u najširem smislu) i 5. statističko prognožiranje. Naposljetku, čak se i sama teorija kaosa, kao najnoviji hit u operacijskim istraživanjima i umjetnoj inteligenciji, može svrstati u tu skupinu metoda. Primijenjeno na samu or-



Slika 5. Modeliranje – simuliranje – učenje (Grladinović, 1999)  
 Figure 5 Modelling – simulating – learning (Grladinović, 1999)

ganizaciju proizvodnje, prethodna se koncepcija očituje tako da se interaktivnom igrom na modelu stječu znanja o ponašanju realnog sustava (sl. 5) (Grladinović, 1999).

## 2.9. Inteligentni proizvodni sustavi 2.9 Intelligent production systems

Na kraju uvodnih razmatranja donosimo jednu od mogućih sinteza onoga što u radu nazivamo inteligentnim proizvodnim sustavom. Bez obzira na formu i specifični oblik konkretne realizacije, koncepcija računalom integrirane proizvodnje nezamisliva je bez prikladne upravljačko-nadzorne strukture. Uloga te strukture identična je pak ulozi živčanih stanica bioloških organizama u prirodi. Suvremeni fleksibilni proizvodni sustavi (*Flexible Manufacturing System - FMS*) imaju ova obilježja:


1. autonomiju; sustav potpuno samostalno obavlja svoju osnovnu funkciju, pri čemu maksimalno nastoji ograničiti nepovoljan utjecaj okoline,
2. računalno upravljanje i nadzor; središnje računalo nadzire sve komponente sustava, određuje raspodjelu poslova, aktivnosti i zadataka u svezi s njima, te im dostavlja sve nužne informacije,
3. organizaciju; sustav je organiziran tako da funkcionira i u situacijama kada se tijekom vremena dinamički mijenja opseg poslova (prema tipu, količini i trajanju), pri čemu može uočiti i riješiti uska grla u proizvodnji te osigurati interne pričuve (npr. materijala, opreme, rada, energije ...),
4. opću dijagnostiku; sustav je sposoban sam uočiti zastoj zbog nedostatka ili pogreške u pojedinim resursima (na obratcima, opremi, materijalu, radnim mjestima, informacijama), te na to ispravno reagira-

ti odgovarajućom promjenom stanja; istodobno pomoću senzorskih uređaja mora moći mjeriti kvalitetu svih internih radnih postupaka i komponenata sustava,

5. optimizaciju funkcija i resursa: sustav mora imati sposobnost optimiranja pojedinih funkcionalnih obilježja u realnom vremenu, prije, za vrijeme i nakon odvijanja pojedinih poslova i aktivnosti,
6. prognostičku preventivu; na temelju podataka iz vlastite povijesti sustav mora moći predvidjeti ponašanje pojedinih svojih komponenata u budućnosti kako bi poduzeo zadane preventivne akcije,
7. veze s okolinom; sustav mora imati vezu s cjelokupnom okolinom koja neposredno utječe na obavljanje njegovih zadaća (Katalinić, 1992).

Većina navedenih svojstava ujedno su i obilježja onoga što se u običnom žargonu može smatrati inteligentnim ponašanjem. Suvremeni fleksibilni proizvodni sustav na neki način ima obilježja inteligentnoga proizvodnog sustava (*Intelligent Manufacturing System - IMS*) (ili se može reći da teži tome). Na slici 6. pojednostavnjeno je prikazana opća paradigma svega onoga što u sklopu rada pod tim razumijevamo. Pri tome nije osobito bitno koliko je to prividno inteligentno ponašanje posljedica istinskoga autonomnog djelovanja programa nadzornog računala (opća ekspertna potpora odlučivanju), čovjeka (donositelja odluke) koji nadzire rad sustava putem računala i programa, ili pak interaktivno djelovanje na relaciji čovjek – računalo - računalni program. Svojstvo inteligencije takvom sustavu može dati samo i isključivo informatička komponenta, koja ima ulogu živčanog sustava bioloških organizama (Benić, 1995).





**Slika 6.** Opći prikaz inteligentnoga proizvodnog sustava (Benić, 1995)  
**Figure 6** General review of intelligent production system (Benić, 1995)

Inteligencija se pak u takvim sustavima može oživotvoriti isključivo kao istodobno djelovanje upravljačko-nadzornog sustava na dvije razine, među kojima postoje međusobne veze (komunikacija-prijenos podataka). Hardverske performanse suvremenih računala i softverskih mogućnosti suvremenih, objektivno usmjerenih instrumentarija, omogućuju praktičnu realizaciju sustava koji usporedno može djelovati:

- na razini rješavanja tekućih poslova i zadataka
- na razini računalnog učenja i kasifikacije, koja se sastoji od:
  - prikupljanja i analize podatka
  - samostalnog sastavljanja modela
  - analize modela
  - rješavanja modela
  - analize dobivenih rješenja

s ciljem:

- klasifikacije tih modela
- upoznavanja svojstava modela (prema prethodno zadanim pravilima i postupcima) te prepoznavanja sličnih modela kako bi se korisniku mogao predložiti postupak rješavanja problema
- uočavanja ugrađenih ograničenja, kako bi sam sustav i/ili korisnik mogao dograđivati postojeći sustav nadzora i upravljanja.

Veze između navedenih razina djelovanja nužne su kako bi se novostečeno znanje na razini računalnog učenja moglo primijeniti i za konkretno rješavanje problema. Na taj se način u sustav, u praktičnom obliku, uz atribuciju *učenje novog znanja* može ugraditi i atribuci-

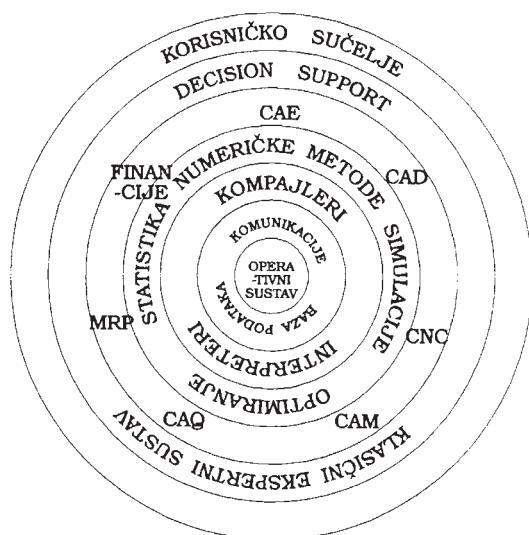
ja *primjena novostečenog znanja*, što je pak ključno obilježje inteligencije.

Osnovni cilj i namjena inteligentnih proizvodnih sustava jest služenje čovjekovim potrebama. To pak znači da sustav samostalno ili u suradnji s čovjekom kao nadzornim organom stvara nove materijalne vrijednosti (dobra). U tom se smislu i inteligencija ugrađena u nj može promatrati isključivo i jedino kao sustav koji može donositi odluke i na temelju toga upravljati pojedinim hardverskim sastavnicama inteligentnoga proizvodnog sustava. Pri tome u upravljački dio sustava trebaju biti ugrađena sljedeća načela (parafraziramo tri zakona robotike<sup>\*</sup>).

1. Sustav ne smije ozlijediti čovjeka (zahtjev sigurnosti), a svojom neaktivnošću ne smije dopustiti da organizacija i okolina u kojoj djeluje trpe štetu (zahtjevi ekonomičnosti i ekološkičnosti).
2. Upravljačko-nadzorna komponenta sustava pri čovjekovoj intervenciji mora dati prednost njegovim zahtjevima, a ne ciljevima samog sustava, osim ako je to proturječno prvom zakonu.
3. Sustav mora čuvati vlastiti integritet (zahtjev samoodržanja), osim ako je to proturječno prvom i drugom zakonu.

Iako je za čovjeka do danas to još uvijek teško dostižan ideal u praksi, mnogi prethodni elementi već postoje ili se razvijaju unutar postojeće CIM koncepcije. Suvremena koncepcija logističkog upravljanja radnim operacijama (*Manufacturing Operations Management - MOM*) u krajnjoj se liniji potpuno uklapa u prethodnu

<sup>\*</sup> Tri čuvena i osnovna zakona robotike postavio je poznati pisac znanstvene fantastike Isaac Asimov u priči Runaround, objavljenoj u ožujku davne 1942. godine u izdanju Astounding Science Fictiona.



Slika 7. Različiti slojevi softvera za umjetnu inteligenciju (Benić, 1995)  
 Figure 7 Different software levels for artificial intelligence (Benić, 1995)

Legenda/Legend

korisničko sučelje (*user's interface*), potpora odlučivanju (*decision support*), klasični ekspertni sustav (*traditional expert system*), CAE računalom podržano inženjerstvo (*Computer Aided Engineering*), CAD računalom podržano projektiranje (*Computer Aided Design*), CNC – kompjutorsko brojčano vođenje (*Computer Numerical Control*), CAM – računalom podržana proizvodnja (*Computer Aided Manufacturing*), CAQ – računalom podržana kvaliteta (*Computer Aided Quality*), MRP – planiranje materijalnih resursa (*Material Resource Planning*), financije (*finance*), statistika (*statistics*), numeričke metode (*numerical methods*), simulacije (*simulations*), optimiranje (*optimisation*), kompajleri (*compilers*), interpreteri (*interpreters*), komunikacije (*communications*), baza podataka (*data base*), operativni sustav (*operations system*)

koncepciju. Na slici 7. prikazana je tipična shema mogućega upravljačkog softvera bez kojega ne može funkcionirati koncepcija inteligentnih proizvodnih sustava. Softverska komponenta takvog sustava (barem prema postojećim suvremenim koncepcijama razvoja softvera) složena je, što pak znači da on djeluje u međusobno povezanim slojevima. Koliko će u pojedinom sloju ona biti kompletna (u smislu ugrađenog softvera), ovisi o specifičnim potrebama konkretnoga proizvodnog sustava.

Upravljanje proizvodnim sustavom isključivo je zadaća operativne i taktičke razine odlučivanja. Pritom je, naime, riječ o zadatku istodobnog upravljanja operacijama, kao i o upravljanju procesom proizvodnje (u cjelini ili djelomično). Pri tome se, ovisno o tipu poslova i zadataka te odluke koju treba donijeti, može govoriti o prvoj ili drugoj razini odlučivanja.

Navedeni aspekt upravljanja i kontrole proizvodnje ujedno je i jedan od temelja na kojima se zasniva suvremena koncepcija logističkog upravljanja radnim operacijama u proizvodnji. Na temelju točno specificiranih zahtjeva, za poznatog kupca ili za poznato tržište potrebno je izraditi proizvode specificirane kakvoće. Ako je kupac poznat, cjelokupna se proizvodnja mora obaviti do strogo određenog roka. Ako se proizvodi za poznato tržište, situacija je slična, samo se pritom cijela proizvodnja mora obaviti što je brže moguće. Da bi se postigli ti ciljevi, proizvodnju treba organizirati i ponekad neposredno upravljati proizvodnim operacijama (komponenta *on-line* odlučivanja) dok je proizvodni proces u tijeku, *Work in Process - WIP*. Upravljanje proizvodnjom koja je u tijeku zahtijeva i povratnu vezu na relaciji donositelj odluke – proizvodni sustav, koja omogućuje preventivne i korekcijske postupke kako bi se postigao glavni cilj na razini proizvodnje - potpun završetak proizvodnje do planiranog termina. To pak znači da osim potisne komponente (u informacijskom

smislu) u upravljanju proizvodnjom (od pozicija prema proizvodu) u sustav mora biti ugrađena i povlačna komponenta (od proizvoda prema pozicijama). Pri tome je potisna komponenta u biti unaprijedno planiranje proizvodnje (terminiranje), a povlačna komponenta znači reterminiranje proizvodnje i može postojati samo ako postoji interna komponenta kontrole koja ima zadaću kontrolirati kakvoću završene proizvodnje (Benić, 1995).

**3. ZAKLJUČAK**  
**3 CONCLUSION**

U tvrtkama za preradu drva i proizvodnju namještaja navedene koncepcije upravljanja osiguravaju prikladan način na koji se mogu rješavati problemi u proizvodnji i poslovanju. Koncepcijama je zajedničko da se na temelju sposobnosti razumijevanja, zaključivanja, učenja, primjene znanja i informacijskih tehnologija, opažanja i prepoznavanja događaja i objekata mogu koristiti u smislu savjetodavne inteligentne potpore procesima odlučivanja i upravljanja poduzećima za preradu drva i proizvodnju namještaja. Te se koncepcije međusobno dopunjuju i čine opću logističku koncepciju, koja u preradi drva i proizvodnji namještaja može poprimiti različite oblike, od tzv. smisao-znanje tehnologije i informacijske tehnologije, bez obzira na to o kakvoj je koncepciji riječ. Ona mora biti sposobna davati suvisle odgovore te moći rješavati situacije u opsegu u kojemu smo je opskrbili znanjem o proizvodnji i poslovanju tvrtke za preradu drva i proizvodnju namještaja. Takvo savjetodavno svojstvo prikazanih koncepcija čvrst je oslonac u okolini koja zbuñuje.

Opisane koncepcije danas čine suvremenu koncepciju u izgradnji i vrednovanju teorija, posebice onih vezanih za djelovanje proizvodnih sustava u preradi drva i proizvodnji namještaja.

## LITERATURA REFERENCES

1. Anderson, J. E., 1994: *Management of Manufacturing, Model and Analysis*, Addison-Wesley Publishing Company, Workingham.
2. Angehrn, A. A., 1991: *Modelling by Example: A Link Between Users, Models and Methods in DSS*, European Journal of Operations Research, Special Issue: Sixth Euro Summer Institute Decision Support Systems, vol. 55, 296-308.
3. Benić, D., 1995: *Inteligentni proizvodni sustavi*, interna skripta, Fakultet strojarstva i brodogradnje u Zagrebu, Zagreb.
4. Benić, R., 1971: *Organizacija rada u drvnjoj industriji*, Znanje, Zagreb.
5. Benić, D., 1993: *A Decision Support System for Production Planning and Control*, 3rd International Conference on Advanced Manufacturing Systems and Technology - AMST'93, Udine Proceedings, vol. II, 165-172.
6. Benić, D., 1993: *Matematičko i simulacijsko modeliranje proizvodnih sustava*, Zbornik radova CIM'93, Hrvatska akademija znanosti i umjetnosti, Hrvatska zajednica proizvodnog strojarstva, Zagreb.
7. Figurić, M. i sur., 1995: *Production System in Wood Industry V*, Faculty of Forestry, Zagreb.
8. Forrester, J. W., 1980: *Industrial Dynamics*, Massachusetts Institute of Technology Press Cambridge, Massachusetts and London, England, Second Preliminary Edition, Ninth Printing, Copyright 1963 by Jay W. Forrester.
9. Forrester, J. W., 1992: *Policies, Decisions and Information Sources for Modeling*, European Journal of Operational Research, vol. 59, 42-63.
10. Forsyth, R.; Rada, R., 1986: *Machine Learning - Applications in Expert Systems and Information Retrieval*, Ellis Horwood Ltd., UK.
11. Graham, A. K.; Morecroft, J.D.W.; Senge, P. M.; Sterman, J.D., 1992: *Model Supported Case Studies for Management Education*, European Journal of Operational Research, Vol. 59, 151-166.
12. Grladinović, T., 1999: *Upravljanje proizvodnim sustavima u preradi drva i proizvodnji namještaja*, Šumarski fakultet Sveučilšta u Zagrebu, Zagreb.
13. De Geus, A. P., 1992: *Modelling to Predict or to Learn*, European Journal of Operational Research, Vol. 59, 1-5.
14. Katalinić, B., 1992: *Design Control Structures and Strategies for Complex Flexible Manufacturing Systems*, Zbornik radova II. savjetovanja "Suvremeni trendovi proizvodnog strojarstva", Fakultet strojarstva i brodogradnje u Zagrebu, Zagreb.
15. Lane, D. C., 1992: *Modelling as Learning: A Consultancy Methodology for Enhancing Learning in Management Teams*, European Journal of Operational Research, Vol. 59, 64-84.
16. Majdandžić, N., 1988: *Upravljanje proizvodnjom*, Informatički sistem planiranja, Strojarski fakultet u Slavonском Brodu, Slavonski Brod.
17. Mitchell, Jr., F. H., 1991: *CIM Systems, An Introduction to Computer - Integrated Manufacturing*, Prentice-Hall International Inc, New York.
18. Morecroft, J. D., 1992: *Executive Knowledge, Models and Learning*, European Journal of Operational Research, Special Issue: Modelling for Learning, vol. 59, 9-27.
19. Schroeder, R. G., 1999: *Upravljanje proizvodnjom*, MATE, Zagreb.
20. Senge, P. M.; Sterman, J. D., 1992: *System Thinking and Organizational Learning: Acting Locally and Thinking Globally in the Organization of the Future*, European Journal of Operational Research, vol. 59, 137-150.
21. Winston, P. H., 1984: *Artificial Intelligence*, Second Edition, Addison-Wesley Publ. Co., Reading, Massachusetts, USA.
22. \*\*\* 1990: *Artificial Intelligence and Expert Systems in Manufacturing, The Scope, Application and Limitations of Intelligent Manufacturing Systems*, Proceedings, IFS Conferences, London.
23. \*\*\* 1994: *ISO 9000 QUALITY MANAGEMENT*, ISO Standard Compendium, Fifth Edition, International Organization for Standardization, Geneva, Switzerland.

### Corresponding address:

Prof. TOMISLAV GRLADINOVIĆ, PhD

Department for Production Organization  
Faculty of Forestry, Zagreb University  
Svetošimunska 25  
10000 Zagreb  
Croatia  
e-mail: grladin@sumfak.hr