

PRIMJENA EKSPERTNOG SUSTAVA PRI ODREĐIVANJU KLASE PRIORITETA RADNOG NALOGA U POJEDINAČNOJ PROIZVODNJI

Roberto Lujić, Tomislav Šarić, Goran Šimunović

Pregledni članak

Analiziranjem stanja u proizvodnim poduzećima pokazalo se kako je u proizvodnji često prisutno neispunjene obveze prema krajnjem kupcu, kašnjenje u rokovima isporuke, narušavanje ugleda firme i/ili plaćanje visokih penala. Uz neadekvatan model terminiranja koji često puta nema mogućnost izrade varijanti planova kao jedan od najvažnijih uzročnika kašnjenja navedeni su neadekvatni i neprimjenjivi modeli prioriteta. Definiran je pojam prioriteta i predložen novi model klase prioriteta za pojedinačnu i maloserijsku proizvodnju, baziran na ekspertnim sustavima. Predloženi model u odnosu na postojeća pravila prioriteta uvođi niz novih parametara, ne samo iz službe tehnologije, već i iz službi prodaje i nabave. Klase prioriteta riješene su na razini radnih naloga i uzimaju u obzir različite vrste atributa ali i njihovih vrijednosti.

Ključne riječi: ekspertni sustav, radni nalog, pravilo prioriteta, pojedinačna proizvodnja

Application of Expert System for Determination of Work Order Priority Class in Piece Production

Subject review

The analysis of the state of affairs in manufacturing companies has shown that in a number of cases the obligations towards end customer remain unfulfilled, that due dates of delivery are not observed, that the image of the firm is damaged and that the penalties are high. Apart from an inadequate scheduling model often lacking the possibility for plan variants to be made, the inadequate and inapplicable priority models have often been stated as the most important reasons for running behind schedule. This paper defines the notion of priority and suggests a new class priority model for the piece and small scale production based on expert system. With regard to the existing priority rules the proposed model introduces a number of new parameters, not only for the technology department but also for the purchasing and sales departments. Priority classes are solved for work orders and consider not only various kinds of attributes but also their values.

Keywords: expert system, work order, priority rule, piece production

1

Uvod

Introduction

Cilj svakog poduzeća je oblikovati takvu organizacijsku strukturu koja će mu omogućiti stabilno poslovanje, optimalno iskorištenje materijalnih i ljudskih resursa te omogućiti brzo reagiranje na utjecaje iz pripadajuće okoline. Od poduzeća se zahtijeva prilagodljiva organizacijska struktura koja omogućava poduzeću ne samo prilagođavanje promjenama, već i sudjelovanje u njihovu kreiranju, podsticanju, diktiranju, ali i iniciranju. Dijametalno suprotan zahtjev ovom je relativna stabilnost poslovanja što se omogućuje kroz specijalizaciju i racionalizaciju poslovanja uz znatno snižavanje troškova. Stoga je zadatak uspostaviti ravnotežu između dva naizgled suprostavljenih zahtjeva: za stabilnošću s jedne strane i za prilagodljivošću s druge strane.

Da bi poduzeće uspjelo opstati na tržištu od njega se zahtijeva da zadovolji zahtjeve kupca s obzirom na kvalitetu, cijenu i rok isporuke. Navedeni kriteriji mogu se ostvariti samo uz restrukturiranje postojećih poduzeća, uvođenjem suvremenih tehnologija, promjenama organizacijskih oblika i sudjelovanjem motiviranog osoblja, kako u fazi odlučivanja tako i u fazi realizacije poslova.

Iskustva iz pojedinačne proizvodnje pokazala su česta kašnjenja zbog složenih uvjeta proizvodnje na koju utječe veliki broj faktora koji dovode do značajnih odstupanja rokova isporuke, što dovodi do potrebe za neplanskim angažiranjem dodatnog rada s povećanim

troškovima proizvodnje. Analiza pokazuje glavne uzroke ovakvog odstupanja [1,2]:

- a) neadekvatno određivanje prioriteta
- b) neprilagođeni modeli terminiranja specifičnostima pojedinačne proizvodnje.

Danas se od rukovodstva proizvodnih sustava traži da u što kraćem roku doneše što pouzdanije odluke. Važnost donošenja pravovremenih i pravovaljanih odluka ne može proizići iz nepouzdanih i nepotpunih podataka, kao i neadekvatnih modela prioriteta i terminiranja.

Svakodnevno povećanje broja radnih naloga u pojedinačnoj i maloserijskoj proizvodnji zahtijeva i primjenu novih alata zasnovanih na umjetnoj inteligenciji kako u proizvodnom procesu tako i pri određivanju prioriteta rasporeda tehnoloških operacija na izradi i montaži dijelova, sklopova i proizvoda.

Istraživanje na projektima financiranim od strane Ministarstva znanosti i tehnologije Republike Hrvatske (Razvoj upravljačko-informacijskih sustava proizvodnih poduzeća (152001), Sustav upravljanja pojedinačnom proizvodnjom (00-35) i Ekspertni sustav izrade tehnologije pojedinačne proizvodnje (152014), voditelj projekata prof. dr. sc. Niko Majdandžić), i proučavanjem literature [1-13], pokazalo je postojanje velikog broja programskih paketa za pojedinačnu proizvodnju, odnosno proizvodnju koja ima karakter projekta, koji se temelje na metodama i tehnikama mrežnog planiranja. Također, postoji i veliki broj programskih sustava koji su primjenjivi kod serijske proizvodnje, a koji se

temelje na metodama planiranja resursa i proizvodnje (planiranju potreba materijala - Material Planning Resources, MRP), integriranom upravljanju proizvodnjom (Manufacturing Resource Planning, MRP II) i proizvodnji bez zaliha (Just In Time, JIT)) do razine tehnoloških operacija i proizvodnih kapaciteta. Na osnovi analize došlo se do spoznaje o nedostatku povezanosti tih dviju razina, odnosno, uočeno je nepostojanje veza među pripadajućim planovima za pojedinačnu proizvodnju i termina izrade elemenata u svrhu zadovoljenja rokova iz planova prodaje kako bi se iz rokova plana projekta automatski dobili rokovi proizvodnje i/ili nabavke dijelova trgovačke i uvozne robe, te rokovi izrade dijelova, sklopova ili operacija u kooperaciji.

U tu svrhu razvijeni su različiti algoritmi za određivanje prioriteta, a time i redoslijeda obavljanja operacija na proizvodnim kapacitetima koji uzimaju u obzir redoslijed pristizanja i/ili duljinu trajanja operacije. Primjeri takvih pravila su: prema načinu dolaska operacija [14-17], prema duljini trajanja [18-22], prema datumu isporuke [23, 24], prema postotku završenog posla [18, 19], pravilo prema sličnosti operacija [25], prema redu čekanja [18], slučajan raspored [18, 20], dinamički prioriteti [26] itd.

Neki od njih uključuju i primjenu alata umjetne inteligencije (genetičkih algoritama, neuronskih mreža, neizrazite logike i ekspertnih sustava) pri rješavanju problema rasporeda [27-46].

2 Pojedinačna proizvodnja

Piece production

Proizvodnja se može definirati kao složeni proces preobrazbe sirovine u finalni proizvod zahtijevane kvalitete nekim od sredstava rada, a u svrhu ispunjenja krajnje potrebe kupca.

Današnju proizvodnju karakterizira:

- skraćenje vremena proizvodnje i isporuka u zahtjevanim rokovima
- smanjenje troškova proizvodnje i snižavanje cijene proizvoda
- smanjenje zaliha
- prilagođavanje proizvoda zahtjevima kupca.

Da bi se proizvodnja mogla realizirati, potrebno je osigurati komunikaciju između sustava i okoline kroz tokove: materijala, ljudi, energije i informacija [47].

Prema tipu, proizvodnju je moguće podijeliti na:

- komadnu proizvodnju (pojedinačnu, maloserijsku i serijsku proizvodnju)
- masovnu proizvodnju i
- procesnu ili kontinuiranu proizvodnju.

Pojedinačna proizvodnja predstavlja tip proizvodnje gdje se proizvod ili usluga definiraju tehničkim zahtjevima, načrtima ili uzorcima. Pojedinačnu proizvodnju karakterizira vrlo mala proizvodnost i niska standardiziranost proizvoda (prilagodljivost proizvoda

prema zahtjevima kupaca) gdje se proizvod definira prema tehničkim zahtjevima. Sastavnice, tehnologija proizvodnje i normativi materijala, kao i potrebni alati, rješavaju se nakon ugovaranja posla. Kalkulacija se radi procjenom potrebnog rada i materijala.

Javlja se u dva oblika [2]:

- proizvodnja ili usluge po projektu (narudžbi)
- proizvodnja istog tipa proizvoda ali u varijantama rješenja koje se značajno razlikuje.

Proizvodnja po projektu (narudžbi) je takav tip proizvodnje ili usluga koji se obavlja samo jednom i to za određeni posao i mala je vjerojatnost njena ponavljanja. Tipični primjer pojedinačne proizvodnje su proizvodnja plovnih objekata, izrada rezervnih dijelova i komponenti po narudžbi, opreme u izgradnji postrojenja u energetici, itd.

Karakteristike ovog tipa proizvodnje su [2,5,48]:

- visoka novčana ulaganja u projekt
- intenzivno uključivanje kupaca
- fleksibilnost procesa
- često se realizira kod kupca, a ne u tvornici
- tehnički vrlo složena
- visoka cijena i dužina trajanja plana
- sastavnica nije poznata i često se razvija s razvojem dokumentacije čije su izmjene i revizije česte
- tehnologija se rješava iskustveno i prema procjeni potrebnih vremena
- kapaciteti su neusklađeni s potrebama jer se potrebe stalno mijenjaju, te je potrebno imati radnike koji rade na više raznovrsnih strojeva
- potrebe kooperacije osciliraju
- za konstrukciju i izradu alata te njegove probe obično nema dovoljno vremena.

Tri glavna zadatka u upravljanju pojedinačnom proizvodnjom su:

- zadržati troškove unutar propisanih kalkulativnih vrijednosti
- održati rok prema zahtjevima kupca
- postići kvalitetu prema zahtjevima kupca.

Varijantna komadna proizvodnja je povoljnija u odnosu na pojedinačni oblik proizvodnje prema projektu pošto se pojedini sklopovi, odnosno operacije na izradi proizvoda, ponavljaju s izmijenjenim zahtjevima.

3

Umjetna inteligencija i ekspertni sustavi

Artificial intelligence and expert systems

Umjetna inteligencija bavi se problemom "inteligentnog" ponašanja stroja odnosno traži odgovor na pitanje kako konstruirati stroj koji će se ponašati tako da ga možemo nazvati inteligentnim.

Klasifikacija umjetne inteligencije prema vrsti rješavanja problema [2]:

- sustavi za rješavanje ljudskih uobičajenih zadataka

- (prepoznavanje slika i govora, prevođenje prirodnih jezika, primjena u robotici itd.)
- sustavi za rješavanje formalnih zadataka (logičke igre, matematička logika, geometrija, integralni račun itd.)
 - sustavi za rješavanje ekspertnih zadataka (konstruiranje, planiranje proizvodnje, znanstvena analiza i dijagnostika, finansijska analiza itd.).

U području umjetne inteligencije rezultat aktivnosti je inteligentni sustav koji ima sposobnost prilagođavanja, zaključivanja, odlučivanja, prepoznavanja, učenja.

Svaki sustav koji se smatra intelligentnim pokazuje sljedeća svojstva [49]:

- Pokazuje prilagodljivo ciljno usmjereni ponašanje. Ima zadatak da željeni cilj predoči u podcilj i da koristi znanje o operacijama i postupcima koji prenove željeni cilj u slijed akcija. Ako neki od podciljeva nije ostvariv sustav traži alternativno rješenje prema konačnom cilju sustava.
- Uči na temelju iskustva. Sustav ima algoritme za automatsku modifikaciju strukture i funkcija na temelju iskustva koje stječe u radu. Učenje podrazumijeva da sustav može prikupljati, prikazivati i upotrebljavati znanje.
- Koristi velike količine znanja. Količina znanja koja je pohranjena u sustav mora biti jednaka količini znanja koju posjeduje čovjek da bi riješio takav problem.
- Pokazuje svojstva svjesnosti. Sustav ima sposobnost objašnjavanja svojeg ponašanja, nadgledanja te oporavka u slučaju pogreške.
- Komunicira s čovjekom prirodnim jezikom i govorom. Sustav mora komunicirati s čovjekom i drugim intelligentnim sustavima na prijateljski način gdje će upotrebljavati prirodni jezik i govor.
- Tolerira pogreške i nejasnoće u komunikaciji.
- Odgovara u stvarnom vremenu.

Pod pojmom ekspertni sustav podrazumijeva se računalom podržan sustav, utemeljen na znanju i iskustvu stručnjaka u takvom obliku da može pružiti intelligentan savjet ili donijeti intelligentnu odluku o određenom problemu. Poželjna dodatna značajka, koju mnogi smatraju temeljnom, je sposobnost sustava da na zahtjev provjeri svoj način rasuđivanja u obliku izravno shvatljivom korisniku [50].

Ključne aktivnosti za područje ekspertnih sustava, koje su ujedno i predmet istraživanja su [51]:

- prikupljanje znanja
- prikaz znanja
- upravljanje zaključivanjem i
- objašnjavanje pronađenih rješenja.

- Ekspertni sustav mora sadržavati sljedeće [52]:
- podrobno specifično znanje iz problemskog područja

- tehniku pretraživanja
- podržavanje heurističke analize
- sposobnost kreiranja novog znanja na temelju postojećeg
- simboličko procesiranje
- sposobnost objašnjavanja svojih zaključaka.

Ekspertni sustavi pripadaju sustavima za potporu odlučivanja i kao takvi omogućavaju prikaz problema i nalaženja rješenja kod kojih je znanje nepouzdano i ne može se prikazati pomoću jednadžbi, procedura, i sl., problema koji se ne mogu modelirati niti riješiti primjenom tradicionalnih metoda za potporu odlučivanja kao što su statistika, simulacija, tabični kalkulatori, stablo odlučivanja itd. jer je znanje temeljeno na iskustvu, a ekspert se često služi metodom pokušaja i pogrešaka u rješavanju problema jer ne postoji jednoznačna procedura rješavanja problema. Stoga ekspertni sustavi rješavaju probleme na osnovi znanja iz nekog užeg problemskog područja i pritom se ponašaju slično kao i eksperti iz problemskog područja. Tablica 1 daje usporedbu eksperta i ekspertnog sustava.

*Tablica 1. Usporedba eksperta i ekspertnog sustava
Table 1. Comparison between an expert and an expert system*

Faktor	Ekspert	Ekspertni sustav
Raspoloživost	Radnim danom	Uvijek
Zemljopisno određenje	Lokalno	Bilo gdje
Sigurnost	Nezamjenjiv	Zamjenljiv
Pouzdanost	Djelomična	Vrlo visoka
Nestalnost	Da	Ne
Performanse	Promjenjive	Konzistentne
Trajnost	Ograničena	Neograničena
Brzina	Promjenjiva	Konzistentna i obično veća
Rad u opasnim okolinama	Ograničen	Neograničen
Cijena	Visoka	Prihvatljiva

Strukturu ekspertnog sustava čini baza znanja, baza činjenica, mehanizam zaključivanja, mehanizam objašnjavanja rezultata, mehanizam sakupljanja znanja i korisničko sučelje. Sve nabrojano [51] u određenoj sinergijskoj konjunkturi daje strukturu ekspertnog sustava.

4

Lansiranje

Launching

Lansiranje poslova predstavlja pokretanje akcija na izradi proizvoda ili obavljanju usluge uz provjeru raspoloživosti resursa [2].

U proizvodnim sustavima s razvijenim sustavom terminiranja, lansiranje utječe na redoslijed terminiranja. U proizvodnim sustavima u kojima se samo grubo planira proizvodnja (bez provjere raspoloživosti kapaciteta i potrebnih resursa) lansiranje se obavlja intuitivno dajući prioritete radnim nalozima prema trenutnim procjenama stanja kapaciteta i rokova radnog naloga.

U serijskoj komadnoj i kontinuiranoj proizvodnji lansiranje predstavlja pripremu i provjeru svih resursa za nesmetano odvijanje proizvodnje.

U pojedinačnoj, a ponekad i u maloserijskoj proizvodnji, lansiranje ima i zadatak stalnog praćenja mogućih promjena te osiguranje potrebne dokumentacije za proizvodnju.

Lansiranje općenito sadrži sljedeće poslove [2]:

- provjeru pripremljenosti dokumentacije, alata, materijala i ispravnosti kapaciteta za proizvodnju koja se lansira
- praćenje proizvodnje i pokretanje akcija za rješavanje nastalih problema u proizvodnji: kvar stroja, neispravnost alata, pogreške u dokumentaciji, škart i dorada na operaciji itd.
- analizu gotovosti radnih naloga i pripremanje dokumentacije i transporta za otpremu proizvoda kupcu.

Izbor veličine serije i redoslijeda "puštanja" u proizvodnju ovisi o ugovorenim rokovima, raspoloživim kapacitetima, stanju pripremljenosti resursa (dokumentacija, materijal, alat). Redoslijed lansiranja radnih naloga određuje se prema prioritetu tehnoloških operacija ili radnih naloga. Svaki radni nalog za svoju realizaciju ostvaruje određeno kretanje i obradu u proizvodnji, koje je određeno tehnološkim postupcima i rasporedom kapaciteta. U proizvodnom sustavu dolaze različiti poslovi, a tehnološke operacije mogu imati zahtjeve za istim kapacitetima što uzrokuje pojavu "čekanja" pred radnim mjestima. Nameće se potreba za određivanjem redoslijeda uzimanja tehnoloških operacija u rad s ciljevima ispunjenja rokova isporuke i ostvarenja što manjih proizvodnih troškova. Taj redoslijed uzimanja iz reda "čekanja" ovisi o prioritetu [2].

4.1

Prioriteti

Priority rule

Pod pojmom prioriteta podrazumijeva se veličina koja izražava relativnu hitnost proizvoda, sklopa i dijela, čime izravno utječe na vrijeme čekanja za izvršenje radne operacije, vremena protokola i vremena završetka [2].

Prioriteti određuju slijed poslova kako će se obavljati na proizvodnim kapacitetima. Dodjelom prioriteta definiraju se karakteristike poslova na osnovu kojih se određuje redoslijed zapošljavanja radnih mjesta. Na takav se način svakom poslu određuje odgovarajući značaj. Ovisno o tipu proizvodnje različit je značaj i utjecaj prioriteta:

U serijskoj proizvodnji kapaciteti su usklađeni sa potrebama proizvodnje, tako da nema većih čekanja pred pojedinim kapacitetima.

U pojedinačnoj proizvodnji radni nalozi dolaze sa različitim zahtjevima za kapacitetima, te na taj način prioriteti radnih naloga daju prednost pri raspoređivanju i izradi tehnoloških operacija na proizvodnim kapacitetima.

Kod kontinuirane proizvodnje, prioritet ima više

značaja u isporuci kupcu nego redoslijedu proizvoda.

Način na koji se odabiru prioriteti na proizvodima ponajprije ovisi o broju i važnosti zahtjeva i kriterija koji su postavljeni [53]. Ako se radi o malom broju zahtjeva velike važnosti, težište je na kvalitativnoj i kvantitativnoj analizi svojstava i ponašanja koja dolaze u uži izbor putem informiranja ili iskustva. Kod velikog broja zahtjeva i kriterija isključivo se odabire primjena kvantitativnih metoda odlučivanja.

Prioriteti, osim što su odgovorni za određivanje slijeda poslova, su odgovorni i za dodjeljivanje resursa (radnika, alata i materijala) određenom poslu. Redoslijed dodjeljivanja resursa je u skladu s unaprijed postavljenim skupom ciljeva koji se pokušavaju ispuniti, npr. zadovoljenje roka isporuke, minimiziranje vremena kašnjenja naloga i sl.

Kod pojedinačne proizvodnje cilj je izvršenje zadatka u roku, prema zahtjevima i u okviru dozvoljenih materijalnih sredstava. Jedna od važnijih funkcija odvijanja procesa je terminiranje projekta, što uključuje efektivno raspoređivanje poslova na resurse kojih u većini slučajeva nema dovoljno a sve s ciljem realizacije zadatka.

Kod određivanja prioriteta u pojedinačnoj proizvodnji polazi se od praktične potrebe određivanja prioriteta svakog radnog naloga koji ulazi u proizvodnju. Na taj način, svi proizvodni elementi ili usluge, koji se nalaze na jednom radnom nalogu, imali bi automatski veći prioritet od bilo kojeg proizvodnog elementa sa radnog naloga koji ima manji prioritet.

Potrebno je osigurati najveći značaj za prioritet radnog naloga na osnovu kojeg će se svim tehnološkim operacijama na sklopovima i dijelovima promatranoj radnog naloga omogućiti prednost pri raspoređivanju tehnoloških operacija na proizvodne kapacitete u odnosu na tehnološke operacije sklopova i dijelova na radnom nalogu manjeg prioriteta.

5

Prijedlog modela za određivanje klase prioriteta radnog naloga

Proposal model for determination of work order priority class

Cilj predloženog istraživanja je pokazati kako je moguće primjenom ekspertnog sustava omogućiti određivanje klase prioriteta na temelju definiranih atributa. Na osnovi provedenih terenskih istraživanja metodom anketiranja definirani su heurističkim pristupom atributi i vrijednosti atributa važni za postavljeni model istraživanja (tablica 2).

U razradi istraživanja postavljen je cilj. Cilj je da nam ekspertni sustav da odgovor na pitanje: Koji će radni nalog na osnovi predloženih atributa imati koju klasu prioriteta, a time i prednost u proizvodnom procesu?

Vrijednosti prioriteta koji će se ostvariti primjenom navedenih atributa svrstane su u klase od 1 do 12, pri čemu klasa prioriteta 1 predstavlja najvišu klasu

prioriteta, a klasa 12 najnižu.

Neki od atributa su jednostavniji neki složeniji i u funkciji su od nekih drugih vrijednosti.

*Tablica 2. Prikaz atributa
Table 2. Review of attributes*

Atributi	Vrijednosti atributa
Datum isporuke	<ul style="list-style-type: none"> • dug • kratak • kasni
Važnost kupca	<ul style="list-style-type: none"> • velika • srednja • mala
Penali	<ul style="list-style-type: none"> • visoki • mali • nema
Složenost osiguranja resursa	<ul style="list-style-type: none"> • jednostavno • složeno
Mogućnost alternativnih tehnoloških postupaka	<ul style="list-style-type: none"> • nemoguće • moguće
Faktor nabave	<ul style="list-style-type: none"> • složen • djelomično složen • jednostavan
Faktor raspoloživog vremena	<ul style="list-style-type: none"> • 1 • 1,5 • 2 • 2,5

Rješenje zadatka dano je u obliku "drveta odlučivanja" pri čemu ekspertni sustav odabire atribut koji mu je preliminaran odnosno osnovni. Drvo se sastoji od čvorova, listova i null-listova. Čvor predstavlja događaj, a svaki list je moguće rješenje zadatka. Null-list je rješenje bez rješenja odnosno za zadane uvjete ne postoji rješenje.

Atribut: Datum isporuke

Ukoliko je datum isporuke kratak mogućnost neispunjerenja obveza se povećava pogotovo ako je ukupno tehnološko vrijeme vrlo blisku vremenu do datuma isporuke. U takvom slučaju datum isporuke poprima vrijednosti prema tablici 3.

*Tablica 3. Atribut: Datum isporuke
Table 3. Attribute: Due date*

Atributi	Vrijednosti atributa
Datum isporuke	<ul style="list-style-type: none"> • dug • kratak • kasni

Atribut: Određivanje važnosti kupca = f (ostvarena dobit, ispunjavanje obveza plaćanja, učestalost naručivanja)

Na osnovi mogućih kombinacija dodjeljuju se vrijednosti kvalitativno ili kvantitativno. Tablica 4 daje prikaz nekih od vrijednosti (ostale vrijednosti u intervalu dobiju se međusobnim kombiniranjem utjecajnih faktora). Ukupan broj mogućih kombinacija (bez ponavljanja) utjecajnih faktora iznosi 84.

Veća vrijednost (kvalitativno ili kvantitativno) znači i veći značaj ukupnog prioriteta pa tako i prednost promatranog radnog naloga u odnosu na

ostale. Veća vrijednost dodjeljuje se novom kupcu ili kupcu posebne važnosti po ostvarenim poslovima i plaćanju u rokovima, srednja vrijednost srednjim kupcima po plaćanju i opsegu narudžbi, a najmanja vrijednost za manje važne i u plaćanju nepouzdane kupce.

*Tablica 4. Atribut: Određivanje važnosti kupca
Table 4. Attribute: Significance of customers*

Ostvarena dobiti	Ispunjavanje obveza plaćanja	Učestalost naručivanja	Primjer predloženih vrijednosti
velika	dobra	velika	velika
srednja	srednja	srednja	srednja
mala	loša	mala	mala

Atribut: Penali

Ugovoreni penali ovise o neispunjjenju roka isporuke i uglavnom se izražavaju kao postotak ostvarene dobiti. Atribut Penali može poprimiti vrijednosti prema tablici 5.

*Tablica 5. Atribut: Penali
Table 5. Attribute: Penalties*

Atributi	Vrijednosti atributa
Penali	<ul style="list-style-type: none"> • visoki • mali • nema

Atribut: Složenost osiguranja resursa

Ovim faktorom obuhvaćaju se mogući promašaji s materijalom pri osiguranju proizvodnje (tablica 6).

*Tablica 6. Atribut: Složenost osiguranja resursa
Table 6. Attribute: Complexity of resources assuring*

Atributi	Vrijednosti atributa
Složenost osiguranja resursa	<ul style="list-style-type: none"> • jednostavno • složeno

Atribut: Mogućnost varijantnih tehnoloških postupaka

Ovaj atribut govori nam da li postoji mogućnost alternativnih odnosno varijantnih tehnoloških postupaka i u kojoj mjeri (tablica 7).

*Tablica 7. Atribut: Mogućnost alternativnih tehnoloških postupaka
Table 7. Attribute: Possibility of alternative technological procedures*

Atributi	Vrijednosti atributa
Mogućnost alternativnih tehnoloških postupaka	<ul style="list-style-type: none"> • nemoguće • moguće

Atribut: Faktor nabave = f (dobavljača, vremena dobavljanosti)

Može se izraziti kvalitativno (nemoguće, djelomično moguće, moguće) ili kvantitativno u intervalu (1-3) i dodjeljuje ga tehnolog (tablica 8). Veća vrijednost atributa znači težu dobavljanost osnovnog materijala. I ovdje vrijedi da su u tablici prikazane samo cjelobrojne vrijednosti (ostale vrijednosti u intervalu dobiju se međusobnim kombiniranjem utjecajnih faktora).

Tablica 8. Atribut: Faktor nabave
Table 8. Attribute: Supply factor

Dobavljač	Cijena dobavljaljivosti	Faktor nabave
pouzdan	mala	nemoguće
srednje pouzdan	srednja	djelomično moguće
nepouzdan	velika	moguće

Atribut: Faktor raspoloživog vremena

Ovaj se atribut određuje prema omjeru ukupnog i raspoloživog vremena na potrebnim kapacitetima za realizaciju radnog naloga (tablica 9), a u funkciji je raspoloživosti kapaciteta, ukupno potrebnog vremena (zbroj svih tehnoloških vremena), roka isporuke, sistemskog datuma (najraniji mogući početak).

Izražava se kvantitativno pri čemu manji broj predstavlja veću mogućnost neispunjerenja obveza prema kupcu a samim time povećava vrijednost konačnog prioriteta.

Tablica 9. Atribut: Faktor raspoloživog vremena
Table 9. Attribute: Available time factor

Atributi	Vrijednosti atributa
Faktor raspoloživog vremena	<ul style="list-style-type: none"> • 1 • 1,5 • 2 • 2,5

6

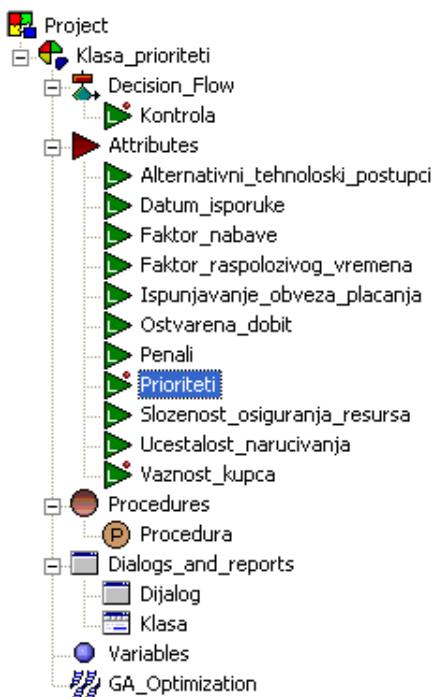
Primjer određivanje klase prioriteta radnog naloga primjenom ekspertnog sustava

Example of determination of work order priority class by applying of expert system

Ekspertni sustav omogućava krajnjem korisniku izbor najpovoljnijeg rješenja na osnovi njihova zahtjeva. Omogućuje praćenje ponašanja sustava uz identifikaciju odstupanja koja mogu ugroziti rad sustava, omogućujući donošenje pravovremenih i pravovaljanih odluka s ciljem poduzimanja akcija u sustavu zasnovanom na trenutnim događajima i raspoloživim podacima. Sustav je zasnovan na znanju koje je prezentirano u obliku stabla odlučivanja, pravila ili događaja. Razvoj sustava baziranog na znanju vrlo je složen posao s mnogo problema jer su ekspertiza, know-how, procedure, politike i ostala poslovna znanja često puta nedostupna npr. često puta su pohranjena u kompetenciji pojedinaca ili su slabo formulirana/dokumentirana.

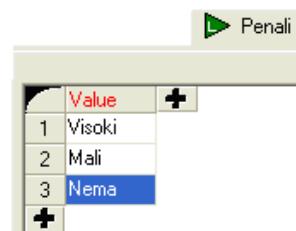
Odluke se donose na osnovu atributa koje je odredio ekspert, a koje krajnji korisnik odabire putem dijalog-a, proračuna ili čitanjem postojećih podataka. Tablica događaja sadrži listu primjera ili pravila koji pokazuju kakva će odluka biti različitim kombinacijama atributa. Atributi u stablu odlučivanja ili tablici događaja mogu biti prikazani drugim stablom odlučivanja ili tablicom događaja. Ograničenja omogućuju kreiranje takvih pravila koja osiguravaju da samo ispravna/poželjna kombinacija iz skupa svojstava budu izabrana na osnovu zahtjeva krajnjeg korisnika.

Ekspertni sustav je strukturiran kao projekt (slika 1). Svaki se modul sastoji od objekata – atributa, procedura, dijalog sučelja i izvještaja, varijabli i optimizacijskog alata baziranog na genetičkim algoritmima.



Slika 1. Izgled projekta za dani problem
Figure 1. Project review for selected problem

Nakon toga pristupa se definiranju svakog pojedinog atributa s pripadajućim vrijednostima svakog (slika 2).



Slika 2. Vrijednosti atributa Penali
Figure 2. Values of attribute Penalties

Ukoliko se radi o složenom atributu koji se sastoji od drugih atributa koristi se sustav ulančavanja. Uz navedeno potrebno je definirati i tablicu slučajeva. Slika 3. prikazuje primjer određivanja složenog atributa Vaznost kupca.

Slika 4 prikazuju djelić razrađene tablice slučajeva za rješavanje problema određivanja klase prioriteta. Tablica slučajeva sastoji se 1295 redaka i prikazuje dio mogućih kombinacija pri rješavanju ovog problema. Napravljen je i skraćeni prikaz stabla odlučivanja kako bi se dobila vizija danog problema (slika 5).

	Otvarena_dobit	Ispunjavanje_obveza_plaćanja	Ucestalost_narucivanja	Vaznost_kupca
1	Velika	Dobra	Velika	Velika
2	Velika	Srednja	Velika	Velika
3	Velika	Loša	Velika	Srednja
4	Velika	Dobra	Srednja	Velika
5	Velika	Srednja	Srednja	Srednja
6	Mala	Loša	Srednja	Srednja
7	Velika	Dobra	Mala	Velika
8	Velika	Srednja	Mala	Srednja
9	Velika	Loša	Mala	Mala
10	Srednja	Srednja	Srednja	Srednja
11	Srednja	Dobra	Srednja	Srednja
12	Srednja	Loša	Srednja	Mala
13	Mala	Dobra	Srednja	Srednja
14	Mala	Loša	Mala	Mala
15	Mala	Dobra	Velika	Mala

Slika 3. Primjer određivanja složenog atributa pomoću tablice slučajeva
Figure 3. Example of determination of complex attribute by the cases table

	Penali	Datum_isporuke	Vaznost_kupca	Faktor_raspoloživog_vremena	Faktor_nabave	Složenost_osiguranja_resursa	Alternativni_tehnoloski_postupci	Prioriteti
1	Visoki	Kratak	Velika	1	Složen	Složena	Nemoguće	19
2	Nema	Kratak	Velika	1	Složen	Složena	Nemoguće	17
3	Mali	Kratak	Velika	1	Složen	Složena	Nemoguće	18
4	Visoki	Kratak	Velika	1,5	Složen	Složena	Nemoguće	18
5	Nema	Kratak	Velika	1,5	Složen	Složena	Nemoguće	16
6	Mali	Kratak	Velika	1,5	Složen	Složena	Nemoguće	17
7	Visoki	Kratak	Velika	2	Složen	Složena	Nemoguće	17
8	Nema	Kratak	Velika	2	Složen	Složena	Nemoguće	15
9	Mali	Kratak	Velika	2	Složen	Složena	Nemoguće	16
10	Visoki	Kratak	Velika	2,5	Složen	Složena	Nemoguće	16
11	Nema	Kratak	Velika	2,5	Složen	Složena	Nemoguće	14
12	Mali	Kratak	Velika	2,5	Složen	Složena	Nemoguće	15
13	Visoki	Kratak	Velika	1	Složen	Jednostavna	Nemoguće	18
14	Nema	Kratak	Velika	1	Složen	Jednostavna	Nemoguće	16
15	Mali	Kratak	Velika	1	Složen	Jednostavna	Nemoguće	17
16	Visoki	Kratak	Velika	1,5	Složen	Jednostavna	Nemoguće	17
17	Nema	Kratak	Velika	1,5	Složen	Jednostavna	Nemoguće	15
18	Mali	Kratak	Velika	1,5	Složen	Jednostavna	Nemoguće	16
19	Visoki	Kratak	Velika	2	Složen	Jednostavna	Nemoguće	16
20	Nema	Kratak	Velika	2	Složen	Jednostavna	Nemoguće	14
21	Mali	Kratak	Velika	2	Složen	Jednostavna	Nemoguće	15
22	Visoki	Kratak	Velika	2,5	Složen	Jednostavna	Nemoguće	15
23	Nema	Kratak	Velika	2,5	Složen	Jednostavna	Nemoguće	13
24	Mali	Kratak	Velika	2,5	Složen	Jednostavna	Nemoguće	14
25	Visoki	Kasni	Velika	1	Složen	Složena	Nemoguće	20
26	Nema	Kasni	Velika	1	Složen	Složena	Nemoguće	18
27	Mali	Kasni	Velika	1	Složen	Složena	Nemoguće	19
28	Visoki	Kasni	Velika	1,5	Složen	Složena	Nemoguće	19
29	Nema	Kasni	Velika	1,5	Složen	Složena	Nemoguće	17
30	Mali	Kasni	Velika	1,5	Složen	Složena	Nemoguće	18
31	Visoki	Kasni	Velika	2	Složen	Složena	Nemoguće	18

Slika 4. Tablica slučajeva za dati problem određivanja klase prioriteta
Figure 4. Cases table for selected problem of priority class determination

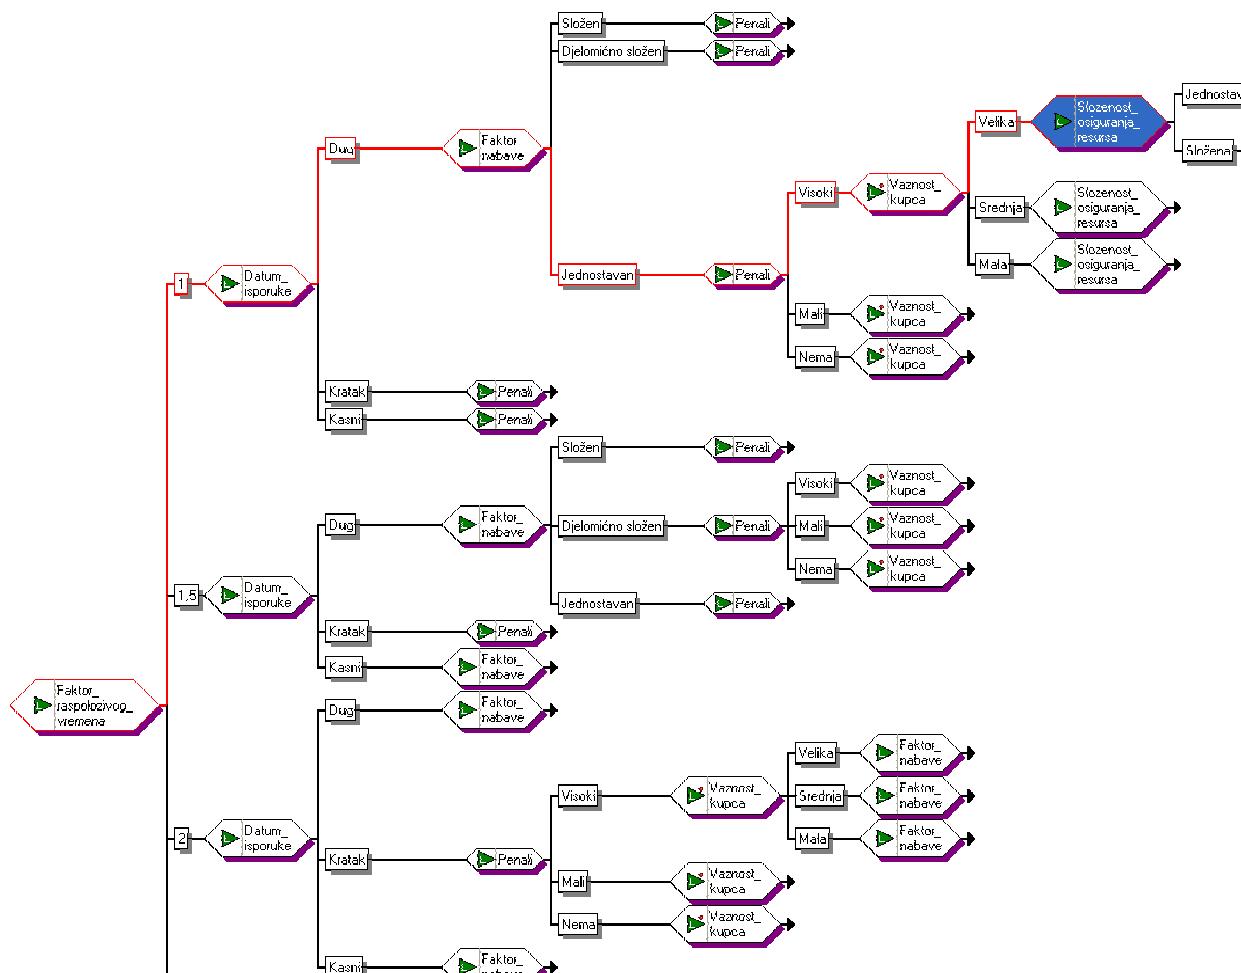
Kroz niz dijalogova boksova, pri čemu su samo neki prikazani na slikama 6. i 7. određuju se vrijednosti pojedinih atributa i na osnovu tih odabranih veličina dobiva se vrijednost Klase prioriteta.

Izlazne vrijednosti koje su dobivene prolaskom kroz niz dijalog boksova svrstane su u vrijednosne kategorije koje kao krajnji rezultat daju određenu Klasu

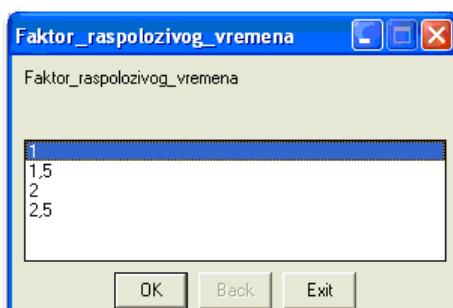
prioriteta (slika 8.).

Iz danog primjera može se zaključiti kako je odabran radni nalog, ovisno o odabranim parametrima poprimio vrijednost Klase prioriteta 6 ili 7 odnosno prema izračunatim vrijednostima 13 ili 14.

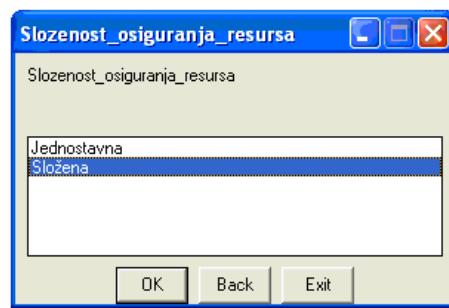
Primjer dijela stabla odlučivanja za odabrani primjer je na slici 9.



Slika 5. Stablo odlučivanja
Figure 5. Decision tree



Slika 6. Odabir vrijednosti atributa Faktor_raspolozivog vremena
Figure 6. Selection of value for attribute Available time factor



Slika 7. Odabir vrijednosti atributa Složenost_ostiguranja_resursa
Figure 7. Selection of value for attribute Complexity of resources assuring

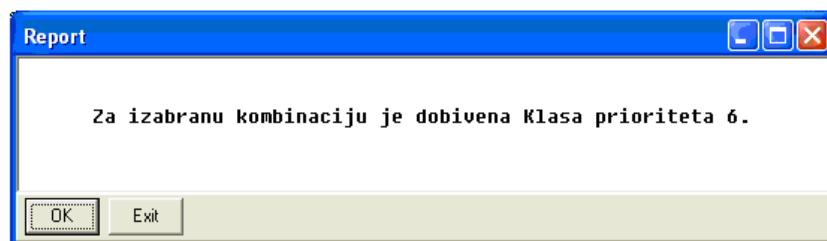


Figure 8. Obtained priority class for selected example
Slika 8. Prikaz dobivene Klase prioriteta za uneseni primjer

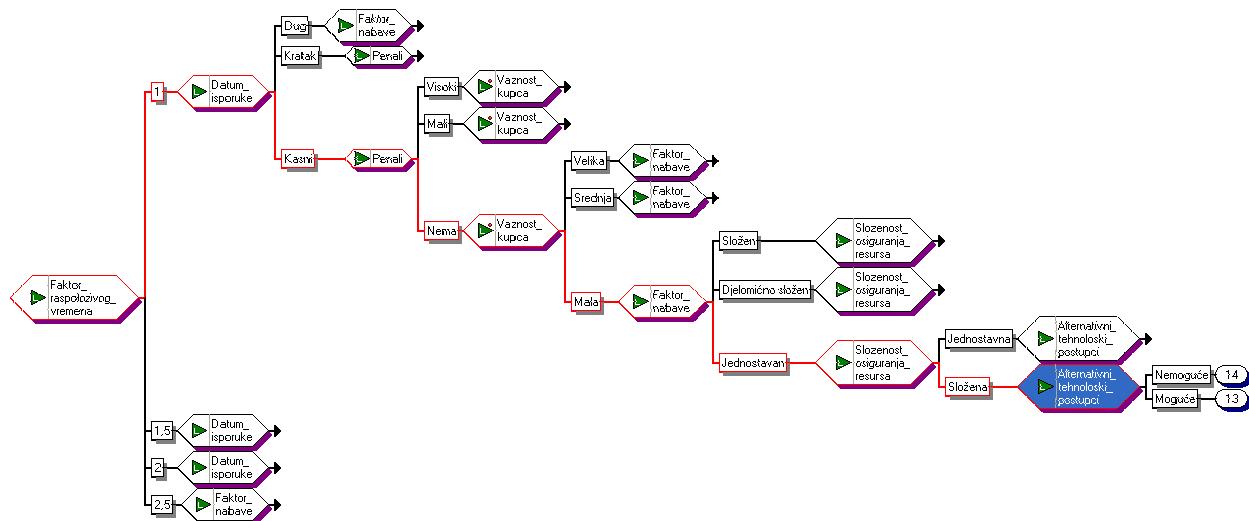


Figure 9. Part of decision tree
Slika 9. Dio stabla odlučivanja

7

Zaključak

Conclusion

Analizom dosadašnjih rješenja i stanja postignutih u proizvodnim poduzećima orijentiranih pojedinačnoj i maloserijskoj proizvodnji, zaključilo se da dolazi do značajnog kašnjenja pri isporuci. Problemi vezani uz kašnjenje očituju se kroz nisku proizvodnost; nisku standardiziranost proizvoda jer se proizvod definira prema zahtjevima kupca; nefleksibilnost procesa; sastavnici koja nije poznata i koja se često razvija s razvojem dokumentacije čije su izmjene i revizije česte; tehnologiju koja se rješava iskustveno i prema procjeni potrebnih vremena; kapacitetima koji su neusklađeni s potrebama jer se potrebe stalno mijenjaju itd.

Jedan od glavnih uzročnika tog kašnjenja je neadekvatan model prioriteta. Pošto ni jedno od navedenih pravila prioriteta ne uzima u obzir navedene parametre (datum isporuke, važnost kupca, penali, složenost osiguranja resursa, mogućnost alternativnih tehnoloških postupaka, faktor nabave i faktor raspoloživog vremena), već su isključivo orijentirani na operaciju i djeluju lokalno, iskazana je potreba razvoja novog modela prioriteta. Svako od navedenih pravila pokriva neke od navedenih parametara npr. datum isporuke, raspoloživost kapaciteta, ukupan broj operacija, odnos tehnološkog i preostalog vremena, ali bez međusobne zajedničke interakcije.

Cilj rada je bio predvidjeti takve parametre u modelu prioriteta kako bi se moglo izvršiti određivanje klase prioriteta primjenom ekspertnog sustava, a u svrhu ostvarivanja skraćenja vremena izrade.

Problem se očitovalo u određivanju utjecajnih parametara u modelu prioriteta: datum isporuke, važnost kupca, penali, složenost osiguranja resursa, mogućnost alternativnih tehnoloških postupaka, faktor nabave i faktor raspoloživog vremena kao i vrijednosti

koje će poprimiti pojedini atributi.

Ostvareni rezultati primjenom navedenih modela mogu se podijeliti na teorijske i praktične.

Teorijski rezultat je ostvaren kroz izradu modela prioriteta za pojedinačnu proizvodnju temeljen na eksperternom sustavu.

Praktični rezultati su ostvareni kroz:

- donošenje preciznijih odluka u što je moguće kraćem vremenu
- mogućnost povezivanja i implementacije razvijenog modela u informacijski sustav upravljanja kao podrške u realizaciji terminiranja.

Dobiveni rezultati ohrabruju i obvezuju na daljnje razvijanje i unaprjeđivanje navedenog modela pri čemu posebnu pozornost treba posvetiti:

- određivanju vrijednosti prioriteta za svaki radni nalog unutar klase prioriteta
- uključivanju drugih atributa koji imaju utjecaj na klase prioriteta, a u radu nisu obuhvaćeni
- proširivanju postojećih atributa sa novim vrijednostima i kriterijima primjenom kvantitativnih metoda odlučivanja (višekriterijsko vrednovanje – metoda težine svojstava).

8

Reference

References

- [1] Lujić, R. Planiranje i praćenje montaže velikih objekata. // Magistarski rad, FSB, Zagreb, 1999.
- [2] Majdandžić, N.; Lujić, R.; Matičević, G.; Šimunović, G.; Majdandžić, I. Upravljanje proizvodnjom. Strojarski kultet, Slavonski Brod, 2001.
- [3] Barták, R. Towards Mixed Planning and Scheduling.// In Proceedings of CPDC2000 Workshop (invited talk), Gliwice, 2000.
- [4] Beach, R. Muhlemann, A. P.; Price, D. H. R.; Paterson, A.; Sharp, J. A. A review of manufacturing flexibility. //

- European Journal of Operational Research, Vol. 122, No. 1 (2000), str. 41-57.
- [5] Brucker, P.; Drexel, A.; Möhring, R.; Neumann, K.; Pesch, E.: Resource-constrained project scheduling: Notation, classification, models, and methods. // European Journal of Operational Research, Vol. 112, No. 1 (1999), str. 3-41.
- [6] Castillo, L.; Fdez-Olivares, J.; González, A. Automatic generation of control sequences for manufacturing systems based on partial order planning techniques. // Artificial Intelligence in Engineering, Vol. 14, No. 1(2000), str. 15-30.
- [7] Daniel, V.; Guide, R. Production planning and control for remanufacturing: industry practice and research needs. // Journal of Operations Management, Vol. 18, No. 4 (2000), str. 467-483.
- [8] Ecker, Klaus H. Scheduling of resource tasks. // European Journal of Operational Research, Vol. 115, No. 2 (1999), str. 314-327.
- [9] Howard, A.; Kochhar, A.; Dilworth, J. Functional requirements of manufacturing planning and control systems in medium-sized batch manufacturing companies. // Integrated Manufacturing Systems, Vol. 10, No. 3 (1999), str. 136-145.
- [10] Jacobs, L. W.; Lauer, J. DSS for Job Shop Machine Scheduling. // Industrial management & Data System, Vol. 9, No 4 (1994), str. 15-23.
- [11] Meybodi, M. Z. Integrating production activity control into a hierarchical production-planning model. // International Journal of Operations & Production Management, Vol. 15, No 5(1995), str. 4-25.
- [12] Palmer, G. J. An Integrated Approach To Manufacturing Planning (Optimisation in Process Planning and Job Shop Scheduling). // Doctoral dissertation (PhD), A thesis submitted to the University of Huddersfield, February 1994.
- [13] Stoop, P.; Wiers, V. The complexity of scheduling in practice. // International Journal of Operations & Production Management, Vol. 16, No. 10(1996), str. 37-53.
- [14] Jones, A.; Rabelo, L. C. Survey of Job Shop Scheduling Techniques. // NISTIR, National Institute of Standards and Technology, Gaithersburg, MD, 1998.
- [15] Bender, M. Flow and Stretch Metrics for Scheduling Continuous Job Streams. // SODA: ACM-SIAM Symposium on Discrete Algorithms, A Conference on Theoretical and Experimental Analysis of Discrete Algorithms, 1998.
- [16] Selladurai, V.; Aravindan, P.; Ponnambalam, S. G.; Gunasekaran, A. Dynamic simulation of job shop scheduling for optimal performance. // International Journal of Operations & Production Management, Vol. 15 No. 7(1995), str. 106-120.
- [17] Leu, B.; Nazemetz, J. W. Comparative analysis of group scheduling heuristics in a flow shop cellular system. // International Journal of Operations & Production Management, Vol. 15, No. 3(1995), str. 143-157.
- [18] Holthaus, O.; Rajendran, C. New dispatching rules for scheduling in a job shop - an experimental study. // International Journal of Advanced Manufacturing Technology, Vol. 13, No. 2 (1997), str. 148-153.
- [19] Morgan, J. R.; Mahmoodi, F.; Mosier, C. T. Analysis of scheduling schemes in a random flexible manufacturing system. // Proceedings of the NE DSI Virgin Islands Meeting, 1996.
- [20] Kulkarni, R. Exploiting the Scheduling Algorithms in SAS/OR. // SoftwareSAS Institute Inc., Cary, NC, SUGI Proceedings, 1994.
- [21] Bassett, G.; Todd, R. The SPT Priority Sequence Rule: The Illusion of Efficiency and the Reality of Bottlenecks. // International Journal of Operations & Production Management, Vol. 12, No. 6 (1994), str. 70-78.
- [22] Huq, F.; Huq, Z. The sensitivity of rule combinations for scheduling in a hybrid job shop. // International Journal of Operations & Production Management, Vol. 15, No. 3 (1995), str. 59-75.
- [23] Bauer, A.; Bullnheimer, B.; Hartl, R. F.; Strauß, C.: An Ant Colony Optimisation Approach for the Single Machine Total Tardiness Problem. // This work was supported from Austrian Science Foundation under Grant F-01005, 1999.
- [24] Lu, S. H.; Kumar, P.R. Distributed scheduling based on due dates and buffer priorities. // IEEE Transactions on Automatic Control, 36, 1991, str. 1406-1416.
- [25] Jain, S.; Gan, B.; Lim, C.; Low, Y. Bottleneck based modelling of semiconductor supply chains. // Int. Conf. on Modeling and Analysis of Semiconductor Manufacturing, Arizona, May, 2000.
- [26] Khamooshi, H. Network-based project planning and scheduling. // Industrial Management & Data Systems, Vol. 96, No. 8 (1996), str. 13-22.
- [27] Abramson, D.; Abela J. A Parallel Genetic Algorithm for Solving the School Timetabling Problem. // 15th Australian Computer Science Conference, Hobart, Feb, 1992.
- [28] Azzaro-Pantel, C.; Bernal-Haro, L.; Baudet, P.; Domenech, S.; Pibouleau, L. A two-stage methodology for short-term batch plant scheduling discrete-event simulation and genetic algorithm. // Computers & Chemical Engineering, Vol. 22, No. 10 (1998), str.1461-1481.
- [29] Bierwirth, C.; Mattfeld, D. C.: Production Scheduling and Rescheduling with Genetic Algorithms. // Evolutionary Computation, Vol. 7, No. 1 (1999), str. 1-17.
- [30] Boston, K.; Bettinger, P.: Combining tabu search and genetic algorithm heuristic techniques to solve spatial harvest scheduling problems. // Forest Science. Vol. 48, No. 1 (2002), str. 35-46.
- [31] Cai, X.; Li, K.N. A genetic algorithm for scheduling staff of mixed skills under multi criteria, European Journal of Operational Research, Vol. 125, No. 2 (2000), str. 359-369.
- [32] Fang, H. L.; Ross, P.; Come, D. A promising Genetic Algorithm Approach to Job Shop Scheduling, Rescheduling and Open Shop Scheduling Problems. // Proceedings of fifth International Conference on Genetic Algorithms, S. Forrest (ed), San Mateo, 1993, str. 375-382.
- [33] Fang, H. L.: Genetic Algorithm in Timetabling and Scheduling. // Doctoral Thesis, University of Edinburg, 1994.
- [34] Husbands, P.; Jermy, G.; McIlhagga, M.; Ives, R. Two Applications of Genetic Algorithms to Component Design. // Evolutionary Computing: Selected papers from AISB workshop on evolutionary computing. / Ed. T. Fogarty, Springer-Verlag, LNCS, Vol. 1143, 1996, str. 50-61.
- [35] Ilhagga, M. Solving Generic Scheduling problems with a Distributed Genetic Algorithm. // In: Proceedings of the ASIB Workshop on Evolutionary Computing, 1997 / Eds. D Corne and J Shapiro, Manchester April 1997, str. 85-90.

- [36] Jahangirian, M.; Conroy, G.V.: Intelligent dynamic scheduling system: the application of genetic algorithms, *Integrated Manufacturing Systems.* // Vol. 11, No. 4 (2000), str. 247-257.
- [37] Koza, J. R.: *Genetic Programming.* // Proceedings Encyclopedia of Computer Science and Technology, Marcel-Dekker, 1997, str. 29-43.
- [38] Majdandžić, N.; Lujić, R.; Šimunović, G.; Matičević, G. Applying genetic algorithm for production plan optimisation. // 17th International Conference on CAD/CAM, Robotics and Factories of the Future – CARS& FOF 2001, Durban, South Africa, July 10-12, 2001, str. 1079-1086.
- [39] Maturana, F.; Gu, P.; Naumann, A.; Norrie, D. H. Object-oriented job-shop scheduling using genetic algorithms. // *Computers in Industry*, Vol. 32, No. 3 (1997), str. 281-294.
- [40] Michalewicz, Z. *Genetic Algorithm + Data Structures = Evolution Programs.* Springer-Verlag, Berlin, Germany, 1992.
- [41] Sakawa, M.; Mori, T. An efficient genetic algorithm for job-shop scheduling problems with fuzzy processing time and fuzzy due date. // *Computers & Industrial Engineering*, Vol. 36, No. 2 (1999), str. 325-341.
- [42] Yamada, T.; Nakano, R. Genetic Algorithms for Job-Shop Scheduling Problems. // Proceedings of Modern Heuristic for Decision Support, UNICOM seminar, London, 18-19 March (1997), str. 67-81.
- [43] Kathuria, R.; Anandarajan, M.; Igbariac, M. Selecting IT applications in manufacturing: a KBS approach. // *The International Journal of Management Science*, Vol. 27 (1999), str. 605-616.
- [44] Bistline, G. W.; Banerjee, S.; Banerjee, A. RTSS: An interactive decision support system for solving real time scheduling problems considering customer and job priorities with schedule interruptions. // *Computers Ops Res.* Vol. 25, No. 11 (1998), str. 981-995.
- [45] Adenso-Diaz, B.; Ignacio, G.; Tuya, J.: Incorporating fuzzy approaches for production planning in complex industrial environments: the roll shop case. // *Engineering Applications of Artificial Intelligence*, Vol. 17 (2004), str. 73-81.
- [46] Lujić, R. Doprinos modelu terminiranja u sustavu upravljanja pojedinačnom proizvodnjom. // Doktorska disertacija, Strojarski fakultet, Slavonski Brod, 2002.
- [47] Veža, I. Projektiranje proizvodnih procesa. Sveučilište u Splitu, FESB, Split, 1994.
- [48] Drexel, A.; Nissen, R.; Patterson, J. H.; Salewski, F. ProGen/x An instance generator for resource-constrained project scheduling problems with partially renewable resources and further extensions. // *European Journal of Operational Research*, Vol. 125, No. 1(2000), str. 59-72.
- [49] Reddy, R. The challenge of artificial intelligence. // *Computer*, Vol. 29, No. 10, (1996), str. 86 - 98.
- [50] Sesartić, J. Ekspertni sustav za vođenje procesa pečenja klinkera. // Doktorska disertacija, Elektrotehnički fakultet Sveučilišta u Zagrebu. - Elektrotehnički fakultet, Zagreb, 1988.
- [51] Čerić, V. Ekspertni sustavi. Skripta, Ekonomski fakultet, Zagreb, 2002.
- [52] Rolston, D. W. *Principles of Artificial Intelligence and Expert Systems Development.* McGraw-Hill, 1988.
- [53] Filetin, T. Prilog metodičkom postupku izbora materijala pri konstruiranju. // Doktorska disertacija, Fakultet strojarstva i brodogradnje, Zagreb, 1986.

Author's Address (Adresa autora):

PhD Roberto Lujić, Assistant professor
 University of Osijek
 Mechanical Engineering Faculty
 Trg I. B. Mazuranic 2
 35000 Slavonski Brod, Croatia
 Tel: 0038535446718
 Fax: 0038535446446
 E-mail: Roberto.Lujic@sfsb.hr

PhD Tomislav Šarić, Assistant professor
 University of Osijek
 Mechanical Engineering Faculty
 Trg I. B. Mazuranic 2
 35000 Slavonski Brod, Croatia
 Tel: 0038535446718
 Fax: 0038535446446
 E-mail: Tomislav.Saric@sfsb.hr

PhD Goran Šimunović, Assistant professor
 University of Osijek
 Mechanical Engineering Faculty
 Trg I. B. Mazuranic 2
 35000 Slavonski Brod, Croatia
 Tel: 0038535446718
 Fax: 0038535446446
 E-mail: Goran.Simunovic@sfsb.hr