

AVTOMATSKI SPROTNI NADZOR KVALITETE
IZDELKOV V KOSOVNIH INDUSTRIJAH

Doktorska disertacija
Mednarodna podiplomska šola Jožefa Stefana
Ljubljana, Slovenija, maj 2009

Mentor: *prof. dr. Dani Juričič*

Komisija za oceno doktorske disertacije:

Prof. dr. Stanko Strmčnik, predsednik, Institut »Jožef Stefan«, Ljubljana, Slovenija

Prof. dr. Juš Kocijan, član, Institut »Jožef Stefan«, Ljubljana, Slovenija

Prof. dr. Igor Škrjanc, član, Univerza v Ljubljani, Fakulteta za elektrotehniko, Ljubljana, Slovenija

Jani Kleindienst

AVTOMATSKI SPROTNI NADZOR KVALITETE IZDELKOV V KOSOVNIH INDUSTRIJAH

Doktorska disertacija

MONITORING OF THE PRODUCT QUALITY IN MANUFACTURING INDUSTRIES

Doctoral Dissertation

Mentor: prof. dr. Đani Juričić

Maj 2009

MEDNARODNA PODIPLOMSKA ŠOLA JOŽEFA STEFANA
JOŽEF STEFAN INTERNATIONAL POSTGRADUATE SCHOOL

Ljubljana, Slovenija



Kazalo

1	Uvod	1
1.1	Pregled dosedanjih raziskav	2
1.2	Primeri uporabe	5
1.3	Cilji disertacije	7
1.4	Struktura disertacije	9
2	Opis demonstracijskega proizvodnega procesa	13
2.1	Podatki in parametri v proizvodnem procesu	14
2.2	Organizacija proizvodnega procesa	14
2.3	Sledenje materialom	15
2.4	Problem zbiranja podatkov za potrebe podpore odločanju	16
2.4.1	Veliko različnih transportnih enot	17
2.4.2	Serije izdelkov	17
2.4.3	Različne dimenzije transportnih palet	17
2.4.4	Identifikacija surovin	17
2.5	Prenova proizvodnega procesa	18
2.5.1	Spremna dokumentacija	18
2.5.2	Delovna dokumentacija	19
2.5.3	Spremembe v postopkih	20
2.6	Informatizacija proizvodnega procesa	23
2.6.1	Spremljanje strojev	24
2.6.2	Vnašanje proizvodnih dogodkov	25
2.6.3	Programska oprema	25
2.6.4	Upravljanje podatkov	26
2.6.5	Komunikacija z ostalimi informacijskimi sistemi	27
3	Izbira optimalnega števila terminalov	31
3.1	Postavitev problema	32
3.1.1	Kriterijska funkcija	32
3.2	Reševanje optimizacijskega problema	33

3.2.1	Izračun čakalnih časov na množici dogodkov	33
3.2.2	Določanje kritičnih čakalnih časov	35
3.2.3	Optimizacijska metoda	36
3.2.4	Ocenjevanje dnevne porazdelitve dogodkov	36
3.3	Primer uporabe	37
3.4	Diskusija	38
3.5	Sklep	40
4	Orodja za analizo proizvodnih podatkov	41
4.1	Model linearne regresije	41
4.1.1	Ocena najmanjše kvadratne napake	41
4.1.2	Analiza	42
4.1.3	Metoda instrumentalnih spremenljivk	44
4.2	Kolinearnost	45
4.2.1	Primer redundantnih spremenljivk	45
4.2.2	Reševanje problema slabe pogojenosti informacijske matrike	46
4.2.3	Reševanje problema neinformativnih podatkov z latentnimi strukturami	48
4.3	Glavne komponente	49
4.3.1	Analiza modela glavnih komponent	52
4.3.2	Izbira baznih vektorjev	53
4.4	Praktični vidiki	54
4.4.1	Linearna regresija na osnovi metode glavnih komponent	54
4.5	Novi problemi	54
4.5.1	Asociativna regresija	55
4.6	Povezovanje vhoda in izhoda	56
4.6.1	Metoda delnih najmanjših kvadratov	56
4.7	Logistična regresija	58
4.7.1	Osnovna teorija	59
4.7.2	Reševanje problema kolinearnosti	60
4.7.3	Uporaba manjšega števila latentnih spremenljivk	61
4.7.4	Mera ujemanja	62
5	Modeliranje procesa brizganja	63
5.1	Podatki	63
5.2	Regresijski model	65
5.3	Primerjava regresijskih metod	67
5.3.1	Analiza s koračno regresijo	67
5.3.2	Analiza z metodo glavnih komponent	72

5.3.3	Primerjava rezultatov	76
6	Nadzor kakovosti izdelkov	77
6.1	Podatki	77
6.1.1	Združevanje vhodnih in izhodnih parametrov	78
6.2	Logistični regresijski model	79
6.2.1	Izračun na izvornih podatkih	82
6.2.2	Uporaba metode glavnih komponent	82
6.3	Rezultati	82
6.4	Sprotni nadzor kakovosti	86
6.5	Komentarji	89
7	Netehniški vidiki	91
	Sklep	101
	Zahvale	105
	Literatura in viri	105
	Kazalo slik	115
	Kazalo tabel	119
	Kazalo algoritmov	121
	Priloge	123
A	Seznam objav iz disertacije	123
B	Lienarna algebra	125
B.1	Prostori in baze	125
B.2	Linearne preslikave	126

Povzetek

Nepričakovane ustavitve in izpadi kakovosti izdelkov še vedno predstavljajo težave v sodobnih proizvodnih sistemih. Do teh pojavov pogosto pride brez vidnega zunanjega vzroka, četudi je proces normalno deloval dalj časa. Posledice se kažejo v izgubah v proizvodnji in zmanjšani učinkovitosti, kar pomeni manjši dobiček. Klasične metode statistične kontrole so povsem nezmožne primernega zaznavanja težav in ugotavljanja njihovih vzrokov. Razlog je v tem, da te metode obravnavajo parametre kakovosti izdelka posamično in ne upoštevajo notranje povezave med spremenljivkami procesa.

V želji po večanju konkurenčnosti evropski proizvajalci čedalje več sredstev vlagajo v vodenje kakovosti proizvodnje na podlagi modelov procesa, ki jih lahko dobimo iz velikih količin procesnih podatkov. Z boljšim razumevanjem procesa je mogoče bolje napovedovati in s tem obvladovati njegovo obnašanje. Iz tega motiva izvira tudi pričujoča disertacija.

Namen disertacije je zgraditi koncept sistema za nadzor in kontrolo kakovosti izdelkov v kosovnih industrijah. Dodana vrednost pristopa temelji na integraciji sodobnih informacijskih tehnologij za zbiranje procesnih podatkov in naprednih postopkov za sintezo modelov, interpretacijo podatkov in podporo odločanju. Modeliranje sloni na statistični regresiji ob prisotnosti koreliranosti v podatkih. Ker so nekateri pokazatelji kakovosti proizvodnje (kakovost izdelka ali razpoložljivost opreme) definirani v zalogi diskretnih vrednosti $\{0, 1\}$, se v disertaciji ukvarjamo z uporabo logistične regresije v kontekstu koreliranosti v parametrih vstopnih surovin in tehnoloških parametrih procesa. Razviti statistični modeli služijo za zaznavanje neskladij med izmerjenimi podatki, kar je osnova za pravočasno detekcijo problemov v proizvodnji. Predlagani koncepti so v disertaciji delno preizkušeni na simuliranih zgledih, delno pa na realnih podatkih iz proizvodnje.

Abstract

Unexpected production breakdowns and unpredictable defects in product quality remain critical problems in modern manufacturing systems. Usually occurring by no obvious exterior cause and often during periods of smooth production, they lead to production losses and reduced process availability, which results in lower profit rates. Conventional statistical methods of process control are completely unable to provide adequate warnings and examine the causes, since they are focused on individual output variables and largely ignore the inherent relationship between process variables.

In quest of improved competitiveness, the European manufacturing sector is attempting to shift the production and business paradigm towards innovative model-based solutions that make use of the large amount of process data generated daily. Improved insight enables more predictable performance of large scale manufacturing processes.

In this spirit, the aim of this project is to build up a prototype system for surveillance and control of product quality in complex manufacturing processes. The novelty of the approach is based on the integration of modern e-manufacturing solutions for accurate acquisition of production data and advanced regression and classification methods for model synthesis, data interpretation and decision support. The modeling approach is based on statistical regression with correlated data. Since the outcomes of some of the performance indicators (product quality, availability of equipment) reside inside $\{0, 1\}$ interval, the present dissertation is concerned with the logistic regression within the context of correlation between starting materials and technological parameters of the production process. Developed statistical models are used for the perception of disparities in measured data, which is the basis for timely problem detection. The concepts shown in the underlying thesis were tested on simulated examples and real production data.

Seznam kratic

ERP	=	(ang. enterprise resource planing) informacijski sistemi za planiranje virov podjetja
MES	=	(ang. manufacturing execution systems) informacijski sistemi za spremljanje in nadzor proizvodnje
MSEB	=	(ang. mean squared error of the beta parameter vector) srednja kvadratna napaka vektorja koeficientov beta
PCA	=	(ang. principal component analysis) metoda glavnih komponent
PCR	=	(ang. principal component regression) regresija z metodo glavnih komponent
PLS	=	(ang. partial least squares) metoda delnih najmanjših kvadratov
SCADA	=	(ang. supervisory control and data acquisition) informacijski sistemi za nadzorno vodenje in zajemanje podatkov
TBM	=	(ang. transferable belief model) modela prenosa zaupanja

Poglavje 1

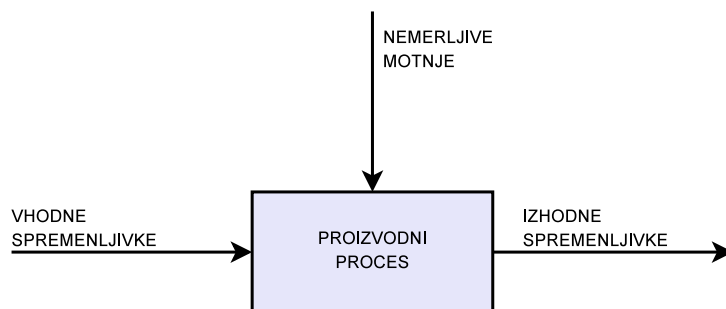
Uvod

Proizvodni sektor predstavlja eno glavnih gonilnih moči ekonomske rasti Evropske skupnosti, saj pomeni okoli 18% celotne dodane vrednosti in zaposluje okoli 34 milijonov ljudi [59]. Zadnjih nekaj desetletij se ta sektor sooča z migracijo nekaterih tradicionalnih panog na Daljni vzhod, na trge s cenejšo delovno silo. Poleg teh, nepopravljivih izgub, se soočamo tudi s hitro modernizacijo daljnovzhodnih dežel, ki tako postajajo enakovredni tekmeči tudi na visokotehnoloških področjih. Kot odgovor na to grožnjo je evropska industrija definirala prioritete, med katerimi so visoka zmogljivost in prilagodljivost procesov [6], [42], ki omogočajo boljšo učinkovitost in poslovno politiko. Taka iniciativa pa zahteva učinkovito izrabo informacijskih virov za celovito, na znanju temelječo podporo odločanju [13].

Proizvodni proces, ki je glavna aktivnost industrijskih podjetij, je običajno kompleksen, saj je sestavljen iz različnih operacij, medsebojno povezanih z materialnimi, energijskimi in informacijskimi tokovi ter omejen s časovnimi, tehnološkimi in organizacijskimi omejitvami [46], [50]. Slabosti današnje procesne kontrole se kažejo v subjektivni zaznavi proizvodnih ciljev (dobičkonosnost), pogosto nepredvidljivih variacijah procesnih parametrov in spremenljivk, subjektivnemu sprejemanju odločitev in tudi v velikih količinah nestrukturiranih podatkov, ki izvirajo iz različnih informacijskih sistemov [73].

Proizvodna podjetja se trudijo na najrazličnejše načine povečati svojo konkurenčno prednost. Zaradi tega so njihovi proizvodni procesi podvrženi optimizacijam in izboljšavam, katerih namen je povečanje učinkovitosti opreme [22]. Za kakršne koli ukrepe pa je potrebno zadostno poznavanje proizvodnega procesa, kar pa je mogoče doseči le z ustrezno informacijsko podporo [11]. Z večanjem kompleksnosti procesi niso več obvladljivi brez te podpore. Na proizvodni proces lahko gledamo kakor na preslikavo (slika 1.1), ki vhodne parametre (lastnosti surovin, tehnološki parametri izdelave) preslika v vektor izhodnih parametrov, ki zajemajo podatke o kakovosti izdelkov, njihove fizikalne lastnosti, itd. Predvidevamo, da bi bilo mogoče z modeliranjem proizvodnega procesa na

podlagi teh podatkov vzpostaviti boljši nadzor ter s korektivnimi ukrepi aktivno posegati vanj z namenom doseganja boljše učinkovitosti.



Slika 1.1: *Proizvodni proces*. S stališča modeliranja lahko na proizvodni proces gledamo kot na preslikavo, ki vektor vhodnih parametrov preslika v vektor izhodnih parametrov.

Iz informacijsko podprtega proizvodnega procesa izvirajo številni podatki. S spremljanjem proizvodnega procesa se v podatkovne zbirke beleži na stotine procesnih spremenljivk. Obseg teh podatkov je prevelik, da bi bili obvladljivi brez primernih orodij, ki iz velike količine podatkov izluščijo uporabne informacije. Za iskanje zakonitosti¹ v podatkih se zato uporabljajo orodja podatkovnega rudarjenja. Orodja podatkovnega rudarjenja so razširjena na različnih področjih industrijskih in poslovnih sistemov [26]. V industrijskih panogah se podatkovno rudarjenje uporablja za analiziranje velikih količin procesnih podatkov z namenom izboljšave proizvodnega procesa, izboljšave kakovosti izdelkov in racionalizacije rabe energije. Zaradi pomanjkanja primernih orodij, znanja in razpoložljivosti človeških virov je v industrijskih panogah takih sistemov manj kakor v ostalih panogah [54].

1.1 Pregled dosedanjih raziskav

Modeliranje proizvodnih sistemov

Sodobni proizvodni sistemi so preveč kompleksni, da bi jih lahko natančno opisali z enačbami, ki izvirajo iz fizikalnih principov [57]. Alternativa je lahko to, da zvezo med vhodi in izhodi opišemo s stohastičnim modelom iz nekega nabora (v splošnem) nelinearnih struktur. Zveze med vhodnimi in izhodnimi parametri s tem zgubijo fizikalni pomen, tako da je vloga modela le opis dogajanj, ne pa tudi njihova fizikalna interpretacija.

Sinteza modelov iz podatkov je stara disciplina, ki jo gojijo v statistiki, sistemski identifikaciji [30], [28] in strojnem učenju. Rezultat je velik nabor postopkov, znanih kot

¹Pri iskanju zakonitosti gre za iskanje vzorcev in korelacij v podatkih, klasifikacijo in grupacijo spremenljivk, vse z namenom identifikacije povezav in razmerij, ki so bila do tedaj neznana.

podatkovno rudarjenje [62]. Različni pristopi služijo različnim namenom, pri čemer ima vsak prednosti in slabosti. Najbolj uporabljane so statistične metode, umetne nevronske mreže [43], induktivno učenje in Bayesove mreže [28]. Uporabo pri problemih nadzora in diagnostike napak lahko zasledimo v številnih knjigah in člankih [71], [38], [60].

V zadnjem desetletju je bilo modeliranje iz podatkov uporabljeno v raznih podjetjih, predvsem tistih, ki so fokusirani na stranke, kot npr. zavarovalnice, banke in telekomunikacije; primeri iz proizvodnje: Texas Instruments (diagnostika napak), Caterpillar (kontrola kvalitete izpustov) [26], Ford (analiza hrupa in vibracij). Čeprav se uporablja na mnogih segmentih v podjetjih, metoda še ni širše sprejeta.

Podatkovno rudarjenje pokriva širok spekter nalog. V industrijskih procesih so te naloge najpogosteje povezane z nadzorom in upravljanjem procesov, s sistemi za podporo odločanju ter sistemi za diagnostiko in odkrivanje napak [9]. V teh aplikacijah se pogosto uporabljajo naslednji primeri podatkovnega rudarjenja:

- regresijske tehnike, ki se uporabljajo za sestavo mehkih (navideznih) senzorjev, kjer je nek novi parameter lahko izpeljan iz množice merjenih vrednosti;
- klasifikacijske tehnike, ki se uporabljajo za napovedovanje, ali bo končni izdelek ustrezal določenim merilom in za klasifikacijo tipov napak v ustrezne razrede;
- deskriptivne tehnike modeliranja (npr. metoda glavnih komponent), ki med posameznimi spremenljivkami iščejo korelacije, pomembne za nadaljnje razumevanje procesa in za statistične obdelave.

Najpogostejše tehnike pa obsegajo:

- faktorske statistične modele, kot sta metoda glavnih komponent in metoda delnih najmanjših kvadratov;
- modeli nevronske mreže;
- modeli mehke logike.

Faktorski statistični modeli

Faktorski statistični modeli, ki se uporabljajo v podatkovnem rudarjenju, vključujejo metodo glavnih komponent in metodo delnih najmanjših kvadratov. Ti metodi se uporabljata za transformacijo statistično odvisnih procesnih spremenljivk v manjšo množico statistično neodvisnih spremenljivk. Tehnike so pogosto imenovane tudi tehnike reduciranja podatkov, saj poiščejo faktorje, ki imajo mnogo manjšo dimenzijo od originalnih podatkov, pri tem pa vseeno ohranjajo glavne trende. Pogosto je mogoče npr. 100 vhodnih spremenljivk reducirati na 5 ali 6 novih in pri tem ohraniti 40 do

80% variabilnosti izvirnih podatkov [54]. Metoda glavnih komponent omogoča boljše razumevanje podatkov, saj identificira korelacije med samimi vhodnimi podatki, kakor tudi med vhodnimi in izhodnimi podatki.

Faktorski statistični modeli so uporabni povsod, kjer imamo opravka s:

- podatki kontaminiranimi s šumom;
- podatkovnimi serijami z manjkajočimi vzorci;
- koreliranimi spremenljivkami v podatkovnih bazah;
- podatkovnimi bazami z velikim številom spremenljivk in malo vzorci.

Tipične aplikacije v industrijskih okoljih vključujejo [40]:

- multivariantno statistično procesno kontrolo;
- klasifikacijo izdelkov;
- napovedovanje vrednosti parametrov in lastnosti izdelkov.

Nevronske mreže

Nevronske mreže in mehka logika sta tehniki za opisovanje nelinearne povezave med vhodnimi in izhodnimi podatki v sistemih. Podobno kakor človeški sistem nevronov, so tudi umetne nevrnske mreže sestavljene iz vhodnih in izhodnih enot, ki so primerno povezane. Med vhodnimi in izhodnimi enotami je lahko več skritih plasti, sestavljenih iz blokov v obliki nelinearne prenosne funkcije². Povezavam med posameznimi enotami so dodeljene uteži. Signali, ki so pripeljani na vhod, se tako preslikajo na izhode naslednjega nivoja. Struktura nevrnske mreže omogoča zaznavanje vzorcev in napovedovanje vrednosti spremenljivk na podlagi učnih podatkov. Sistemi nevrnskih mrež se dobro obnesejo v primeru neodvisnih vhodnih spremenljivk.

Modeli nevrnskih mrež se uporabljajo v primerih, ko imamo opravka z:

- zašumljenimi podatki;
- množicami podatkov z manjkajočimi vzorci;
- večjimi množicami podatkov, tako po številu spremenljivk, kakor tudi po številu vzorcev;
- množicami podatkov z malo spremenljivkami in veliko vzorci;

²Pojem *prenosne funkcije* je uporabljen v širšem pomenu.

Tipične aplikacije v industrijskih okoljih vključujejo:

- zaznavanje izrednih situacij in vzrokov problemov;
- klasifikacijo izdelkov;
- napovedovanje vrednosti parametrov in lastnosti izdelkov.

Mehka logika

Mehka logika razširja Boolovo logiko z dvema stanjema (0 in 1) na neskončno število stanj (interval $[0,1]$). V običajni logiki so trditve lahko bodisi resnične ali napačne (zaloga vrednosti 0 in 1), mehka logika pa dovoljuje tudi vmesne vrednosti - delno pravilnost oziroma stopnjo pripadnosti. Modeliranje v mehki logiki je verjetnostno in omogoča pretvorbo numeričnih podatkov v kvalitativne attribute. Največ se uporablja za iskanje pravil in za grupiranje. Iz zbranih podatkov je tako mogoče izločiti nabor pravil, ki se nato uporabljajo za napovedovanje odziva na neznane spremenljivke. Pri podatkih, ki sestojijo iz vhodov in izhodov nekega sistema, služijo načela mehke logike za grupacijo podatkov v skupine s podobnim obnašanjem.

Modeli mehke logike so uporabni na enakih področjih kot modeli nevronske mreže. V obeh primerih gre za orodja, primerna za reševanje nelinearnih problemov. Ker pa so obratovni režimi izbranega testnega industrijskega procesa bolj ali manj konstantni, lahko povezave med procesnimi spremenljivkami zadosti dobro opišemo z linearnimi modeli, oziroma z modeli, ki so linearni v parametrih [24].

1.2 Primeri uporabe

Pregled obstoječe literature pokaže, da se v industriji uporabljajo različne tehnike podatkovnega modeliranja. Glavnina aplikacij podatkovnega rudarjenja je namenjena nadzoru procesa, mehkim senzorjem, sistemom za detekcijo napak in sistemom za podporo odločanju [54]. Isti vir tudi navaja pogosto uporabo regresijskih metod za pripravo mehkih senzorjev, ko se določeni procesni parametri ne merijo neposredno, ampak se pridobivajo na podlagi razpoložljivih merjenih količin. Metoda glavnih komponent pa se uporablja za identifikacijo korelacij med spremenljivkami. Celotno delo [23] je namenjeno odkrivanju napak v procesih z uporabo modelov.

V [72] je predstavljena primerjalna študija različnih procesno diagnostičnih metod, ki so osnovane na podatkih. Kot glavne metode za izločanje statističnih informacij iz zgodovine procesnih podatkov vir navaja metodo glavnih komponent in metodo delnih najmanjših kvadratov. Pri tem se opirajo na predhodno zabeležene podatke in potrebujejo relativno malo modeliranja in apriornega znanja.

Nevronske mreže in metodo glavnih komponent so uporabili na primer za napovedovanje nastanka gub v proizvodnji papirja [15]. Gubanje papirja se sicer meri naknadno, ko je proizvodnja role že končana. Tako odkrite gube pa pomenijo dodatno mehčanje papirja in s tem povezane stroške. Med procesom izdelave se merijo različni procesni parametri, na podlagi katerih se nato naredi napoved, ali bo nagubanost papirja znotraj ali zunaj tolerančnega območja. Procesne parametre, ki so bili uporabljeni za učenje nevronske mreže, so zaradi zmanjšanja dimenzije in odprave korelacije med njimi predhodno obdelali z metodo glavnih komponent. Vir še navaja, da je bila uporaba obeh tehnik koristna, saj je reduciranje podatkov z metodo glavnih komponent imelo za posledico enostavnejši model nevronske mreže.

Uporaba metode glavnih komponent in metode delnih najmanjših kvadratov v procesu vlivanja jekla je predstavljena v [81]. Z omenjenima metodama so odkrili korelacije v večji količini procesnih podatkov. Z izločitvijo dominantnih vzorcev v podatkih so določili normalno delovanje procesa. Obnašanje, ki odstopa od teh vzorcev, pa pomeni anomalije. Model je omogočil boljše razumevanje odvisnosti med vhodnimi podatki procesa in odkrivanjem napak.

Metodo glavnih komponent in metodo delnih najmanjših kvadratov so uporabili tudi za detekcijo napak in napovedovanje porabe goriva v proizvodnem procesu podjetja Honeywell [79]. Na podlagi procesnih podatkov, ki so bili zajeti med normalnim delovanjem procesa, je bil zgrajen model. Odstopanja od normalnega delovanja služijo za detekcijo napak. S pomočjo metode delnih najmanjših kvadratov so pripravili model za napovedovanje pretoka plina. Model je sposoben napovedovati napake nekaj ur preden se dejansko zgodijo in nudi operaterjem dovolj časa, da pripravijo korektivne ukrepe.

Običajno se pri uporabi metode glavnih komponent predpostavlja, da proces deluje stabilno, da so procesni podatki porazdeljeni normalno in da niso časovno odvisni, kar omejuje uporabnost metode. V [12] in [41] avtorji predlagajo koncept, ki klasično metodo glavnih komponent razširi tako, da uporablja model Gaussovih mešanic za aproksimacijo podatkov v latentnem podprostoru modela.

Primerjalna študija nevronske mreže, metode delnih najmanjših kvadratov in metode glavnih komponent pri optimalni izbiri mehkih senzorjev je podana v [80]. Avtorji obravnavajo analize različnih množic podatkov, od merjenih vrednosti do različnih variacij, ki jih pridobijo z metodo glavnih komponent. Študija ugotavlja pozitivne učinke v smislu povečanja zanesljivosti modela, če se procesni parametri, ki imajo vpliv na variabilnost izhoda, izbirajo z metodo glavnih komponent.

Procesni podatki in metode statistične procesne kontrole se uporabljajo za sprotno napovedovanje nepravilnosti v procesu izdelave polprevodniških vezij [65].

Iz kemijske industrije je poznan [20] še sistem za diagnosticiranje napak, ki je sestavljen iz detekcijskega in izločevalnega modula. V detekcijskem modulu so uporabljene

multivariantne statistične tehnike, izločevalni modul pa je realiziran kot nevronska mreža za klasifikacijo vzorcev.

Logistična regresija se v literaturi pogosto pojavlja v povezavi z ekonometrijo [25], [4], [17]) in medicino [58], [35]. Predvsem v medicini se uporablja za napovedovanje različnih stopenj tveganja. Uporaba te metode v industriji je redka.

V industrijskih aplikacijah zasledimo uporabo logistične regresije v procesu valjanja jekla [31]. V jeklarski industriji je valjanje ključni proces, ki običajno predstavlja zadnjo operacijo preoblikovanja jekla v končni izdelek. Prav zaradi tega so napake in izmet še toliko bolj nezaželene, saj izničijo vse predhodne operacije. Razpoke in brazde so pogoste napake, ki se pojavljajo v procesu valjanja. Vir navaja, da je bilo razvitih nekaj metod, ki bi samodejno zaznavale napake v postopku valjanja, ampak so bile zaradi neustreznih delovnih pogojev (visoke temperature, velika hitrost valjanja, itd.) neuspešne. Vir zato predlaga uporabo logistične regresije za modeliranje kakovosti postopka. Model na podlagi zveznih procesnih spremenljivk določa binarni parameter kakovosti (dobra ali slaba kakovost). V jeklarski industriji izdelek ustreza kakovostnim merilom, če število napak ne presega praga. V predstavljenem primeru so logistično regresijo razširili z načeli koračne regresije. Postopek izgradnje modela se začne z uporabo vseh predikcijskih spremenljivk, ki se v iterativnem postopku nato izločajo.

Razširitev logistične regresije z metodo glavnih komponent je predstavljena v [2] in [19]. Študiji podajata teoretično ozadje take razširitve, predstavljeni pa so tudi primeri uporabe na simuliranih podatkih. Isti avtorji v [18] predstavljajo primer tako razširjene logistične regresije za modeliranje klimatskih pojavov. Sicer pa je znana uporaba take kombinacije metod še v medicini [27] in pri napovedovanju napak v programski kodi [49].

S področja simulacije diskretnih dogodkov v proizvodnji je poznan primer primerjave kompleksnih proizvodnih sistemov [45]. Predlagano je simulacijsko ogrodje za primerjavo proizvodnih sistemov različnih tipov.

Pregled obstoječe literature in raziskav pokaže, da uporaba statističnih regresijskih metod v velikoserijski kosovni industriji ni pogosta. Glede na uspešnost teh metod na ostalih področjih, je razlog manjšega zanimanja verjetno v tem, da gre pri velikoserijski kosovni proizvodnji pogosto za nezahtevne izdelke, pri katerih je proces izdelave obvladljiv že s preprostejšimi orodji in tehnikami. To pa ne drži v primeru obravnavanega izdelka, saj mora ustrezati zelo visokim standardom kakovosti, njegova izdelava pa vsebuje nekaj faz, ki so zelo občutljive na lastnosti vhodnih materialov in izbiro tehnoloških parametrov.

1.3 Cilji disertacije

Paradigma o klasični statistični kontroli kvalitete temelji na ločenem obravnavanju parametrov kvalitete [34]. V primeru kompleksnejših izdelkov je tak način pomanjkljiv,

saj je kakovost definirana hkrati z več parametri [39]. Pri tem se ne izkoriščajo relacije med procesnimi spremenljivkami, zato je celostna obravnava relacij v sistemu mnogo bolj obetaven pristop. Ustrezni model služi za iskanje odgovora na naslednja vprašanja:

1. Koliko je redundantne informacije v podatkih, ki jih zbira informacijski sistem?
2. Ali je informativna vsebnost zbranih podatkov takšna, da se da nedvoumno ločevati stanja procesa pri različnih napakah?³
3. Ali je možno identificirati “skrite” vhode?⁴
4. Ali je Gaussova porazdelitvena funkcija primerna za opis vpliva nemerljivih pojavov (šuma) v proizvodnem procesu?

Odgovore na zastavljena vprašanja, ustrezno prevedena v formalno matematično obliko, je smiselno iskati na področju verjetnostne teorije in statistike, sistemske teorije in umetne inteligence. Iskanje informacije v podatkih oziroma sklepanje iz podatkov je področje posebnega interesa za industrijsko prakso. Informatizacija proizvodnje je napredovala do te mere, da ima že veliko podjetij implementirano sprotno zbiranje in arhiviranje proizvodnih podatkov. Odprto in v praksi praviloma nerešeno vprašanje je avtomatsko iskanje informacij v podatkih, ki so potrebne za spremljanje procesa.

Transformacija iz podatkov v informacijo je lahko zelo zapleten proces, ki ga v večji ali manjši meri opravljajo operaterji na podlagi izkušenj in intuicije. Tak pristop se (morda) deloma obnese v proizvodnjah z nespremenljivim naborom izdelkov, zelo pa je vprašljiv s stališča učinkovitosti proizvodnje, če se nabor izdelkov dinamično spreminja. V takih primerih je doba učenja operaterja lahko bistveno daljša od časa učenja, ki ga potrebuje algoritem na podlagi statističnega modela procesa. Nekatera teoretična vprašanja, zlasti identifikacija in kvantifikacija vpliva nemerljivih motenj, so doslej obširno obdelana v kontekstu vodenja in diagnostike sistemov. Večina del predpostavlja, da je nominalni parameterski model procesa oz. model motenj pospremljen z modelom negotovosti njegovih parametrov oziroma strukture. Te apriorne informacije v našem primeru nimamo, zato bo problem identifikacije nemerljivih motenj potrebno v celoti formulirati v statističnem kontekstu.

Cilji disertacije so naslednji:

- analiza problema nepričakovanih izpadov kakovosti izdelkov v masovni proizvodnji s primerom proizvodnje komutatorjev;

³To je ključna informacija kot predpogoj za uspešno lokalizacijo napak in s tem dosego maksimalne diagnostične ločljivosti.

⁴Gre za ugotavljanje, ali na kvaliteto izdelka vplivajo še kakšni parametri, ki jih ne merimo (ali se jih ne da meriti), ter kolikšen je njihov vpliv na izhodno kvaliteto.

- načrtovanje, optimizacija in izvedba informacijskega sistema za zbiranje podatkov o proizvodnih parametrih;
- sinteza statističnih modelov, ki povezujejo parametre vstopnih surovin oziroma polizdelkov, proizvodne parametre in parametre končnih izdelkov;
- ovrednotenje koncepta na modelnem primeru proizvodnje komutatorjev.

Primarni cilj disertacije je sinteza statističnih modelov za povezavo tehnoloških parametrov in parametrov surovin s podatki o končnih izdelkih. Za doseg tega cilja je potrebnih vrsto predhodnih ukrepov. Najprej je potrebno zagotoviti ustrezne podatke o proizvodnem procesu. Ker procesni podatki nastajajo v različnih oblikah in na različnih mestih je za njihovo zbiranje potreben proizvodni informacijski sistem. Eden izmed ciljev disertacije je bil tudi razvoj takega informacijskega sistema. Šele na podlagi ustreznih podatkov iz proizvodnega procesa so mogoče analize izpadov kakovosti, izbira analitičnih metod in sinteza modelov. Ena izmed nalog disertacije je tudi preizkus različnih regresijskih metod in določitev take, ki je najprimernejša za analizo procesnih podatkov.

Izvirnost prispevka je v formulaciji in rešitvi stohastičnega optimizacijskega problema pri določanju optimalnega števila informacijskih terminalov ter v uporabi logistične regresije, razširjene z metodo glavnih komponent, za modeliranje proizvodnega procesa s področja velikoserijske kosovne industrije. Močan vidik je tudi netehnični, saj je bilo za doseg ciljev disertacije potrebno izvesti številne aktivnosti, ki nimajo znanstvenega ozadja.

1.4 Struktura disertacije

Koncept sistema za podporo odločanju pri modeliranju proizvodnje smo zgradili in delno preizkusili na primeru proizvodnje komutatorjev podjetja Kolektor Sikom d.o.o.. V proizvodnem procesu nastaja veliko podatkov, ki pa se bodisi merijo in shranjujejo na različnih mestih, med seboj niso povezani, so vprašljive zanesljivosti ali pa se sploh ne shranjujejo. Podroben pregled zatečenega stanja podajamo v poglavju 2. Tako obstoječa organizacija, kakor tudi način spremljanja podatkov iz proizvodnje nista omogočala modeliranja proizvodnega procesa na predlagan način. V nadaljevanju poglavja opisujemo aktivnosti, ki so bile potrebne za vzpostavitev stanja, v katerem je mogoče opazovanje in modeliranje proizvodnega procesa. Sočasno smo izvajali prenovo in optimizacijo postopkov v proizvodnji ter uvajali informacijski sistem, ki omogoča zajem ustreznih podatkov. Ker proizvodnja opazovanih izdelkov poteka že več časa, se številne aktivnosti niso izvajale optimalno ali pa so bile celo odvečne. Cilj prenove proizvodnega procesa je bil doseči stanje, ki bo omogočalo zajemanje nedvoumnih podatkov, kjer bodo vhodni

parametri enolično povezani z izhodi. Prenova je zato potekala na več nivojih znotraj podjetja Kolektor Sikom d.o.o.. Sočasno z reorganizacijo procesa smo razvijali in uvajali informacijski sistem, ki operativno skrbi za zbiranje vseh potrebnih podatkov.

Proizvodni informacijski sistem nekatere podatke pridobiva iz poslovnega informacijskega sistema, nekateri podatki se zajemajo neposredno iz strojev, nekateri pa se vnašajo s pomočjo namenskih terminalov, ki so nameščeni v proizvodnem obratu. Ker predstavlja izbira optimalnega števila takih terminalov svojevrsten problem, je ta tematika obravnavana v poglavju 3. Izvirnost tega prispevka je formulacija stohastičnega optimizacijskega problema in njegova rešitev.

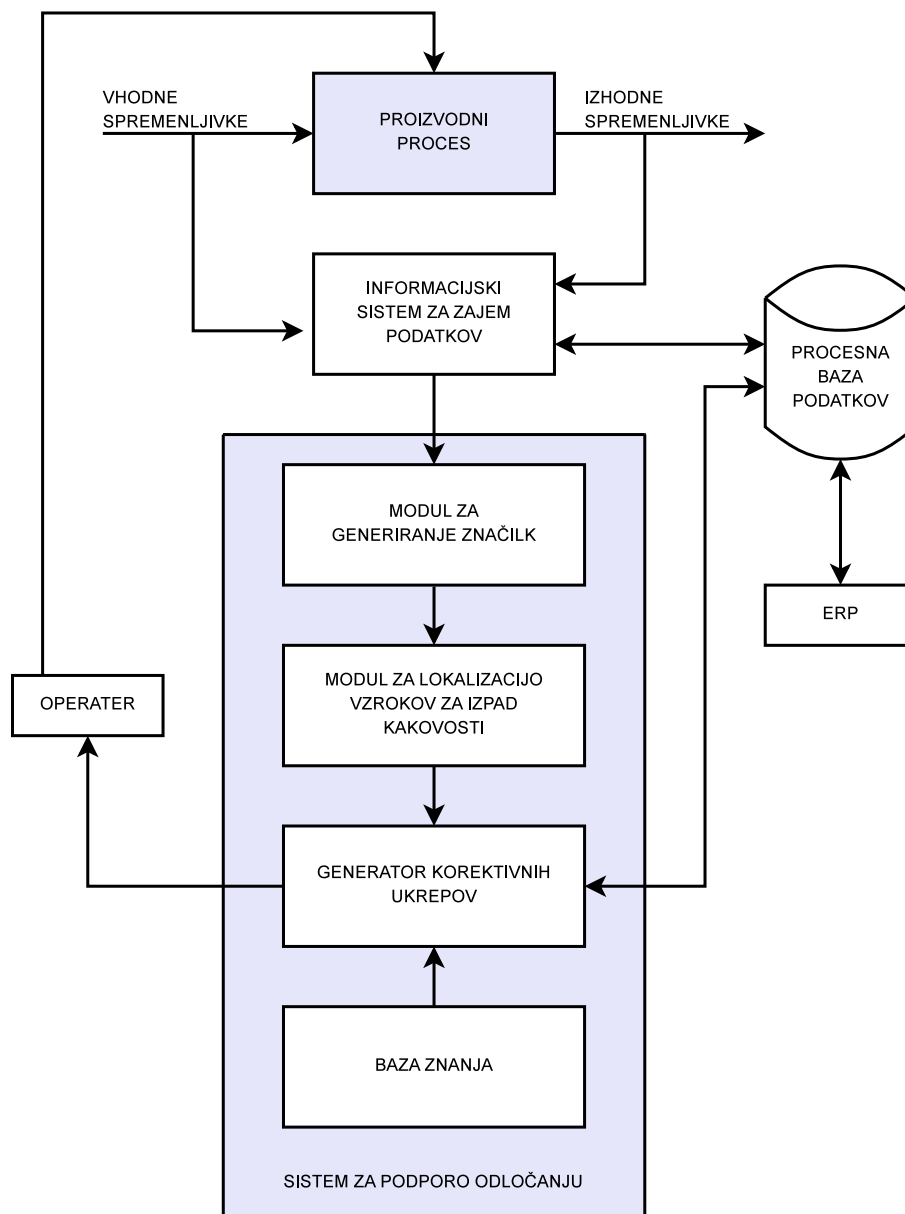
V poglavju 4 sledi opis nekaterih orodij, primernih za analizo in modeliranje proizvodnih procesov. Narava opazovanega proizvodnega procesa narekuje formulacijo dveh tipov problemov:

1. take, kjer na podlagi realnih vhodnih spremenljivk modeliramo fizikalno količino;
2. take, kjer na podlagi realnih vhodnih spremenljivk modeliramo verjetnost.

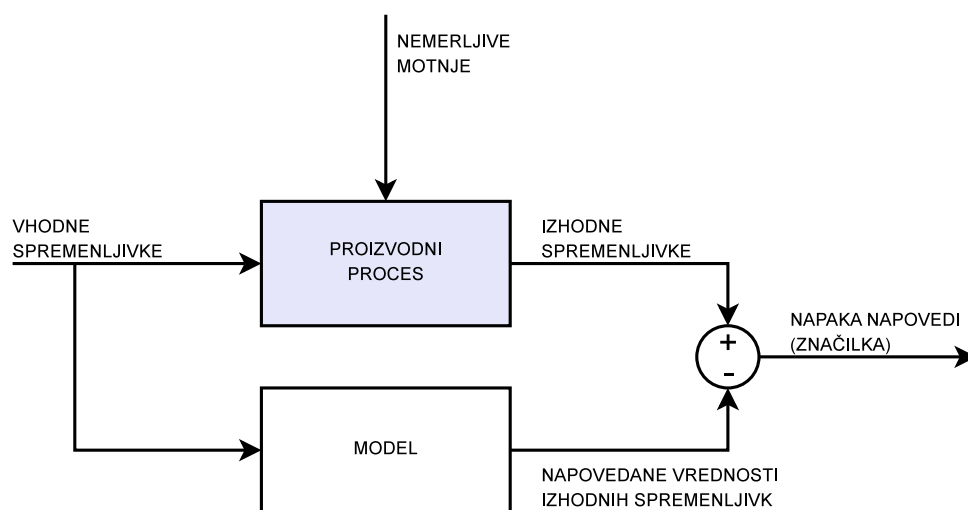
V prvem primeru smo modelirali raztezek, fizikalno lastnost izdelka v odvisnosti od tehnoloških parametrov izdelave. Uporabili smo metode linearne regresije, postopki in rezultati pa so predstavljeni v 5. poglavju.

V 6. poglavju obravnavamo modeliranje kakovosti izdelka na podlagi fizikalnih parametrov uporabljenih surovin. Ker je kakovost izdelkov binarna vrednost (izdelek je bodisi dober ali slab) smo v tem primeru uporabili logistično regresijo. Osrednji problem, ki smo ga posebej pozorno preučevali je kolinearnost v vhodnih podatkih, zato smo predlagali metode in postopke, ki to kolinearnost odpravijo. Ideja nadzora v obeh primerih je, da se na nominalnih podatkih proizvodnega procesa pripravi njegov model. Ta model nato deluje vzporedno s proizvodnim procesom. Rezultati realnega procesa in njegovega modela se nato primerjajo, njihova razlika pa predstavlja napako. Če je napaka v predpisanih mejah, potem lahko smatramo, da je proces v nominalnem (referenčnem) stanju. Če se napaka prične povečevati, je to znak, da je v procesu prišlo do anomalij oziroma napak. Pri identifikaciji tovrstnih problemov je mogoče uporabiti pravilo 3σ [53]. Izboljšana metoda nadzora tako ne obravnava več zgolj izhodnih procesnih podatkov, katerih vrednosti nihajo v odvisnosti od vhodov, ampak se osredotoča na odstopanje delovanja proizvodnega procesa od predvidenega obašanja, ki ga pridobimo s pomočjo modela [7]. Shema sistema s tako zasnovo je prikazana na sliki 1.2, delovanje modula za generiranje značilk pa na sliki 1.3.

V poglavju 7 opisujemo še netehnične vidike raziskave. Predstavljena je hierarhija nivojev odločanja v obravnavanem podjetju, akterji, njihove vloge in interesi v procesu reorganizacije proizvodnje in uvajanja informacijskega sistema.



Slika 1.2: *Struktura sistema za nadzor proizvodnje in podpora odločanju.* Procesni podatki in podatki iz sistema ERP (ang. Enterprise Resource Planning) tvorijo osnovo sistemu za podpora odločanju, ki preko operaterja tvori povratno zanko.



Slika 1.3: *Modul za generiranje značilke.* Model deluje vzporedno s proizvodnim procesom in napoveduje izhode. Večanje rezlike med dejanskimi in napovedanimi izhodi pomeni anomalije ali napake v proizvodnem procesu.

Poglavje 2

Opis demonstracijskega proizvodnega procesa

Za potrebe vrednotenja koncepta nadzora kakovosti izdelkov v kosovnih industrijah smo izbrali proces proizvodnje komutatorjev. Gre za izdelek z nazivom **komutator A** (slika 2.1)¹. Proizvaja se v velikih serijah v proizvodnem obratu podjetja Kolektor Sikom d.o.o. v Idriji.



Slika 2.1: *Komutator A*. Preko prevodnih lamel se v navitje rotorja prenaša električni tok. Rotorska navitja so spojena s kljukicami komutatorja.

Proizvodni proces izdelka je razdeljen na več faz oziroma operacij. Ključne so:

1. izdelava polizdelkov 1,

¹Zaradi zaščite zaupnih podatkov v disertaciji ne uporabljamo pravih imen za polizdelke in surovine temveč ustrezne številčne kode

2. izdelava polizdelkov 2,
3. izdelava končnega izdelka.

V proizvodni proces vstopata dve vhodni surovini. Izdelava se začne na liniji izdelave polizdelkov 1, kjer v postopek vstopa surovina 1. Surovina 1 se preoblikuje v polizdelke 1. Gotovi polizdelki se nato operejo v pralnem sredstvu. Izdelava se nadaljuje na liniji izdelave polizdelkov 2. Po zaključeni obdelavi potujejo polizdelki 2 na staranje. Prvi del staranja se izvaja v pečeh, ob v naprej predpisanem temperaturnem poteku. Drugi del je naravno staranje. Po staranju polizdelki 2 vstopajo na linijo končnih obdelav, kjer se najprej preveri premer izvrtin. Izdelki se pred in po krivljenju kljukic krtačijo. Končna linija se nadaljuje v končno kontrolo, kjer se pri izdelkih najprej preveri električna prebojnost med lamelami, nato pa sledi avtomatska optična kontrola. Izdelki, ki ustrezajo kriterijem kakovosti, se pakirajo v embalažo, ki se ustrezno označi in pošlje kupcem.

Proizvodnja končnega izdelka **komutator A** poteka na treh linijah, saj se najprej izdelata **polizdelek 1** in **polizdelek 2**. Hierarhija izdelka, polizdelkov in materialov je prikazana na sliki 2.2.

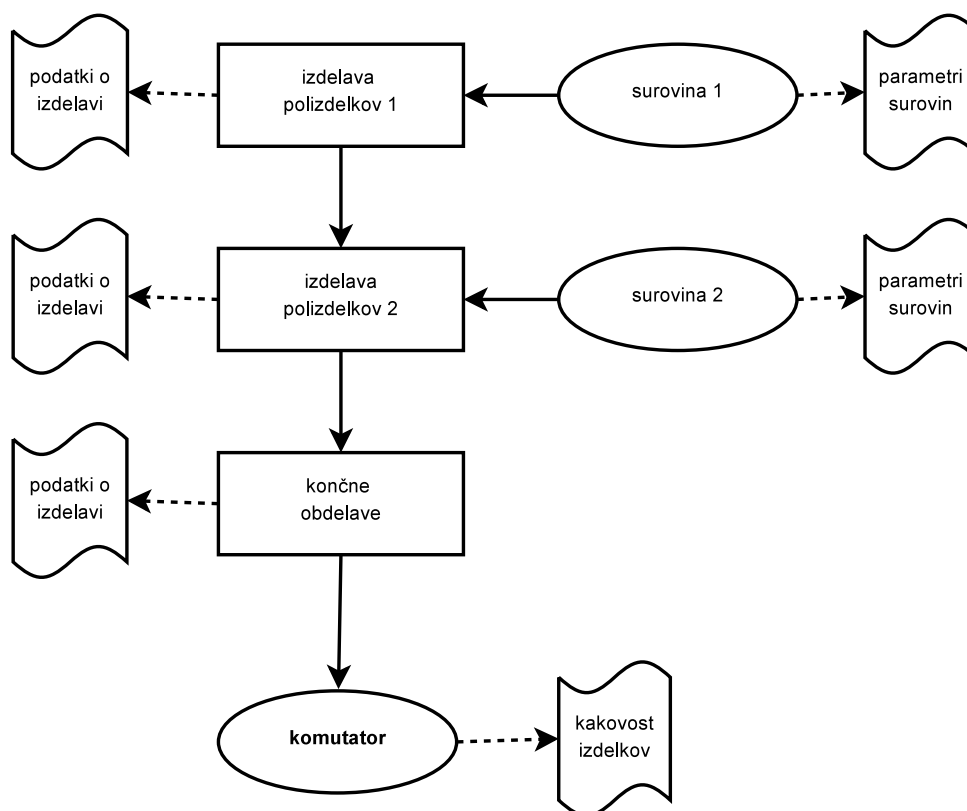
2.1 Podatki in parametri v proizvodnem procesu

V proizvodnem procesu nastajajo številni podatki. Kakovost izdelkov je odvisna od parametrov vhodnih materialov ter tehnoloških parametrov izdelave. V izbrani izdelek vstopata dva vhodna materiala: surovina 1 in surovina 2. Za obe surovini se vršijo meritve različnih fizikalnih parametrov. Odvisno od pomembnosti posameznih količin se meritve opravljajo za vsako serijo ali pa se izvajajo na preskok. Na tehnološko zahtevnejših operacijah se beležijo različni tehnološki parametri, kot so temperature ali tlaki. Med izvajanjem proizvodnega procesa se beležijo tudi podatki, ki pričajo o njegovi kakovosti. Ti podatki zajemajo količine proizvedenih izdelkov, čase izdelave, zastoje in izmet. Podatki se zajemajo v informacijski sistem *SAP R/3*, so pa pomemben pokazatelj učinkovitosti² proizvodnega procesa [3].

2.2 Organizacija proizvodnega procesa

Proizvodni proces v podjetju *Kolektor Sikom d.o.o.* je urejen preko **delovnih nalogov**. Vsak delovni nalog je razdeljen na več diskretnih **operacij**, katerih vrstni red in nabor sta definirana v **tehnološkem postopku** izdelka. Enak izdelek se običajno izdeluje na več delovnih nalogih. Vsaka izmed omenjenih operacij se izvaja na predpisanem **delovnem**

²Izraz učinkovitost se nanaša na kazalec uspešnosti proizvodnje tim. **skupno učinkovitost**, ki združuje *razpoložljivost*, *zmogljivost* in *kakovost* proizvodnega procesa.



Slika 2.2: Shema toka materialov in nastajanja podatkov. Končni izdelek, ki je sestavljen iz dveh polizdelkov, v katera se vgrajujeta dva vhodna materiala. O obeh materialih so na voljo fizikalni parametri. Podatki o izdelavi so na voljo za vse tri operacije.

mestu. Delovno mesto je sestavljeno iz enega ali več **strojev**, ki so sposobni izvajati enako operacijo. **Vstopno delovno mesto** je tisto, kjer v izdelek vstopa kateri izmed vhodnih materialov ali polizdelkov. Iz katerih materialov ali polizdelkov je izdelek sestavljen, je določeno v njegovi **kosovnici**.

2.3 Sledenje materialom

Sledenje materialom v proizvodnem procesu je pomembno zaradi povezave med parametri vhodnih surovin in tehnološkimi parametri na eni strani ter med kakovostjo proizvodnega procesa na drugi. Temelj sledenja materialov so **spremniki listi**. Spremniki list spremlja vsako transportno enoto (zaboj) izdelkov, ki potuje skozi proizvodnjo. Delavci na spremniknem listu ročno izpolnjujejo rubriki, ki sta pomembni za sledenje materialom:

1. **izvor surovine 1** - številka oziroma oznaka surovine 1;
2. **šarža surovine 2** - številka oziroma oznaka šarže surovine 2.

Postopek sledenja materialom je sledeč: delavec na vstopni operaciji shrani oznako (nalepko oz. spremni dokument) vhodnega materiala, ki se trenutno uporablja za izdelovanje. Ko izdelki v transportnih enotah prehajajo mimo te (vstopne) operacije, delavec izpolni ustrezno rubriko spremnega lista, kamor prepíše oznako vhodnega materiala, ki se trenutno uporablja za izdelavo.

Če se pojavi potreba po ugotavljanju vhodnih materialov za neko serijo izdelkov, je potrebno ročno pregledovanje arhiviranih spremnih listov.

2.4 Problem zbiranja podatkov za potrebe podpore odločanju

Zatečeno stanje "sistema" za zbiranje podatkov v glavnem temelji na ročnem beleženju dogodkov, kar dopušča preveč možnosti za vnos napake.

Za potrebe pričujoče raziskave je potrebno doseči stanje, ki bo omogočalo elektronsko sledenje uporabljenim materialom. Uporabljene materiale je potrebno enolično povezati s serijami končnih izdelkov. Podatke, ki bi omogočali omenjene povezave, bi bilo mogoče zagotoviti z beleženjem dveh ključnih dogodkov v vsaki fazi izdelave:

1. začetek uporabe nove šarže vhodnega materiala;
2. začetek obdelave izdelkov nove transportne enote.

Glavne težave, ki jih je bilo treba premostiti, so naslednje:

1. transportne enote obsegajo relativno majhne količine izdelkov, zato je število šarž, ki nastane med proizvodnjo, relativno veliko;
2. v podjetju se ne operira s serijami izdelkov;
3. transportne palete³ so različnih dimenzij, zato lahko prihaja do mešanja izdelkov iste serije;
4. obstoječe oznake surovin ne omogočajo avtomatske identifikacije;
5. sledljivost surovin in polizdelkov na začetku proizvodnje ter skozi vse nadaljnje faze proizvodnje.

³Na transportne palete se odlaga večja količina zabojev z izdelki ali polizdelki.

2.4.1 Veliko različnih transportnih enot

Izdelek **komutator A** se izdeluje v količinah do 18000 na izmeno, transportne enote (zaboji) pa imajo kapaciteto 700 izdelkov. To pomeni, da operater linije v izmeni obdela do 25 transportnih enot. Vhodne surovine so v embalažnih enotah pakirane v dovolj velikih količinah, da se zamenjajo največ enkrat v izmeni. Tako stanje pomeni obdelavo do 25 spremnih listov z enako vsebino, kar ni optimalno.

2.4.2 Serije izdelkov


V podjetju še niso uvedene serije izdelkov. Pod serijo si predstavljamo množico izdelkov, ki je narejena iz enakih vhodnih surovin in z enakimi tehnološkimi parametri izdelave. Trenutno se operacije sledenja nanašajo na posamezne transportne enote, čeprav velikost posameznih serij presega velikost transportnih enot. Prav tako se vse operacije, povezane s sledenjem izvajajo ročno - na spremne dokumente transportnih enot se ročno izpolnjujejo rubrike o poreklu vhodnih materialov. Tudi oznake končnih izdelkov ne nudijo možnosti ugotavljanja porekla izdelkov drugače kakor po datumu izdelave.

2.4.3 Različne dimenzije transportnih palet

V proizvodnem procesu izdelki med posameznimi operacijami potujejo na transportnih paletah. Te transportne palete so na različnih mestih različnih dimenzij. Ob vpeljavi serij bi tako prihajalo do mešanja izdelkov med serijami. Primer takega mešanja je operacija pranja bakrenih surovcev, ki na operacijo pranja prihajajo na paletah drugačnih dimenzij od tistih, na katerih operacijo zapuščajo. V primeru vpeljave serij bi se ena serija označevala in transportirala na eni paleti. Zaradi različnih kapacitet palet bi se serija po končani operaciji pranja bodisi razdelila na dve paleti, lahko pa bi se na eni paleti znašli izdelki dveh različnih serij.

2.4.4 Identifikacija surovin

Surovine, ki vstopajo v proizvodni proces, pripadajo šaržam, za katere poznamo fizikalne in tehnološke lastnosti. Surovine so zato opremljene z ustreznimi oznakami na spremnih etiketah, ki pa se izpolnjujejo ročno (primer je prikazan na sliki 2.3), zato avtomatska identifikacija ni mogoča. V primeru spremljanja lastnosti vgrajenih surovin bi morali operaterji linij ročno vnašati identifikacijske oznake iz spremnih etiket v informacijski sistem.



Slika 2.3: Primer obstoječih identifikacijskih etiket za surovino 1. Vse informacije so izpolnjene ročno, zato avtomatska identifikacija surovine ni mogoča.

2.5 Prenova proizvodnega procesa

Zaradi trenutnega stanja v proizvodnji so za analizo podatkov potrebni določeni ukrepi. Del teh ukrepov predstavlja organizacijska prenova, katere posledica je optimizacija proizvodnega procesa. Prenova proizvodnega procesa zajema naslednje vidike:

1. spremenijo se vloga in postopki za delo s spremnimi dokumenti;
2. spremenijo se vloga in postopki za delo z delovnimi listi;
3. definirajo se postopki za delavce, ki so potrebni za zagotavljanje vseh podatkov;
4. optimizirajo se transportno-logistični postopki.

2.5.1 Spremna dokumentacija

Spremni dokument oziroma spremni list je nosilec informacij o uporabljenih vhodnih materialih in parametrih izdelave določene količine izdelkov. Je nekakšna enolična serijska številka določene količine izdelkov, saj se posamezni izdelki zaradi velikih proizvodnih količin ne označujejo. Spremni list še vedno ostaja osnova za vse podatke v zvezi s sledenjem. Optimiziran postopek predvideva uporabo manjšega števila spremnih listov in njihovo doslednejšo uporabo. Izdajanje (tiskanje) spremnih listov je izvedeno samodejno, glede na trenutno situacijo v proizvodnji. Namesto dosedanjega postopka, ko vsaki

transportni enoti pripada svoj spremni list, se število spremnih listov zmanjša tako, da se izdajajo le za posamezne serije. Serija izdelkov, ki pripada enemu spremnemu listu, bo narejena iz enakih šarž vhodnih materialov in z enakimi tehnološkimi parametri izdelave. Nasprotno je lahko zaradi transportno - logističnih potreb ena serija razdeljena na več spremnih listov. Poleg omenjenih podatkov bo spremni list tudi nosilec t.i. izhodnih podatkov proizvodnega procesa. Za vsak izdani spremni list bodo znane količine izdelanih kosov, izmeta, časa izdelave in časa zastojev. Izhodni podatki se bodo na spremne liste beležili samodejno, pridobljeni pa bodo iz krmilnikov strojev.

Postopek obdelave spremnih listov

Življenjski cikel spremnega lista se bo začel s tiskanjem in bo trajal do pripojitve k novemu spremnemu listu⁴, oziroma do predaje končnega izdelka v skladišče. Med tem se bo spremni list uporabljal za registracijo dogodkov, ki bodo omogočali sledljivost. V zvezi s spremnim listom bodo povezane aktivnosti:

- tiskanje spremnega lista;
- vnos črtne kode zaradi beleženja parametrov.

Tiskanje spremnih listov

Tiskanje spremnega lista je potrebno vsakič, ko se zaključi izdelava trenutne serije, oz.:

- ob spremembi tehnoloških parametrov izdelave;
- ob menjavi šarže surovine ali polizdelka;
- ob prehodu na nov delovni nalog;
- ob zamenjavi delavca.

Za komutator A se tiskanje spremnega lista izvaja na dveh delovnih mestih: na liniji izdelave polizdelkov 1 in na liniji izdelave polizdelkov 2.

2.5.2 Delovna dokumentacija

Delovna dokumentacija oziroma delovni listi imajo v podjetju Kolektor Sikom d.o.o. dvojno vlogo: urejevalci linij dobijo na njih podatek o dodeljenem delu, hkrati pa jih uporabljajo za poročanje o količini opravljenega dela. Vloga delovnih listov ostaja nespremenjena. Do sprememb prihaja le v postopku njihove obdelave. Delovni list se

⁴Do pripojitve spremnega lista k novemu pride takrat, ko se v proizvodnem procesu združi tok dveh ali več polizdelkov v nov polizdelek ali končni izdelek.

bo uporabljal za registracijo dogodkov, kot so prijava ali odjava dela ter opredelitev zastoja. Vodja delovne enote bo za operacijo delovnega naloga natisnil le en delovni list, ki bo služil za začetno prijavo. Ostali delovni listi se bodo tiskali ob odjavi ali menjavi dela. Samodejno natisnjeni delovni listi bodo vsebovali tudi podatke⁵, ki jih delavci sedaj vpisujejo ročno. Delavec bo delovni list verificiral s svojim podpisom in ga oddal kakor do sedaj.

2.5.3 Spremembe v postopkih

Na posameznih delovnih mestih se bodo nekoliko spremenili postopki. Uvedla se bo registracija dogodkov, ki bo omogočala natančno zbiranje podatkov o proizvodnem procesu. Sistem bo omogočal zbiranje dveh različnih vrst podatkov:

1. podatki o realizaciji (pomembni za SAP R/3 in merjenje učinkovitosti),
2. podatki o sledenju.

Podatki o realizaciji vključujejo količino proizvedenih izdelkov, čas proizvodnje teh izdelkov, količino in tip izmeta ter čase in tipe zastojev. Osnovni ključ za te podatke je trojica **stroj-delavec-oznaka operacije**⁶. Za vsako trojico nastane en ustrezen zapis⁷.

V podatkih o sledenju pa bodo na spremni list vezane informacije o uporabljenih vhodnih materialih in parametrih izdelave.

Postopki za zbiranje podatkov o opravljenem delu

Za pridobivanje podatkov o realizaciji se bodo uporabili postopki, ki so že utečeni v ostalih oddelkih podjetja Kolektor Sikom d.o.o.. Za razliko od ostalih oddelkov se bodo podatki o zastojih in izdelanih kosih zajemali avtomatsko iz strojev, novost pa bosta prijavi dogodkov za menjavo delavca ali delovnega naloga. Delavci bodo na terminalih prijavljali dogodke:

prijava dela - s tem dogodkom delavec sporoči v sistem, da je pričel z izdelavo delovnega naloga. Dogodek se uporablja, kadar na liniji z delom začenja delavec, pred tem pa na liniji ni potekalo nobeno drugo delo ali pa je bila linija v fazi priprave ali

⁵Gre za podatek o delavcu, stroju, času izdelave ter številu izdelanih kosov (dobrih, slabih in vzrokov za slabe kose) ter o tipu in trajanju posameznih zastojev.

⁶Vsak delovni nalog je razdeljen na operacije. Pri razpisu delovnih nalogov vsaka izmed teh operacij dobi enolično oznako (imenovano tudi številka potrditve ali številka časovnega lista). Poročanje o opravljenem delu se nato navezuje na oznako operacije.

⁷Če delavec na liniji preko celotne izmene obdeluje en delovni nalog, ima to za posledico en zapis s podatki: številka delavca, številka stroja, številka delovnega naloga, številka časovnega lista, čas dela, količina dobrih izdelkov, količine in tipi izmeta, trajanje in tipi zastojev, ...

nastavljanja. Prijava se izvede s pomočjo delovnega lista. V času prijave je potrebno ponastaviti števec izdelanih kosov. Podatki, ki se vnašajo: številka stroja, številka delavca in številka časovnega lista. Ob prijavi se izvedejo preverjanja:

1. ali so vsi vneseni podatki veljavni;
2. ali je stroj prost;
3. ali je operacijo mogoče opravljati na izbranem stroju.

Če je zadoščeno vsem pogojem, prijava uspe, sicer se na terminalu izpiše ustrezno obvestilo.

prijava več del - postopek je enakovreden večkratni izvedbi **prijave dela**. Uporablja se v primerih, kjer en delavec hkrati opravlja delo na več različnih strojih ali linijah ter vsa dela začne istočasno. Podatki, ki se vnašajo so številka delavca ter eden ali več parov številke stroja in časovnega lista.

opredelitev zastojev - med izvajanjem del lahko na stroju ali liniji prihaja do zastojev. Zastoji (začetek in konec) se beležijo avtomatsko. Glede na nastavitve stroja, se vsak zastoj označi bodisi kot *kratki* ali kot *dolgi*. Dolge zastoje je potrebno pred zaključkom dela opredeliti še s tipom zastoja. Delavec ima za izbrani stroj na voljo spisek zastojev, pri čemer mora za vsakega vnesti ustrezen tip iz šifrant. Podatki, ki se vnašajo, so številka stroja (izbira) ter po potrebi številke zastojev.

prijava in odjava zastoja - za stroje in linije, na katerih spremljanje ne poteka samodejno, je potrebno daljše zastoje beležiti s pomočjo registracije dogodkov ob začetku in koncu zastoja. Ob nastanku zastoja je potreben vnos:

- številke stroja,
- številke zastoja.

Preveri se ustreznost vnesenih podatkov. Za stroj se še preveri, če ima prijavljeno operacijo. Če so izpolnjeni vsi pogoji, prijava uspe. Dogodek ob odpravi zastoja zahteva le vnos številke stroja. Sistem preveri, če je na izbranem stroju zastoj prijavljen.

odjava delavca - po zaključeni izmeni delavec z registracijo tega dogodka zaključi vsa svoja dela. Podatek, ki se vnaša je številka delavca.

odjava strojev - po zaključeni izmeni delavec z registracijo tega dogodka zaključi delo na enem ali več strojih. Podatki, ki se vnašajo so številke strojev.

menjava delavca - dogodek se uporablja pri delu na linijah ali strojih, kjer delo poteka nepretrgoma, tudi ob menjavi izmene, ko se zamenja delavec, delovni nalog pa ostane nespremenjen. Registracija tega dogodka je enakovredna **odjavi stroja** in **prijavi dela**. Razlika je v tem, da je za vnos potrebnih manj podatkov in da sta oba dogodka registrirana sočasno. Potreben vnos podatkov:

- številka stroja,
- številka delavca (novi delavec),
- število izdelanih kosov⁸.

menjava delovnega naloga - dogodek se uporablja pri delu na linijah ali strojih, kjer delo poteka nepretrgoma. Z registracijo dogodka se v sistem sporoči, da se je pričelo delo na novem delovnem nalogu, čeprav gre za isti izdelek in se linija ali stroj ni zaustavila. Registracija tega dogodka je enakovredna **odjavi stroja** in **prijavi dela**. Razlika je v tem, da je za vnos potrebnih manj podatkov in da sta oba dogodka registrirana sočasno. Podatki, ki se vnašajo: številka stroja in številka novega časovnega lista.

Postopki za sledenje

Čeprav so postopki za sledenje enotni, se na delovnih mestih ne bodo uporabljali vsi. Na liniji polizdelkov 1 v proizvodni proces vstopa surovina 1. Koluti surovine 1 so označeni s spremnimi nalepkami, ki se izdajo v skladišču. Spremne etikete so opremljene s črtno kodo.

Na liniji izdelave polizdelkov 2 v proces vstopata dve vhodni surovini: surovina 2 in polizdelki 1. Serija polizdelkov 1 je opremljena s spremnim listom, vreča surovine 2 pa s spremno nalepko. Oba dokumenta sta opremljena s črtno kodo. Postopek za beleženje sledenja je identičen tistemu na liniji izdelave polizdelkov 1, le da v proizvodni proces na tem delovnem mestu vstopata dva vhodna materiala.

Na liniji izdelave končnih izdelkov v proces izdelave komutatorja ne vstopa noben nov material. Preko linije prehajajo le serije polizdelkov 2, opremljene s spremnimi listi. Delavec na tej liniji registrira prehod vsakega spremnega lista in s tem prenese nanj vse parametre o izdelavi zaključene serije. Delavci bodo na terminalih prijavljali dogodke:

prijava nove vhodne šarže ali spremnega lista - kadar se zamenja vhodna šarža katere izmed surovin ali polizdelkov, je potrebna registracija nove šarže. Operater s tem sporoči informacijskemu sistemu, da se je zaključila stara serija in začela nova, katere izdelki imajo drugačne lastnosti. Po uspešni registraciji se samodejno natisne

⁸Število izdelanih kosov se ročno vpisuje le, če stroj ni povezan v sistem samodejnega spremljanja.

spremi list za končano serijo. Delavec je o spremnem listu obveščen. Podatki, ki se vnašajo: številka stroja in številka nove šarže.

tiskanje spremnega lista - tiskanje spremnega lista je mogoče kadarkoli med delom. S tem se zaključi tekoča serija. Ta dogodek se uporablja, kadar pride do različnih sprememb v nastavitvah stroja ali linije. Za izvedbo dogodka je potrebno vnesti le številko stroja.

2.6 Informatizacija proizvodnega procesa

Informatizacija proizvodnega procesa, katere posledica je uvedba informacijskega sistema za zbiranje podatkov, predstavlja drugi del ukrepov. Med izvajanjem proizvodnega procesa nastaja mnogo podatkov, ki so pomembni za poslovne informacijske sisteme in merjenje zmogljivosti [21], saj predstavljajo povratno informacijo o dejanskem stanju in dogajanju v proizvodnji. Na podlagi teh podatkov se primerja skladnost izvajanja proizvodnje z zastavljenimi plani [69], [70]. S trajnim spremljanjem proizvodnje in analiziranjem podatkov je mogoče pridobiti boljše informacije o trajanju posameznih faz proizvodnega procesa in temu primerno prilagoditi tudi planiranje. Seveda pa je vse omenjeno izvedljivo ob predpostavki, da so zbrani podatki točni in zanesljivi. Uvajanje proizvodnih informacijskih sistemov povečuje točnost in zanesljivost takih podatkov [10]. Zaradi avtomatiziranega zbiranja je to tudi učinkovitejše od ročnega.

Informacijski sistem za spremljanje proizvodnje mora v čim večji meri zadovoljiti dva cilja:

1. poseg v proizvodni proces podjetja mora biti čim manjši;
2. kakovost pridobljenih informacij mora biti čim večja [66].

Uporabljeni informacijski sistem za spremljanje proizvodnje *Sinapro* [63] je zasnovan okoli komponent:

1. sistema za zajemanje podatkov iz **strojev**;
2. **informacijskih terminalov** za vnašanje (prijavo) proizvodnih dogodkov;
3. **programske opreme za spremljevalne aktivnosti**, kot so tiskanje spremne in delovne dokumentacije, pregledovanje in potrjevanje zajetih podatkov in urejanje vhodnih podatkov;
4. centralne **baze podatkov**, ki jo uporabljajo vse komponente sistema;
5. programske opreme za **izmenjavo podatkov** z zunanjimi sistemi.

2.6.1 Spremljanje strojev

Pri zajemanju podatkov neposredno iz strojev se vsi podatki pridobivajo samodejno, brez posredovanja operaterjev. Delovanje strojev običajno nadzirajo krmilniki. Ti majhni računalniki poleg krmiljenja raznih mehanskih komponent⁹ vodijo tudi podatke o različnih časih, alarmih in številu izdelanih kosov. Priklop na take krmilnike je običajno mogoč preko namenskih industrijskih vodil. V zadnjem času pa se tudi na tem področju uveljavljajo standardne tehnologije, kot je omrežje *ethernet*. Kadar poseg v obstoječe krmilnike ni mogoč ali dovoljen¹⁰, je potrebno na stroje namestiti namenske krmilnike in senzorje, ki spremljajo delovanje strojev. Vsi taki krmilniki morajo neprestano komunicirati z nadzornim računalnikom - pošiljajo mu podatke o stanju stroja. V krmilnem računalniku se izvaja program, ki zbrane podatke preoblikuje in shranjuje za nadaljnjo uporabo. Od sistemov SCADA se tak sistem razlikuje po tem, da ne omogoča pošiljanja nadzornih ukazov na stroje [8]. Stroški avtomatskega spremljanja strojev naraščajo linearno z vsakim strojem. Njihov precejšen del predstavlja zaradi dimenzij proizvodnih obratov tudi ožičenje¹¹. Podjetja pa imajo svoje obrate pogosto na več lokacijah. V takih primerih je zaradi velike frekvence pošiljanja podatke potrebno shranjevati lokalno, v matično enoto podjetja pa se prenašajo le po določenih časovnih intervalih. Posamezni stroji se v sistem avtomatskega spremljanja vključujejo iz enega ali več razlogov:

- stroški delovanja stroja so veliki, zato je potrebno zaradi boljše izrabe natančno spremljati njegovo delovanje;
- stroj predstavlja ozko grlo in je potrebno stalno nadzorovati njegovo učinkovitost [5];
- stroj že brez posegov nudi zadovoljive podatke in so stroški vključitve v sistem avtomatskega spremljanja nizki;
- za stroj je potrebno shranjevati različne parametre izdelovanja, ki se kasneje uporabljajo za nadzor kakovosti izdelkov.

⁹Krmilniki na stroju odpirajo in zapirajo hidravlične in pnevmatske ventile, vključujejo in izključujejo motorje, grelce in podobno, hkrati pa preko različnih senzorjev pridobivajo povratno informacijo o trenutnem stanju stroja.

¹⁰Ponekod že proizvajalci strojev ne dajejo podatkov o krmilnikih, ponekod pa posegov v stroje ne želijo opravljati podjetja.

¹¹Zaradi hitrega padanja cen predstavljajo brezžični mediji za prenos podatkov resno alternativo. Vendar pa je potrebno upoštevati, da se v proizvodnih obratih pogosto nahaja mnogo naprav (frekvenčni pretvorniki, točkovni varilniki, visokonapetostni vodi, indukcijski grelci, ...), ki onemogočajo delovanje radijskim tehnologijam.



Slika 2.4: *Informacijski terminal (proizvajalec Kolektor Synatec [36]).* Terminal je nameščen na stebru znotraj proizvodnega obrata. Lega terminala je določena tako, da je dostopen z več različnih delovnih mest.

2.6.2 Vnašanje proizvodnih dogodkov

Tak način zbiranja podatkov predvideva sodelovanje delavcev, vnos posameznih dogodkov pa mora biti čim hitrejši in čim enostavnejši. Vnosna mesta je zato potrebno čim bolj približati delavcem - tako v funkcionalnem kot v fizičnem smislu. Informacijski sistem mora biti zasnovan tako, da ga delavci uporabljajo brez večjih naporov med delom, hkrati pa mora nuditi kakovostne informacije o poteku dela v proizvodnji. Za vnašanje proizvodnih dogodkov se uporabljajo namenski terminali, ki so opremljeni s čitalnikom črtnih kod in zaslonom, občutljivim na dotik (slika 2.4). Skladno z zahtevami je zasnovana tudi programska oprema. Glavni meni za izbiro modulov in uporabo ukazov znotraj modulov se nahaja v spodnji vrstici zaslona. Posamezni moduli so označeni z lastnimi ikonami, vedno pa sta prisotna še navigacijska gumba za pomik v začetni meni ali pomik po meniju nazaj (slika 2.5). Večji del zaslona uporabljajo posamezni moduli, ki so sestavljeni iz področja za vnosna polja ter področja za izpis sporočil. Postopki posameznih modulov so opisani v poglavju 2.5.3.

2.6.3 Programska oprema

Vodje izmen, obratov ali predelavci izvajajo aktivnosti, za katere je predvidena uporaba programske opreme na osebnih računalnikih. Med te aktivnosti spadajo:

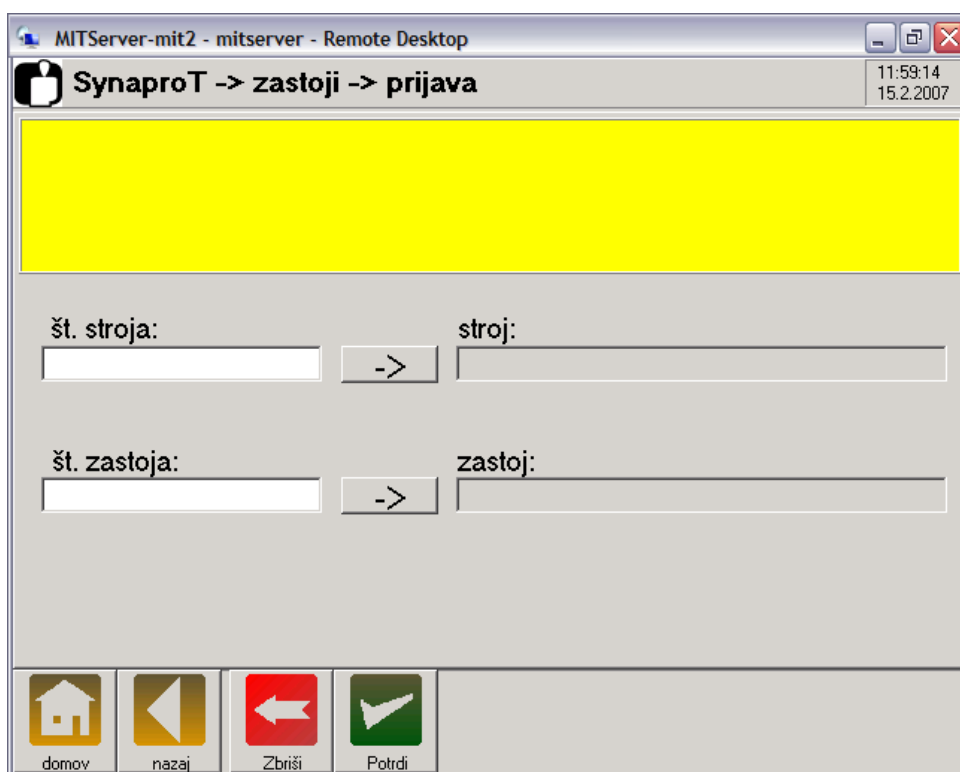


Slika 2.5: *Uporabniški vmesnik na terminalih.* Začetna zaslonska maska omogoča izbiro posameznih sklopov dogodkov.

- tiskanje delovne in spremne dokumentacije,
- urejanje osnovnih podatkov, kot so sezname strojev, delavcev,
- pregledovanje zbranih podatkov iz proizvodnje,
- ročno vnašanje podatkov v primeru napačnega vnosa v proizvodnji,
- potrjevanje avtomatsko zbranih podatkov,
- nadziranje dogajanja v proizvodnji,
- opravljanje različnih analiz.

2.6.4 Upravljanje podatkov

Zaradi porazdeljene arhitekture informacijskega sistema za spremljanje proizvodnje tvori njegovo jedro sistem za upravljanje baz podatkov. Spremljanje proizvodnje zahteva zajemanje podatkov na več mestih. Ta mesta se lahko nahajajo znotraj enega oddelka,

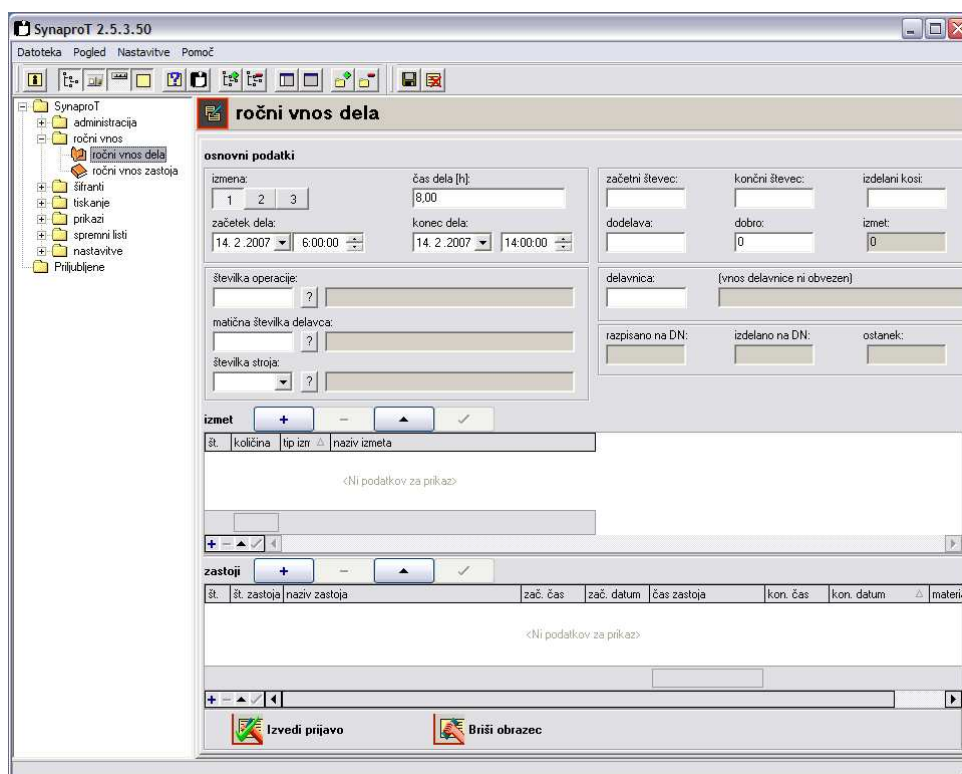


Slika 2.6: Modul za prijavo zastoja na stroju. Zgornji (rumeni) del zaslona je namenjen prikazu sporočil, preko katerih operater dobiva povratne informacije o poteku postopka. Osrednji del je namenjen vnosu posameznih podatkov, ki lahko poteka preko čitalnika črtne kode ali pa preko navidezne zaslonske tipkovnice. Spodnji del zaslona zasedajo gumbi: dva stalna navigacijska gumba ter gumbi, ki jih dodajajo posamezni moduli.

lahko pa se nahajajo tudi v oddaljenih obratih. V obeh primerih obstaja potreba po skupnem hranjenju podatkov. Shranjevanje podatkov iz strojev in naprav zahteva konstantno obremenitev podatkovnega strežnika. V časovni enoti se pojavlja veliko število manjših transakcij. Ker nekateri proizvodni procesi zahtevajo stalno prisotnost nadzornega sistema, mora biti tudi podatkovni strežnik razpoložljiv 24 ur vse dni v tednu. Za razliko od terminalov za registracijo dogodkov, je podatkovni strežnik nenadomestljiv člen v celotni verigi.

2.6.5 Komunikacija z ostalimi informacijskimi sistemi

Podatki, ki se zbirajo s spremljanjem proizvodnje, predstavljajo pomemben vir informacij za poslovni informacijski sistem [61]. Ker je podjetje živa tvorba, je tudi pretok podatkov znotraj in med informacijskimi sistemi konstanten. Izmenjava podatkov med poslovnim informacijskim sistemom in sistemom za spremljanje proizvodnje tvori zanko (slika 2.8).

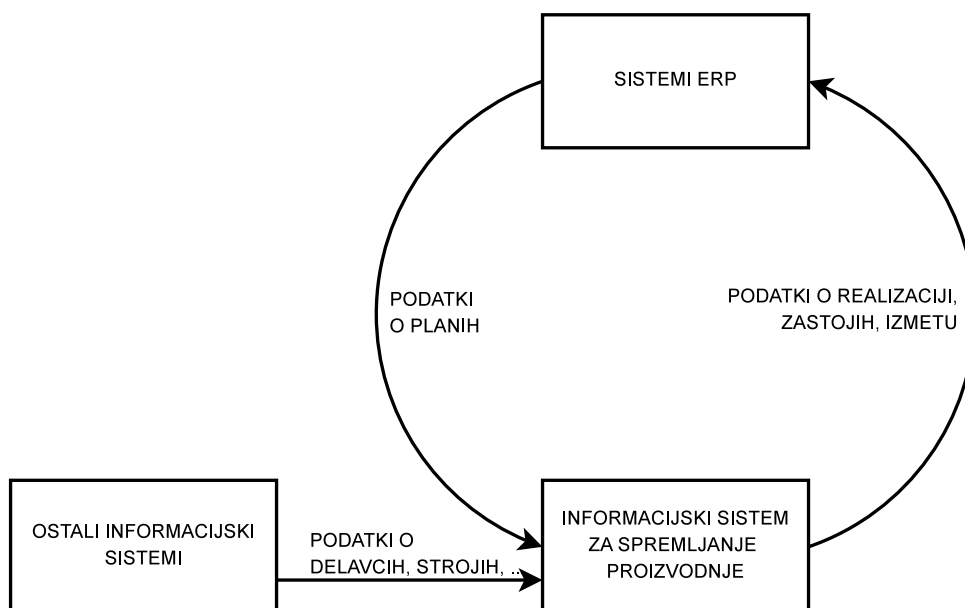


Slika 2.7: Modul za ročni vnos podatkov o opravljenem delu. Modul omogoča vodjem izmen ali obratov, da ročno vnesejo vse podatke o opravljenem delu. Ti podatki zajemajo trajanje dela, delovni nalog, število proizvedenih izdelkov, število in vzroke za neustrezne izdelke ter čase in vzroke morebitnih zastojev.

Plani, ki se pripravljajo v poslovnem informacijskem sistemu, v obliki delovnih nalogov in operacij potujejo v sistem za spremljanje proizvodnje, ki za delovanje potrebuje še druge podatke:

- seznam strojev,
- seznam delavcev,
- seznam zastojev,
- seznam okvar - izmet.

Sistem za spremljanje proizvodnje nato skrbi, da dela potekajo v skladu s plani. Med delovanjem pripravlja podatke o izdelavi, izmetu in opravljenih zastojih. Podatki se nato posredujejo v poslovni informacijski sistem. Ker sistem za spremljanje proizvodnje deluje ločeno od glavnega vira podatkov, uporablja svojo operativno zbirko podatkov. Pogosto poslovni informacijski sistem ne nudi vseh potrebnih podatkov. V takih primerih se podatki črpajo iz več različnih virov.



Slika 2.8: *Izmenjava podatkov.* Tok podatkov med poslovnim informacijskim sistemom in sistemom za spremljanje proizvodnje tvori zanko.

Prenosi podatkov se opravljajo samodejno po v naprej predvidenem urniku. Kljub temu pa je predvidena možnost, da v izrednih primerih operaterji sprožijo prenos podatkov izven urnika.

Izmenjava podatkov se izvaja preko vmesnih datotek. Oba udeležena informacijska sistema svoj izhod zapisujeta v datoteke na dogovorjenem mestu na datotečnem strežniku. Nasprotni strani nato te datoteke odpreta in jih obdelata vrstico za vrstico. Tak način je izvedljiv hitro in enostavno, vendar je potrebno paziti na sinhrono delovanje. Če bi sistem na eni strani v datoteko zapisoval, hkrati pa bi drug sistem iz te datoteke bral, bi lahko prišlo do napak. Oba sistema se morata zato natančno držati urnika in pravil prenosa. Pri obliki vmesnih datotek je v uporabi enostavni zapis, kjer so vrednosti posameznih polj vrstice fiksne širine. Datoteka s fiksno širino stolpcev je enostavnejša za dekodiranje, a hkrati manj fleksibilna pri morebitnih spremembah.

Poglavje 3

Izbira optimalnega števila terminalov

Informacijski sistem za spremljanje proizvodnje, ki smo ga za potrebe raziskave vpeljali v podjetju Kolektor Sikom d.o.o., je opisan v poglavju 2.6. Za njegovo delovanje so potrebni informacijski terminali, preko katerih operaterji strojev in linij vnašajo dogodke. Poseben problem predstavlja določanje optimalnega števila informacijskih terminalov. Namen pričujočega poglavja je formulacija in rešitev stohastičnega optimizacijskega problema za izbiro optimalnega števila terminalov z upoštevanjem tako stroškov terminalov, kakor tudi stroškov, ki so posledica njihovega premajhnega števila.

Pri spremljanju proizvodnje z beleženjem dogodkov je za optimalno delovanje sistema pomembno zadostno število informacijskih terminalov. V primeru, da je število terminalov premajhno, oziroma so neustrezno razporejeni, lahko v času večjih obremenitev¹ prihaja do čakanja na proste terminale. V nasprotnem primeru, ko je terminalov preveč, pa prinašajo nepotrebne stroške.

To poglavje se osredotoča na izbiro optimalnega števila informacijskih terminalov. Pri postavitvi terminalov je potrebno upoštevati:

- gostoto dogodkov, ki se pojavljajo v proizvodnem obratu,
- čas trajanja posameznih prijav,
- razdalje med delovnimi mesti in terminali,
- stroške terminalov oziroma stroške njihovega vzdrževanja in ožičenja.

Z nižanjem števila nameščenih terminalov se stroški namestitve sicer manjšajo, posledično pa se večajo stroški zaradi čakanja delavcev na vnos podatkov. Problem, ki je obravnavan v tem poglavju, je določitev optimalne razmestitve terminalov, ki bo minimizirala celotno stroškovno kriterijsko funkcijo.

¹Največje obremenitve informacijskih terminalov beležimo v času menjave izmene.

Za registracijo dogodka mora urejevalec stroja ali linije pristopiti k informacijskemu terminalu in vnesti potrebne podatke. V primeru, da je terminal že zaseden, mora počakati, da predhodni operater zaključi postopek registracije dogodka. Sistem spremljanja proizvodnje je zasnovan tako, da je mogoče uporabiti vsakega izmed terminalov. Za doseganje čim večje učinkovitosti proizvodnega procesa morajo biti čakalni časi čim manjši, v skrajnem primeru pa jih sploh ni. Vendar pa taka rešitev ni optimalna, saj z večanjem števila terminalov naraščajo tudi stroški njihove postavitve in vzdrževanja. Izbrati je potrebno tako kriterijsko funkcijo, ki bo zajemala oba tipa stroškov.

3.1 Postavitev problema

3.1.1 Kriterijska funkcija

Naj bo N število terminalov in $J_{cost}(N)$ funkcija stroškov, ki jih ima podjetje z njihovo namestitvijo, normirana na en dan. Izhodišče predstavlja amortizacijska doba terminala, ki znaša 4 leta. Letni strošek terminala, ki se razdeli na število delovnih dni v letu, je tako sestavljen iz stroškov amortizacije in stroškov vzdrževanja. Prvi znaša četrtnino nabavne cene, drugi pa 10% nabavne cene na leto.

Dnevni stroški $J_w(N)$, ki nastanejo zaradi čakalnih časov za prijavo dogodkov na terminalu, so preprosto

$$J_w = c_w \tau(n | N) \quad (3.1)$$

pri čemer je c_w cena dela delavca v enoti časa, $\tau(n | N)$ pa kumulativni dnevni čas čakanja za n -ti dan.

Komentar

Čas, potreben za vnos dogodka, znaša okoli 30 sekund in se ne šteje za izgubo tako kot čas čakanja.

Komentar

Pričakovani dnevni čakalni čas $\tau(n | N)$ je naključna spremenljivka, ki je opisana s funkcijo porazdelitve gostote verjetnosti $p(\tau(n | N))$, ki je definirana na odprtem intervalu $[0, \infty)$. Njena analitična oblika ni znana.

Zaradi raztrosa čakalnih časov pri možnih realizacijah je smiselno poiskati takšen τ_α , za katerega velja, da je verjetnost $P(\tau \leq \tau_\alpha)$ enaka $1 - \alpha$, pri čemer je $0 \leq \alpha \leq 1$ stopnja signifikantnosti. Npr. pri $\alpha = 0,05$ lahko s 95% verjetnostjo trdimo, da bo realizirani čakalni čas pri danem številu terminalov N enak $\tau(N) \leq \tau_{0.05}(N)$ [76].

Torej, za optimalno izbiro terminalov predlagamo reševanje naslednjega stohastičnega optimizacijskega problema:

$$N^*(\alpha) = \underset{N \geq 1}{\operatorname{argmin}} (J_{\text{cost}}(N) + c_w \tau_\alpha(N)) \quad (3.2)$$

Komentar

Optimalno število terminalov N^* je odvisno od stopnje signifikantnosti α . To je nujna posledica stohastične narave čakalnih časov. Če hočemo kriterijsko funkcijo prilagoditi skrajnim primerom (npr. manj verjetnim realizacijam čakalnih časov), je potrebno izbrati manjši α , ki pomeni manjše tveganje.

Komentar

Kriterijska funkcija (3.2) je unimodalna, saj je prvi člen v vsoti na desni strani strogo monotono naraščajoča funkcija $J_{\text{cost}}(N)$, drugi člen pa strogo monotono padajoča funkcija $\tau_\alpha(N)$. Torej zagotovo obstaja N , pri katerem kriterijska funkcija doseže minimum.

3.2 Reševanje optimizacijskega problema

Za reševanje optimizacijskega problema (3.2) je pomembno poznavanje porazdelitve dogodkov tekom delovnega časa. Komulativni dnevni čakalni čas $\tau(n|N)$ v dnevu n z N razpoložljivimi terminali je odvisen od števila in razporeda dogodkov. Tak čas je mogoče izračunati s simulacijo. Čakalni časi se med različnimi dnevi spreminjajo naključno, njihova porazdelitev pa je lahko poljubna. Zato torej ni mogoče v naprej predvideti parametrizacije funkcije gostote verjetnosti $p(\tau(n|N))$ - aproksimirati jo je potrebno s histogramom $\tau(n|N)$, za kar pa je potrebno izbrati dovolj velik n_D .

3.2.1 Izračun čakalnih časov na množici dogodkov

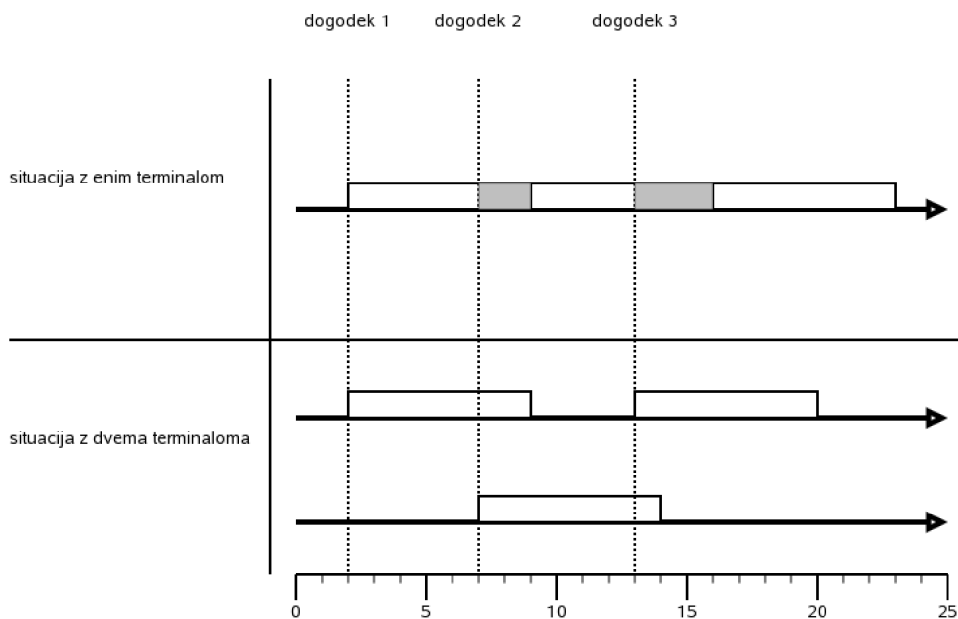
Predpostavimo, da imamo na voljo množico dogodkov za daljše obdobje (npr. za n_D dni). Naj bo $k - ti$ dogodek, ki se je zgodil $n - tega$ dne označen s časom $t_{n,k}$. Tako dobimo množico

$$T(n_D) = \{t_{1,1}, t_{1,2}, \dots, t_{1,K_1}, t_{2,1}, \dots, t_{2,K_2}, \dots, t_{n_D,1}, \dots, t_{n_D,K_{n_D}}\} \quad (3.3)$$

Za izračun dnevnih čakalnih časov predlagamo algoritem 3.1. Končni rezultat je zaporedje čakalnih časov po dnevih $T = \{\tau(1|N), \dots, \tau(n_D|N)\}$. Časovna kompleksnost omenjenega algoritma je $O(m \cdot N_{\text{max}})$, pri čemer m predstavlja število vseh dogodkov v učnem intervalu, N_{max} pa predstavlja največje število terminalov, za katerega nas še zanimajo podatki o čakalnih časih.

Algoritem 3.1 Izračun dnevnih čakalnih časov

- 1: določitev terminala, ki bo prvi prost za prijavo;
 - 2: izračun časa, ko bo terminal na voljo za prijavo;
 - 3: izračun čakalnega časa (razlika med časom sprostitve terminala in časom dogodka);
 - 4: rezervacija terminala za čas trajanja prijave;
 - 5: povečanje skupnega časa čakanja v tekočem dnevu;
-



Slika 3.1: *Ilustracija izračuna čakalnih časov.* Na spodnji skali je prikazan čas. Posamezni trakovi v obeh situacijah predstavljajo trajanje prijave. Osenčeni trakovi v situaciji z enim terminalom predstavljajo čakalne čase.

Na sliki 3.1 sta prikazana primera izračuna čakalnih časov za situaciji z enim in dvema terminaloma. V obeh primerih nastopijo trije dogodki ob časih 2, 7 in 13. Obdelava vsakega izmed dogodkov na terminalu traja 7 časovnih enot. Prvi dogodek ob času 2 takoj preide v obravnavo v obeh situacijah. Enako se v situaciji z dvema terminaloma zgodi pri preostalih dveh dogodkih. V situaciji z enim terminalom, je ta zaseden ob nastanku drugega in tretjega dogodka. Obravnava drugega dogodka, ki se pojavi ob času 7, se odloži do sprostitve terminala (čas 9). Obravnava tretjega dogodka se iz enakega razloga prestavi iz časa nastanka 13 za 3 časovne enote. Čakalni čas je na diagramu osenčen. V navedenem primeru je čakalni čas pri enem terminalu 5 časovnih enot, pri situaciji z dvema terminaloma pa čakanja ni bilo.

3.2.2 Določanje kritičnih čakalnih časov

Na podlagi množice $T(n_D)$ se lahko izračuna histogram za naključno spremenljivko $\tau(N)$. Histogram je približek za funkcijo porazdelitve verjetnosti. Seveda se ta spreminja v odvisnosti od števila terminalov in je njena analitična oblika v splošnem težko določljiva. Čeprav je $\tau(N)$ vsota posameznih čakalnih časov $\tau(1|N), \dots, \tau(n_D|N)$, izračunanih za dneve $1, 2, 3, \dots, n_D$, je skoraj nemogoče analitično določiti povezavo med $p(\tau(d|N))$ in $p(\tau(N))$.

Za določitev τ_α porazdelitve $p(\tau(N))$ uporabimo centralni limitni izrek [76], ki pravi:

Izrek [52]. Naj bodo x_1, x_2, \dots, x_r enakomerno porazdeljene neodvisne naključne spremenljivke s povprečno vrednostjo μ in varianco σ^2 . Naj bo

$$S_r = \frac{\sum_{i=1}^r x_i}{r} \quad (3.4)$$

potem tudi porazdelitev

$$Z_r = \frac{\sqrt{r}(S_r - \mu)}{\sigma} \quad (3.5)$$

konvergira k normalni porazdelitvi $\mathcal{N}(0, 1)$. Limitno razmerje Z_r je normalno porazdeljeno s povprečno vrednostjo enako nič in enotno varianco. Za potrebe predstavljenega problema se osredotočimo na vsoto

$$\tau(N) = \sum_{i=1}^{n_D} \tau(i|N) \quad (3.6)$$

normalno porazdeljenih $\tau(i|N)$ s povprečno vrednostjo μ in varianco σ^2 . Torej je standardna vsota

$$Z(n_D) = \frac{\tau(N) - n_D \cdot \hat{\mu}}{\sqrt{n_D} \cdot \hat{\sigma}} \quad (3.7)$$

normalno porazdeljena s povprečno vrednostjo 0 in varianco 1. Vemo, da je kritična vrednost Z_α

$$P(Z \leq Z_\alpha) = \alpha \quad (3.8)$$

iz tabele kritičnih vrednosti za normalno porazdelitev. Glede na to je kritična vrednost $\tau(N)$ določena z:

$$\tau(N) = \frac{Z_\alpha \sqrt{n_D} \hat{\sigma} + n_D \cdot \hat{\mu}}{\tau(N)} \quad (3.9)$$

kjer

$$\begin{aligned} \hat{\mu} &= \frac{\tau(N)}{n_D} \\ \hat{\sigma}^2 &= \frac{1}{n_D - 1} \sum_{i=1}^{n_D} (\tau(i|N) - \hat{\mu})^2 \end{aligned}$$

3.2.3 Optimizacijska metoda

Kriterijska funkcija (3.2) ima argument iz množice naravnih števil. V našem primeru imamo opravka z enodimenzionalnim problemom, kjer je iskanje sorazmerno enostavno, saj gre minimume običajno pričakovati pri relativno majhnih vrednostih števila terminalov. Zato bomo uporabili najbolj enostaven postopek, ki je prikazan v algoritmu 3.2.

Algoritem 3.2 Iskanje optimuma

```
1:  $N_{opt} = 0$ ;  
2:  $J_{opt} = 10^{10}$ ;  
3: for  $N = 1$  to  $N_{max}$  do  
4:   izračun histograma čakalnih časov za  $N$  terminalov;  
5:   izračun kritičnega čakalnega časa  $\tau_\alpha$ ;  
6:   izračun kriterijske funkcije  $J(N)$ ;  
7:   if  $J(N) < J_{opt}$  then  
8:      $N_{opt} = N$ ;  
9:      $J_{opt} = J(N)$ ;  
10:  end if  
11: end for
```

3.2.4 Ocenjevanje dnevne porazdelitve dogodkov

Ročno pridobivanje podatkov² je lahko zamudno, neučinkovito in ima visoko ceno³. Zato lahko predvidevamo, da podatki sestojijo iz množice n_{OP} dnevni zapisov ($n_{OP} \ll n_D$).

Gostota dogodkov tekom dneva ni konstantna, ampak se spreminja (slika 3.2). Profil gostote dogodkov je odvisen od tipa proizvodnje (delavniška proizvodnja se razlikuje od masovne). Interval med dvema dogodkoma, ki nastopita ob časih t_i in t_{i+1} , je naključna spremenljivka, za katero predvidevamo eksponentno porazdelitev

$$p(\Delta t \mid \lambda(t)) = \lambda(t)e^{-\lambda(t)\Delta t} \quad (3.10)$$

kjer $\Delta t = t_{i+1} - t_i$ in $\lambda(t)$ predstavljata parameter porazdelitve, ki se spreminja s časom. Za poenostavitev problema dnevne profile $\lambda(t)$ aproksimiramo s funkcijo $\lambda(t) = \lambda_i$, $t_{i-1}^* \leq t \leq t_i^*$, $i = 1, \dots, \nu$. Predvidevamo, da se dnevni profil med posameznimi dnevi ne spreminja.

Za dane podatke

$$D_{n_{OP}} = \{t_{1,1}, t_{1,2}, \dots, t_{1,K_1}, t_{2,1}, \dots, t_{2,K_2}, \dots, t_{n_{OP},1}, \dots, t_{n_{OP},K_{n_{OP}}}\}$$

²Brez uporabe informacijskih terminalov.


³V smislu vloženega dela in časa, ki sta potreba za pridobivanje podatkov.

je potrebno poiskati funkcijo gostote verjetnosti $p(\lambda_i | D_{n_{OP}})$. Mogoče je dokazati [16], da je največja pričakovana verjetnost

$$p(\lambda_i) = \frac{k}{\sum_{j=1}^k x_j} \quad (3.11)$$

kjer $x_j \in \{x_{1,r_1}, x_{1,r_2}, \dots, x_{1,r_{s_1}}, x_{2,r_1}, \dots\}$ tako da $x_{i,s} = t_{i,s+1} - t_{i,s}$ kjer $t_i^* \leq t_{i,s+1}, t_{i,s} \leq t_{i+1}^*$.

Izraz $2\lambda_i(\sum_j x_j)$ ima porazdelitev chi-kvadrat z $2n$ prostostnimi stopnjami. Na podlagi teh dejstev je s simulacijo *Monte Carlo* [43] mogoče generirati množico dogodkov $T(n_D)$ iz izraza (3.3).




Slika 3.2: Povprečno število dogodkov na minuto preko celotnega dneva. Izrazitejše izstopanje nastopi le pri menjavah izmen, ob 6., 14. in 22. uri.

3.3 Primer uporabe

V nadaljevanju je predstavljen primer uporabe v kosovni industriji. Gre za obrat z okoli 60 delavci v dveh izmenah. Delni vpogled v naravo proizvodnje odraža frekvenca dogodkov v obratu (3.2). Učna množica obsega 10 delovnih dni. Na podlagi tega profila je bil ocenjen parameter λ , ki je bil uporabljen v simulaciji *Monte Carlo* za pripravo dogodkov za 83 delovnih dni. Slika 3.3 prikazuje gostoto simuliranih dogodkov, ki se zelo ujema z gostoto dejanskih dogodkov. Pri optimizaciji števila terminalov smo izhajali iz konkretnih podatkov o stroških in sicer $c_w = 4,6$ in $c_0 = 1500^4$.

⁴Enote so namenoma izpuščene.



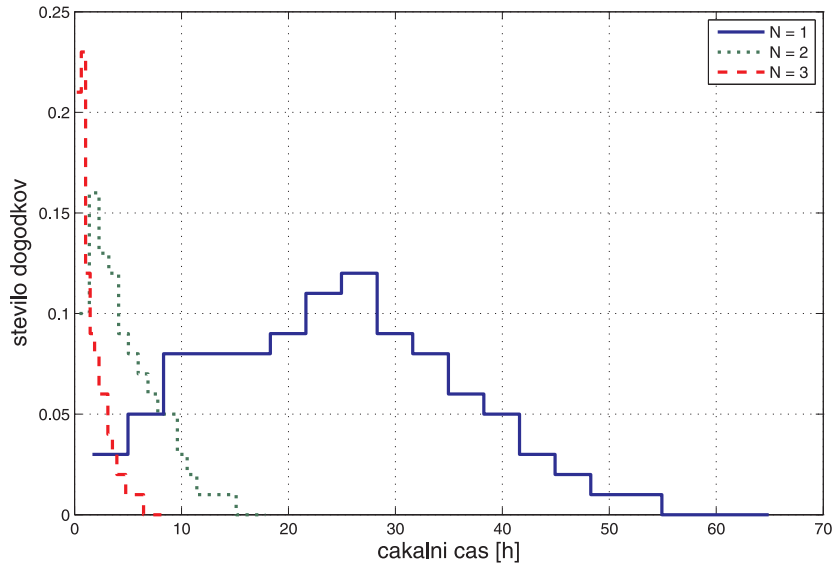
Slika 3.3: *Primerjava ocenjenega profila λ* . Rdeča in modra krivulja predstavljata predvideno in dejansko gostoto dogodkov v razponu 83 dni (predvidevanja so napravljena na podlagi 10-dnevnega izseka dejanskih dogodkov).

Med iskanjem optimalnega števila terminalov se za vsako število terminalov izračuna nov histogram. Slika 3.4 prikazuje histograme za $N = 1, 2, 3$. Kritični pričakovani čas se približuje vrednosti 0 z večanjem števila terminalov. Na sliki 3.5 so narisane vrednosti kriterijske funkcije (3.2) v odvisnosti od števila terminalov. Na sliki 3.6 je prikazana odvisnost minimuma N^* od vrednosti parametra α . Očitno je, da se z večanjem α optimalno število terminalov zmanjšuje. To najlažje pojasnimo s tem, da ima povečani α za posledico preveč optimistične (prekratke) kumulativne čase čakanja. Priporočljiva vrednost ($\alpha=0,05$) je bila določena na podlagi analize histograma čakalnih časov. Z izbiro take vrednosti z veliko verjetnostjo zagotovimo upoštevanje velikega dela čakalnih časov.

3.4 Diskusija

V zvezi z rezultati lahko komentiramo naslednje:


1. Predstavljena rešitev je v veliki meri odvisna od učnih podatkov. Zato je temu področju potrebno posvetiti še dodatno pozornost. Napačno izbrani učni podatki ne odražajo dejanskega stanja proizvodnje.
2. Rešitev testnega primera se presenetljivo sklada z dosedanja prakso razporejanja terminalov v proizvodnih obratih. Izkustveno pravilo predvideva postavitev enega




Slika 3.4: *Histogrami porazdelitve čakalnih časov.* Prikazani so histogrami za število terminalov $N = 1, 2, 3$. Z večanjem števila terminalov se pričakovani čakalni časi hitro približujejo vrednosti 0.

terminala na vsakih 10 do 15 delavcev, odvisno od velikosti posameznega obrata.

3. Predstavljena rešitev omogoča enostaven pregled in primerjavo predvidenih dnevnih



Slika 3.5: *Kriterijska funkcija J_{cost} .* Prikazana je kriterijska funkcija za izbrano kritično vrednost $\alpha = 0,05$, v odvisnosti od števila terminalov N . Najnižjo vrednost (17,73) doseže pri $N = 5$.



Slika 3.6: *Odvisnost optimalnega števila terminalov N^* od parametra α . Prikazane so vrednosti za $\alpha \in [0, 1]$.*

stroškov v odvisnosti od števila terminalov. Pri znani kriterijski funkciji (slika 3.5) lahko namreč hitro ugotovimo, kolikšen dodaten strošek pomeni namestitve dodatnih terminalov za primer okvare katerega izmed osnovnih terminalov.

4. V tej fazi ne upoštevamo geografske razporeditve terminalov, ampak se osredotočamo le na njihovo število. Predpostavlja se, da se terminali porazdelijo enakomerno po proizvodnji in se poti med delovnimi mesti in terminali po dolžini bistveno ne razlikujejo.

3.5 Sklep

Prikazan pristop reševanja problema razmestitve terminalov v proizvodnji temelji na stohastični optimizaciji kriterijske funkcije. Cilj dela je bil izpeljati postopek, po katerem bi lahko določali optimalno število terminalov za dani primer proizvodnje. Kriterijska funkcija upošteva dve vrsti stroškov: take, ki nastanejo zaradi nabave terminalov in take, ki nastajajo zaradi čakanja delavcev na prost terminal. Mogoča nadgradnja predstavljene rešitve bi lahko upoštevala še geografsko komponento. Terminalov v proizvodnji ni mogoče razporejati poljubno, ampak je potrebno upoštevati opremljenost posamezne lokacije z električnim in komunikacijskim priključkom. Ker terminali obstajajo tudi v brezžični izvedbi, vendar so ustrezno dražji, bi bilo smiselno v nadgradnji predstavljene rešitve upoštevati tudi ta dejavnik.

Poglavje 4

Orodja za analizo proizvodnih podatkov

Cilj disertacije je tudi iskanje skritih povezav med vhodnimi spremenljivkami proizvodnega procesa in med njegovimi izhodi. Gre torej za modeliranje neodvisnih spremenljivk (izhodi proizvodnega procesa) na podlagi vhodnih spremenljivk, ki predstavljajo parametre vhodnih surovin in tehnološke parametre. Za ta namen uporabljamo različne regresijske metode. Ker imamo opravka z izhodi dveh tipov: realnimi in binarnimi vrednostmi so v tem poglavju opisane različne regresijske metode, ki se uporabljajo za modeliranje v obeh primerih. V obeh primerih pa so predstavljene metode, ki odpravljajo problem kolinearnosti v vhodnih podatkih.

4.1 Model linearne regresije

Zajete podatke lahko predstavimo z matrikama X (vhodni podatki) in Y (izhodni podatki). Če imamo opraviti s k meritvami, n vhodnimi spremenljivkami in m izhodnimi, potem je matrika X dimenzije $k \times n$, matrika Y pa je dimenzije $k \times m$. Običajno je število meritev večje od števila spremenljivk ($k \gg n$). Pri regresijskem problemu iščemo tako matriko neznanih parametrov F , da zadostimo enačbi (4.1) [30]

$$Y = X \cdot F \tag{4.1}$$

Gre za iskanje optimuma v prostoru $n \cdot m$ parametrov.

4.1.1 Ocena najmanjše kvadratne napake

V enostavnem sistemu imamo opravka samo z enim izhodnim signalom, Y_i ($m = 1$). V tem primeru imamo namesto z matriko parametrov opravka z vektorjem F_i . Regresijski problem takega primera je predstavljen v enačbi (4.2).

$$Y_i = X \cdot F_i \tag{4.2}$$

Ker je $k > n$, v splošnem ne obstajajo eksaktne rešitve enačbe (4.2). Pri iskanju najboljšega približka enačbi (4.2) dodamo še napako in dobimo enačbo (4.3):

$$\tilde{Y}_i = X \cdot F_i + E_i \quad (4.3)$$

kjer je E_i vektor dimenzije k in predstavlja napako v posameznih meritvah. Pri sestavljanju modela imamo namreč na voljo le meritve y , ki vsebujejo šum. V regresijskem problemu imamo tako več neznank kakor omejitvev, zato ga je mogoče prevesti v optimizacijski problem. Napake E_i iz enačbe (4.3) predstavljajo razliko med modelom in podatki, do katere pride zaradi

- naključnih napak v merilnem postopku,
- naključnih nemerljivih vplivov ter
- nepopolnosti modela (vsak model je zgolj aproksimacija stvarnosti).

Eden izmed osnovnih pristopov k reševanju problema je *minimizacija vsote kvadratov napak* [30]. Vsoto kvadratov napak lahko izrazimo kot

$$\begin{aligned} E_i^T E_i &= (Y_i - X F_i)^T (Y_i - X F_i) \\ &= Y_i^T Y_i - Y_i^T X F_i - F_i^T X^T Y_i + F_i^T X^T X F_i \end{aligned} \quad (4.4)$$

Dobljeni rezultat je skalarna vrednost, odvajamo ga lahko po vektorju F_i :

$$\frac{d(E_i^T E_i)}{dF_i} = 0 - X^T Y_i - X^T Y_i + 2X^T F_i \quad (4.5)$$

Ker velja

$$\frac{d^2(E_i^T E_i)}{dF_i^2} = 2X^T X > 0 \quad (4.6)$$

je ta ekstrem tudi minimum enačbe, saj ima kvadratna funkcija le en ekstrem. Kjer ima odvod vrednost nič, dobimo optimalne parametre:

$$-2X^T Y_i + 2X^T X F_i = 0 \quad (4.7)$$

iz česar izhaja:

$$F_i = (X^T X)^{-1} X^T Y_i \quad (4.8)$$

4.1.2 Analiza

Sledi opis teoretične analize, ki jo lahko uporabimo za vrednotenje modela najmanjših kvadratov.

Konsistentnost modela

Za oceno parametrov lahko napišemo:

$$\begin{aligned}
 \hat{F}_i &= (X^T X)^{-1} X^T Y_i \\
 &= (X^T X)^{-1} X^T (X F_i + E_i) \\
 &= F_i + (X^T X)^{-1} X^T \cdot E_i
 \end{aligned} \tag{4.9}$$

kjer so \hat{F}_i ocene parametrov in F_i parametri "dejanskega" procesa. Očitno je \hat{F}_i naključna spremenljivka zato, ker je E_i naključna spremenljivka. Torej \hat{F}_i predstavlja realizacijo naključnega procesa. Iz tega lahko izpeljemo enačbo za napako parametrov:

$$\tilde{F}_i = F_i - \hat{F}_i = (X^T X)^{-1} X^T \cdot E_i \tag{4.10}$$

Pričakovana vrednost napake parametrov je enaka nič ob predpostavki, da sta X in E_i nekorelirani:

$$E\{\tilde{F}_i\} = (X^T X)^{-1} X^T E\{E_i\} = 0 \tag{4.11}$$

Če predpostavka o nekoreliranosti ne drži, imamo opravka s *pristranskostjo* [30]. Če je matrika X deterministična in ima E povprečje enako nič, ni težav, vendar tema pogojema ni vedno zadoščeno.

Negotovost parametrov

Zanesljivost regresijskega modela iz enačbe (4.8) lahko aproksimiramo s preverjanjem variabilnosti parametrov. Iz enačbe (4.10) izpeljemo kovariančno matriko vektorja parametrov:

$$\begin{aligned}
 E\{\tilde{F}_i \tilde{F}_i^T\} &= E\left\{((X^T X)^{-1} X^T E_i)((X^T X)^{-1} X^T E_i)^T\right\} \\
 &= (X^T X)^{-1} X^T \cdot E\{E_i E_i^T\} \cdot X (X^T X)^{-1} \\
 &= (X^T X)^{-1} X^T \sigma_e^2 I X (X^T X)^{-1} \\
 &= \sigma_e^2 (X^T X)^{-1}
 \end{aligned} \tag{4.12}$$

Varianco šuma σ_e^2 lahko ocenimo iz variance rekonstrukcijske napake $\tilde{Y}_i = Y_i - \hat{Y}_i = Y_i - X \hat{F}_i$. Varianca parametrov je povezana tako z lastnostmi šuma, določenimi z varianco σ_e^2 , kakor tudi z lastnostmi matrike $X^T X$. Oceno napake parametrov lahko uporabimo pri določanju pomembnosti vhodnih spremenljivk x_j . Pri modelu najmanjših kvadratov je pripadajoči element kovariančne matrike enak $E\{\tilde{F}_j^2\} = \sigma_{jj}^2$. Če predpostavimo, da poznamo obliko funkcije gostote verjetnosti napake, lahko dobimo približek verjetnosti, da ima parameter F_{jj} vrednost nič namesto ocenjene vrednosti \tilde{F}_{ii} . Taka spremenljivka nima vpliva na model in jo lahko zato ignoriramo.

Mere ujemanja modela z meritvami

Za oceno, kako dobro se regresijski model ujema z učnimi podatki, se uporablja kriterij R^2 (*R kvadrat*) [30], ki pove, koliko variance pravega izhoda lahko pojasnimo z modelom:

$$R^2 = 1 - \frac{SS_E}{SS_T} \quad (4.13)$$

kjer za i -ti izhod izračunamo vsoto kvadratov ostanka [76]:

$$SS_E = (Y_i - \hat{Y}_i)^T (Y_i - \hat{Y}_i) = (Y_i - XF_i)^T (Y_i - XF_i) \quad (4.14)$$

in skupno vsoto kvadratov, ki je za podatke s povprečjem enakim nič:

$$SS_T = Y_i^T Y_i \quad (4.15)$$

R^2 torej pove, koliko skupne variabilnosti izhoda pojasnjuje model. Če ima R^2 vrednost enako 1, lahko model natančno napoveduje vso variabilnost izhoda. Čeprav je R^2 standardna mera za opis ujemanja najmanjših kvadratov, ni dovolj dober pristop za vrednotenje modela, saj za ocenjevanje modela uporablja iste podatke, kot so bili uporabljeni za njegovo izgradnjo. Uporaba tega kriterija za vrednotenje modela zato vedno preferira metodo najmanjših kvadratov pred ostalimi metodami, ne glede na občutljivost modela na šum.

Pri praktični uporabi metode najmanjših kvadratov se srečujemo z dvema problemoma:

- koreliranost med regresorji in šumom ter
- kolinearnost med samimi regresorji.

4.1.3 Metoda instrumentalnih spremenljivk

Če predpostavimo, da je matrika $\mathcal{X}^T X$ obrnljiva, potem je spodnji problem rešljiv:

$$F = (\mathcal{X}^T X)^{-1} \mathcal{X}^T Y \quad (4.16)$$

Kakor v enačbi (4.9), lahko tudi v tem primeru najdemo korespondenco med šumom in matriko parametrov:

$$\hat{F} = F + (\mathcal{X}^T X)^{-1} \mathcal{X}^T E \quad (4.17)$$

Napaka parametrov pa ima obliko:

$$\tilde{F} = (\mathcal{X}^T X)^{-1} \mathcal{X}^T E \quad (4.18)$$

Za minimizacijo napake modela mora med \mathcal{X} in X obstajati velika korelacija, med \mathcal{X} in E pa majhna. Prvemu pogoju lahko zadostimo z izbiro $\mathcal{X} = X$. Če hočemo hkrati zadostiti tudi drugemu pogoju, je potrebno poseči po ne-trivialnih rešitvah. Spremenljivke v \mathcal{X} so v tem primeru imenovane *instrumentalne spremenljivke*. Kako določiti instrumentalne spremenljivke z dobrimi lastnostmi, je odvisno od posameznega primera.

4.2 Kolinearnost

Pri dimenzijsko kompleksnih problemih pridejo pomanjkljivosti multilinearne regresije še bolj do izraza. V smislu najmanjše vsote kvadratov so modeli linearne regresije optimalni. Na preprostih primerih ni mogoče videti, da je optimalnost včasih v nasprotju z uporabnostjo. Omenjeni problemi se izkažejo toliko bolj v primerih z večjimi količinami slabih podatkov. Največji problem multilinearne regresije pa predstavlja (multi) kolinearnost. Multikolinearnost je statistični pojav, ko med dvema ali več vhodnimi spremenljivkami multilinearne regresije prihaja do močne korelacije [48].

4.2.1 Primer redundantnih spremenljivk

Za primer vzemimo sistem z dvema spremenljivkama, x_1 in x_2 , tako da je $x = (x_1 \ x_2)^T$. Naj bosta x_1 in x_2 statistično neodvisni, t.j. naj velja $x_1(k) = \xi(k) + \epsilon_1(k)$ in $x_2(k) = \xi(k) + \epsilon_2(k)$. Zaporedji $\epsilon_1(k)$ in $\epsilon_2(k)$ sta medsebojno nekorelirani in imata enako varianco σ^2 . Gre za primer, ko imamo opravka z dvema meritvama iste spremenljivke ξ , v obeh meritvah pa je prisoten šum. V tem primeru bi obe meritvi skupaj lahko dali boljšo oceno za spremenljivko ξ . Za ugotovitev, kaj taka kolinearnost pomeni v praksi, je potrebno najprej izračunati matriko $X^T X$, ki nastopa v regresijski enačbi.

$$\begin{aligned} X^T X &= \begin{pmatrix} \sum_{i=1}^k x_1^2(i) & \sum_{i=1}^k x_1(i)x_2(i) \\ \sum_{i=1}^k x_1(i)x_2(i) & \sum_{i=1}^k x_2^2(i) \end{pmatrix} \\ &\approx k \cdot \begin{pmatrix} E\{\xi^2\} + \sigma^2 & E\{\xi^2\} \\ E\{\xi^2\} & E\{\xi^2\} + \sigma^2 \end{pmatrix} \end{aligned} \quad (4.19)$$

Enačba lastnih vrednosti zgornje matrike je

$$\det \left\{ \lambda \cdot I_2 - k \cdot \begin{pmatrix} E\{\xi^2(k)\} + \sigma^2 & E\{\xi^2(k)\} \\ E\{\xi^2(k)\} & E\{\xi^2(k)\} + \sigma^2 \end{pmatrix} \right\} = 0 \quad (4.20)$$

Lastni vrednosti sta

$$\begin{cases} \lambda_1 = 2k \cdot E\{\xi^2(k)\} + k\sigma^2 \\ \lambda_2 = k\sigma^2 \end{cases} \quad (4.21)$$

Iz teorije matrik je znano, da *pogojenostno število matrike* določa njene numerične lastnosti. Pogojenost je razmerje med največjo in najmanjšo lastno vrednostjo. Če pogojenost narašča proti neskončnosti, postane matrika postopoma neobrnljiva [30]. Matrika $X^T X$ iz zgornjega primera ima pogojenost

$$\text{cond}\{X^T X\} = 1 + 2 \cdot \frac{E\{\xi^2(k)\}}{\sigma^2} \quad (4.22)$$

iz česar sledi, da manjša kot je razlika med spremenljivkama x_1 in x_2 (σ^2 je majhna), večja je občutljivost regresijske enačbe. V skrajnem primeru pride do izrojenosti, ko

rang matrike $X^T X$ postane manjši od polnega ranga [47]. Posledica tega je, da vseh parametrov ni mogoče enolično oceniti iz podatkov.

Iz zgornjega primera je razvidno, da je pozornost pri uporabi regresijske analize potrebno posvečati matriki $X^T X$ in njeni obrnljivosti, saj iz tega izvira največ problemov. Dve linearno odvisni meritvi med spremenljivkami x sta dovolj, da model postane slab.

4.2.2 Reševanje problema slabe pogojenosti informacijske matrike

Za reševanje problemov, ki nastajajo zaradi kolinearnosti, obstaja več različnih pristopov. Pogosto uporabljeni metodi sta *metoda ortogonalnih najmanjših kvadratov* in *regularizacija Tikhonova* [30].

Ortogonalni najmanjši kvadrati

Ker problemi linearne regresije izvirajo iz obrnljivosti matrike $X^T X$, je eden izmed načinov, kako se ogniti numeričnim težavam zaradi slabe pogojenosti izboljšanje numeričnih lastnosti te matrike. Če bi bili vektorji vhodnih spremenljivk ortogonalni, da bi veljalo $X^T X = I$, bi bile lastnosti matrike boljše. Z *Gram-Schmidtovim postopkom* [30] je mogoče sestaviti nove spremenljivke Z na tak način, da je zgornjemu pogoju zadoščeno: za vsak i ($1 \leq i \leq n$) definiramo Z_i :

$$Z'_i = X_i - \sum_{j=1}^{i-1} X_i^T Z_j \cdot Z_j \quad (4.23)$$

$$Z_i = \frac{Z'_i}{\sqrt{Z_i'^T Z'_i}} \quad (4.24)$$

Začnemo pri $Z_1 = \frac{X_1}{\sqrt{X_1^T X_1}}$. Zgornje enačbe predstavimo v matrični obliki z

$$Z = X \cdot M \quad (4.25)$$

kjer je M zgornje-trikotna matrika, za katero velja

$$Z_i^T Z_j = \begin{cases} 1, & i = j \\ 0, & i \neq j \end{cases} \quad (4.26)$$

Torej velja tudi $Z^T Z = I$. Z uporabo teh vmesnih spremenljivk imamo matriko preslikave iz Z v Y definirano kot

$$F = (Z^T Z)^{-1} Z^T Y = Z^T Y \quad (4.27)$$

oziroma z uporabo originalnih spremenljivk X kot

$$F = M X^T Y \quad (4.28)$$

Regularizacija Tikhonova

Osnovna ideja je, da se kovariančni matriki eksplicitno prepreči singularnost (neobrnljivost). Spada v večjo skupino *regularizacijskih metod*, ki izboljšujejo numerične lastnosti podatkov. Namesto kriterija iz enačbe (4.4) sedaj uporabimo kriterij:

$$\begin{aligned} E_i^T E_i + F_i^T Q_i F_i = \\ Y_i^T Y_i - Y_i^T X F_i - F_i^T X^T Y_i + F_i^T X^T X F_i + F_i^T Q_i F_i \end{aligned} \quad (4.29)$$

kjer je Q_i pozitivno definitna matrika uteži. Odvod v tem primeru znaša

$$\frac{d(E_i^T E_i)}{dF_i} = 0 - X^T Y_i - X^T Y_i + 2X^T F_i + 2Q_i F_i \quad (4.30)$$

Optimum je dosežen pri vrednosti odvoda nič

$$-2X^T Y_i + 2X^T X F_i + 2Q_i F_i = 0 \quad (4.31)$$

iz česar sledi

$$F_i = (X^T X + Q_i)^{-1} X^T Y_i \quad (4.32)$$

V primeru sistema z več izhodnimi spremenljivkami, kjer velja, da je matrika uteži enaka za vse izhode ($Q_i = Q$), lahko enačbo zapišemo kot

$$F_{RR} = (X^T X + Q)^{-1} X^T Y \quad (4.33)$$

Pogosto ne razpolagamo z vnaprejšnjimi informacijami o parametrih, zato matrika uteži Q ne more biti enolično določena. Običajno se za Q izbere diagonalna matrika, pogosto pa se matrika Q določi kar z enačbo $Q = q \cdot I$, kjer je $q > 0$ neko majhno število. Tak pristop prepreči, da bi bila matrika, ki jo je potrebno obrniti, singularna. V postopku je matrika Q prišteta kovariančni matriki podatkov. Kaj se v tem primeru zgodi z lastnimi vrednostmi? Lastne vrednosti lahko določimo tudi z rešitvijo izraza determinante


$$|(X^T X + q \cdot I) - \lambda I| = |X^T X - (\lambda - q) \cdot I| \quad (4.34)$$

Kadar prištejemo qI matriki $X^T X$, so njene lastne vrednosti premaknjene navzgor za vrednost q , tako da imajo lastne vrednosti, ki so bile prej enake nič, sedaj vrednost večjo od nič ($q > 0$). Pogojenost matrike se v tem primeru izboljša. Parametri takega modela so običajno bolj konzervativni kakor pri nominalni linearni regresiji.

Enak učinek je mogoče doseči tudi v standardni (multi)linearni regresiji, če je podatkom dodan beli šum z znano kovarianco $\frac{1}{k}qI$. Če ta šum ni koreliran¹ z X , potem je kovariančna matrika podatkov z dodatnim šumom enaka $\frac{1}{k}(X^T X + qI)$.

Obstajata torej dva načina, ki poskrbita za obrnljivost matrike $X^T X$ in s tem za izboljšanje lastnosti regresijskega modela:

¹Kar je enostavno doseči, saj je šum izdelan umetno.



Slika 4.1: *Izboljšani model odvisnosti $y = f(x)$.* Celotna preslikava je sestavljena iz dveh vmesnih preslikav.

1. Informacije lahko *ignoriramo*, tako da izpustimo redundantne spremenljivke. Problem pri tem pristopu je, da tudi redundantne spremenljivke lahko nosijo nekaj informacije. V tem primeru torej ignoriramo nekaj dostopnih informacij.
2. V model lahko vpeljemo dezinformacijo z dodajanjem šuma spremenljivkam.

Ne glede na to, ali modelu informacijo dodajamo ali odvezujemo z namenom izboljšanja njegovega delovanja, imamo opravka z določeno mero heuristike. Redundanca v podatkih namreč povzroča problem kolinearnosti. Čeprav so lahko meritve bolj ali manj medsebojno odvisne, vsaka od njih še vedno prinaša nekaj informacije.

4.2.3 Reševanje problema neinformativnih podatkov z latentnimi strukturami

Za izboljšanje regresijskega modela je prevzet naprednejši sistem, ki ga prikazuje slika 4.1. Iščemo torej interno strukturo, ki bi bolje povzela obnašanje sistema. Ta interna struktura naj bi bila linearni pod-prostor. Podatkovne vrednosti so najprej preslikane na bazo interne strukture, od tam pa so preslikane v izhodni prostor, kamor preslikujejo tudi standardne metode linearne regresije. Ker sta obe preslikavi linearni, ju je mogoče združiti. Tako je model na zunanost še vedno viden kakor enostopenjska preslikava: $Y = (XF^1)F^2 = X(F^1F^2) = XF$. Sedaj imamo namesto z eno približno preslikavo opravka z dvema. Vprašanje, ki se pri tem postavlja, je, ali ne bo model zaradi tega postal še občutljivejši na šum. Odgovor je negativen, saj na model ne vpliva število preslikav, temveč njihove korelacijske lastnosti [30]. Izkaže se, da ima preslikava iz vhodnih v latentne spremenljivke in nato iz latentnih v izhodne dobre lastnosti. Izgradnja regresijskega modela se tako izvaja po postopku, opisanem v algoritmu 4.1.

V algoritmu 4.1 Z predstavlja interne koordinate, ki se ujema z učenimi podatki v X in Y . V nekaterih posebnih primerih (ortonormalna baza θ) je mogoče zgornji postopek tudi poenostaviti. Ostaja torej problem, kako določiti bazo θ , da bi s tem povečali

Algoritem 4.1 Izgradnja regresijskega modela

- 1: določitev baze θ ;
 - 2: sestavljanje preslikave prve faze $F^1 = \theta(\theta^T\theta)^{-1}$;
 - 3: izračun latentnih spremenljivk $Z = XF^1$;
 - 4: sestavljanje preslikave druge faze $F^2 = (Z^T Z)^{-1} Z^T Y$;
-

zmožnosti regresije. Kadar je rang baze enak številu prostostnih stopenj podatkov², jih je mogoče natančno rekonstruirati oziroma je preslikava med podatki in njihovo transformirano predstavitev obrnljiva. To pomeni tudi, da bo naključni šum, ki je prisoten v vzorcih, tam tudi ostal. Dober model naj bi predstavljal samo pomembne stvari iz podatkov, nepomembne pa ignoriral, vse to z neko razumno redukcijo podatkov. V konkretnem primeru taka redukcija podatkov pomeni zmanjšanje dimenzije - število baznih vektorjev je torej manjše od dimenzije podatkov ($N < n$).

Predpostavimo, da ima vhodni vektor dimenzijo n , izhodni dimenzijo m , dimenzija latentne baze je N , k pa je število vzorcev. Nominalni regresijski model s preslikavo F iz vhodnega v izhodni prostor ima $n \cdot m$ prostih parametrov (neznank) in $k \cdot m$ enačb. To pomeni, da je v povprečju

$$\frac{k \cdot m}{n \cdot m} = \frac{k}{n} \quad (4.35)$$

omejitev za vsak parameter. Večje kot je to število, boljša postaja ocena v statističnem smislu, saj ima naključni šum manjši pomen.

Če med vhomom in izhodom uporabimo še latentno bazo, imamo najprej preslikavo iz vhodnega prostora v latentno bazo ($n \cdot N$ parametrov) in nato še preslikavo iz latentne baze v izhodni prostor ($N \cdot m$ parametrov). Vse skupaj pomeni, da je povprečno število omejitev na parameter enako

$$\frac{k \cdot m}{n \cdot N + N \cdot m} = \frac{k}{N(1 + \frac{n}{m})} \quad (4.36)$$

Če velja, da je $N \ll n$, potem je ena od koristi ta, da se občutljivost modela na šum zmanjša. Seveda ob predpostavki, da N latentnih spremenljivk nosi vso potrebno informacijo.

4.3 Glavne komponente

Hipoteza, na katero se osredotočamo sedaj, je, da *varianca v podatkih nosi informacijo*. Na tej predpostavki temelji tudi *metoda glavnih komponent*³ in pripadajoča regresijska metoda. Na kratko: pri metodi glavnih komponent gre za iskanje smeri, v kateri imajo

²To običajno pomeni, da imamo n baznih vektorjev, ki predstavljajo n -razsežne podatke.

³Ang. Principal Component Analysis - PCA.

podatki največjo variabilnost. Te smeri se nato uporabijo za bazo internega modela [14]. Medtem ko je šum naključen, korelacije med spremenljivkami odkrivajo lastnosti resničnega sistema.

Predpostavimo, da je θ_i smer največje variabilnosti, ki jo iščemo. Podatke iz X nato projiciramo na ta eno-razsežen pod-prostor z uporabo enačbe $Z_i = X\theta_i$. Kot rezultat dobimo vektor, sestavljen iz skalarjev za vsako izmed k meritev iz X . Varianco projekcije lahko izračunamo po enačbi

$$E\{z_i^2(k)\} = \frac{1}{k} \cdot Z_i^T Z_i = \frac{1}{k} \cdot \theta_i^T X^T X \theta_i \quad (4.37)$$

Rešitev lahko obstaja le, če je velikost vektorja θ_i omejena. Dolžina vektorja je omejena, če velja $\theta_i^T \theta_i = 1$. To pomeni, da imamo opravka z optimizacijskim problemom z omejitvijo

$$\begin{cases} f(\theta_i) = \frac{1}{k} \cdot \theta_i^T X^T X \theta_i \\ g(\theta_i) = 1 - \theta_i^T \theta_i \end{cases} \quad (4.38)$$

Z uporabo Lagrangevih multiplikatorjev določimo optimalno rešitev za θ_i

$$\frac{dJ(\theta_i)}{d\theta_i} = \frac{d}{d\theta_i} (f(\theta_i) - \lambda_i \cdot g(\theta_i)) = 0 \quad (4.39)$$

ali

$$2\frac{1}{k} \cdot X^T X \theta_i - 2\lambda_i \theta_i = 0 \quad (4.40)$$

kar da rezultat

$$\frac{1}{k} X^T X \cdot \theta_i = \lambda_i \cdot \theta_i \quad (4.41)$$

S tem prevedemo problem iskanja največje variabilnosti na *problem lastnih vrednosti*, kjer je najdeni bazni vektor θ_i tudi lastni vektor matrike $R = \frac{1}{k} \cdot X^T X$. Lastni vektorji kovariančne matrike so imenovani *glavne komponente*.

Zaradi narave problema lastnih vrednosti pomeni, da če θ_i zadosti enačbi (4.41), potem tej enačbi zadosti tudi $\alpha\theta_i$, kjer je α poljubna skalarna vrednost. Zaradi tega predpostavimo, da so lastni vektorji vedno normirani na enotno dolžino, tako da velja $\theta^T \theta = 1$.

Rešitev problema največje variabilnosti je prav tako podana z lastnimi vektorji. Pravzaprav obstaja n rešitev. Katero izbrati, lahko pojasnimo z drugim odvodom

$$\frac{d^2 J(\theta_i)}{d\theta_i^2} = \frac{2}{k} \cdot X^T X - 2\lambda_i \cdot I \quad (4.42)$$

Za doseg maksimuma funkcije $J(\theta_i)$ mora veljati

$$\frac{d^2 J(\theta_i)}{d\theta_i^2} \leq 0 \quad (4.43)$$

kar pomeni, da mora biti drugi odvod semi-negativno definitna matrika. Za vsak vektor ξ velja

$$\xi^T \cdot \left(\frac{2}{k} \cdot X^T X - 2\lambda_i \cdot I \right) \cdot \xi \leq 0 \quad (4.44)$$

Za vektor ξ lahko na primer izberemo katerega koli izmed lastnih vektorjev ($\xi = \theta_j$)

$$\begin{aligned} \theta_j^T \cdot \left(\frac{2}{k} \cdot X^T X - 2\lambda_i \cdot I \right) \cdot \theta_j &= \\ \frac{2}{k} \cdot \theta_j^T \cdot X^T X \cdot \theta_j - 2\lambda_i \cdot \theta_j^T \theta_j &= \\ 2\lambda_j \cdot \theta_j^T \theta_j - 2\lambda_i \cdot \theta_j^T \theta_j &= \\ 2\lambda_j - 2\lambda_i &\leq 0 \end{aligned} \quad (4.45)$$

Zgornje vedno drži za glavni vektor θ_i , ki pripada največji lastni vrednosti, ne glede na vrednost $1 \leq j \leq n$.

Simetrija in ne-negativnost lastnih vrednosti

Kovariančna matrika podatkov $R = \frac{1}{k} \cdot X^T X$ določa lastnosti baznih vektorjev metode glavnih komponent. Matrika R je simetrična, ker za elementa R_{ij} in R_{ji} obstajata ekvivalentna izraza

$$R_{ij} = \frac{1}{k} \cdot X_i^T X_j = \frac{1}{k} \cdot X_j^T X_i = R_{ji} \quad (4.46)$$

Če enačbo (4.41) pomnožimo z leve z vektorjem θ_i^T , dobimo

$$\frac{1}{k} \cdot \theta_i^T X^T X \cdot \theta_i = \lambda_i \cdot \theta_i^T \theta_i \quad (4.47)$$

Enačba (4.47) v osnovi sestoji iz dveh produktov: $\theta_i^T X^T X \cdot \theta_i$ na levi strani in $\theta_i^T \theta_i$ na desni strani enačbe. Produkta lahko interpretiramo kot kvadrata dolžin vektorjev. Ker morata biti ti vrednosti realni števili, večji ali enaki nič in ker je k pozitivno celo število, je očitno, da je lastna vrednost λ_i vedno realno število, ki je večje ali enako nič.

Ortogonalnost lastnih vektorjev

Enačbo (4.41) pomnožimo z leve, tokrat z lastnim vektorjem θ_j^T , dobimo

$$\theta_j^T R \theta_i = \lambda_i \cdot \theta_j^T \theta_i \quad (4.48)$$

Ker je R simetrična matrika ($R = R^T$), velja $\theta_j^T R = (R^T \theta_j)^T = (R \theta_j)^T = \lambda_j \theta_j^T$, iz česar lahko izpeljemo enačbo

$$\lambda_j \cdot \theta_j^T \theta_i = \lambda_i \cdot \theta_j^T \theta_i \quad (4.49)$$

oziroma

$$(\lambda_i - \lambda_j) \cdot \theta_j^T \theta_i = 0 \quad (4.50)$$

Za različni λ_i in λ_j lahko zgornja enačba velja le, če je $\theta_j^T \theta_i = 0$. To pomeni, da so za simetrično matriko R njeni lastni vektorji ortogonalni. Zaradi privzete normalizacije so lastni vektorji ortonormalni. Ortonormalnost je ključnega pomena za lastnosti metode glavnih komponent. Zaradi ortogonalnosti so lastni vektorji nekorelirani. To pomeni, da je mogoča analiza vsake smeri posebej, ne da bi to vplivalo na analizo ostalih smeri.

4.3.1 Analiza modela glavnih komponent

Oglejmo si lastnosti spremenljivk v novi bazi. Imamo n lastnih vektorjev θ_i s pripadajočimi lastnimi vrednostmi λ_i . Od sedaj naprej predpostavimo, da so pari urejeni padajoče glede na njihove numerične vrednosti, tako da velja: $\lambda_i \geq \lambda_j$ za $i < j$. To je mogoče, ker so lastne vrednosti realna števila, večja ali enaka nič. Lastne vektorje in lastne vrednosti predstavimo z matrikama

$$\Theta = (\theta_1 \mid \cdots \mid \theta_n) \quad (4.51)$$

in

$$\Lambda = \begin{pmatrix} \lambda_1 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \lambda_n \end{pmatrix} \quad (4.52)$$

kjer je dimenzija matrik Θ in Λ enaka $n \times n$. Problem lastnih vrednosti lahko v tem primeru zapišemo kot

$$\frac{1}{k} X^T X \cdot \Theta = \Theta \cdot \Lambda \quad (4.53)$$

Prej je bilo pokazano, da so vektorji, ki tvorijo Θ ortonormalni, kar pomeni, da je ortonormalna tudi matrika Θ in zato velja $\Theta^T = \Theta^{-1}$. Ker je $X\Theta = Z$ zaporedje spremenljivk, predstavljenih v novi, latentni bazi, lahko zapišemo

$$\frac{1}{k} \cdot Z^T Z = \frac{1}{k} \cdot \Theta^T X^T X \Theta = \Theta^T \Theta \cdot \Lambda = \Lambda \quad (4.54)$$

Zgornje pomeni, da so nove spremenljivke medsebojno nekorelirane, ker je njihova kovariančna matrika Λ diagonalna. Posamezne lastne vrednosti λ_i pa neposredno razkrivajo variance novih spremenljivk. Podroben pogled tega pokaže (*definicija sledi matrike*)

$$\begin{aligned} \text{var}\{z_1\} + \cdots + \text{var}\{z_n\} &= \\ \lambda_1 + \cdots + \lambda_n &= \\ \text{tr}\{\Lambda\} &= \\ \text{tr}\left\{\frac{1}{k} \cdot \Theta^T X^T \cdot X \Theta\right\} &= \\ \text{tr}\left\{\frac{1}{k} \cdot X^T X \cdot \Theta \Theta^T\right\} &= \\ \text{tr}\left\{\frac{1}{k} X^T X\right\} &= \\ \frac{1}{k} x_1^2 + \cdots + \frac{1}{k} x_n^2 &= \\ \text{var}\{x_1\} + \cdots + \text{var}\{x_n\} & \end{aligned} \quad (4.55)$$

Zgoraj uporabljena sled matrike vrne vsoto diagonalnih elementov kvadratne matrike. Zamenjava vrstnega reda množenja je mogoča zaradi lastnosti sledi matrike, saj za vse kvadratne matrike A in B velja

$$\text{tr}\{AB\} = \sum_{i=1}^{n_A} \sum_{j=1}^{n_B} A_{ij} B_{ji} = \sum_{j=1}^{n_B} \sum_{i=1}^{n_A} B_{ji} A_{ij} = \text{tr}\{BA\} \quad (4.56)$$

Enačba (4.55) pomeni, da je vsa variabilnost iz x prisotna tudi v z . Glede na predpostavko, da variabilnost nosi informacijo, je v z prisotna tudi vsa informacija iz x . Če je potrebno reducirati dimenzijo, je optimalni pristop ta, da izpustimo spremenljivke, ki nosijo najmanj informacije. Če namesto n uporabimo N razsežno bazo ($N < n$), potem naj bo sestavljena iz

$$\Theta = (\theta_1 \mid \cdots \mid \theta_N) \quad (4.57)$$

kjer so vektorji θ_1 do θ_N smeri z največjo variabilnostjo v prostoru podatkov. Če nato rekonstruiramo vektor originalnih podatkov x z uporabo spremenljivk reducirane baze tako, da je $\hat{x} = \theta z$, potem ima napaka

$$\tilde{x} = x - \hat{x} = x - \sum_{i=1}^N z_i \cdot \theta_i = \sum_{i=N+1}^n z_i \cdot \theta_i \quad (4.58)$$

varianco

$$E\{\tilde{x}^T(k)\tilde{x}(K)\} = \sum_{i=N+1}^n \lambda_i \quad (4.59)$$

iz česar sledi, da lastne vrednosti matrike $R = \frac{1}{k} \cdot X^T X$ nudijo neposredno metodo za oceno signifikantnosti baznih vektorjev metode glavnih komponent. Količina podatkov, ki bo izgubljena z izločitvijo baznega vektorja θ_i , je enaka λ_i .

4.3.2 Izbira baznih vektorjev

Pri metodi glavnih komponent je eno ključnih vprašanj, kako izbrati latentno bazo. Za normalizirane podatke $\sum_{i=1}^n \lambda_i = n$ velja groba ocena [30], da se vključi le tiste latentne vektorje θ_i , pri katerih za njihove pripadajoče lastne vrednosti velja $\lambda_i > 1$. Te smeri nosijo nadpovprečno velik del skupne informacije. Upoštevamo lahko tudi obnašanje lastnih vrednosti; če jih narišemo razvrščeno, v padajočem vrstnem redu in pri tem zaznamo hiter padec med dvema lastnima vrednostma, potem lahko postavimo red modela na zadnjo vrednost pred padcem.

Če prva komponenta izrazito prevladuje, obstajajo razlogi za preverjanje, ali je bila predpriprava podatkov ustrezna. Če podatki niso centrirani na povprečje, potem lahko v modelu namesto resnične variabilnosti podatkov prevladuje to povprečje. Če je najmanjša lastna vrednost enaka nič, pomeni, da je množica meritev linearno odvisna. Do tega lahko

pride tudi, kadar imamo na voljo premalo meritev ($k < n$), čeprav lahko metodo glavnih komponent v takih primerih vseeno uporabimo. V splošnem se običajni modeli linearne regresije obnašajo bolje, če imamo na voljo veliko število kakovostnih meritev ($k \gg n$), metode z latentno bazo pa so boljše v primerih z manjšim številom vzorcev.

Če obstajajo lastni vektorji z natančno enakimi lastnimi vrednostmi, potem njihova izbira ni enolična. V tem primeru vsaka njihova linearna kombinacija zadosti pogoju enačbe (4.41). To še posebej drži za take podatke, kjer je kovariančna matrika enaka enotni matriki. Metoda glavnih komponent v tem primeru ne najde nobene strukture.

4.4 Praktični vidiki

V nadaljevanju je predstavljenih nekaj praktičnih omemb metode glavnih komponent.

4.4.1 Linearna regresija na osnovi metode glavnih komponent

Metoda glavnih komponent se že dalj časa uporablja za potrebe klasifikacije in redukcije podatkov. V obeh primerih je glavna ideja reduciranje redundantnih podatkov. Ta ideja je prisotna tudi v regresijskih aplikacijah. Izkaže se, da lastni vektor, ki pripada največji lastni vrednosti, pojasnjuje največ kovariance v podatkih. Lastna vrednost neposredno pojasnjuje, kolikšen del variabilnosti podatkov je zajet v smeri pripadajočega lastnega vektorja. To nam nudi zelo neposreden način za ugotavljanje pomembnosti baznih vektorjev metode glavnih komponent. Bazne vektorje, ki imajo majhen vpliv v podatkih, lahko enostavno izpustimo. Z uporabo tega reduciranega nabora baznih vektorjev (θ_{PCA}) lahko neposredno preidemo na regresijsko metodo glavnih komponent. Tudi če baza internega modela ni reducirana, še vedno nudi izboljšavo nekaterih numeričnih lastnosti, saj so bazni vektorji ortogonalni. Zaradi ortogonalnosti baznih vektorjev velja $Z = XF^1 = X\theta_{PCA}$ in postopek modeliranja lahko opišemo z enačbo

$$\begin{aligned} F &= F^1 F^2 \\ &= \theta_{PCA} (\theta_{PCA}^T X^T X \theta_{PCA})^{-1} \theta_{PCA}^T X^T Y \\ &= \theta_{PCA} (k \Lambda_N)^{-1} \theta_{PCA}^T X^T Y \end{aligned} \tag{4.60}$$

4.5 Novi problemi

Pristop z regresijo glavnih komponent pri izogibanju problemu kolinearnosti ni recept, ki bi bil uspešen v vseh primerih. Spodnji primer demonstrira to trditev. Predpostavimo, da opazujemo dve neodvisni spremenljivki, x_1 in x_2 , tako da je $x = (x_1 \ x_2)^T$. Za

poenostavitev naj model ne vsebuje šuma. To pomeni, da je kovariančna matrika enaka

$$\begin{aligned} \frac{1}{k} \cdot X^T X &= \frac{1}{k} \cdot \begin{pmatrix} \sum_{\mathcal{K}=1}^k x_1^2(\mathcal{K}) & \sum_{\mathcal{K}=1}^k x_1(\mathcal{K})x_2(\mathcal{K}) \\ \sum_{\mathcal{K}=1}^k x_1(\mathcal{K})x_2(\mathcal{K}) & \sum_{\mathcal{K}=1}^k x_2^2(\mathcal{K}) \end{pmatrix} \\ &\approx \begin{pmatrix} E\{x_1^2(\mathcal{K})\} & 0 \\ 0 & E\{x_2^2(\mathcal{K})\} \end{pmatrix} \end{aligned} \quad (4.61)$$

Lastni vrednosti sta v tem primeru trivialni: $\lambda_1 = E\{x_1^2(\mathcal{K})\}$ in $\lambda_2 = E\{x_2^2(\mathcal{K})\}$, lastna vektorja pa sta $\theta_1 = (1 \ 0)^T$ in $\theta_2 = (0 \ 1)^T$. Če je katera izmed lastnih vrednosti manjša, jo lahko po prej predstavljenem načelu izpustimo iz sistema. Predpostavimo, da iz sistema izpustimo θ_2 . Kaj se zgodi, če lahko razmerje med vhodnimi spremenljivkami x in izhodnimi y izrazimo z $y = f(x_2)$ (x_1 oziroma θ_1 v tem razmerju nista vključena)? To pomeni, da bi bil regresijski model, ki uporablja metodo glavnih komponent z reducirano bazo, v tem primeru *popolnoma neuspešen*.

4.5.1 Asociativna regresija

Iz zgornjega primera je razvidno, da je v primeru izgradnje modela z latentnimi spremenljivkami potrebno vzeti v zakup tudi izhodne spremenljivke. V ta namen definiramo

$$v(k) = \begin{pmatrix} x(k) \\ y(k) \end{pmatrix} \quad (4.62)$$

in postavimo model z metodo glavnih komponent za $v(k)$. V tem primeru enakovredno upoštevamo vhode in izhode pri določanju latentnih spremenljivk. Pripadajoča kovariančna matrika tako postane

$$\frac{1}{k} \cdot V^T V = \frac{1}{k} \cdot \left(\begin{array}{c|c} X^T X & X^T Y \\ \hline Y^T X & Y^T Y \end{array} \right) \quad (4.63)$$

Problem lastnih vrednosti zato lahko zapišemo kot

$$\frac{1}{k} \cdot \left(\begin{array}{c|c} X^T X & X^T Y \\ \hline Y^T X & Y^T Y \end{array} \right) \cdot \begin{pmatrix} \theta_i \\ \phi_i \end{pmatrix} = \lambda_i \cdot \begin{pmatrix} \theta_i \\ \phi_i \end{pmatrix} \quad (4.64)$$

Lastni vektorji v zgornji enačbi so razdeljeni na dva dela: vektorji θ_i pripadajo vhodnim spremenljivkam, vektorji ϕ_i pa izhodnim. Izbira najpomembnejših lastnih vektorjev poteka po običajnem, prej predstavljenem postopku, rezultat pa je N lastnih vektorjev, ki imajo obliko

$$\begin{pmatrix} \theta \\ \phi \end{pmatrix} \quad (4.65)$$

Lastni vektorji tako sestavljajo preslikavo med vhodi x in izhodi y , matriki θ in ϕ pa lahko uporabimo za ocenjevanje y na asociativni način. Med regresijo poznamo le

vhodne spremenljivke. Te spremenljivke prilagajamo vhodni bazi, določeni z θ z danimi preslikanimi spremenljivkami z

$$Z = X \cdot \theta^T (\theta^T \theta)^{-1} \quad (4.66)$$

Izhodna preslikava je definirana z izhodno bazo ϕ . Ker so koordinate z poznane, lahko zapišemo oceno

$$\hat{Y} = Z \cdot \phi \quad (4.67)$$

S kombinacijo zgornjega dobimo regresijski model

$$F = \theta^T (\theta^T \theta)^{-1} \phi \quad (4.68)$$


Zgornji model funkcionira, če je dimenzija vhoda n mnogo večja od dimenzije izhoda m . Problem ohlapno povezanih vhodnih in izhodnih spremenljivk še vedno obstaja. Korelirane spremenljivke, ki dominirajo v lastnih vektorjih, so lahko iz iste skupine - lahko so vse izhodne ali pa vse vhodne spremenljivke. Ekskluzivno modeliranje njihove medsebojne odvisnosti lahko poruši vrednost regresijskega modela. V tem primeru je potrebna bolj strukturirana obravnava podatkov; vloži vhodov in izhodov morata biti strogo ločeni med analizo, naloga regresijskega modela pa je, da ju poveže.

4.6 Povezovanje vhoda in izhoda

Zgoraj je bil prikazan pretiran poudarek metode glavnih komponent na vhodnih spremenljivkah. Naslednji korak predstavlja povezovanje vhodov z izhodi. Za to obstaja več različnih načinov. Ena izmed pogosto uporabljenih je (regresijska) *metoda delnih najmanjših kvadratov* [30].

4.6.1 Metoda delnih najmanjših kvadratov

Problem metode glavnih komponent je, da se osredotoča predvsem na vhodne podatke X in ne upošteva izhodnih Y . V modelu ne želimo zajeti variance podatkov, temveč korelacijo med X in Y . V metodi delnih najmanjših kvadratov lahko bazne vektorje izpeljemo na enak način, kakor v primeru metode glavnih komponent, le da se tokrat namesto na variabilnost osredotočamo na korelacije. Postopek je v tem primeru nekoliko bolj zapleten, saj ne prestrukturiramo le vhodnega bloka X , ampak iščemo tudi interno strukturo izhodnega bloka Y [75]. Postopek se začne tako, da se podatki iz X najprej preslikajo v pod-prostor z nižjo dimenzijo, ki se razteza čez bazne vektorje θ_i . Od tukaj so podatki preslikani v pod-prostor podatkov Y , ki se razteza čez bazne vektorje ϕ_i . Šele od tukaj se opravi končna preslikava v prostor Y . Cilj metode je poiskati take bazne vektorje θ_i in ϕ_i , da je korelacija med vektorji preslikanih podatkov $X\theta_i$ in $Y\phi_i$ največja [60],



Slika 4.2: *Izboljšan model odvisnosti* $y = f(x)$. Celotna preslikava je sestavljena iz treh vmesnih.

medtem ko ostanejo dolžine baznih vektorjev konstantne. Omenjeni cilj ima za posledico optimizacijski problem z omejitvami

$$\begin{cases} f(\theta_i, \phi_i) = \frac{1}{k} \cdot \theta_i^T X^T \cdot Y \phi_i \\ g_1(\theta_i) = 1 - \theta_i^T \theta_i \\ g_2(\phi_i) = 1 - \phi_i^T \phi_i \end{cases} \quad (4.69)$$

kjer imamo ločeni omejitvi g_1 in g_2 . Če definiramo pripadajoča Lagrangeova multiplikatorja η_i in μ_i , dobimo hamiltonijan

$$\frac{1}{k} \cdot \theta_i^T X^T \cdot Y \phi_i - \eta_i(1 - \theta_i^T \theta_i) - \mu_i(1 - \phi_i^T \phi_i) \quad (4.70)$$

katerega odvod znaša

$$\begin{cases} \frac{d}{d\theta_i} \left(\frac{1}{k} \cdot \theta_i^T X^T \cdot Y \phi_i - \eta_i(1 - \theta_i^T \theta_i) - \mu_i(1 - \phi_i^T \phi_i) \right) = 0 \\ \frac{d}{d\phi_i} \left(\frac{1}{k} \cdot \theta_i^T X^T \cdot Y \phi_i - \eta_i(1 - \theta_i^T \theta_i) - \mu_i(1 - \phi_i^T \phi_i) \right) = 0 \end{cases} \quad (4.71)$$

in rezultira v paru enačb

$$\begin{cases} \frac{1}{k} \cdot X^T Y \phi_i - 2\eta_i \theta_i = 0 \\ \frac{1}{k} \cdot Y^T X \theta_i - 2\mu_i \phi_i = 0 \end{cases} \quad (4.72)$$

Če rešimo prvo enačbo za θ_i in drugo za ϕ_i , dobimo

$$\begin{cases} \frac{1}{k^2} \cdot X^T Y Y^T X \theta_i = 4\eta_i \mu_i \cdot \theta_i \\ \frac{1}{k^2} \cdot Y^T X X^T Y \phi_i = 4\eta_i \mu_i \cdot \phi_i \end{cases} \quad (4.73)$$

To pomeni, da rešitev problema lastnih vektorjev da najboljše bazne vektorje. Pomembnost baznih vektorjev θ_i za vhodni blok in ϕ_i za izhodni blok je določena z njihovimi pripadajočimi lastnimi vrednostmi $\lambda_i = 4\eta_i \mu_i$. Ker sta matriki $X^T Y Y^T X$ in $Y^T X X^T Y$ simetrični, so lastni vektorji ortogonalni. Neposredno lahko uporabimo enačbo (4.60). Interna baza θ_i metode delnih najmanjših kvadratov je sestavljena iz podmnožice teh baznih vektorjev, ki so prav tako izbrani na podlagi njihovih pripadajočih lastnih vrednosti. V praksi so bazni vektorji ϕ_i redundantni in jih ni potrebno izračunavati. Ker rang produkta matrik ne more presežati ranga množenih matrik, obstaja le $\min\{n, m\}$ od nič različnih lastnih vrednosti.

Uporabo metode delnih najmanjših kvadratov bomo ilustrirali na primeru izhoda, ki je linearno odvisen od druge vhodne spremenljivke: $y(k) = f \cdot x_2(k)$, kjer je f konstanta. Ker predvidevamo, da x_1 in y nista korelirani spremenljivki, matrika iz enačbe (4.61) tako postane

$$\begin{aligned}
& \frac{1}{k} \cdot X^T Y Y^T X \\
&= \frac{1}{k} \cdot \begin{pmatrix} \sum_k x_1(k)y(k) & \sum_k x_1(k)y(k) & \sum_k x_1(k)y(k) & \sum_k x_2(k)y(k) \\ \sum_k x_1(k)y(k) & \sum_k x_2(k)y(k) & \sum_k x_2(k)y(k) & \sum_k x_2(k)y(k) \end{pmatrix} \\
&\approx \begin{pmatrix} E^2\{x_1(k)y(k)\} & E\{x_1(k)y(k)\} \cdot E\{x_2(k)y(k)\} \\ E\{x_1(k)y(k)\} \cdot E\{x_2(k)y(k)\} & E^2\{x_2(k)y(k)\} \end{pmatrix} \quad (4.74) \\
&= \begin{pmatrix} 0 & 0 \\ 0 & f^2 \cdot E^2\{x_2^2(k)\} \end{pmatrix}
\end{aligned}$$

Očitno je največja lastna vrednost, ki pripada drugi vhodni spremenljivki, enaka $f^2 \cdot E^2\{x_2^2(k)\}$ - ne glede na razmerje varianc x_1 in x_2 . To tudi pomeni, da bo baza vedno vsebovala vektor $(0 \ 1)^T$ in glede na predpostavljeno odvisnost je to tudi pogoj za sestavo delujočega regresijskega modela. Lastna vrednost, ki pripada prvi vhodni spremenljivki, ima vrednost nič, kar pomeni, da x_1 nima nobenega vpliva na y .

4.7 Logistična regresija

V logistični regresiji iščemo relacijo med regresorji X , ki so realna števila in rezultatom Y , ki je tudi realno število. V proizvodnih sistemih obstaja razred problemov, kjer je rezultat procesa binarna spremenljivka, na primer izdelek je dober ali slab. Logistična regresija se uporablja za napovedovanje verjetnosti, da bo izdelek dober ali slab v odvisnosti od procesnih pogojev. Kot pri ostalih oblikah regresije tudi tukaj uporabljamo več vhodnih spremenljivk, ki so lahko numerične ali kategorične. Odziv, ki se napoveduje s pomočjo logistične regresije, je vedno znotraj intervala $[0, 1]$ oziroma je podan z verjetnostjo dogodka. Primer logistične funkcije je prikazan na sliki 4.3. Značilnost logističnega modela je, da postane nestabilen, kadar med vhodnimi podatki obstaja močna odvisnost. Tudi pri logistični regresiji se v primeru velikega števila vhodnih spremenljivk pojavlja potreba po njihovem reduciranju, za kar se lahko uporabi metoda glavnih komponent, opisana v poglavju 4.3.

4.7.1 Osnovna teorija

Naj bodo $\mathcal{X}_1, \mathcal{X}_2, \dots, \mathcal{X}_p$ opazovane zvezne spremenljivke, za katere vektorje meritev označimo z x_1, x_2, \dots, x_p in naj bo n število vzorcev. Matriko X meritev vhodnih spremenljivk zapišemo kot

$$X = (x_1 \mid \cdots \mid x_p) \quad (4.75)$$


Naj bo $Y = (y_1, \dots, y_n)^T$ vektor binarnih meritev odziva \mathcal{Y} na pripadajoče vzorce \mathcal{X} , kjer za posamezne vrednosti velja $y_i \in \{0, 1\}, i = 1, \dots, n$. Potem logistični regresijski model zapišemo kot [2]

$$y_i = \pi_i + \epsilon_i \quad (4.76)$$

kjer je π_i verjetnost za odziv \mathcal{Y} na $(\mathcal{X}_1 = x_{i1}, \mathcal{X}_2 = x_{i2}, \dots, \mathcal{X}_p = x_{ip})$, ki jo zapišemo

$$\pi_i = P\{\mathcal{Y} = 1 \mid \mathcal{X}_1 = x_{i1}, \mathcal{X}_2 = x_{i2}, \dots, \mathcal{X}_p = x_{ip}\} = \frac{e^{\beta_0 + \sum_{j=1}^p x_{ij}\beta_j}}{1 + e^{\beta_0 + \sum_{j=1}^p x_{ij}\beta_j}} \quad (4.77)$$

kjer so $\beta_0, \beta_1, \dots, \beta_p$ parametri modela, ϵ_i pa so napake s povprečjem enakim nič in varianco $\text{var}[\epsilon_i] = \pi_i(1 - \pi_i), i = 1, \dots, n$.



Slika 4.3: Primer funkcije logit $f(x) = \frac{1}{1+e^{-x}}$. Katerakoli vrednost iz intervala $(-\infty, \infty)$ se preslika v interval $[0, 1]$.

Definirajmo *logit* transformacije kot

$$l_i = \ln \left(\frac{\pi_i}{1 - \pi_i} \right), i = 1, \dots, n \quad (4.78)$$

kjer $\frac{\pi_i}{1 - \pi_i}$ predstavlja verjetnost za odziv $\mathcal{Y} = 1$ pri opazovani vrednosti $x_i = (x_{i1}, \dots, x_{ip})$. Potem lahko model logistične regresije zapišemo kot splošni model linearne regresije, kjer kot vezno funkcijo uporabimo logit transformacijo iz enačbe (4.78):

$$L = X \cdot \beta \quad (4.79)$$

kjer je $L = (l_1, \dots, l_n)^T$ vektor logit transformacij, $\beta = (\beta_0, \beta_1, \dots, \beta_p)^T$ je vektor parametrov, $X = (1_n | \mathcal{X})$ pa je matrika vhodov, ki ji dodamo konstantni regresor v obliki stolpca enic ($1_n = (1 \dots 1)^T$).

Razmerje med odzivom in vsakim prediktorjem lahko interpretiramo kot verjetnostno razmerje parametrov modela. Iz enačbe (4.77) sledi, da je eksponent j -tega parametra verjetnostno razmerje za uspeh ($\mathcal{Y} = 1$), kadar vrednost j -tega prediktorja povečamo za eno enoto in ostali prediktorji ostanejo nespremenjeni.

4.7.2 Reševanje problema kolinearnosti

V razdelkih 4.3 in 4.6.1 sta omenjena linearna regresijska modela, ki problem kolinearnosti rešujeta s pomočjo metode glavnih komponent in metode delnih najmanjših kvadratov. Obe metodi se uporabljata tudi za zmanjševanje nabora prediktorjev pri logistični regresiji.

Model logistične regresije iz enačbe (4.77) zapišemo s pomočjo latentnih spremenljivk Z [2] (v tem primeru uporabimo vse latentne spremenljivke), ki jih dobimo s transformacijo z metodo glavnih komponent, opisano v poglavju 4.2.3

$$\pi_i = \frac{e^{\beta_0 + \sum_{j=1}^p \sum_{k=1}^p z_{ik} \Theta_{jk} \beta_j}}{1 + e^{\beta_0 + \sum_{j=1}^p \sum_{k=1}^p z_{ik} \Theta_{jk} \beta_j}} = \frac{e^{\beta_0 + \sum_{k=1}^p z_{ik} \gamma_k}}{1 + e^{\beta_0 + \sum_{k=1}^p z_{ik} \gamma_k}} \quad (4.80)$$

kjer so $z_{ik}, (i = 1, \dots, n; k = 1, \dots, p)$ elementi matrike vhodov, preslikane v latentni prostor ter $\gamma_k = \sum_{j=1}^p \Theta_{jk} \beta_j, (k = 1, \dots, p)$. Θ je matrika lastnih vektorjev (enačba (4.51)) kovariančne matrike vhodnih podatkov $X^T X$. Tak logistični model lahko zapišemo tudi v matrični obliki

$$L = X \cdot \beta = Z \cdot V^T \cdot \beta = Z \cdot \gamma \quad (4.81)$$

kjer velja $Z = (1 | X \cdot \Theta)$ in $V = \left(\begin{array}{c|c} 1 & \mathbf{0}^T \\ \hline \mathbf{0} & \Theta \end{array} \right)$, $\mathbf{0} = (0, \dots, 0)^T$, $\mathbf{1} = (1, \dots, 1)^T$. Parametre β logističnega modela izračunamo po enačbi

$$\beta = V \cdot \gamma \quad (4.82)$$

4.7.3 Uporaba manjšega števila latentnih spremenljivk

V primeru kolinearnosti v vhodnih podatkih je za doseganje boljših rezultatov potrebno operirati z reduciranim naborom latentnih spremenljivk. V ta namen razdelimo matriki Z in V [19]

$$Z = \left(\begin{array}{cccc|ccc} 1 & z_{11} & \dots & z_{1s} & z_{1s+1} & \dots & z_{1p} \\ 1 & z_{21} & \dots & z_{2s} & z_{2s+1} & \dots & z_{2p} \\ \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ 1 & z_{n1} & \dots & z_{ns} & z_{ns+1} & \dots & z_{np} \end{array} \right) = (Z_{(s)}|Z_{(r)}) \quad (4.83)$$

$$V = \left(\begin{array}{cccc|ccc} 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & \Theta_{11} & \dots & \Theta_{1s} & \Theta_{1s+1} & \dots & \Theta_{1p} \\ 0 & \Theta_{21} & \dots & \Theta_{2s} & \Theta_{2s+1} & \dots & \Theta_{2p} \\ \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ 0 & \Theta_{p1} & \dots & \Theta_{ps} & \Theta_{ps+1} & \dots & \Theta_{pp} \end{array} \right) = (V_{(s)}|V_{(r)}) \quad (4.84)$$

Potem velja $Z_{(s)} = X \cdot V_{(s)}$ in $Z_{(r)} = X \cdot V_{(r)}$. Originalne parametre modela β lahko izrazimo kot

$$\beta = V \cdot \gamma = V_{(s)} \cdot \gamma_{(s)} + V_{(r)} \cdot \gamma_{(r)} \quad (4.85)$$

kjer velja $\gamma = (\gamma_0 \ \gamma_1 \ \dots \ \gamma_s | \gamma_{s+1} \ \dots \ \gamma_p)^T = (\gamma_{(s)}^T | \gamma_{(r)}^T)^T$. Ob upoštevanju tega lahko model logistične regresije iz enačbe (4.81) zapišemo kot

$$L = Z \cdot \gamma = Z_{(s)} \cdot \gamma_{(s)} + Z_{(r)} \cdot \gamma_{(r)} \quad (4.86)$$

Iz modela lahko odstranimo zadnjih r latentnih spremenljivk in tako dobimo

$$y_i = \pi_{i(s)} + \epsilon_{i(s)} \quad (4.87)$$

kjer velja

$$\pi_i = \frac{e^{\beta_0 + \sum_{j=1}^s z_{ij} \gamma_j}}{1 + e^{\beta_0 + \sum_{j=1}^s z_{ij} \gamma_j}} \quad (4.88)$$

Model lahko ekvivalentno izrazimo v matričnem zapisu z vektorjem transformacij $L_{(s)} = (l_{1(s)}, \dots, l_{n(s)})$ s komponentami $l_{i(s)} = \ln \left(\frac{\pi_{i(s)}}{1 - \pi_{i(s)}} \right)$

$$L_{(s)} = Z_{(s)} \cdot \gamma_{(s)} = X V_{(s)} \cdot \gamma_{(s)} = X \cdot \beta_{(s)} \quad (4.89)$$

Parametre modela logistične regresije, pri katerem uporabimo le prvih s latentnih spremenljivk, pa zapišemo kot:

$$\beta = V_{(s)} \cdot \gamma_{(s)} \quad (4.90)$$

4.7.4 Mera ujemanja

Pri logistični regresiji se za mero ujemanja uporablja *devianca*, ki jo izračunamo kot logaritem funkcije podobnosti (ang. likelihood) [1] po enačbi

$$\text{devianca}(\beta) = 2 \cdot \sum_{i=1}^n \left(y_i \cdot \log \left(\frac{y_i}{\pi_i} \right) + (1 - y_i) \cdot \log \left(\frac{1 - y_i}{1 - \pi_i} \right) \right) \quad (4.91)$$

Pri izračunu deviance velja dogovor $0 \cdot \log(0) = 0$.

Srednja kvadratna napaka regresijskih koeficientov (MSEB, ang. *mean squared error of the beta parameter vector*) se računa po enačbi

$$\text{MSEB} = \frac{1}{p+1} \sum_{j=0}^p \left(\hat{\beta}_j - \beta_j \right)^2 \quad (4.92)$$

Vektor β predstavlja resnične parametre modela, vektor $\hat{\beta}$ pa njihove ocene. Ker pravi parametri niso poznani, se za oceno standardne napake koeficientov uporabljajo diagonalni elementi kovariančne matrike ocene parametrov [29]

$$\widehat{\text{cov}}(\hat{\beta}) = \left(X^T \widehat{W} X \right)^{-1} \quad (4.93)$$

kjer je $\widehat{W} = \text{diag}(\pi_i(1 - \pi_i))$.

Poglavje 5

Modeliranje procesa brizganja

V proizvodnji komutatorja srečujemo dva tipa procesov in sicer take, ki jih lahko opišemo s klasično linearno regresijo in take, ki jih opišemo z logističnimi modeli. Ker v analizi procesa brizganja modeliramo sistem, katerega vhodi in izhodi so realne spremenljivke, sta v tem primeru uporabljeni metodi linearne regresije.


Na liniji izdelave polizdelkov 1, ki je bila zajeta v raziskavi, je nekaj časa potekalo merjenje temperature in tlaka brizganja. V odvisnosti od nastavljene temperature in tlaka smo v okviru raziskave opazovali obdelovalni¹ in naknadni² skrček oziroma raztezek komutatorja [33]. Ugotavljali smo odvisnost obdelovalnega skrčka od vsakega parametra posebej. Ker je naknadni skrček oziroma raztezek odvisen od dodatnega procesa staranja komutatorja, o katerem pa nimamo podatkov, je ta izhodni parameter izpuščen.

5.1 Podatki

Meritve obsegajo 189 vzorcev. Za vsak vzorec je na voljo podatek o izmerjenem tlaku in temperaturi brizganja ter raztezek. Tlak in temperatura predstavljata neodvisni spremenljivki in bosta zato označeni z x_1 (tlak) in x_2 (temperatura). Izhodno spremenljivko (obdelovalni raztezek) označimo kot y . Čeprav so bili vzorci izmerjeni v dveh različnih gnezdih, so med seboj precej podobni. Primer se zato osredotoča le na eno brizgalno gnezdo. Na sliki 5.1 so na ločenih grafih prikazani vhoda $x_1(t)$ in $x_2(t)$ ter izhod $y(t)$.

¹Obdelovalni skrček oziroma raztezek je definiran kot razlika med premerom izmetalne igle in premerom luknje ohlajenega brizganega komutatorja.

²Naknadni skrček oziroma raztezek je definiran kot razlika premerov lukenj komutatorjev pred in po operaciji staranja.




Slika 5.1: *Vhodni in izhodni podatki.* $x_1(t)$ in $x_2(t)$ predstavljata neodvisna tehnološka parametra tlak in temperaturo, $y(t)$ pa je odvisna spremenljivka - obdelovalni raztezek.

5.2 Regresijski model

Ker ne poznamo fizikalnih odvisnosti med vhodnimi in izhodno spremenljivko, lahko o linearni odvisnosti le domnevamo. Za preizkus nelinearne odvisnosti, poleg izvornih spremenljivk x_1 in x_2 , v model dodamo še kombinacije potenc in produktov izvornih spremenljivk. Preizkusili smo tudi kombinacije eksponentnih in trigonometričnih funkcij osnovnih spremenljivk, ker pa gre v tem primeru za statični model, so razširitve s potencami in njihovimi kombinacijami dale najboljše rezultate. Razširjeni regresijski model zapišemo kot

$$\begin{aligned} y = & \theta_1 x_1 + \theta_2 x_2 + \theta_3 x_1^2 + \theta_4 x_2^2 + \theta_5 x_1^3 + \\ & \theta_6 x_2^3 + \theta_7 x_1^4 + \theta_8 x_2^4 + \theta_9 x_1 x_2 + \theta_{10} x_1 x_2^2 + \\ & \theta_{11} x_1^2 x_2 + \theta_{12} x_1^2 x_2^2 + \theta_{13} x_1^2 x_2^3 + \theta_{14} x_1^3 x_2^2 + \theta_{15} x_1^3 x_2^3 + \\ & \theta_{16} x_1^4 x_2^4 + \theta_{17} x_1^3 x_2^4 + \theta_{18} x_1^4 x_2^3 + \theta_{19} x_1^4 x_2^2 + \theta_{20} x_1^2 x_2^4 \end{aligned} \quad (5.1)$$

S takimi spremenljivkami preverjamo odvisnost izhoda še od 2., 3. in 4. potence vhodov, ter od nekaterih produktov takih kombinacij. Pareto diagram singularnih vrednosti matrike razširjenih vhodov je prikazan na sliki 5.2. Iz diagrama je razvidno, da s petimi spremenljivkami lahko opišemo več kakor 95% variance celotnega modela. Iz tega sledi, da so si umetno ustvarjene spremenljivke medsebojno zelo podobne. Dodajanje takih spremenljivk sicer povečuje ujemanje modela z resničnimi podatki, vendar pa hkrati v model vnaša negotovost.



Slika 5.2: *Singularne vrednosti matrike*. Stolpci predstavljajo posamezne singularne vrednosti matrike vhodnih podatkov z umetno dodanimi spremenljivkami (skala na levi strani). Krivulja prikazuje odstotek informacije, ki ga v model vnašamo z dodajanjem posameznih dimenzij (skala na desni strani).

5.3 Primerjava regresijskih metod

Pregled singularnih vrednosti matrike razširjenih vhodnih podatkov pokaže, da imamo v vhodnih podatkih opraviti z redundanco. V nadaljevanju bomo prikazali dve regresijski metodi, primerni za obdelavo redundančnih podatkov. Za analizo takih podatkov so primerne regresijske metode, ki na različne načine reducirajo vhodne podatke:

koračna regresija (ang. *stepwise regression*) v iterativnem postopku izbira prediktorje tako, da povečuje ujemanje modela z merjenimi podatki [67]. Za ocenjevanje se lahko uporabljajo različne metode: t -test, F -test, ocena R^2 in druge. Postopek koračne regresije je lahko zasnovan tako, da se začne z modelom brez spremenljivk (t.i. pristop *naprej*), v katerega se nato dodajajo statistično signifikantne spremenljivke ena po eno. Druga možnost je t.i. pristop *nazaj*, ki za začetni model izbere takega z vsemi možnimi vhodi in nato enega po enega odstranjuje vhode, ki niso statistično signifikantni. Obstaja še tretja možnost, ki je kombinacija prej naštetih. V tem primeru pa se v vsakem koraku posebej odloča, ali se bodo spremenljivke dodale ali odvzele;


regresija z metodo glavnih komponent (ang. *principal component regression*³) temelji na metodi glavnih komponent (*PCA*), ki se uporabi za preslikavo vhodnih spremenljivk v vmesni, latentni prostor. Latentni prostor je izbran tako, da so njegovi bazni vektorji ortogonalni. Preslikava v latentni prostor ohrani vso informacijo, ker pa tvorba latentnih spremenljivk poteka tako, da vsaka nova spremenljivka (ki je linearna kombinacija izvornih) opisuje več informacije kakor tiste za njo, je to optimalni pristop za reduciranje vhodnih podatkov, saj lahko latentne spremenljivke z majhno varianco odstranimo in s tem izgubimo le majhen del informacije. Slabost metode je v tem, da pri tvorbi latentne baze ne upošteva povezav med vhodnimi in izhodnimi spremenljivkami, ampak se osredotoča le na korelacije med vhodi.

Pri preizkusu regresijskih metod smo želeli preveriti, kako dobro se ocene prilegajo meritvam. Pri regresijskem modelu za proizvodni proces je pomembno predvsem njegovo obnašanje na novih, še neznanih vhodih. Za tak preizkus smo na razpoložljivih podatkih izbrali interval, ki predstavlja učne podatke (slika 5.3). Validacija metod je bila opravljena na območjih izven učnega intervala.

5.3.1 Analiza s koračno regresijo

Metoda koračne regresije, ki je bila uporabljena v tem primeru, deluje tako, da postopek začne z začetnim naborom vsebovanih spremenljivk, nato pa v vsakem koraku poizkuša

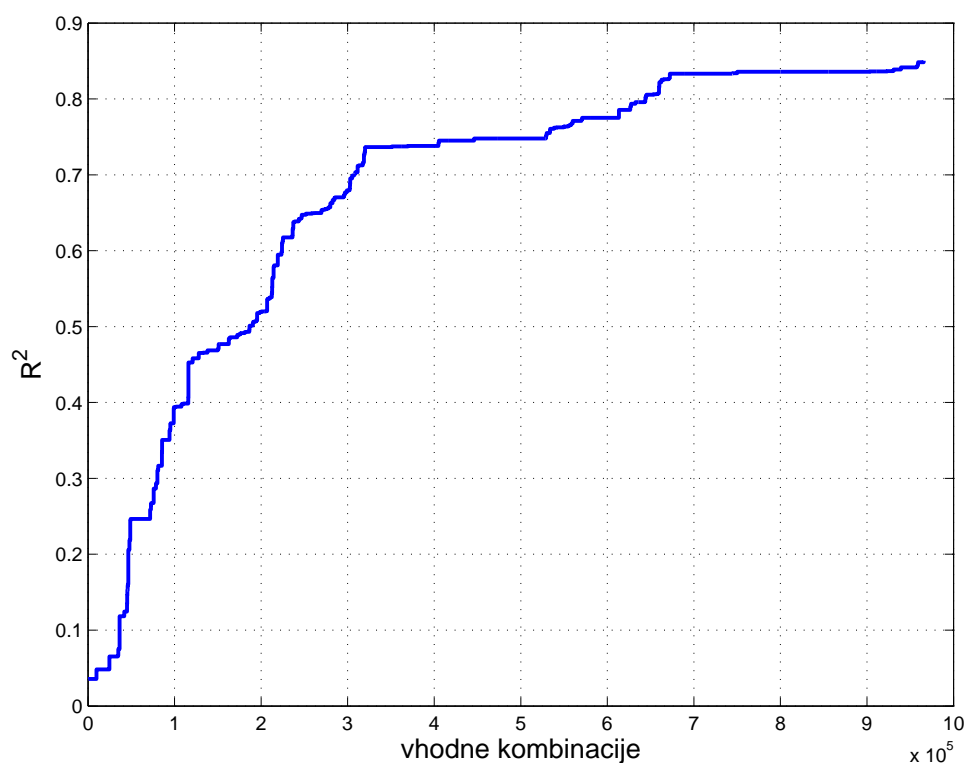
³Metoda je podrobneje predstavljena v poglavju 4.3.



Slika 5.3: Učna množica podatkov. Prikazani so vhodni (x_1 , x_2) in izhodna (y) spremenljivka. Večje rdeče točke predstavljajo interval učne množice, manjše modre točke pa validacijski interval.

najbolje povečati točnost modela z dodajanjem ali odvzemanjem ene spremenljivke. Postopek se zaključi s korakom, ko nobeno dodajanje ali odvzemanje ne poveča ujemanja modela z merjenimi podatki. Zaradi takega postopka je rezultat modela odvisen od začetnega nabora podanih spremenljivk. V primeru regresijskega modela z 20 vhodi imamo tako na voljo 1.048.576 (2^{20}) kombinacij različnih vhodnih naborov. Rešitve, ki jih išče taka metoda, so torej lokalno optimalne in ne nujno tudi globalno.

Ker je število vhodnih spremenljivk preveliko, je kombinacij preveč, da bi jih bilo mogoče v praksi preizkušati v razumnem času. Za analizo metode in njenega obnašanja pa je bil tak preizkus opravljen. Razpon ocene R^2 je prikazan na sliki 5.4 (vrednosti so urejene naraščajoče). Iz histograma ocene R^2 (slika 5.5) lahko sklepamo, da veliko število vhodnih kombinacij vodi k dobri oceni R^2 , nimamo pa zagotovila, da bomo v vseh primerih dobili optimalen nabor prediktorjev. Najboljša ocena $R^2 = 0,8985$ je bila dosežena v sedmih primerih, v katerih so v končni izbor prišli regresorji x_1 , x_2^3 , x_1^4 , x_2^4 ,




Slika 5.4: *Razpon ocene R^2* . Pri različnih kombinacijah začetnega nabora prediktorjev v metodi koračne regresije dobimo različne ocene R^2 . Ocene so urejene od najmanjše do največje.


$x_1^2x_2^2$, $x_1^4x_2^2$ in $x_1^2x_2^4$. Regresijski model v tem primeru zapišemo kot

$$\begin{aligned}
 y = & - 3,5090 \cdot x_1 \\
 & + 1,5132 \cdot x_2^3 \\
 & + 10,5084 \cdot x_1^4 \\
 & - 2,0010 \cdot x_2^4 \\
 & - 2,7508 \cdot x_1^2x_2^2 \\
 & - 11,8281 \cdot x_1^4x_2^2 \\
 & + 6,8660 \cdot x_1^2x_2^4
 \end{aligned} \tag{5.2}$$

Ocene regresijskih koeficientov in njihovi intervali zaupanja so prikazani na sliki 5.6. Metoda koračne regresije bi bila primernejša za uporabo v sistemih z manjšim številom vhodnih spremenljivk oziroma v statičnih sistemih, ko bi bilo mogoče s preizkusom vseh kombinacij določiti optimalen model. V tem primeru bi bilo potrebno bodisi s poznavanjem fizikalnih odvisnosti med vhodi in izhodi ali kako drugače omejiti nabor vhodnih spremenljivk. V nasprotnem primeru nimamo nobenega zagotovila, da metoda koračne regresije najde optimalne regresijske koeficiente.



Slika 5.5: *Histogram ocene R^2* . Pri različnih kombinacijah začetnega nabora prediktorjev v metodi koračne regresije dobimo različne ocene.



Slika 5.6: *Ocene regresijskih koeficientov za metodo koračne regresije. Prikazani so koeficienti in njihovi intervali zaupanja pri stopnji signifikantnosti 0,95.*

5.3.2 Analiza z metodo glavnih komponent

Pri regresiji z metodo glavnih komponent imamo možnost izbire števila latentnih (vmesnih) spremenljivk. Preizkus metode je bil zastavljen tako, da se je za različno število⁴ latentnih spremenljivk izračunala ocena R^2 iz enačbe (4.13). Rezultati izračuna so predstavljeni v tabeli 5.1 in sliki 5.7. Regresijski model v tem primeru postavimo kot

$$Y = XF = (XF^1)F^2 \quad (5.3)$$

Preslikava prve faze preslika izvorne podatke v latentni prostor ($Z = XF^1$). V drugi fazi pa se uporabi že znana metoda najmanjših kvadratov ($F^2 = (Z^T Z)^{-1} Z^T Y$). Model doseže najboljše ujemanje s podatki pri šestih latentnih spremenljivkah.

Ocene regresijskih koeficientov in njihovi intervali zaupanja so prikazani na sliki 5.8.


Tabela 5.1: *Gibanje ocene R^2* . Prikazana je ocena modela v odvisnosti od števila latentnih spremenljivk (N) pri analizi z metodo glavnih komponent.

N	R^2
1	0,7867
2	0,8119
3	0,8128
4	0,8365
5	0,8597
6	0,8871
7	0,8679
8	0,8819
9	0,8371
10	0,5298

Komentar

Dodatno razlago potrebuje gibanje ocene R^2 , ki bi po pričakovanjih morala naraščati z večanjem števila latentnih spremenljivk, saj z vsako novo dimenzijo v latentni bazi povečamo količino upošteevane informacije in model bi se moral zaradi tega bolje prilagoditi izmerjeni vrednosti. Namesto pričakovanega naraščanja ocene R^2 pa le-ta do uporabe

⁴Ocena R^2 se je računala do desetih latentnih spremenljivk, saj je le prvih deset singularnih vrednosti matrike vhodnih podatkov večjih od 0.




Slika 5.7: Gibanje ocene R^2 . Prikazana je ocena modela v odvisnosti od števila latentnih spremenljivk (N) pri analizi z metodo glavnih komponent.

šestih latentnih spremenljivk narašča, nato pa niha in pri uporabi deset latentnih spremenljivk celo drastično pade.


Podrobni pregled dogajanja na učnem intervalu pokaže, da le na tem delu prihaja do večjega ujemanja pri uporabi desetih latentnih spremenljivk ($R^2 = 0.9199$), kakor pri uporabi le šestih ($R^2 = 0.9099$). Če se osredotočimo na gibanje ocene R^2 pri različnem številu latentnih spremenljivk (slika 5.9) samo na učnem intervalu, potem dobimo potrditev domneve, da večanje števila latentnih spremenljivk izboljšuje oceno modela R^2 .

Regresijska metoda *PCR* poišče regresijske koeficiente tako, da na podanem intervalu doseže najboljše ujemanje z izmerjenim izhodom. Večanje števila latentnih spremenljivk pomeni tudi večanje točnosti napovedi, čeprav je lahko doprinos pri dodajanju posameznih dimenzij zanemarljiv in v model vnaša negotovost. Vendar pa regresijska metoda gradi model le na učni množici, brez poznavanja validacijske množice podatkov. Če opazujemo le učno množico, se ocena R^2 z večanjem števila latentnih spremenljivk po pričakovanju veča - model dosega boljše ujemanje z izmerjenim izhodom. Boljše ujemanje modela na učni množici ne pomeni nujno tudi boljšega ujemanja na validacijskem intervalu, saj lahko neznani vhodni podatki vsebujejo tudi vrednosti ali kombinacije, ki v učni množici niso



Slika 5.8: *Ocene regresijskih koeficientov za regresijo z metodo glavnih komponent. Prikazani so koeficienti in njihovi intervali zaupanja pri stopnji signifikantnosti 0,95.*

bile zajete. In tak je tudi opazovani primer. Ocena se namreč izvaja tudi na taki vrednosti spremenljivke x_1 , ki v učni množici ni zajeta.



Slika 5.9: Gibanje ocene R^2 za učni interval. Prikazana je ocena modela v odvisnosti od števila latentnih spremenljivk (N) pri analizi z metodo glavnih komponent. Ocena je narejena samo na učnem intervalu.


5.3.3 Primerjava rezultatov

Primerjava ocene R^2 iz tabele 5.2, ki jo dobimo z uporabo obeh regresijskih metod, pokaže, da je bilo najboljše ujemanje ocene z merjenimi podatki doseženo s koračno regresijo. Temu v prid govori tudi medsebojna primerjava ocene izhoda, ki je prikazana na sliki 5.10. Regresija z metodo glavnih komponent dosega slabše ujemanje z meritvijo v osrednjem delu validacijskega intervala, večji pa je tudi njen interval zaupanja. Vendar pa je za doseg takega rezultata potrebno preizkusiti veliko različnih kombinacij začetnih naborov vhodnih spremenljivk, saj metoda koračne regresije išče lokalno najboljši rezultat. V primeru regresije z metodo glavnih komponent je potrebna le transformacija matrike vhodnih podatkov v latentno bazo.

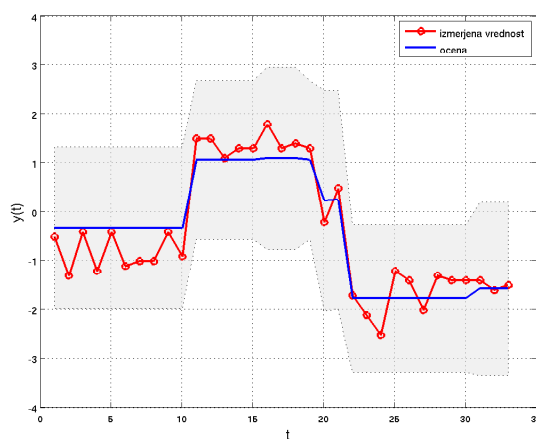
Tabela 5.2: *Primerjava rezultatov.* Primerjava ocene R^2 po obeh uporabljenih regresijskih metodah.

metoda	R^2
koračna regresija	0,8985
regresija z metodo glavnih komponent	0,8871

a)



b)



Slika 5.10: *Medsebojna primerjava ocene izhoda obeh metod.* Prikazana je primerjava ocene izhoda, dobljene z metodo koračne regresije (a) in z regresijo z metodo glavnih komponent (b).

Poglavje 6

Nadzor kakovosti izdelkov

V poglavju 5 smo obravnavali tip procesa, ki ima za vhode in izhode realne spremenljivke. V primeru nadzora kakovosti pa imamo opravka z binarnim izhodom - izdelek je lahko dober ali slab. Za modeliranje takega procesa smo uporabili logistično regresijo.

Sprotni nadzor kakovosti se izvaja na liniji izdelave polizdelkov 1, kjer imamo sprotne podatke o uporabljeni surovini ter o kakovosti izdelkov. Pri izdelavi se izdelki glede na doseganje kakovosti razvrstijo v dve skupini: **dobre** in **slabe** izdelke. Za vsako izdelano serijo se pridobi podatek o številu izdelkov v obeh kategorijah. Na podlagi obeh količin se izračuna parameter *kakovosti* (enačba (6.3)), ki se shrani za vsako serijo in se uporablja tudi za izračun *skupne učinkovitosti*. Podatek o kakovosti oziroma količini dobrih in slabih izdelkov vsake serije pa lahko interpretiramo tudi kot verjetnost, da je nek izdelek v seriji dober, pri čemer imamo toliko ponovitev, kolikor je vseh izdelkov v opazovani seriji.

6.1 Podatki

V proizvodni proces spremljanega izdelka *komutator A* vstopata dve surovini: *surovina 1* in *surovina 2*. Pri drugi surovini se meri in shranjuje vrednosti 22 parametrov¹. Vsi parametri vhodnih materialov se vodijo in shranjujejo v okviru informacijskega sistema SAP R/3. Izvoz podatkov je mogoč preko vmesnih datotek v obliki preglednic pisarniške zbirke *OpenOffice.org* [51]. Za vsako šaržo vhodne surovine se definira t.i. *številka inšpekcijske šarže*. Pod to številko so zabeleženi podatki o vseh parametrih surovine. Ta podatek pa je tudi vsebovan na spremnih etiketah materialov v proizvodnji. Za vsak parameter se izvede več meritev, o katerih se zabeleži:

1. številko inšpekcijske šarže

¹Parametri se lahko bodisi izmerijo v lastnem laboratoriju, lahko pa se uporabijo vrednosti, ki jih poda proizvajalec. V nekaterih primerih pa se zabeleži tako izmerjena vrednost, kakor tudi proizvajalčev podatek. Zaradi tega se nekateri parametri pojavijo dvakrat.

2. spodnjo mejno vrednost
3. zgornjo mejno vrednost
4. srednjo vrednost meritev
5. standardni odklon meritev
6. varianco meritev.

Za nadaljnje obdelave podatkov je bilo potrebno parametre iz datotek v obliki preglednic uvoziti v sistem za upravljanje baz podatkov in jih tam preoblikovati in povezati s podatki o kakovosti izdelkov. Za to smo uporabili postopek, ki je predstavljen v algoritmu 6.1.

Algoritem 6.1 Uvoz parametrov v sistem za upravljanje baz podatkov

- 1: priprava podatkovne tabele za vsak parameter;
 - 2: priprava seznama vseh uporabljenih inšpekcijskih šarž;
 - 3: združitev vseh tabel parametrov v skupni pogled;
-

Običajno je, da se pri novih vhodnih materialih beležijo parametri vsake inšpekcijske šarže, kasneje pa se v primeru stabilnih vrednosti začne uvajati t.i. merjenje na preskok. Parametri, ki so ključni za zagotavljanje ustrezne kakovosti, se beležijo za vsako šaržo, pri ostalih pa se uvaja preskok šarže, ki se postopoma veča do 32. Pri vhodnih materialih, ki se uporabljajo dalj časa, se večina parametrov izmeri in zabeleži le pri vsaki 32. pošiljki.

Izmed vseh 22 parametrov je po izločitvi podvojenih in nepopolnih podatkov ostalo 13 parametrov, ki so uporabni za izvajanje analize.

6.1.1 Združevanje vhodnih in izhodnih parametrov

Zgoraj prikazani podatki predstavljajo vhodne parametre proizvodnega procesa. Podatke o uspešnosti proizvodnega procesa (izhodne parametre) pa zagotavlja v ta namen razvit proizvodni informacijski sistem. Le-ta skrbi za zbiranje podatkov, ki zajemajo:

- čase izdelav,
- čase in vzroke zaustavitev opreme,
- količine proizvedenih izdelkov, ki ustrezajo zahtevam kakovosti,
- količine izdelkov, ki ne ustrezajo zahtevam kakovosti ter razloge zavrnitve,
- časovne normative za proizvodnjo izdelkov²,

²Časovni normativi se ne zbirajo v okviru proizvodnega informacijskega sistema, ampak se kot sestavni del planov prenašajo iz poslovnega informacijskega sistema SAP R/3. Časovni normativi predpisujejo, koliko časa je potrebnega za izdelavo določene količine izdelkov.

- oznake inšpekcijskih šarž vhodnih materialov.

Za potrebe spremljanja odvisnosti uspešnosti proizvodnega procesa so bile vpeljane t.i. *serije* izdelkov. Serija predstavlja množico izdelkov, ki so bili izdelani v enakih okoliščinah, katere zajemajo:

- uporabljeni sta bili isti inšpekcijski šarži obeh vhodnih materialov;
- za vse tri operacije v postopku izdelave velja:
 - izdelki so bili izdelani v isti izmeni;
 - izdelki so bili izdelani na istem stroju;
 - stroj je upravljal isti delavec;
 - stroj je deloval z istimi parametri nastavitvev.

V tem primeru se ena serija izdeluje največ eno izmeno. Kadar že med izmeno pride do menjave vhodne surovine ali polizdelka, se prične z izdelovanjem nove serije izdelkov. Ker se v sistem zabeležijo menjave vhodnih materialov (preko številke inšpekcijske šarže), so za vsako serijo poznani parametri vhodnih surovin. Iz časov delovanja in zastojev, dobrih in slabih izdelkov ter iz časovnih normativov se nato preračunajo osnovni kazalci uspešnosti proizvodnje [78]: *razpoložljivost*, *zmogljivost* in *kakovost*, katerih produkt je t.i. *skupna učinkovitost*, ki je eden izmed pogosteje uporabljenih kazalcev v kosovni industriji. Osnovni kazalci se izračunajo po enačbah (6.1), (6.2) in (6.3):

$$\text{razpoložljivost} = \frac{\text{efektivni čas dela}}{\text{efektivni čas dela} + \text{čas zaustavitvev}} \quad (6.1)$$


$$\text{zmogljivost} = \frac{\text{število dobrih izdelkov} + \text{število slabih izdelkov}}{\text{efektivni čas dela} \times \text{časovni normativ}} \quad (6.2)$$

$$\text{kakovost} = \frac{\text{število dobrih izdelkov}}{\text{število dobrih izdelkov} + \text{število slabih izdelkov}} \quad (6.3)$$

6.2 Logistični regresijski model

V nadaljevanju se bomo osredotočili na sproti nadzor kakovosti izdelkov. Parameter kakovosti, ki se spremlja na nivoju serij, predstavlja delež dobrih izdelkov opazovane serije. Tako lahko za posamezno serijo določimo izid Y , ki pomeni verjetnost, da so vsi izdelki serije dobri ($Y = 1$). Predvidevamo pa, da je ta verjetnost odvisna od trinajstih parametrov uporabljene surovine. Regresijski model postavimo kot

$$p_i \equiv p_i(\beta) \equiv \mathbb{P}(Y_i = 1 | X = x) = \frac{e^{\beta_0 + \sum_{j=1}^{13} x_{ij}\beta_j}}{1 + e^{\beta_0 + \sum_{j=1}^{13} x_{ij}\beta_j}} \quad (6.4)$$




Slika 6.1: Vhodni in izhodni podatki proizvodnega procesa. Prikazani so vhodni parametri surovin x_1, \dots, x_{13} in izhodni parameter - kakovost izdelkov y .

Naloga takega modela je poiskati fiksni regresijski koeficient β_0 in ostalih trinajst koeficientov $\beta_1, \dots, \beta_{13}$, tako da parametri surovin, ki so zajeti v okviru učne množice, čim bolj napovedujejo verjetnost dobrih izdelkov v seriji.

Za potrebe analize je bila vzorčena učna množica meritev, ki je zajemala vse podatke vhodnega materiala in podatek o kakovosti. Učna množica obsega 100 šarž vhodnega materiala. Na sliki 6.1 so prikazani grafi vseh uporabljenih vhodnih parametrov in izhodnega parametra kakovosti. Za potrebe analize so vsi vhodni parametri normirani na srednjo vrednost 0 in varianco 1. Matrika vhodnih parametrov je označena z X , posamezni parametri - stolpci matrike X so označeni z x_1, x_2, \dots, x_{13} , vektor izhodnega parametra kakovosti pa z y .

Izračun singularnih vrednosti kovariančne matrike vhodnih podatkov $X^T X$ (slika 6.2 in tabela 6.1) pokaže, da ohranimo več kakor 95% informacije z reduciranjem parametrov na 10. Zadnji dve singularni vrednosti sta v primerjavi z ostalimi zelo majhni, najmanjša je v okviru štirimestne natančnosti celo enaka nič, kar nakazuje močno korelacijo v vhodnih



Slika 6.2: *Singularne vrednosti matrike*. Stolpci predstavljajo posamezne singularne vrednosti matrike parametrov vhodnih surovin (skala na levi strani). Krivulja prikazuje odstotek informacije, ki ga v model vnašamo z dodajanjem posameznih parametrov (skala na desni strani).

Tabela 6.1: *Singularne vrednosti matrike vhodnih podatkov*. Tabela prikazuje vseh 13 singularnih vrednosti matrike, urejene padajoče.

i	λ_i
1	22,7356
2	19,8240
3	18,0061
4	16,5587
5	15,9967
6	13,7679
7	10,9335
8	10,4572
9	8,9814
10	8,1700
11	4,7950
12	1,4241
13	0,0000

podatkih.

6.2.1 Izračun na izvirnih podatkih

Za izračun koeficientov modela logistične regresije se uporablja *Matlabova* metoda `mnrfit` [44]. Metoda se uporablja s klicem `B = mnrfit(X,Y)`, kjer je X matrika z n vrsticami (meritvami) in p stolpci (prediktorji), Y pa je matrika z n vrsticami, katere stolpci predstavljajo število izidov posameznih kategorij. Metoda podatkom iz matrike X samodejno doda konstantni regresor, zato le-tega ni potrebno eksplicitno dodajati v podatke.

V primeru analize proizvodnih podatkov vrstice predstavljajo podatke posamezne serije izdelkov. V matriki X so po stolpcih razvrščeni vhodni parametri. Matrika Y ima v tem primeru dva stolpca, prvi stolpec vsebuje število dobrih izdelkov, drugi stolpec pa število slabih.

Po pričakovanju zaradi prej ugotovljene korelacije v vhodnih podatkih (zadnja lastna vrednost je v okviru štirimestne natančnosti enaka nič) metoda ne da pravih rezultatov. Prvih osem koeficientov $(\beta_0, \beta_1, \dots, \beta_7)$ dobi vrednost *NaN* (oznaka za vrednosti, ki imajo nedefinirane numerične vrednosti), metoda pa tudi izpiše sporočilo, da je vhodna matrika v okviru delovne natančnosti singularna.

6.2.2 Uporaba metode glavnih komponent

V poglavjih 4.7.2 in 4.7.3 je predstavljeno ozadje uporabe metode glavnih komponent v logistični regresiji. Postopek v *Matlabu* je bilo potrebno razširiti tako, da najprej opravi pretvorbo vhodnih podatkov v latentni prostor. V tem primeru torej rešujemo spodnji regresijski problem

$$p_i \equiv p_i(\gamma) \equiv \mathbb{P}(Y_i = 1 | Z = z) = \frac{e^{\beta_0 + \sum_{j=1}^k z_{ij} \gamma_j}}{1 + e^{\beta_0 + \sum_{j=1}^k z_{ij} \gamma_j}} \quad (6.5)$$

kjer iščemo regresijske koeficiente γ za matriko Z , ki predstavlja izvirne podatke X , preslikane v latentni prostor. Število latentnih spremenljivk k se lahko v primeru redundance v vhodnih podatkih tudi zmanjša. Regresijski koeficienti za izvirne podatke X pa se izračunajo po enačbi (4.82). Za uporabo metode glavnih komponent v logistični regresiji poskrbi postopek iz algoritma 6.2.

6.3 Rezultati

Zgoraj opisani postopek je bil preizkušen z različnim številom latentnih spremenljivk. Za vsako ponovitev je bila izračunana devianca iz enačbe (4.91). Rezultati izračuna deviance

Algoritem 6.2 Logistična regresija z metodo glavnih komponent


- 1: izračun kovariančne matrike $S = \frac{1}{n-1} \cdot X^T X$;
 - 2: izračun lastnih vrednosti (D) in lastnih vektorjev (V) kovariančne matrike S ;
 - 3: sortiranje lastnih vektorjev glede na pripadajoče lastne vrednosti;
 - 4: preslikava podatkov v latentni prostor $Z = X \cdot V$;
 - 5: razširitev matrike lastnih vektorjev z vrha in z leve strani z vrednostmi 0, ter vrednostjo 1 za zgornji levi element;
 - 6: krčenje podatkov v latentnem prostoru Z in matrike lastnih vektorjev V na zahtevano število latentnih spremenljivk;
 - 7: izračun regresijskih koeficientov G v latentnem prostoru z metodo *mnr fit*;
 - 8: preslikava koeficientov iz latentnega v izvirni prostor $B = V \cdot G$;
-

pri uporabi različnega števila latentnih spremenljivk so prikazani v tabeli 6.2 in na sliki 6.3. Najmanjša devianca (0.6441) je bila dosežena pri uporabi 12 latentnih spremenljivk.

Tabela 6.2: *Devianca modela logistične regresije*. Gibanje deviance modela v odvisnosti od števila latentnih spremenljivk (N) pri uporabi logistične regresije z metodo glavnih komponent.

N	devianca
1	2.0121
2	2.0050
3	1.8678
4	1.4334
5	1.0608
6	1.0564
7	1.0555
8	0.6979
9	0.6828
10	0.6828
11	0.6576
12	0.6441
13	0.6453

Devianca se od uporabe osmih latentnih spremenljivk dalje le malo spreminja. Zaradi velike koreliranosti ene izmed spremenljivk z ostalimi zelo narastejo intervali zaupanja nekaterih regresijskih koeficientov pri uporabi 13 latentnih spremenljivk. Na sliki 6.4 je prikazana primerjava regresijskih koeficientov in njihovih intervalov zaupanja pri uporabi



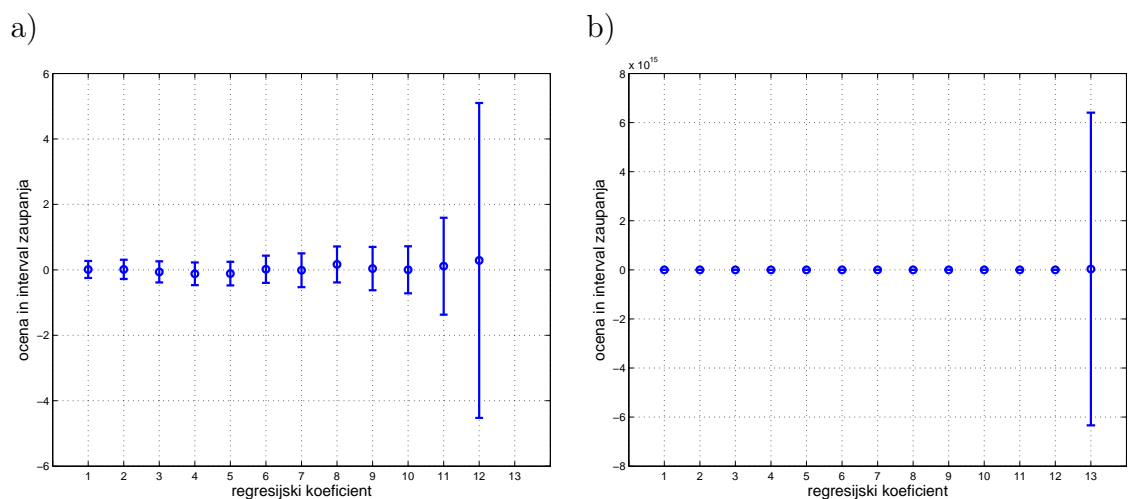
Slika 6.3: *Devianca modela logistične regresije.* Prikazano je gibanje deviance modela v odvisnosti od števila latentnih spremenljivk (N) pri uporabi logistične regresije z metodo glavnih komponent.

12 in 13 latentnih spremenljivk. Za izračun intervalov zaupanja se uporablja enačba [29]


$$[\hat{\beta} - z_{\alpha/2} \cdot \widehat{s.e.}(\hat{\beta}), \hat{\beta} + z_{\alpha/2} \cdot \widehat{s.e.}(\hat{\beta})] \quad (6.6)$$

kjer so $\widehat{s.e.}(\hat{\beta})$ standardne napake koeficientov, katerih ocene so enake diagonalnim elementom matrike iz enačbe (4.93).

Primerjava ocene za kakovost izdelkov z merjeno vrednostjo je za model z 12 latentnimi spremenljivkami prikazana na sliki 6.5.



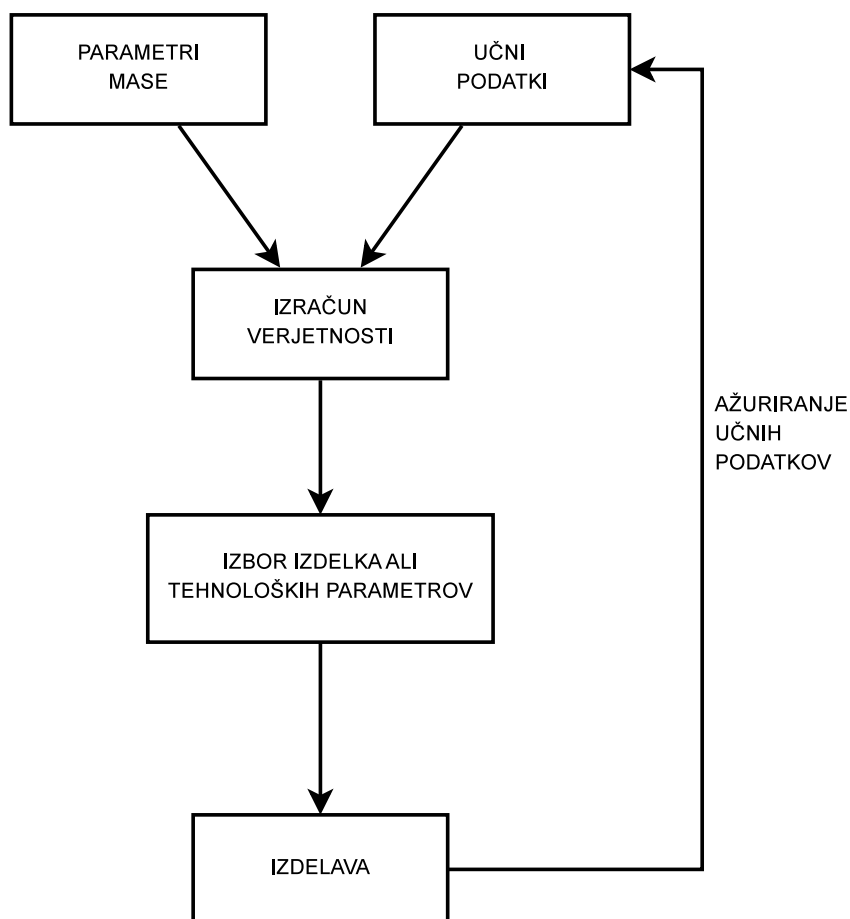
Slika 6.4: *Primerjava regresijskih koeficientov.* Primerjava koeficientov in njihovih intervalov zaupanja za regresijski model z 12 (a) in 13 (b) latentnimi spremenljivkami. Grafa imata zaradi velikega intervala zaupanja pri uporabi 13 latentnih spremenljivk različni skali. Za intervale zaupanja je uporabljena stopnja signifikantnosti 0,95.



Slika 6.5: *Primerjava izhoda z oceno za metodo logistične regresije.* Prikazan je izmerjen izhod $y(t)$, njegova ocena $\hat{y}(t)$ in njen interval zaupanja (senčeno območje) pri stopnji signifikantnosti 0,95. Uporabljen je bil model z 12 latentnimi spremenljivkami.

6.4 Sprotni nadzor kakovosti

Iz predstavljenega primera je razvidno, da je mogoče z veliko gotovostjo (95%) predvideti ozko območje verjetnosti za pojav slabih izdelkov na podlagi parametrov vhodnih materialov. V primeru spremljanja kakovosti različnih tipov izdelkov bi bilo mogoče na podlagi lastnosti materiala določiti njegovo uporabo v izdelku, kjer je verjetnost za pojav slabih kosov najmanjša. Za podporo takemu odločanju predlagamo sistem, katerega shema je prikazana na sliki 6.6. Sistem odločanja deluje tako, da na podlagi parametrov trenutno uporabljenega materiala in učnih podatkov določi verjetnosti za pojav slabe kakovosti po različnih tipih izdelkov. Na podlagi teh verjetnosti se nato izbere tip izdelka, kjer je verjetnost za pojav slabih izdelkov najmanjša. Če so v učno množico vključeni tudi parametri izdelave, lahko tak sistem predlaga tudi izbiro optimalnih parametrov.




Slika 6.6: *Blokovna shema sprotnega nadzora kakovosti izdelkov.* Na podlagi parametrov surovine in učnih podatkov se izračuna verjetnost pojava slabih izdelkov, na osnovi katere odločitveni sistem nato predlaga ustrezne tehnološke parametre ali tip izdelka. Podatki o izdelavi se nato uporabijo za ažuriranje učne množice.

Material se nato porablja v proizvodnem procesu, kjer se spremljajo dejanski parametri kakovosti. Ti parametri nudijo povratno informacijo in se nato uporabijo za ažuriranje učne množice.

Vendar pa je na podlagi spoznanj iz poglavja 5.3.2 potrebna previdnost pri posameznih vhodnih parametrih, ki se nahajajo izven območja, zajetega v učni množici. V tem primeru je operaterju lahko v pomoč prikaz nove vrednosti glede na porazdelitev starih. Predlagamo prikaz nove vrednosti parametra glede na histogram vrednosti, ki so zajete v učni množici. Primer takega prikaza je na sliki 6.7. Operater iz takega prikaza hitro zazna, če se parametri surovine nahajajo izven območja, ki je bilo zajeto v učni množici.

Alternativa predlagani rešitvi bi bila uporaba staističnih metod odločanja [32] oziroma uporaba drugih verjetnostnih pristopov, na primer modela prenosa zaupanja (TBM³) [55], [56]. Posebej zanimiv je problem odločanja na modelih logistične regresije, ki bo ostal izziv za nadaljnje raziskave.

³ang. transferable belief model.



Slika 6.7: Pomoč operaterju pri prikazu verjetnosti slabih izdelkov. Pri izračunu verjetnosti pojava slabih izdelkov se uporabijo parametri vhodne surovine. Nove, neznane vrednosti se lahko nahajajo izven območja tistih vrednosti, ki so zajete v učni množici. Operaterjem je lahko v pomoč grafični prikaz novih vrednosti (navpične rdeče črte) glede na porazdelitve vrednosti, ki so zajete v učni množici.

6.5 Komentariji

Pri sistemu za sprotno napovedovanje kakovosti izdelkov, ki ga predlagamo v poglavju 6.4, je potrebno upoštevati še dejavnike, ki lahko zmanjšujejo točnost napovedi. Najpomembnejši dejavniki zajemajo:

1. meritve parametrov na preskok
2. napake v podatkih
3. mešanje izdelkov na kasnejših operacijah
4. kasnejšo zaznavo napak in slabih izdelkov
5. spremembe v proizvodnem procesu.

Meritve določenih parametrov se ne izvajajo za vsako serijo, ampak na preskok, ki lahko pomeni beleženje podatkov le za vsako 8., 16. ali 32. serijo. V tem primeru v proizvodni proces prihajajo materiali, katerih parametri niso v celoti poznani. Če je takih parametrov večina, ocena verjetnosti za dobre izdelke ni mogoča. V meritvah podatkov pogosto prihaja tudi do napak. Napake so prisotne tako pri meritvah vhodov, kakor tudi pri meritvah kakovosti. Posebnost predstavljajo tudi izdelki, ki zaradi prevelikega premera luknje ne ustrezajo kakovostnim merilom, a se jih vseeno ne tretira kot neustrezne, saj je s kupci mogoče doseči dogovor o uporabi takih izdelkov. Dodatno težavo predstavljajo tudi pogoste spremembe v proizvodnem procesu, ki se stalno prilagaja različnim dejavnikom na trgu [64]. Pogoste so selitve izdelkov med posameznimi stroji ali linijami, neredko pa se med oddelki, obrati ali podjetji znotraj koncerna premikajo celotne konfiguracije linij. Modeli, ki so osnovani na učnih podatkih, v takih primerih ne opisujejo več proizvodnega procesa. Potrebna je vnovična priprava učnih podatkov in izgradnja novega modela.

Poglavje 7

Netehniški vidiki

Izvedba pričujoče disertacije temelji na zbiranju podatkov iz proizvodnega procesa. Bistveno pri tem je dejstvo, da je bilo treba zatečen sistem zbiranja podatkov dopolniti oziroma nadgraditi. To pa pomeni umešavanje v utečene informacijske in poslovne tokove, kar terja vključevanje ljudi na različnih nivojih hierarhije v podjetju [74]. Namen poglavja je nakazati pomen obvladovanja netehniških vidikov pri načrtovanju, implementaciji in vrednotenju informacijskega sistema za podporo odločanju¹. Netehniški vidiki predstavljajo pomembno dimenzijo v zahtevnejših projektih avtomatizacije in informatizacije. Strmčnik in Černetič v [68] navajata, da je človek ena izmed bistvenih aktivnih sestavin tovrstnih procesov. Ljudje so imeli ključno vlogo tudi v vseh aktivnostih, ki so bile potrebne za zagotovitev vseh podatkov raziskave. Te aktivnosti so zajemale tako predstavnike najvišjega vodstva koncerna, kakor tudi posamezne operaterje linij in strojev. Imena oseb so namenoma izpuščena.

Akterji v projektu, njihove vloge in interesi

V celoten projekt smo bili vključeni akterji s treh strani, vsaka s svojimi željami, pričakovanji in motivacijo. Nosilec projekta izdelave prototipa sistema za podporo odločanju je bilo podjetje *Synatec d.o.o.*². Glavni interes Synateca je bila vpeljava pilotskega projekta za spremljanje proizvodnje v katerega izmed Kolektorjevih obratov. Tak pilotski projekt bi kasneje služil kot odskočna deska za širjenje sistema na celotno proizvodnjo komutatorjev. Drugi akter je bilo proizvodno podjetje *Kolektor Pro d.o.o.*³.

¹Ker sem vse aktivnosti, opisane v tem poglavju, izvajal samostojno, je poglavje napisano v prvi osebi ednine.

²Podjetje Synatec d.o.o. se je kasneje preimenovalo v Kolektor Synatec d.o.o. ter se s 1.1.2007 združilo s še nekaterimi podjetji v novo podjetje, Kolektor Sinabit d.o.o.

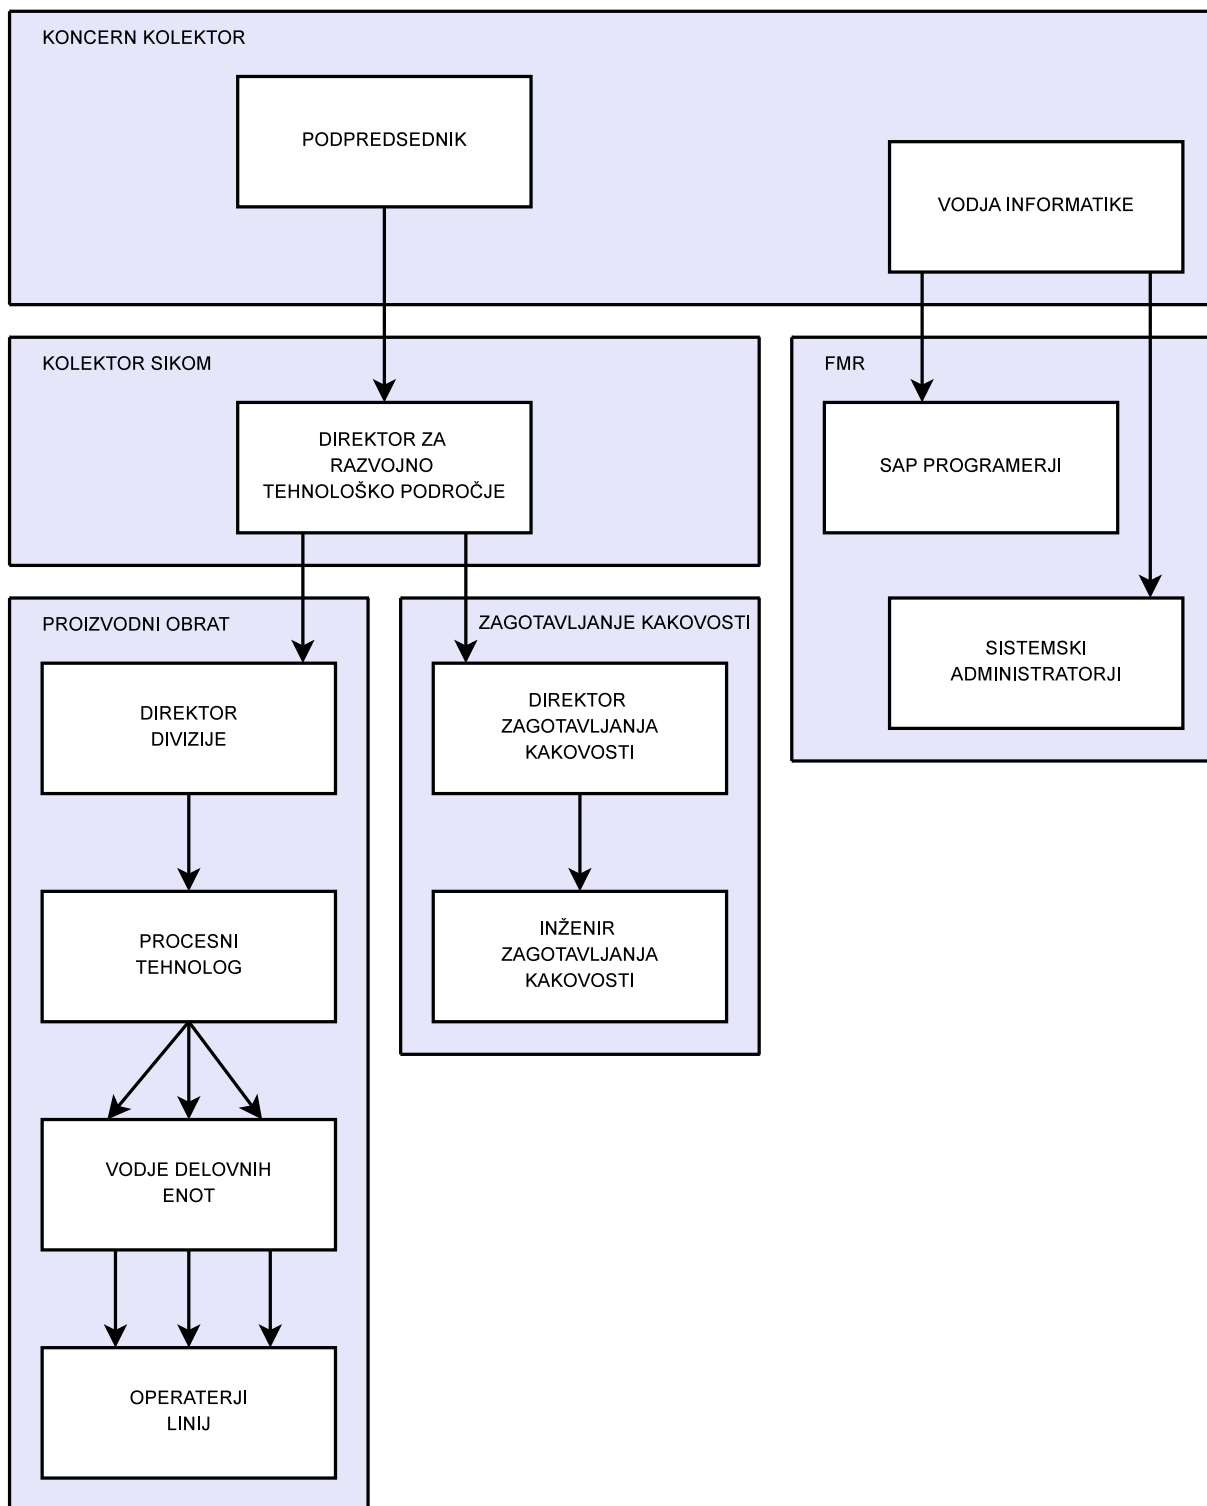
³Podjetje Kolektor Pro d.o.o. se je v času trajanja projekta reorganiziralo in preimenovalo v Kolektor Sikom d.o.o.

Glavna motivacija podjetja je bila vpeljava informacijskega sistema za spremljanje proizvodnje ter uvedba informacijske podpore sledljivosti. Tudi v tem primeru je bila raziskava odvisnosti proizvodnih parametrov sekundarnega pomena. Na enem izmed sestankov je bilo s strani vodstva tega podjetja izraženo, da zanje pomeni vpeljava informacijske podpore proizvodnji in sledenju izdelkov dovolj velik doprinos, da bodo šteli projekt za uspešnega. Kot tretji akter sem se v celotni zadevi pojavil sam. Projekt mi je bil zanimiv iz stališča razvoja informacijskih sistemov za spremljanje proizvodnje, saj bi obstoječe sisteme, ki so bili osredotočeni pretežno na zbiranje podatkov, nadgradil še z analitičnimi moduli, ki bi bili namenjeni podpori odločanju v proizvodnji. Taki moduli predstavljajo pomembno dodano vrednost pri obdelavi podatkov. Poleg omenjene motivacije sem imel tudi dva konkretno izražena cilja: vpeljavo informacijskega sistema za spremljanje proizvodnje in dokončanje doktorskega študija.

Začetna iniciativa in izbira teme

Ideja, ki sem jo zagovarjal, je bila, da bi bilo mogoče povezati parametre surovin in tehnološke parametre izdelave na eni strani s kakovostjo izdelkov na drugi strani. V teh povezavah naj bi bilo po mojih predvidevanjih mogoče najti določene zakonitosti, na podlagi katerih bi lahko osnovali model, ki bi pomagal pri sprejemanju odločitev in pripomogel k dvigu učinkovitosti proizvodnega procesa.

Idejo je bilo potrebno predstaviti vodstvu proizvodnega podjetja. V tej fazi se vodstvo koncerna ni več vključevalo v dogovore, temveč sem se dogovarjal z vodstvom proizvodnega podjetja ter z direktorji posameznih divizij znotraj tega podjetja. Proizvodno podjetje je bilo v tistem času razdeljeno na tri divizije, kjer so izdelovali komutatorje, ter na orodjarno. **Vsi direktorji divizij za raziskavo niso bili zainteresirani, delavniški tip proizvodnje v orodjarni pa se je izkazal za neprimerne za izvajanje analiz.** Omenjena ideja o iskanju zakonitosti med vhodnimi in izhodnimi parametri proizvodnega procesa sprva ni bila sprejeta. Namesto te sem dobival predloge, ki bi sicer reševali večje ali manjše probleme znotraj proizvodnje, vendar bi bilo za njihovo realizacijo potrebnega le nekaj inženirskega dela. Vmes je bilo danih tudi nekaj predlogov, ki bi ustrezali obema kriterijema (koristi v proizvodnji in doprinos k znanosti), vendar se je po začetnem navdušenju sogovornikov na naslednjih sestankih pokazalo, da takihboljšav ne potrebujejo. Na koncu je vendarle prevladal konsenz, da se opravi prvotno predlagana raziskava. Izbrati je bilo potrebno še pilotski izdelek, ki bi bil vključen v raziskavo. Izbrali smo tak izdelek, ki se izdeluje v velikih serijah, njegova proizvodnja je konstantna in se ne seli med različnimi linijami. Čeprav je postopek iskanja tega konsenza opisan v enem samem odstavku, je zaradi polne obremenitve in temu primerne razpoložljivosti sogovornikov, kakor tudi moje obremenitve na zaključujočih se projektih, trajal leto in



Slika 7.1: Hierarhija udeležencev projekta znotraj Koncerna Kolektor. Med projektom sem imel v Koncernu Kolektor in njegovih podjetjih opravka z ljudmi na različnih nivojih.

pol. K temu je dodatno pripomogla še reorganizacija koncerna in menjava vodstva v posameznih divizijah.

Pregled zatečenega stanja

Imeli smo primerno temo raziskave in strinjanje vodstva proizvodnega podjetja za njeno izvedbo. Naslednji korak je zato pomenil ugotavljanje, kateri podatki v podjetju so primerni za vključitev v raziskavo. Glavna kriterija za izbiro sta bila dostopnost in točnost informacij. Poleg tega pa so informacije morale omogočati medsebojne povezave. Kot prvi so se na seznamu znašli podatki o rezultatih proizvodnega procesa, ki so že bili del našega sistema za spremljanje proizvodnje. Ti podatki zajemajo čase izdelav, prekinitve v delovanju opreme ter število ustrezno in neustrezno proizvedenih izdelkov, ki omogočajo izračun razpoložljivosti, zmogljivosti in kakovosti, katerih produkt, skupna učinkovitost, je pomemben pokazatelj uspešnosti proizvodnega procesa v kosovnih industrijah. Omenjeni podatki so zadovoljevali oba prej omenjena kriterija.

Pomemben del vhodnih podatkov predstavljajo parametri surovin. Nekateri izmed teh parametrov se izmerijo v laboratoriju podjetja, nekateri pa se prepíšejo iz specifikacij proizvajalca surovine. Vsem je skupno to, da so zabeleženi v poslovnem informacijskem sistemu, zato naj bi bili tudi relativno enostavno dostopni. Posebnost teh parametrov je le, da se nekateri merijo na preskok, torej se ne zabeležijo za vsako šaržo surovin, ampak le na vsako dvaintrideseto. Pregled stanja postopkov zajema parametrov je pokazal, da se večina izmed parametrov, pomembnih za pilotski izdelek, zajema za vsako serijo. Pri proizvodovanju o parametrih surovin ni bilo večjih težav, vse je bilo opravljeno v nekaj dogovorih na oddelku za zagotavljanje kakovosti.

Skupino vhodnih podatkov poleg parametrov surovin tvorijo tudi tehnološki parametri izdelave. Tukaj so mišljeni predvsem parametri tehnološko najzapletenejše operacije - brizganja plastične mase. Za kakovost končnega izdelka je pomemben časovni potek tlaka in temperature v brizgalnih gnezdih. Za pridobivanje parametrov bi bil potreben poseg v krmilje stroja. Poseg pa bi bil potreben tudi zaradi pridobivanja podatkov o številu proizvedenih izdelkov in o zastojih med delom. Dogovor je bil, da spremembo programa opravi vzdrževalna služba proizvodnega podjetja, ki tudi sicer skrbi za tovrstne posege v primeru sprememb v režimih delovanja strojev. Postopek za spremembo programa je stekel, vendar sem po nekaj tednih dobil obvestilo, da je dogovorjena sprememba prezahtevno opravilo, saj naj bi bil pomnilnik krmilnika že v celoti zaseden. Za pomoč sem se zato obrnil na bivšega sodelavca, ki je imel izkušnje s tovrstnimi krmilniki. Potrebno je bilo urediti vse formalnosti, saj je bilo tak poseg zunanjemu izvajalcu potrebo potrditi, poleg tega se je bilo potrebno dogovoriti za plačilo, saj je poseg pomenil dodatne stroške. Vsi ti postopki in razpoložljivost bivšega sodelavca so pomenili nekajmesečni zamik v

poteku projekta. Kljub vsem naporom je bilo mogoče program v krmilniku prirediti le toliko, da smo pridobili podatke o izdelanem številu izdelkov in o trajanjih zaustavitvev.

Naslednja skupina podatkov, ki bi lahko nosili informacijo o kakovosti izdelkov, so podatki o reklamacijah. Po nekaj poizvedovanjih se je izkazalo, da kakovost ne igra vedno glavne vloge pri reklamacijah, ampak kupci v nekaterih primerih izdelke reklamirajo iz povsem drugačnih razlogov. Poleg tega se podatki o reklamacijah arhivirajo v opisni obliki, ki ni primerna za izvajanje analiz.

Uvajanje sledljivosti

Po pregledu stanja in razpoložljivosti podatkov v proizvodnji se je pojavilo vprašanje, kako te podatke medsebojno povezati. Za izdelke, pri katerih poznamo parametre kakovosti, je potrebno poznati tudi parametre surovin. Za doseganje tega je bilo v proizvodnem podjetju potrebno vpeljati postopke sledljivosti. Določeni postopki so sicer obstajali, vendar so temeljili na ročnem vpisovanju oznake šarže na spremne dokumente in bili zato neuporabni za avtomatizirano zbiranje podatkov.

Avtomatska identifikacija

Aktivnosti sledljivosti ne zajemajo samo proizvodne funkcije podjetja, ampak tudi skladišče, logistiko in zagotavljanje kakovosti. Za računalniško podprto sledenje je bilo na nivoju celotnega podjetja potrebnih izvesti vrsto reorganizacijskih ukrepov. Ti ukrepi so se začeli že pri izdaji surovin v skladišču, saj obstoječa spremna dokumentacija surovin (etikete) ni omogočala avtomatske identifikacije. Sledili so dogovori s predstavniki oddelka za logistiko in predstavniki oddelka za zagotavljanje kakovosti, katerih cilj je bilo ugotoviti, kateri podatek oziroma oznaka surovin je tista, preko katere je mogoče vzpostaviti enolično povezavo do parametrov, izmerjenih ob vstopu surovine v podjetje. Ko je bila določena taka šifra, so sledili dogovori z vodjo skladišča, ki je moral odobriti spremembe na dokumentaciji ter vodjo informatike, ki je moral odobriti poseg v programski opremi za tiskanje etiket. Ker je za take posege zadolženo koncernsko podjetje, so sledili dogovori s programerko o tipu, obliki in vsebini črtne kode. Ko so bili natisnjeni prvi primerki, je zadevo še enkrat pregledal in odobril vodja skladišča. Sprememba v programski opremi je bila implementirana dokaj hitro. Do problemov je prišlo šele pri začetku uporabe spremenjenega programa, ko se je izkazalo, da tiskalniki v skladišču ne omogočajo tiskanja črtne kode. Modul za izpis podatkov poslovnega informacijskega sistema je namreč zelo omejen, kar se tiče tiskanja grafičnih elementov, med katere spadajo tudi črtne kode. Na drugih oddelkih podjetja to težavo na običajnih tiskalnikih rešujejo tako, da uporabljajo določene tipe tiskalnikov, ki razumejo posebne ukaze, na podlagi katerih

nato sami generirajo črtno kodo. V skladišču se zaradi tiskanja na etikete uporabljajo drugi tiskalniki, ki pa te zmožnosti nimajo. Problem je bil večkrat predstavljen na rednih sestankih z vpletenimi na strani proizvodnega podjetja. Službi informatike je bilo naročeno, naj preizkusi in izbere tip tiskalnikov, ki bi omogočali tiskanje črtne kode, saj je v podjetju neodvisno od moje raziskave potekala in še poteka tudi prenova logističnih procesov. Ker so se odločali za nakup tiskalnikov za dolgoročno obdobje, je bil tudi proces njihove izbire in preizkušanja dolgotrajen. Uspeli pa smo opremiti etikete s šifro, ki omogoča že prej omenjeno povezavo s parametri. Ker smo menili, da bi vsakokratno ročno vnašanje številke šarže surovine predstavljalo preveliko obremenitev operaterjev linij in bi bilo zaradi večmestne številke brez možnosti kontrole podvrženo tudi preveč napakam, sem predlagal izdelavo posebnega programa za tiskanje črtnih kod. Tak program sem nato tudi izdelal. Procesni tehnolog, ki je omenjeni program uporabljal, je ob prihodu novih surovin iz skladišča v proizvodnjo ročno vnesel oznake v novo izdelani program, ki je nato omogočal tiskanje ustreznih črtnih kod. Te črtne kode je nato procesni tehnolog ročno lepil na spremne etikete. Omenjeni postopek sicer ni bil optimalen, saj je zahteval čas za izdelavo programa in čas procesnega tehnologa za pripravo nalepk, vendar smo se s tem izognili precejšnjemu številu napak pri vnosu podatkov. Rešitev je bila ugodna tudi s stališča sprejetja novega informacijskega sistema pri operaterjih linij, saj so obstajali dvomi, da bo preveč dodatnega administrativnega dela operaterjev povzročilo nasprotovanje uvajanju novega sistema.

Prenova postopkov v proizvodnji

Največje spremembe pri postopkih sledenja materialom so bile potrebne v proizvodnem obratu. V projekt in raziskavo so bile vključene tri delovne enote proizvodnega obrata. V vsaki izmed teh enot se izdeluje po en polizdelek oziroma končni izdelek. Vsaka izmed teh enot ima tudi svojega vodjo. S procesnim tehnologom sva pripravila številne predloge o uvedbi novih postopkov in o optimizaciji obstoječih. Vse te predloge je bilo potrebno obravnavati s posameznimi vodji delovnih enot in tudi na skupnih sestankih. Sočasno s postopki sledenja smo razpravljali tudi o postopkih za vnos ostalih podatkov. Sprva je bil celoten proizvodni informacijski sistem sprejet kot povečana stopnja nadzora zaposlenih s strani vodstva, ki bo poleg tega za zaposlene pomenila tudi dodatno administrativno delo. Ta občutek je bil močnejši pri starejših operaterjih, verjetno zaradi nepoznavanja informacijskih tehnologij [37] in apriornega strahu pred njihovo uporabo. Dodatno nasprotovanje je izražal eden izmed vodij delovnih enot. Ker je bil v podjetju zaposlen že dlje časa od ostalih dveh, je imel tudi izkušnje z dvema neuspešnima vpeljavama podobnih informacijskih sistemov za spremljanje proizvodnje. Obakrat je šlo za vpeljavo tovrstnih sistemov, ki pa niso bili povezani z ostalimi informacijskimi sistemi podjetja in zato niso bili del informacijskih tokov. Zaradi tega tudi niso bili nujno potrebni

za potek proizvodnega procesa in njihova uporaba in vzdrževanje sta s časom zamrla. Nasprotovanje je bilo najizrazitejše v celotni skupini, ki je pripadala omenjenemu vodji. Prav zaradi tega sem tej skupini posvetil največ pozornosti. Na več sestankih sem vodji skupine demonstriral uporabo sistema in mu podrobno predstavil vse postopke. Novi postopki za operaterje linij pomenijo zmanjšanje administrativnega dela. Predstavljene so mu bile tudi analize in prikazi, preko katerih je imel večji pregled nad dogajanjem v proizvodnji. Na njegovo željo pa sem v sistemu implementiral tudi funkcijo dodatnega tiskanja, ki je bila povsem izven začrtanih smernic novega sistema, vendar sem s tem dosegel, da je celoten projekt začel dojemati kot nekaj, kar bo v pomoč njemu in njegovim podrejenim. Zaradi teh dogodkov je tudi omenjeni vodja delovne enote postal zagovornik in podpornik uvajanja novega informacijskega sistema in kasneje, po uvedbi, je njegova skupina prva v celoti osvojila uporabo sistema in novih postopkov.

Načrtovanje in implementacija novega sistema

Ker so se podobni informacijski sistemi, z izjemo funkcionalnosti, povezanih s sledenjem, že uporabljali v nekaterih obratih proizvodnega podjetja, s popisom trenutnega stanja in pripravo funkcijske specifikacije ni bilo večjih težav. Prav tako so bile poznane že vse točke povezovanja z ostalimi informacijskimi sistemi podjetja. Izjema so le funkcije, ki so povezane s sledljivostjo. Te funkcije pa so bile večinoma definirane že med postopkom prenove proizvodnega procesa, ki se je ves čas dogajala z upoštevanjem uvajanja informacijskega sistema.

Po potrditvi funkcionalne specifikacije s strani predstavnikov proizvodnega podjetja je sledil razvoj in implementacija novih funkcij. Dotedanji informacijski sistemi niso vsebovali možnosti sledenja uporabljenim materialom, ampak so omogočali zgolj zbiranje podatkov o opravljenem delu, delovanju strojev in zajemu tehnoloških parametrov. Ker se sledljivost navezuje na precej obstoječih modulov, je bila potrebna sprememba oziroma dodelava le teh, potreben pa je bil tudi razvoj nekaj povsem novih modulov. Ker je bil projekt uvajanja informacijskega sistema del raziskave, je imel znotraj našega podjetja poseben status. Ta status je pomenil, da pri razvoju in implementaciji nisem imel na voljo nobenih človeških virov. Običajno bi na projektu takega velikostnega razreda delali vsaj še trije programerji. Edino pri testiranju posameznih modulov sem dobil pomoč študentke praktikantke. Moje delo na projektu je tako obsegalo vodenje, načrtovanje, razvoj, nameščanje programske opreme, kakor tudi montažo in namestitvev tiskalnikov v proizvodnji in montažo konektorjev na omrežne kable.

Pri zagonu sistema je do težav prihajalo pri zagotavljanju tiskalnikov, ki so v proizvodnji potrebni za samodejno tiskanje delovne in spremne dokumentacije. Zaradi postopkov, povezanih z investicijami, se je nabava tiskalnikov zavlekla za nekaj mesecev.

V tem času smo si pomagali z nadomestnimi tiskalniki, ki se sicer uporabljajo ob okvarah rednih tiskalnikov. Dodatno težavo je predstavljalo dejstvo, da nadomestni tiskalniki niso imeli omrežnih priključkov, zato je bilo potrebno zagotoviti še tiskalniški strežnik.

Uporaba novega informacijskega sistema

Po uvedbi informacijskega sistema in uspešnem zagonu vseh njegovih komponent je vodstvo proizvodnega podjetja zahtevalo potrditev oziroma dokaz, da sistem daje pravilne podatke. Za referenco je služil obstoječi informacijski sistem, ki podatke zbira z ročnim vnašanjem. Verifikacija naj bi se izvajala določeno časovno obdobje. Sprva sem verifikacijo opravljal ročno, tako da sem sam primerjal dnevne kumulativne podatke iz podatkovnih zbirk obeh sistemov. Ker je bilo to delo prezamudno, sem izdelal program, ki je namesto mene opravljal primerjavo in je opozarjal le na razlike med obema sistemoma. Vodstvo proizvodnega podjetja je v primeru razhajanj zahtevalo pojasnila. Razhajanj je bilo že od vsega začetka precej. Vsako razhajanje je bilo potrebno raziskati in razjasniti. Za večino primerov je bilo ugotovljeno, da izvirajo iz napak pri vnosu v starejši informacijski sistem, ki ni imel implementiranih vseh preverjanj pri vnosu podatkov.

Pridobivanje ostalih podatkov

Ker smo že v verifikacijskem obdobju zaznali veliko kakovost zbranih podatkov, sem se odločil že te podatke uporabiti za analizo. Zbrani podatki so predstavljali izhodne parametre proizvodnega procesa. Pridobiti je bilo potrebno še podatke o surovinah. Ti podatki se nahajajo v poslovnem informacijskem sistemu. Pridobivanje podatkov je potekalo preko vodje oddelka za zagotavljanje kakovosti, ki je izvoz naročil svojemu podrejenemu. Ta je kasneje ugotovil, da dostopa do omenjenih podatkov nima. Nadaljnja poizvedovanja so vodila do skrbnika modula kakovosti poslovnega informacijskega sistema. Postopki za izvoz podatkov so zamudni, saj je za vsakega izmed parametrov potrebno prebijanje skozi sistem zaslonskih mask. Ker bi v primeru trajnega analiziranja te podatke potreboval pogosteje, sem se na službo za informatiko obrnil s prošnjo za pomoč pri avtomatiziranem izvozu podatkov. Žal se je izkazalo, da izdelava takega programa stroškovno ni sprejemljiva. Predlagal sem, da mi dovolijo dostop do omenjenega modula, kjer bi podatke lahko izvažal sam. Tudi ta rešitev ni bila stroškovno sprejemljiva, saj bi za to potrebovali dodatno licenco za poslovni informacijski sistem. Na koncu je obveljal dogovor, da lahko izvoze opravlja procesni tehnolog proizvodnega obrata, kjer se izvaja analiza, saj naj bi imel licenco za uporabo informacijskega sistema, ker ga uporablja za vsakdanja opravila. Sledil je sestanek s procesnim tehnologom in njegovim nadrejenim, direktorjem divizije, ki sta se strinjala, da izvoze opravi procesni tehnolog.

O tem sem obvestil tudi službo informatike. Ker procesni tehnolog še vedno ni dobil ustrezne avtorizacije za izvoz podatkov, sem se spet obrnil na službo informatike. Dobil sem odgovor, da procesni tehnolog nima licence za uporabo poslovnega informacijskega sistema in da izvoz podatkov na ta način ni mogoč. V zvezi z zapleti sem se nato obrnil na enega izmed direktorjev proizvodnega podjetja, ki je zadolžen za spremljanje poteka raziskave. Ta je nato odobril izvoz skrbniku modula kakovosti. Podatke sem nato imel na voljo v nekaj dneh. Zapletov s podatki o parametrih surovin pa s tem še ni bilo konec, saj so se v tem času spremenili režimi merjenja. Pri vseh parametrih, razen pri dveh, je bilo uvedeno merjenje parametrov na preskok, torej na vsako dvaintrideseto šaržo. Taki podatki so zato nepopolni.

Odzivi uporabnikov

Informacijski sistem za spremljanje proizvodnje vključuje uporabnike na vseh nivojih podjetja. Odzivi vseh uporabnikov so bili pozitivni. Presenečen sem bil nad odzivom enega od operaterjev linij, ki nam je posredoval nekaj predlogov izboljšav sistema, ki smo jih sicer že implementirali v drugih podjetjih in so se izkazali za uspešne. Čeprav so imeli vodje delovnih enot v času verifikacije dvojno delo, saj so morali vnašati podatke v star informacijski sistem in potrjevati podatke v novem, so z izjemo enega svoje delo opravljali vestno in temeljito. Navdušenje nad rezultati delovanja informacijskega sistema sta izrazila tudi procesni tehnolog in direktor divizije.

Sklep

Ob zaključku projekta lahko svoja opažanja in ugotovitve izrazim v nekaj točkah:

- Ves čas projekta je obstajala načelna podpora vodstva koncerna. Podpora vodstva proizvodnega podjetja se je tudi konkretizirala, vendar šele v zaključnih fazah. Tudi sicer je bila v večji meri osredotočena le na uvajanje informacijskega sistema za spremljanje proizvodnje.
- Zainteresiranost uporabnikov je bila, razen nekaj izjem, majhna. Največji interes do projekta so kazali uporabniki informacijskega sistema za spremljanje proizvodnje. Koristi tega sistema so bile najbolj očitne in neposredne. Pri ostalih udeležencih, katerih naloga je bila v večji meri zagotavljanje ali priprava podatkov, spreminjanje obstoječih postopkov ali ostale oblike sodelovanja (npr. zagotovitev tiskalnikov in ostale potrebne opreme), pa je bila zainteresiranost nizka.
- Na splošno je bilo v podjetju zaznati veliko inertnost. Utečene postopke, za katere je očitno, da so neoptimalni ali celo nepotrebni, je bilo težko spreminjati. Tako

so bile potrebe po prenovi informacijskih in delovnih tokov obravnavane zgolj kot investicije.

- Uspeh projekta je bil odvisen od številnih področij in oddelkov podjetja, na katere sem imel kot zunanji udeleženec malo vpliva. Za usklajeno delovanje in zainteresiranost celotne verige udeležencev bi bilo potrebno definirati naloge in odgovornost posameznikov, to pa bi lahko storil le nekdo iz proizvodnega podjetja na dovolj visokem položaju. Aktivnega sogovornika, ki bi imel to možnost, do zaključnih faz projekta nisem imel.
- Zaviralni element v poteku projekta je predstavljalo dejstvo, da glavna iniciativa ni prihajala iz proizvodnega podjetja. V tovrstnih projektih je zelo pomembno, da uporabniki sami zaznajo potrebe in tudi jasno izrazijo zahteve po uvedbi informacijskega sistema.

Sklep

Disertacija obravnava problem napovedovanja kakovosti izdelkov v kosovni industriji na podlagi procesnih parametrov in parametrov vhodnih surovin. Za modeliranje proizvodnega procesa so na voljo različne tehnike. Disertacija se osredotoča na uporabo regresijskih metod, ki uporabljajo učne podatke, izmerjene neposredno v proizvodnem procesu.

Disertacija je tesno povezana s proizvodnim procesom podjetja Kolektor Sikom d.o.o.. Da je modeliranje proizvodnega procesa sploh mogoče, so potrebni zanesljivi podatki iz proizvodnje. Ti podatki morajo poleg tega, da so točni in obsegajo vse potrebne parametre, zajemati tudi čimveč posebnosti proizvodnega procesa. V praksi se je izkazalo, da je proces pridobivanja podatkov časovno zahtevnejši od njihove analize. Za pridobitev ustreznih podatkov je bilo najprej potrebno delno prenoviti proizvodni proces. Pri načrtovanju sprememb je bilo potrebno upoštevati udeležence tega procesa v skoraj celotni hierarhiji podjetja. Šele prenova oziroma optimizacija proizvodnega procesa je omogočala tako organizacijo postopkov, da je bilo mogoče zbiranje procesnih podatkov. Na podlagi nove organizacije je bil nato zasnovan proizvodni informacijski sistem. Delno so se uporabili že obstoječi moduli, module, namenjene spremljanju sledljivosti, pa je bilo potrebno razviti na novo. Pomembno komponento proizvodnega informacijskega sistema predstavljajo terminali za registracijo dogodkov. So vez med informacijskim sistemom in operaterji linij in strojev. V preteklosti smo se vedno srečevali z vprašanjem izbire optimalnega števila terminalov. V ta namen je v disertaciji predstavljena metoda njihove optimalne izbire. Metoda je bila tudi dejansko uporabljena pri uvajanju proizvodnega informacijskega sistema v podjetju Kolektor Sikom d.o.o., ki je predmet disertacije.

Podatki, ki jih obravnava disertacija, so ločeni na parametre vhodnih surovin in na tehnološke parametre proizvodnega procesa. Na kakovost izdelka vplivata obe kategoriji podatkov, vendar je cena zbiranja tehnoloških parametrov previsoka⁴. Kljub temu so bili v omejenem obsegu na voljo podatki o tehnoloških parametrih proizvodnega procesa v povezavi z odvisnim parametrom, ki je povezan s kakovostjo izdelkov. Obravnava vpliva

⁴Za zbiranje tehnoloških parametrov je na stroje potrebno nameščanje posebnih senzorjev, ki imajo zaradi neustreznih pogojev (visoke temperature) tudi kratko življenjsko dobo. Senzorji potrebujejo tudi namenske krmilnike za shranjevanje podatkov.

lastnosti surovin in procesa izdelave na kakovost končnega izdelka je zato ločena. Zaradi narave podatkov so bile za analizo obeh kategorij uporabljene različne regresijske metode. Pri povezavi tehnoloških parametrov z dimenzijo luknje v komutatorju je bila uporabljena metoda linearne regresije oziroma zaradi korelacije med vhodnimi podatki njeni razširitvi: **koračna regresija** in **regresija z metodo glavnih komponent**. Ker gre pri povezavi parametrov vhodnih materialov s kakovostjo izdelkov za drugačen tip problema⁵, se za iskanje povezav uporablja **logistična regresija**. Zaradi močne korelacije med parametri vhodnih materialov je bilo v model logistične regresije potrebno vpeljati pristope, ki jih sicer običajno srečamo v linearni regresiji. V model je bila zato vpeljana metoda glavnih komponent, ki uspešno odpravlja problem korelacije v podatkih.

Rezultat disertacije je posledica uporabe različnih tehnologij, metod in orodij. Celotno delo obsega tako razvojne in raziskovalne, kakor tudi povsem netehnične in organizacijske vidike. Slednji so bili pomembni pri prenovi proizvodnega procesa, razvojno-raziskovalni pa pri implementaciji informacijskega sistema, zbiranju, predpripravi in analizi podatkov. Najpomembnejši prispevki disertacije so:

- Narejena je bila optimizacija oziroma **prenova proizvodnega procesa**. Za prenovu je bilo potrebno sodelovanje akterjev na različnih nivojih proizvodnega podjetja. Pri prenovi je bilo potrebno upoštevati utemeljene in neutemeljene zahteve. Odpraviti je bilo potrebno odvečne postopke. Cilj prenove je bila taka optimizacija proizvodnega procesa, ki omogoča učinkovito zbiranje podatkov. Dejansko smo pri prenovi iskali ustrezen kompromis med učinkovitim zbiranjem podatkov, vplivom tega zbiranja na proizvodni proces ter željami in zahtevami udeležencev proizvodnega procesa.
- Uspešno je bil izpeljan **razvoj informacijskega sistema za spremljanje proizvodnje**. Obstoječi informacijski sistem ni omogočal zbiranja podatkov o sledljivosti. Potrebno je bilo načrtovanje novih modulov in prilagoditev obstoječih. Razvojni proces je obsegal vse faze [77]: analizo zahtev, načrtovanje, implementacijo, testiranje, preizkusno obratovanje, končni zagon sistema.
- Za potrebe uvajanja proizvodnega informacijskega sistema je bila razvita **simulacijska metoda ter formulacija in rešitev stohastičnega optimizacijskega problema**, ki omogoča **določanje optimalnega števila informacijskih terminalov**. Metoda sloni na optimizaciji kriterijske funkcije, ki vključuje stroške terminalov in stroške čakalnih časov.
- Izvedena je bila **analiza vpliva tehnoloških parametrov izdelave na fizikalne lastnosti izdelka** in posledično na njegovo kakovost. Prikazana je bila uporaba

⁵Enak pristop bi bil potreben, če bi vhodni podatki vsebovali tudi parametre proizvodnega procesa.

dveh regresijskih metod na podatkih, ki so zajemali dva tehnološka parametra in en parameter lastnosti izdelka.

- Izvedena je bila **analiza vpliva parametrov vhodne surovine na kakovost izdelkov**. Uporabljena je bila metoda logistične regresije. Zaradi korelacije med vhodnimi podatki je bila potrebna predhodna transformacija z metodo glavnih komponent. V ta namen je bil za okolje *Matlab* **razvit postopek, ki združuje uporabo metode glavnih komponent in logistično regresijo**.

Disertacija pa pušča tudi odprta vprašanja. Kakor je omenjeno v poglavju 6.1.1, lahko uspešnost proizvodnega procesa opisujemo s tremi glavnimi kazalniki: kakovostjo, zmogljivostjo in razpoložljivostjo, ter njihovim produktom skupno učinkovitostjo. V raziskavi je zajeta le kakovost, ostala kazalnika in skupna učinkovitost pa so izpuščeni. Predvsem za izračun zmogljivosti (in posledično skupne učinkovitosti) ni bilo na voljo ustreznih podatkov o časovnih normativih. Ti podatki so namreč prilagojeni planski službi in ne odražajo dejanskih kapacitet opreme.

V proizvodnem procesu nastaja še mnogo podatkov, ki jih v raziskavo ni bilo mogoče zajeti. Razlog za to je bila bodisi prevelika cena merjenja in beleženja takih podatkov bodisi nesistematično beleženje podatkov izven informacijskih sistemov.

Za povečanje natančnosti napovedovanja verjetnosti slabih izdelkov bi bilo potrebno v enotnem modelu združiti tako tehnološke parametre proizvodnega procesa kakor tudi parametre vhodnih surovin. Možnosti za dodajanje novih parametrov iz proizvodnje podjetja Kolektor Sikom d.o.o. v model je še precej, saj v spremljanje še niso vključene vse operacije. Podatke bi bilo mogoče zajemati še v obratu, kjer se preoblikuje bakreni trak, mogoča pa bi bila tudi vključitev podatkov statistične procesne kontrole.

Zahvale

V prvi vrsti gre zahvala mentorju prof. dr. Đaniju Juričiču za izdatno strokovno pomoč in usmerjanje pri mojem doktorskem študiju ter za dragocene nasvete pri nastajanju disertacije.

Za strokovno pomoč se zahvaljujem prof. dr. Jušu Kocijanu in ostalim članom Odseka za sisteme in vodenje Instituta Jožef Stefan.

Za lektoriranje besedila se iskreno zahvaljujem mami Lidiji Kleindienst in za prevod Vanji Rupnik Prezelj.

Ministrstvu za visoko šolstvo, znanost in tehnologijo Republike Slovenije se zahvaljujem za finančno podporo.

Zahvaljujem se Koncernu Kolektor in vsem posameznikom, ki so konstruktivno sodelovali pri uvajanju informacijskega sistema za spremljanje proizvodnje.

Posebna zahvala pa velja Poloni in Leni za spodbudo in potrpljenje.

Literatura

- [1] Agresti, A. *Categorical Data Analysis* (John Wiley & Sons, New York, 2002).
- [2] Aguilera, A. M.; Escabias, M.; Valderrama, M. J. Using principal components for estimating logistic regression with high-dimensional multicollinear data. *Computational Statistics & Data Analysis* **50**, (2005).
- [3] Ahmad, M. M.; Dhafr, N. Establishing and improving manufacturing performance measures. *Robotics and Computer Integrated Manufacturing* **18**, (2002).
- [4] Amemiya, T. *Advanced Econometrics, 6th Edition* (Harvard University Press, Harvard, 1985).
- [5] Aske, E. M. B.; Strand, S; Skogestad, S. Coordinator MPC for maximizing plant throughput. *Computers and Chemical Engineering* **32**, (2007).
- [6] Banaszak, Z.; Zaremba, M; Special issue on Internet-based Distributed Intelligent Manufacturing Systems. *Journal of Intelligent Manufacturing* **14/1** (2003).
- [7] Basseville, M.; Nikiforov, I. V. *Detection of Abrupt Changes: Theory and Applications* (Prentice-Hall, Englewood Cliffs, 1993).
- [8] Boyer, S. *SCADA: Supervisory Control and Data Acquisition* (ISA, Research Triangle Park, 1999).
- [9] Braha, D. (ur.) *Data Mining for Design and Manufacturing* (Springer, New York, 2002).
- [10] Brandl, D. L. Making the business case for business to manufacturing integration. V: *Proceedings of the International Congress of Automation, Systems and Instrumentation*. (Sao Paulo, Brazil, 2001).
- [11] Brown, M. Collaborative production management: a stepwise approach from key performance indicators to workflow processes. *Hydrocarbon Processing* **85/6**, (2006).

- [12] Choi, S.W.; Park, J.H.; Lee, I. B. Process monitoring using a Gaussian mixture model via principal component analysis and discriminant analysis. *Computers and Chemical Engineering* **28**, (2004).
- [13] Doumeingts, G.; Vallespir, B.; Chen, D. Decision modelling GRAI grid. V: Bernus, P. (ur.); Mertins, K. (ur.); Schmidt, G. (ur.) *Handbook on architecture for Information Systems* (Springer, Verlag, 1998).
- [14] Doymaz, F.; Chen, J.; Romagnoli, J.; Palazoglu A. A robust strategy for real-time process monitoring. *Journal of Process Control* **11**, (2001).
- [15] Edwards, P. J.; Murray, A. F.; Wallace, A. R.; Barnard, J. The application of neural networks to the paper-making industry. V: *Proceedings to European Symposium on Artificial Neural Networks* (1999).
- [16] Elfessi, A.; Reineke, D. M. A Bayesian look at classical estimation: The exponential distribution. *Journal of Statistics Education* **9/1**, (2001).
- [17] Enders, W. *Applied Econometric Time Series, 2nd Edition* (John Wiley & Sons, New York, 2004).
- [18] Escabias, M.; Aguilera, A. M.; Valderrama, M. J. Modeling environmental data by functional principal component logistic regression. *Environmetrics* **16/1**, (2004).
- [19] Escabias, M.; Aguilera, A. M.; Valderrama, M. J. Principal component estimation of functional logistic regression: Discussion of two different approaches. *Journal of Nonparametric Statistics* **16/3,4**, (2004).
- [20] Ferrer-Nadal, S.; Yélamos-Ruiz, I.; Graells, M; Puigjaner, L. An integrated framework for on-line supervised optimization. *Computers and Chemical Engineering* **31**, (2007).
- [21] Folan, P; Browne, J. A review of performance measurement: Towards performance management. *Computers in Industry* **56**, (2005).
- [22] Fortuin, L. Performance indicators – Why, where and how. *European Journal of Operational Research* **34/1**, (1988).
- [23] Gertler, J. *Fault Detection and Diagnosis in Engineering Systems* (Marcel Dekker, New York, 1998).
- [24] Gertler, J. All linear methods are equal - and extendible to nonlinearities. V: *Prepr. IFAC Symp. Safeprocess*. 52-63, (Budapest, 2000).

- [25] Greene, W. H. *Econometric Analysis, 5th Edition* (Prentice Hall, New Jersey, 2003).
- [26] Grichnik, T.; Hill, T.; Seskin, M. Predicting quality outcomes through data mining. *Quality Digest Magazine* **26/9**, (2006).
- [27] Harley, J. B. Genome-wide association scan in women with systemic lupus erythematosus identifies susceptibility variants in ITGAM, PXX, KIAA1542 and other loci. *Nature Genetics* **40/2**, (2008).
- [28] Hastie, T.; Tibshirani, R.; Friedman, J. *The elements of statistical learning* (Springer, New York, 2001).
- [29] Hosmer, D. W.; Lemeshow, S. *Applied logistic regression, 2nd Edition* (John Wiley & Sons, New York, 2000).
- [30] Hyotyniemi, H. *Multivariate Regression - Techniques and Tools* (Helsinki University of Technology, Helsinki, 2001).
- [31] Jin, R.; Li, J.; Shi, J. Quality prediction and control in rolling processes using logistic regression. *Transactions of NAMRI/SME* **35**, (2007).
- [32] Juričić, Đ.; Žele, M. Robust detection of faults in command inputs. V: *Preprints of the 15th Triennial World Congress of the International Federation of Automatic Control*. (Barcelona, Spain, 2002).
- [33] Karlin, R. *Vpliv tlaka in temperature v brizgalnem gnezdu na dimenzije im mehanske karakteristike: diplomska naloga*. (Fakulteta za strojništvo, Ljubljana, 2007).
- [34] Kárný, M.; Böhm, J.; Guy, T. V.; Jirsa, L.; Nagy, I.; Nedoma, P.; Tesař, L. *Optimized Bayesian Dynamic Advising: Theory and Algorithms* (Springer, London, 2005).
- [35] Kleinbaum, D. G.; Klein, M. *Logistic Regression: A Self-Learning Text* (Springer, New York, 1994).
- [36] Kolektor Synatec. sl.kolektorsynatec.si (dostop: maj 2009).
- [37] Kosanke, K. (ur.); Jochem, R. (ur.); Nell, J. G. (ur.); Ortiz, B. A. (ur.) Enterprise inter- and intra organisational integration. V: *Proceedings of IFIP*. (Kluwer Academics, 2003)
- [38] Koscielny, J.M. Fault isolation in industrial processes by the dynamic table of states method. *Automatica* **31/5**, (1995).

- [39] Kourti, T.; Nomikos, P.; MacGregor, J. F. Analysis, monitoring and fault diagnosis of batch processes using multiblock and multiway PLS. *Journal of Process Control* **5/4**, (1995).
- [40] Kovács, G. L.; Mezgár, I.; Kopácsi, S.; Gavalcová, D.; Nacsá, J. Application of artificial intelligence to problems in advanced manufacturing systems. *Computer Integrated Manufacturing Systems* **7/3**, (1994).
- [41] Liu, J. S.; Zhang, J. L.; Palumbo, M. J.; Lawrence, C. E. Bayesian Clustering with Variable and Transformation Selections. V: Bernardo J. M. et al. (ur.) *Bayesian Statistics 7* 249–275 (Oxford University Press, 2003).
- [42] Lohman, C.; Fortuin, L.; Wouters, M. Designing a performance measurement system: A case study. *European Journal of Operational Research* **156**, (2004).
- [43] MacKay, D. J. C. *Information theory, inference and learning algorithms* (Cambridge University Press, Cambridge, 2003).
- [44] Matlab. www.mathworks.com (dostop: maj 2009).
- [45] Mönch, L. Simulation-based benchmarking of production control schemes for complex manufacturing systems. *Control Engineering Practice* **15**, (2007).
- [46] Morel, G.; Panetto, H.; Zaremba, M.; Mayer, F. Manufacturing Enterprise Control and Management System Engineering: Paradigms and open issues. *Annual Reviews in Control* **27**, (2003).
- [47] Muller, K. E.; Stewart, P. W. *Linear Model Theory: Univariate, multivariate and mixed models* (John Wiley & Sons, New York, 2006).
- [48] Multicollinearity. en.wikipedia.org/wiki/Multicollinearity (dostop: maj 2009).
- [49] Nagappan, N.; Ball, T.; Zeller, A. Mining metrics to predict component failures V: *Proceedings of the 28th international conference on Software engineering* (Shanghai, China, 2006)
- [50] Neely, A.; Gregory, M; Platts, K. Performance measurement system design: A literature review and research agenda. *International Journal of Operations & Production Management* **15/4**, (1995).
- [51] OpenOffice.org. www.openoffice.org (dostop: april 2009)
- [52] Papoulis, A. *Probability, Random Variables, and Stochastic Processes* (McGraw-Hill, Singapore, 1984).

- [53] Pearson, R. K. *Mining imperfect data: Dealing with contamination and incomplete records* (Siam, Philadelphia, 2005)
- [54] Radu, P.; Mouloud, A. *Application of Data Mining Techniques for Industrial Process Optimization* (CETC, Varennes, 2007).
- [55] Rakar, A.; Juričić, Đ. Diagnostic reasoning under conflicting data: The application of the transferable belief model. *Journal of Process Control* **12**, (2002).
- [56] Rakar, A.; Juričić, Đ. Matching the requirements in model-based fault diagnosis. V: *15th International Workshop on Principles of Diagnosis*. 239-244 (Carcassone, France, 2004).
- [57] Rakar, A.; Zorzut, S.; and Jovan, V. Assessment of production performance by means of KPI. V: *Proceedings of the Control 2004*. (University of Bath, UK, 2004).
- [58] Rosner, B.; Willett, W. C.; Spiegelman, D. Correction of logistic regression relative risk estimates and confidence intervals for systematic within-person measurement error. *Statistics in Medicine* **8/9**, (2006).
- [59] Rull, J. C. *Politični okvir za krepitev proizvodnje EU – za celovitejši pristop k industrijski politiki* (Evropski Parlament, Bruselj, 2006).
- [60] Russell, E. L.; Chiang, L. H.; Braatz, R. D. *Data-driven techniques for fault detection and diagnosis in chemical process* (Springer, New York, 2000).
- [61] Scholten, B. *The road to integration: A guide to applying the ISA-95 standard and manufacturing* (ISA, Research Triangle Park, 2007).
- [62] Sethi, I. K. *Data Mining: An Introduction* (Oakland University, Oakland, 2001).
- [63] Sinapro. sl.kolektorsinabit.si/resitve/proizvodno-informacijske-resitve/ (dostop: maj 2009).
- [64] Skogestad, S. Near-optimal operation by self-optimizing control: From process control to marathon running and business systems. *Computers and Chemical Engineering* **29**, (2004).
- [65] Spanos, C. J.; Guo, H. F.; Miller, A.; Levine-Parrill, J. Real time statistical process control using tool data. *IEEE Transactions on semiconductor manufacturing* **5/4**, (1992).
- [66] Stephanopoulos, G.; Ng, C. Perspectives on the synthesis of plant-wide control structures. *Journal of Process Control* **10**, (2000).

- [67] Stepwise regression. en.wikipedia.org/wiki/Stepwise_regression (dostop: april 2009)
- [68] Strmčnik, S. (ur.) *Celostni pristop k računalniškemu vodenju procesov* (Založba FE in FRI, Ljubljana, 1998).
- [69] Valckenaers, P. (ur.) Special issue on Intelligent Manufacturing Systems. *Computers in Industry* **37/3**, (1998).
- [70] Valckenaers, P. (ur.) Special issue on Intelligent Manufacturing Systems. *Computers in Industry* **43/2**, (2000).
- [71] Venkatasubramanian V.; Rengaswamy, R.; Yin, K.; Kavuri, S. N. A review of process fault detection and diagnosis: Part I: Quantitative model-based methods. *Computers and Chemical Engineering* **27**, (2003).
- [72] Venkatasubramanian V.; Rengaswamy, R.; Yin, K.; Kavuri, S. N. A review of process fault detection and diagnosis: Part III: Process history based methods. *Computers and Chemical Engineering* **27**, (2003).
- [73] Vernadat, F. B. *Enterprise modelling and integration: Principles and applications* (Chapman & Hall, London, 1996).
- [74] Wallace, T.; Kremzar, M. *ERP: Making It Happen* (John Wiley & Sons, New York, 2001).
- [75] Wang, X. Z. *Data mining and knowledge discovery for process monitoring and control* (Springer, New York, 1999)
- [76] Wasserman, L. *All of Statistics: A Concise Course in Statistical Inference* (Springer, New York, 2004).
- [77] Williams, T. J. *The Purdue Enterprise Reference Architecture. In A technical guide for CIM planning and implementation* (ISA, Research Triangle Park, 1992).
- [78] Willmott, P.; McCarty, D. *TPM - A Route to World-Class Performance* (Butterworth - Heinmann, Oxford, 2001).
- [79] Yoon, S.; Landry, J.; Kettaneh, N.; Pepe, W; Wold, S. Multivariate process monitoring and early fault detection (MSPC) using PCA and PLS. V: *Proceedings to Plant Automation and Decision Support Conference* (2003).
- [80] Zamprognaa, E.; Barolo, M.; Seborgb, D. E. Optimal selection of soft sensor inputs for batch distillation columns using principal component analysis. *Journal of Process Control* **15/1**, (2005).

- [81] Zhang, Y.; Dudzic, M. S. Online monitoring of steel casting processes using multivariate statistical technologies: From continuous to transitional operations. *Journal of Process Control* **16/8**, (2006).

Slike

1.1	<i>Proizvodni proces.</i> S stališča modeliranja lahko na proizvodni proces gledamo kot na preslikavo, ki vektor vhodnih parametrov preslika v vektor izhodnih parametrov.	2
1.2	<i>Struktura sistema za nadzor proizvodnje in podporo odločanju.</i> Procesni podatki in podatki iz sistema ERP (ang. Enterprise Resource Planning) tvorijo osnovo sistemu za podporo odločanju, ki preko operaterja tvori povratno zanko.	11
1.3	<i>Modul za generiranje značilnk.</i> Model deluje vzporedno s proizvodnim procesom in napoveduje izhode. Večanje rezlike med dejanskimi in napovedanimi izhodi pomeni anomalije ali napake v proizvodnem procesu.	12
2.1	<i>Komutator A.</i> Preko prevodnih lamel se v navitje rotorja prenaša električni tok. Rotorska navitja so spojena s kljukicami komutatorja.	13
2.2	<i>Shema toka materialov in nastajanja podatkov.</i> Končni izdelek, ki je sestavljen iz dveh polizdelkov, v katera se vgrajujeta dva vhodna materiala. O obeh materialih so na voljo fizikalni parametri. Podatki o izdelavi so na voljo za vse tri operacije.	15
2.3	<i>Primer obstoječih identifikacijskih etiket za surovino 1.</i> Vse informacije so izpolnjene ročno, zato avtomatska identifikacija surovine ni mogoča.	18
2.4	<i>Informacijski terminal (proizvajalec Kolektor Synatec [36]).</i> Terminal je nameščen na stebru znotraj proizvodnega obrata. Lega terminala je določena tako, da je dostopen z več različnih delovnih mest.	25
2.5	<i>Uporabniški vmesnik na terminalih.</i> Začetna zaslonska maska omogoča izbiro posameznih sklopov dogodkov.	26
2.6	<i>Modul za prijavo zastoja na stroju.</i> Zgornji (rumeni) del zaslona je namenjen prikazu sporočil, preko katerih operater dobiva povratne informacije o poteku postopka. Osrednji del je namenjen vnosu posameznih podatkov, ki lahko poteka preko čitalnika črtne kode ali pa preko navidezne zaslonske tipkovnice. Spodnji del zaslona zasedajo gumbi: dva stalna navigacijska gumba ter gumbi, ki jih dodajajo posamezni moduli.	27

2.7	<i>Modul za ročni vnos podatkov o opravljenem delu.</i> Modul omogoča vodjem izmen ali obratov, da ročno vnesejo vse podatke o opravljenem delu. Ti podatki zajemajo trajanje dela, delovni nalog, število proizvedenih izdelkov, število in vzroke za neustrezne izdelke ter čase in vzroke morebitnih zastojev.	28
2.8	<i>Izmenjava podatkov.</i> Tok podatkov med poslovnim informacijskim sistemom in sistemom za spremljanje proizvodnje tvori zanko.	29
3.1	<i>Ilustracija izračuna čakalnih časov.</i> Na spodnji skali je prikazan čas. Posamezni trakovi v obeh situacijah predstavljajo trajanje prijave. Osenčeni trakovi v situaciji z enim terminalom predstavljajo čakalne čase.	34
3.2	<i>Povprečno število dogodkov na minuto preko celotnega dneva.</i> Izrazitejše izstopanje nastopi le pri menjavah izmen, ob 6., 14. in 22. uri.	37
3.3	<i>Primerjava ocenjenega profila λ.</i> Rdeča in modra krivulja predstavljata predvideno in dejansko gostoto dogodkov v razponu 83 dni (predvidevanja so napravljena na podlagi 10-dnevnega izseka dejanskih dogodkov).	38
3.4	<i>Histogrami porazdelitve čakalnih časov.</i> Prikazani so histogrami za število terminalov $N = 1, 2, 3$. Z večanjem števila terminalov se pričakovani čakalni časi hitro približujejo vrednosti 0.	39
3.5	<i>Kriterijska funkcija J_{cost}.</i> Prikazana je kriterijska funkcija za izbrano kritično vrednost $\alpha = 0,05$, v odvisnosti od števila terminalov N . Najnižjo vrednost (17, 73) doseže pri $N = 5$	39
3.6	<i>Odvisnost optimalnega števila terminalov N^* od parametra α.</i> Prikazane so vrednosti za $\alpha \in [0, 1]$	40
4.1	<i>Izboljšan model odvisnosti $y = f(x)$.</i> Celotna preslikava je sestavljena iz dveh vmesnih preslikav.	48
4.2	<i>Izboljšan model odvisnosti $y = f(x)$.</i> Celotna preslikava je sestavljena iz treh vmesnih.	57
4.3	<i>Primer funkcije logit $f(x) = \frac{1}{1+e^{-x}}$.</i> Katerakoli vrednost iz intervala $(-\infty, \infty)$ se preslika v interval $[0, 1]$	59
5.1	<i>Vhodni in izhodni podatki.</i> $x_1(t)$ in $x_2(t)$ predstavljata neodvisna tehnološka parametra tlak in temperaturo, $y(t)$ pa je odvisna spremenljivka - obdelovalni raztezek.	64
5.2	<i>Singularne vrednosti matrike.</i> Stolpci predstavljajo posamezne singularne vrednosti matrike vhodnih podatkov z umetno dodanimi spremenljivkami (skala na levi strani). Krivulja prikazuje odstotek informacije, ki ga v model vnašamo z dodajanjem posameznih dimenzij (skala na desni strani).	66

5.3	<i>Učna množica podatkov.</i> Prikazani so vhodni (x_1, x_2) in izhodna (y) spremenljivka. Večje rdeče točke predstavljajo interval učne množice, manjše modre točke pa validacijski interval.	68
5.4	<i>Razpon ocene R^2.</i> Pri različnih kombinacijah začetnega nabora prediktorjev v metodi koračne regresije dobimo različne ocene R^2 . Ocene so urejene od najmanjše do največje.	69
5.5	<i>Histogram ocene R^2.</i> Pri različnih kombinacijah začetnega nabora prediktorjev v metodi koračne regresije dobimo različne ocene.	70
5.6	<i>Ocene regresijskih koeficientov za metodo koračne regresije.</i> Prikazani so koeficienti in njihovi intervali zaupanja pri stopnji signifikantnosti 0,95.	71
5.7	<i>Gibanje ocene R^2.</i> Prikazana je ocena modela v odvisnosti od števila latentnih spremenljivk (N) pri analizi z metodo glavnih komponent.	73
5.8	<i>Ocene regresijskih koeficientov za regresijo z metodo glavnih komponent.</i> Prikazani so koeficienti in njihovi intervali zaupanja pri stopnji signifikantnosti 0,95.	74
5.9	<i>Gibanje ocene R^2 za učni interval.</i> Prikazana je ocena modela v odvisnosti od števila latentnih spremenljivk (N) pri analizi z metodo glavnih komponent. Ocena je narejena samo na učnem intervalu.	75
5.10	<i>Medsebojna primerjava ocene izhoda obeh metod.</i> Prikazana je primerjava ocene izhoda, dobljene z metodo koračne regresije (a) in z regresijo z metodo glavnih komponent (b).	76
6.1	<i>Vhodni in izhodni podatki proizvodnega procesa.</i> Prikazani so vhodni parametri surovin x_1, \dots, x_{13} in izhodni parameter - kakovost izdelkov y	80
6.2	<i>Singularne vrednosti matrike.</i> Stolpci predstavljajo posamezne singularne vrednosti matrike parametrov vhodnih surovin (skala na levi strani). Krivulja prikazuje odstotek informacije, ki ga v model vnašamo z dodajanjem posameznih parametrov (skala na desni strani).	81
6.3	<i>Devianca modela logistične regresije.</i> Prikazano je gibanje deviance modela v odvisnosti od števila latentnih spremenljivk (N) pri uporabi logistične regresije z metodo glavnih komponent.	84
6.4	<i>Primerjava regresijskih koeficientov.</i> Primerjava koeficientov in njihovih intervalov zaupanja za regresijski model z 12 (a) in 13 (b) latentnimi spremenljivkami. Grafa imata zaradi velikega intervala zaupanja pri uporabi 13 latentnih spremenljivk različni skali. Za intervale zaupanja je uporabljena stopnja signifikantnosti 0,95.	85

6.5	<i>Primerjava izhoda z oceno za metodo logistične regresije.</i> Prikazan je izmerjen izhod $y(t)$, njegova ocena $\hat{y}(t)$ in njen interval zaupanja (senčeno območje) pri stopnji signifikantnosti 0,95. Uporabljen je bil model z 12 latentnimi spremenljivkami.	85
6.6	<i>Blokovna shema sprotnega nadzora kakovosti izdelkov.</i> Na podlagi parametrov surovine in učnih podatkov se izračuna verjetnost pojava slabih izdelkov, na osnovi katere odločitveni sistem nato predlaga ustrezne tehnološke parametre ali tip izdelka. Podatki o izdelavi se nato uporabijo za ažuriranje učne množice.	86
6.7	<i>Pomoč operaterju pri prikazu verjetnosti slabih izdelkov.</i> Pri izračunu verjetnosti pojava slabih izdelkov se uporabijo parametri vhodne surovine. Nove, neznanе vrednosti se lahko nahajajo izven območja tistih vrednosti, ki so zajete v učni množici. Operaterjem je lahko v pomoč grafični prikaz novih vrednosti (navpične rdeče črte) glede na porazdelitve vrednosti, ki so zajete v učni množici.	88
7.1	<i>Hierarhija udeležencev projekta znotraj Koncerna Kolektor.</i> Med projektom sem imel v Koncernu Kolektor in njegovih podjetjih opravka z ljudmi na različnih nivojih.	93

Tabele

5.1	<i>Gibanje ocene R^2.</i> Prikazana je ocena modela v odvisnosti od števila latentnih spremenljivk (N) pri analizi z metodo glavnih komponent.	72
5.2	<i>Primerjava rezultatov.</i> Primerjava ocene R^2 po obeh uporabljenih regresijskih metodah.	76
6.1	<i>Singularne vrednosti matrike vhodnih podatkov.</i> Tabela prikazuje vseh 13 singularnih vrednosti matrike, urejene padajoče.	81
6.2	<i>Devianca modela logistične regresije.</i> Gibanje deviance modela v odvisnosti od števila latentnih spremenljivk (N) pri uporabi logistične regresije z metodo glavnih komponent.	83

Algoritmi

3.1	Izračun dnevnih čakalnih časov	34
3.2	Iskanje optimuma	36
4.1	Izgradnja regresijskega modela	49
6.1	Uvoz parametrov v sistem za upravljanje baz podatkov	78
6.2	Logistična regresija z metodo glavnih komponent	83

Dodatek A

Seznam objav iz disertacije

1. Kleindienst, J. Nadzor proizvodnje v kosovni industriji. *Ventil* **4**, (Fakulteta za strojništvo, Ljubljana, 2008).
2. Kleindienst, J.; Ceferin, S. Sledljivost v kosovni industriji. *Ventil* **5**, (Fakulteta za strojništvo, Ljubljana, 2008).
3. Kleindienst, J.; Juričić, Đ. Določanje optimalnega nabora informacijskih terminalov za spremljanje proizvodnje v kosovnih industrijah. *Strojniški Vestnik* **54/1**, (Fakulteta za strojništvo, Ljubljana, 2008).
4. Kleindienst, J.; Juričić, Đ. Optimal selection of information terminals for data acquisition in manufacturing processes. V: *EUROSIM - Congress on Modelling and Simulation* (Ljubljana, 2007).
5. Kleindienst, J.; Juričić, Đ. Določanje optimalnega nabora informacijskih terminalov za spremljanje proizvodnje v kosovnih industrijah. V: *Zbornik pete konference Avtomatizacija v industriji in gospodarstvu* (Društvo avtomatikov Slovenije, Maribor, 2007).

Dodatek B

Lienarna algebra

B.1 Prostori in baze

V linearni regresiji imamo opravka s preslikavo iz *prostora* vhodnih spremenljivk v *prostor* izhodnih spremenljivk. Principi prostora, podprostora in baze so pojasnjeni spodaj:

Množica vseh mogočih realno-številskih vektorjev x dimenzije n tvori *linearni prostor* \mathcal{R}^n . Če je $\mathcal{S} \in \mathcal{R}^n$ množica vektorjev, potem je *podprostor* razpet s \mathcal{S} (označen s $\mathcal{L}(\mathcal{S})$) množica vseh linearnih kombinacij vektorjev iz \mathcal{S} . Urejena množica linearno neodvisnih vektorjev θ_i , ki se razpenja čez ta prostor, je imenovana *baza* podprostora.

V splošnem so podprostori n razsežnega prostora hiperravnine, ki gredo skozi koordinatno izhodišče. Število linearno neodvisnih vektorjev baze podprostora definira razsežnost oziroma *dimenzijo* tega podprostora. Bazni vektorji θ_1 do θ_N so lahko predstavljeni v matrični obliki

$$\theta = (\theta_1 \mid \cdots \mid \theta_N) \quad (\text{B.1})$$

V N razsežnem podprostoru n razsežnega prostora ima bazna matrika dimenzijo $n \times N$. Z dano bazo lahko vsako točko x tega podprostora predstavimo enolično. Bazne vektorje θ_i lahko interpretiramo tudi kakor osi koordinatnega sistema podprostora. Točko v podprostoru lahko predstavimo tako, da bazne vektorje pomnožimo s skalarnimi vrednostmi z_i

$$x = \sum_{i=1}^N z_i \cdot \theta_i \quad (\text{B.2})$$

oziroma

$$x = \theta \cdot z \quad (\text{B.3})$$

Za izbiro baznih vektorjev (pod)prostora obstaja neskončno možnosti. Obstaja tudi posebna baza, t.i. *naravna baza*. Vse ostale baze je mogoče definirati z upoštevanjem naravne baze. V primeru meritve n spremenljivk so smeri baznih vektorjev določene s

spremenljivkami. Vsaka meritev je lahko obravnavana kot koordinatna vrednost, bazni vektorji pa tvorijo enotno matriko: $\theta = I_n$. Čeprav je ta trivialna baza enostavna za uporabo, ne pomeni nujno najboljše predstavitve podatkov.

B.2 Linearne preslikave

Matrike imajo lahko različne vloge pri predstavitvi podatkov. Lahko vsebujejo zbirke meritev (vhodne in izhodne spremenljivke X in Y), lahko se uporabljajo za ogrodje vektorskih sistemov (bazni vektorji), lahko pa služijo za *linearne transformacije* med različnimi bazami (pod)prostorov. Čeprav so vse matrične operacije linearne transformacije, so na tem mestu najbolj zanimive preslikave med različnimi bazami. Transformacija iz dane baze v naravno je enostavna, uporaba enačbe (B.3) neposredno vrne transformirane koordinate. Vprašanje pa je, kako dobiti koordinate točke z za dano točko x , če je podana nova baza θ . Glede na dimenzije n in N imamo tri možnosti:

- $n \equiv N$: matrika θ je kvadratna in obrnljiva¹. V tem primeru je potrebno rešiti enačbo

$$z = \theta^{-1} \cdot x \quad (\text{B.4})$$

- $n > N$: točke v tem primeru ni vedno mogoče predstaviti v novi bazi. Z uporabo metode najmanjših kvadratov izračunamo približek

$$\hat{z} = (\theta^T \theta)^{-1} \theta^T \cdot x \quad (\text{B.5})$$

- $n < N$: v tem primeru obstaja neskončno možnosti za predstavitev točke v novi bazi. Tudi tukaj poiščemo rešitev s pomočjo metode najmanjših kvadratov, le da tokrat v smislu minimizacije $z^T z$, oziroma iskanja minimuma vrednosti koordinat

$$z = \theta^T (\theta \theta^T)^{-1} \cdot x \quad (\text{B.6})$$

Vse zgornje primere lahko zapišemo v psevdoinverzni notaciji

$$z = \theta^\dagger \cdot x \quad (\text{B.7})$$

Če so bazni vektorji *ortonormalni*², velja $\theta^T \theta = I_N$ (ali $\theta \theta^T = I_n$). To pa pomeni, da imajo enačbe (B.4), (B.5) in (B.6) zelo preprosto rešitev

$$z = \theta^T \cdot x \quad (\text{B.8})$$

¹Obrnljivost je posledica predpostavljene linearne neodvisnosti baznih vektorjev.

²Ortonormalni vektorji so pravokotni in normirani. To pomeni, da je $\theta_i^T \theta_j = 0$, če velja $i \neq j$ in $\theta_i^T \theta_j = 1$, če velja $i = j$.

oziroma

$$Z = X \cdot \theta \tag{B.9}$$

Zgornji rezultat prikazuje pomen ortonormalne baze. Obstajajo pa še dodatne prednosti, ki so povezane z numeričnimi lastnostmi ortogonalnih transformacijskih matrik.