

Univerza v Ljubljani
Fakulteta za elektrotehniko

mag. Dejan Tinta

Odkrivanje napak pri velikoserijski proizvodnji elektromotorjev

Doktorska disertacija

Mentor: doc. dr. Đani Juričić

Ljubljana, 2006

Zahvala

Zahvaljujem se mentorju doc. dr. Daniju Juričiču, ki je v času mojega podiplomskega študija aktivno spremljal in vodil moje delo ter mi nesebično pomagal z dragocenimi nasveti.

Najlepša hvala prof. dr. Stanku Strmčniku za sprejetje na Odsek za sisteme in vodenje Instituta Jožef Stefan ter tehtne pripombe pri nastajanju tega dela.

Prof. dr. Rihardu Karbi se zahvaljujem za skrben pregled disertacije in kritične komentarje za njeno izboljšavo.

Iskrena zahvala gre dr. Janku Petrovčiču za njegovo nepogrešljivo strokovno pomoč in koristne nasvete predvsem pri eksperimentalnem delu.

Zahvalo sem dolžan tudi Dejanu Petelinu za usluge pri programiranju.

Za izkazano pomoč se zahvaljujem še vsem ostalim sodelavcem, ki so kakorkoli pripomogli k nastanku tega dela.

Zahvala velja tudi podjetju Domel d.d. iz Železnikov, katero je omogočilo raziskave, ki so predmet pričujočega dela, in Ministrstvu za visoko šolstvo, znanost in tehnologijo Republike Slovenije, ki je v okviru programa P2-0001 finančno podprlo moj podiplomski študij.

Ne nazadnje se toplo zahvaljujem svojim staršem za vsestransko podporo.

Iskrena hvala vsem, ki so mi stali ob strani na moji študijski poti.

Povzetek

Temeljita avtomatska kontrola izdelkov ima v sodobni velikoserijski proizvodnji elektromotorjev pomembno vlogo pri zagotavljanju kakovosti. Ostra konkurenca na trgu sili proizvajalce k uvajanju sistemov za hitro, zanesljivo in objektivno ocenjevanje kakovosti vsakega proizvedenega motorja. Zaradi specifičnih lastnosti različnih vrst elektromotorjev se izkaže, da splošnonamenski komercialni sistemi za avtomatsko testiranje le-teh v nekaterih primerih niso sposobni ovrednotiti vseh relevantnih parametrov kakovosti. To velja tudi za elektromotorje gospodinjskih sesalnikov (t.i. sesalne enote), na katere se osredotoči disertacija. Le-ti sestojijo iz univerzalnega elektromotorja in zračne turbine, ki sesa zrak. Z namenom, da bi ugodili zgoraj omenjenim zahtevam, je bil izdelan in na proizvodno linijo implementiran diagnostični sistem za avtomatsko preizkušanje sesalnih enot. Fizično je sistem zgrajen iz treh merilnih celic, v katerih se zajema kar deset različnih fizikalnih veličin. Funkcionalno pa ga lahko razdelimo na štiri module: preverjanje karakterističnih veličin sesalnih enot (napajalni tok, električna moč, podtlak in hitrost vrtenja), ocenjevanje kvalitete komutacije, analiza vibracij ter analiza zvoka. V omenjenih modulih se z uporabo različnih algoritmov obdelave signalov iz izmerjenih podatkov določi vrednosti značilk, ki kažejo na potencialne hibe enot. Širok nabor uporabljenih algoritmov zagotavlja zanesljivost, natančnost in občutljivost diagnostičnega sistema. Predstavljeni sistem omogoča odkrivanje slabih sesalnih enot in lokalizacijo izvorov napak.

V pričujoči disertaciji sta podrobneje obravnavana dva izmed omenjenih funkcionalnih modulov. To sta ocenjevanje kvalitete komutacije in analiza vibracij. Kvaliteta komutacije bistveno vpliva na življenjsko dobo univerzalnih elektromotorjev. Zaradi nenadnega prekinjanja toka na kolektorju se inducirajo visoke napetosti, ki povzročijo iskrenje med kolektorjem in ščetkami. Povečano iskrenje pa rezultira v hitrejši obrabi ščetk in kolektorja. Za ocenjevanje kvalitete komutacije sta uporabljena dva načina, pri čemer oba ocenjujeta električne motnje, ki se pojavijo pri procesu komutacije. Prvi temelji na zajemu napajalnega toka in njegovem opazovanju v različnih frekvenčnih območjih. S tem so ovrednotene motnje, ki se pojavijo v toku zaradi "sekanja" le-tega na kolektorju. Drugi način ocenjevanja kvalitete komutacije temelji na vrednotenju visokofrekvenčnih (megaherčnih) napetostnih motenj, katere se

na priključnih sponkah motorjev pojavijo zaradi induciranih napetosti med ščetkami in kolektorjem. Višje kot so te napetosti in posledično intenzivnejše iskrenje, višji je nivo omenjenih motenj. Na podlagi histograma amplitud izbruhov visokofrekvenčnih napetostnih motenj, ki jih meri v ta namen razvita naprava, sta določeni dve značilki. Analiza občutljivosti vseh značilk kvalitete komutacije pokaže, da drugi način ocenjevanja daje mnogo bolj verodostojne rezultate.

Za analizo vibracij lahko trdimo, da je že standarden pristop pri spremljanju delovanja rotacijskih strojev. V primeru sesalnih enot obstajajo trije razlogi za uporabo analize vibracij. Povečane vibracije pomenijo prvič večjo obrabo ležajev. Drugič, vibracije sesalne enote lahko povzročajo hrup sesalnika, ki je moteč za uporabnika. In tretjič, v signalu vibracij so vsebovane informacije o nekaterih lastnostih sesalnih enot. V pričujočem delu so raziskani glavni viri vibracij pri sesalnih enotah. Določen je merilni postopek, ki na osnovi uporabe laserskega merilnika vibracij omogoča avtomatsko izvedbo meritev v treh merilnih točkah (na turbini v aksialni in radialni smeri ter na ohišju v radialni smeri) in zagotavlja minimalen vpliv motilnih vibracij iz okolja. Nadalje so definirane ustrezne značilke vibracij, ki kažejo na določene potencialne napake na enotah. Pri tem je najpomembnejše odkrivanje neuravnoteženosti rotirajočih delov enot. Izvedena je tudi analiza omenjenih značilk in sicer v smislu ponovljivosti meritev vibracij ter v smislu medsebojne odvisnosti oz. neodvisnosti.

Z namenom nadgradnje obstoječega diagnostičnega sistema za potrebe boljše podpore pri spremljanju delovanja proizvodnega procesa je opravljena statistična analiza rezultatov testiranja sesalnih enot na koncu proizvodne linije. Najprej je z uporabo korelacijske analize in dekompozicije po singularnih vrednostih preverjena medsebojna odvisnost vseh značilk. Pri tem se izkaže, da so nekatere značilke močno korelirane med seboj. Nadalje so analizirane porazdelitve posameznih značilk, katerih neparametrično oceno smo dobili s pomočjo histogramov. Porazdelitev "prave" značilke mora imeti vsaj dva izrazitejša vrhova ali pa t.i. rep. V nasprotnem primeru značilka namreč ni ustrezno definirana, saj se ne odziva na nobene spremembe stanja sesalnih enot.

Kakršnekoli spremembe v proizvodnem procesu se v večini primerov odražajo tudi na končnih izdelkih oz. v vrednostih nekaterih značilk. Pri tem ni rečeno, da slednje prekoračijo dopustne meje, temveč se le spremeni njihova porazdelitev. Tako je možno z odkrivanjem sprememb v časovnih vrstah, ki jih v konkretnem primeru tvorijo vrednosti značilk pri zaporedno proizvedenih sesalnih enotah, sklepati na določene spremembe v proizvodnji. S tem namenom se v okviru klasične statistične kontrole, ki predpostavlja normalno porazdelitev podatkov, prikazujejo časovni poteki in nekateri statistični parametri (npr. srednja vrednost, standardna deviacija). V pričujočem delu je predlagana aplikacija Kullback-Leibler-jeve razdalje za detekcijo sprememb v porazdelitvah. Le-ta je uporabna tudi v primerih nenormalnih porazdelitev, ki pa so v praksi (npr. večina obravnavanih značilk) precej pogosti. Njene lastnosti so prikazane

na primeru normalne porazdelitve ob spremenljivi srednji vrednosti in standardni deviaciji. S Kullback-Leibler-jevo razdaljo se primerja trenutno (ocenjeno na množici nazadnje pridobljenih podatkov) porazdelitev posamezne značilke z "referenčno" porazdelitvijo, ki je določena na osnovi vrednosti značilke pri skupini dobrih sesalnih enot. Nadalje je predlagana še utežitev opazovane porazdelitve z linearno funkcijo. Tako je obravnavana mera bolj občutljiva, ko se trenutna porazdelitev začne pomikati proti mejni vrednosti značilke.

Nazadnje je predstavljena zasnova prototipa sistema statistične kontrole. Obstoječa verzija omogoča predvsem selektivno pregledovanje in prikazovanje diagnostičnih rezultatov.

V disertaciji so torej podane nekatere nove rešitve za detekcijo in lokalizacijo napak pri sesalnih enotah. Predlagan pa je tudi nov pristop v okviru statistične kontrole procesov.

Abstract

Profound and automatic quality tests in modern mass production of electric motors play important role in the quality assurance of products. Tough competition on the market increases the need for fast, reliable and objective quality assessment of every single produced motor. Due to specific properties of different types of electric motors common commercial systems for automatic quality testing often fail in the evaluation of all relevant quality parameters in all cases. This holds true also for vacuum cleaner motors, which are discussed in the thesis. A vacuum cleaner motor consists of a universal electric motor and an air turbine serving for air suction. As a step towards meeting the above mentioned objectives, a diagnostic system for automatic quality tests of the vacuum cleaner motors has been designed and also implemented to the assembly line. Physically the system consists of three measuring cells, which measure and gauge ten different physical quantities. Functionally, the system can be divided in four modules, i.e. testing of characteristic quantities of vacuum cleaner motors (supply current, electric power, pressure drop and revolution speed), commutation quality assessment, vibration analysis and sound analysis. Some features are derived from measured data by using different signal processing algorithms. The presence of potential motor faults reflects in the feature values. Such a comprehensive set of algorithms ensures the reliability, precision and in particular sensitivity of the diagnostic system. The system enables detection of faulty motors as well as localisation of fault origin.

In the thesis two functional modules are discussed in details, i.e. commutation quality assessment and vibration analysis. The first substantially impacts universal electric motor lifetime. The commuted collector current induces high voltage peaks, which generate sparking between collector and brushes. Increased sparking causes increased wear of brushes and collector. The commutation quality assessment is performed in two ways. Both of them are based on the assessment of electrical disturbances appearing in commutation process. The first method applies the acquisition of supply current and its evaluation in different frequency areas. In that way the disturbances due to current "cutting" on collector are measured. The second way of the commutation quality assessment is based on the evaluation of high-frequency (megahertz) voltage disturbances, which appear on the motor contacts due to induced

voltage between brushes and collector. The higher is the induced voltage and consequently more intensive sparking, the higher is the level of the disturbances. Amplitudes of outbursts of the high-frequency voltage disturbances are measured by specially designed device. The amplitudes are arranged into a histogram, which serves for derivation of two features. The sensitivity analysis of all commutation related features shows that the second method gives much more credible results.

It is well known that vibration analysis is a standard tool in monitoring rotating machines. In the case of the vacuum cleaner motors its use is justified by three reasons. Increased vibrations cause damages of motor bearings, motor's vibrations can produce unpleasant noise, which is disturbing for end-users, and finally vibration signal carries information about certain motor's properties. In the present work the main vibration sources in vacuum cleaner motors are studied. A measurement procedure based on application of a laser vibrometer is determined. It ensures the elimination of environment vibrations and automatically performs the measurements in three measuring points (on the housing and on the turbine in radial direction and on the turbine in axial direction). Further, the corresponding features, which reflect potential motor faults, are defined. The most important issue here is to reveal unbalanced rotating parts of the motor. The analysis of the repeatability of vibration measurements and the feature independence analysis are also reported.

In order to upgrade the present diagnostic system according to demands for better support in production process performance monitoring, the statistical analysis of end-testing results of manufactured vacuum cleaner motors is performed. First, the mutual dependence of all features is checked by using correlation analysis and singular value decomposition. It is shown that strong correlations between some features exist. Further, distributions of the features are analysed. The nonparametric assessments of distributions are obtained by histograms. The distribution of the "true" feature has to have at least two significant peaks or so called tail. In the opposite case it means that the feature is not defined adequately. Namely, it does not respond to conditions changes in the vacuum cleaner motor.

In most cases, changes in the production process reflect also in the end product, i.e. in some of its features. The distributions of features change, however it does not necessarily imply that they exceed the thresholds. So, some changes in the production can be discovered by detecting changes in time series consisting of the feature values obtained on the consecutively produced motors. In the classical statistical process control, which assumes normal distributions of the data, time charts and some statistical parameters (e.g. mean, standard deviation) are displayed. In the present work the application of Kullback-Leibler distance for change detection in distributions is introduced. It is usable also in the cases of non-normal distributions, which frequently occur in the practice (e.g. most of the discussed features). The properties of the distance under consideration are presented in the example of a normal distribution with varying

mean and standard deviation. By using Kullback-Leibler distance the current distribution (assessed on the set of last obtained data) is compared with "reference" distribution determined according to the feature values in the group of flawless vacuum cleaner motors. Further, the weighting of the observed distribution by a linear function is proposed. In that way the discussed measure becomes more sensitive when the current distribution starts to move towards the feature threshold.

Finally, the design of the prototype system for statistical process control is presented. The current version enables selective inspection of the data and displaying of the diagnostic results.

Let us briefly summarize. Some new solutions for fault detection and localisation in vacuum cleaner motors are given in the thesis. A new approach in the statistical process control is also proposed.

Kazalo

1. Uvod	1
2. Nadzor tehničnih sistemov	5
2.1 Lastnosti diagnostičnih sistemov.....	7
3. Končna kontrola kakovosti sesalnih enot v Domelu	9
3.1 Opis sesalne enote družine 463	9
3.1.1 Sesalna enota tipa 463.3.201	11
3.1.2 Napake pri sesalnih enotah družine 463.....	12
3.2 Prvotno stanje sistema kontrole končnih izdelkov	13
3.3 Avtomatski diagnostični sistem za končno kontrolo sesalnih enot.....	15
3.3.1 Zgradba diagnostičnega sistema.....	15
3.3.2 Merilne celice in njihove funkcije.....	16
3.3.3 Delovanje diagnostičnega sistema.....	18
4. Detekcija in lokalizacija napak na končnih izdelkih	21
4.1 Ocenjevanje kvalitete komutacije.....	21
4.1.1 Komutacija pri univerzalnih elektromotorjih	24
4.1.2 Opis metod za ocenjevanje kvalitete komutacije sesalnih enot.....	26
4.1.2.1 Analiza napajalnega toka.....	27
4.1.2.2 Vrednotenje visokofrekvenčnih napetostnih motenj	30
4.1.3 Analiza občutljivosti značilik kvalitete komutacije.....	35
4.1.4 Statistična analiza značilik kvalitete komutacije	41
4.1.4.1 Statistika pojavljanja sesalnih enot z neustrezno komutacijo.....	41
4.1.4.2 Korelacija med značilkami kvalitete komutacije	43
4.2 Merjenje vibracij	44
4.2.1 Pojasnitev izvorov vibracij pri sesalnih enotah.....	46

4.2.2 Opis merilnega postopka merjenja vibracij v Domelu	51
4.2.3 Analiza značilk za vrednotenje vibracij pri sesalnih enotah.....	53
5. Nadzor proizvodnje	59
5.1 Statistična analiza diagnostičnih rezultatov z linje.....	63
5.1.1 Analiza odvisnosti značilk.....	65
5.1.1.1 Korelacijska analiza.....	66
5.1.1.2 Dekompozicija po singularnih vrednostih.....	67
5.1.1.3 χ^2 test neodvisnosti.....	69
5.1.2 Porazdelitev značilk.....	71
5.2 Zaznavanje sprememb v kakovosti izdelkov.....	80
5.2.1 Lastnosti Kullback-Leibler-jeve razdalje	80
5.2.2 Uporaba Kullback-Leibler-jeve razdalje pri zaznavanju sprememb v kakovosti izdelkov.....	86
5.3 Zasnova sistema statistične kontrole	91
5.3.1 Analiza zahtev in izvedba.....	91
5.3.2 Prikaz delovanja	93
6. Zaključek.....	95
Literatura	99
Dodatek A.....	107
Dodatek B.....	111
Dodatek C.....	119
Dodatek D.....	123
Dodatek E.....	135

1. Uvod

Kakovost v industriji lahko na splošno definiramo kot stopnjo, s katero produkt in s tem tudi delovanje proizvodnega procesa zadovoljuje specifikacijam, ki jih postavlja uporabnik. Za to je potrebna vključenost načrtovalcev, procesnih inženirjev, operaterjev, vzdrževalcev in podpora vodstva. Skupen cilj vseh mora biti izboljšava, pohitritev in pocenitev proizvodnje.

Pri ocenjevanju kakovosti je ključnega pomena standardizacija merjenja kakovosti. Ta pride do izraza posebno v primerih, ko ne obstajajo splošno uveljavljena merila. Standardizacijo merjenja kakovosti lahko definiramo kot kontinuiran, objektivni proces meritev in izboljšav produktov ter proizvodnih procesov v primerjavi z najboljšimi v določeni branži z namenom doseči in obdržati konkurenčno prednost. Bistvo je (Olsson in Newell, 1999):

- nenehno primerjanje trenutnega stanja proizvodnje z njenim stanjem v preteklosti in
- nenehno primerjanje trenutnega stanja proizvodnje s stanjem proizvodnje najboljših proizvajalcev v neki branži.

Ocenjevanje kakovosti vedno temelji na meritvah, včasih pa lahko tudi na subjektivnih ocenah. Ob tem se postavljata dve vprašanji: kako pogosto meriti in kje meriti. Pogostost meritev zavisi od pogostosti motenj, posledic neodkritja motenj in določitev, kaj je sprejemljivo tveganje. Za meritve pa imamo dve možnosti:

- Meritve na končnem produktu, ki kažejo, če le-ta ustreza specifikacijam.
- Meritve motenj na proizvodnem procesu.

Seveda je ob tem potrebno pretehtati tudi ekonomsko upravičenost, pri čemer moramo poleg stroškov upoštevati tako neposredne kot posredne koristi. Z boljšo kontrolo nad parametri kakovosti namreč lahko dosežemo nižje stroške proizvodnje, saj se izognemo kršitvam mejnih vrednosti, po drugi strani pa zmanjšan raztros omogoča delovanje proizvodnje bliže še dopustnim mejam (Olsson in Newell, 1999).

Proces zagotavljanja kakovosti je najtesneje povezan s procesom zaznavanja in lokalizacije napak. Gre za področje, ki je v zadnjih treh desetletjih doživelo zelo intenziven razvoj, pri čemer lahko razlikujemo štiri glavne metodološke usmeritve:

- metode, ki temeljijo na analitičnih modelih,
- metode zasnovane na kvalitativnih modelih,
- metode, ki temeljijo na statističnih pristopih in podatkih iz procesne zgodovine ter
- metode, ki imajo za podlago analizo signalov.

Takšna raznovrstnost je rezultat izjemno pisane specifičnosti posameznih problemskih domen.

Kljub hitro naraščajoči stopnji avtomatizacije v proizvodnih procesih pa avtomatizirana končna kontrola kakovosti relativno počasi prodira v industrijsko prakso. Uveljavila se je predvsem na gospodarskih področjih z višjo stopnjo donosnosti. Vzrok temu je specifičnost posameznih rešitev, ki zahtevajo razvoj novih in vedno bolj zahtevnih pristopov, merilnih metod ter algoritmov. V številnih industrijskih branžah pa so še precej prisotni ročna subjektivna kontrola, preverjanje na naključnih vzorcih ali uporaba preprostih postopkov klasične statistične kontrole. Slednji so lahko v pomoč zgolj za odkrivanje deviacij v kakovosti, ne pomagajo pa pri ugotavljanju dejanskih vzrokov zanjo. Zato vse bolj narašča potreba po nadomestitvi tovrstnih postopkov z avtomatskimi sistemi, ki bi omogočali sprotno in natančno spremljanje stanja proizvodnega procesa in kakovosti vsakega posamičnega končnega izdelka. Tak način kontrole vključuje sposobnost detekcije in lokalizacije morebitnih napak že v zelo zgodnji fazi.

V disertaciji bo kot primer aplikacije kontrole kakovosti podrobneje obravnavano področje električnih rotacijskih strojev, ki so zelo razširjeni tako v proizvodnih procesih kot tudi v izdelkih za široko uporabo. Zgodnje odkrivanje napak (električnega in mehanskega izvora) na omenjenem področju je predmet obsežnih raziskav, zato najprej omenimo le nekaj preglednih člankov: Randall (2002), Isermann (1984), Edwards in sodelavci (1998), Nandi in Toliyat (1999), Mathur in sodelavci (2001) itd. Številni avtorji namreč predlagajo različne pristope za diagnosticiranje specifičnih napak na določenih vrstah elektromotorjev. Zelo učinkovita je izvedba, ki na podlagi analize toka odkriva različne električne in mehanske napake (Gühmann in Filbert, 1991; Röpke in Filbert, 1994; Filbert in Gühmann, 1994; Burnett in sodelavci, 1996). Žal pa ta rešitev v našem primeru ni uporabna, saj serijska vezava rotorskih in statorskih navitij pri univerzalnih motorjih povzroča dušenje hitrih sprememb toka, v katerih se odražajo omenjene napake. Analize toka v kombinaciji z analizo vibracij se poslužujejo tudi Yang in Penman (2000) ter Payne in sodelavci (2000a). Vetter in sodelavci (1994) problem diagnosticiranja elektromotorjev na koncu proizvodne linije rešujejo s pomočjo

analize vibracij in matematičnega modela. Slednjega kot generator značilik za potrebe odkrivanja napak na elektromotorjih uporabljajo tudi Albas in sodelavci (2000), Atay in sodelavci (2001) ter Albas in sodelavci (2006). Sasi in sodelavci (2001) predlagajo opazovanje merjenih veličin na rotacijskem elektromotorju glede na kot zasuka znotraj enega obrata (normiranje s trenutno hitrostjo vrtenja). Ta pristop je primeren predvsem za odkrivanje mehanskih napak pri motorjih z nekonstantno hitrostjo vrtenja.

Na trgu pa obstajajo tudi nekateri komercialni diagnostični sistemi. Schenck (2006) ponuja sistem, ki temelji na analizi vibracij in na matematičnem modelu, medtem ko se Vogelsang & Benning (2006) poslužuje analize vibracij in kvalitete komutacije. Artesis-ov (2006) sistem prav tako deluje na osnovi modela motorja. Značilnost tovrstnih sistemov je splošnonamenskost, tj. uporabnost za različne vrste elektromotorjev. Prav to pa je vzrok za njihovo največjo slabost in sicer premajhno diagnostično občutljivost na nekatere napake pri specifični družini elektromotorjev.

Glavni namen sistemov za avtomatsko končno kontrolo je preizkusiti vsak proizveden izdelek in ga ob morebitnem neustreznemu standardom kakovosti izločiti iz dobave oz. ga glede na določene parametre razvrstiti v ustrezen kakovostni razred. Njihova prednost je večja zanesljivost, objektivnost, natančnost in možnost vrednotenja novih oz. dodatnih parametrov kakovosti.

Poleg same tehnologije za izvedbo testiranja izdelkov pa so pri vpeljevanju diagnostičnih sistemov v proizvodne procese pomembni še drugi vidiki. Avtomatska končna kontrola kakovosti produktov namreč predstavlja le del celotnega sistema zagotavljanja kakovosti v nekem podjetju. Z njeno implementacijo se pojavijo nove povezave oz. možnosti novih povezav z ostalimi segmenti celotnega sistema zagotavljanja kakovosti, kot so npr. trajnostni testi, morebitna kontrola vstopnih surovin oz. sestavnih delov, upravljanje proizvodne linije, razvoj novih tipov oz. izboljšava izdelkov itd. Vse to pa predstavlja dodatne koristi, ki pripomorejo k še boljši kakovosti končnih izdelkov. Zato je celovit pogled na proces zagotavljanja kakovosti zelo pomemben.

Kot že rečeno je ena izmed koristi vpeljave avtomatske končne kontrole tudi pomoč pri upravljanju proizvodne linije. Podatki, ki jih kot rezultate testiranja daje diagnostični sistem, predstavljajo koristen vir informacij za operaterje pri sprejemanju odločitev o potrebnih ukrepih na liniji. V ta namen omenjeni komercialni sistemi za končno kontrolo že ponujajo možnost pregleda zgodovine diagnostičnih rezultatov in prikaz nekaterih osnovnih statističnih parametrov (npr. srednja vrednost, raztros). Kot neizkoriščena možnost se kaže detajlnejša sprotna analiza omenjenih podatkov v smislu podpore operaterjem pri nadzoru proizvodne linije.

V tem delu predstavljene raziskave in dognanja se nanašajo na konkreten primer zagotavljanja kakovosti pri proizvodnji elektromotorjev za gospodinjске sesalnike (t. i. sesalnih enot) v podjetju Domel.

Poleg uvodnega pričujoča disertacija obsega še pet poglavji. V drugem so predstavljene funkcije nadzora tehničnih sistemov in splošne lastnosti diagnostičnih sistemov. Tretje poglavje nas seznanja s stanjem končne kontrole kakovosti sesalnih enot v Domelu. Četrto je namenjeno predstavitvi dveh specifičnih rešitev na nivoju detekcije in lokalizacije napak na elektromotorjih. Razdeljeno je na dve obsežnejši podpoglavji. V prvem je obravnavano ocenjevanje kvalitete komutacije pri univerzalnih elektromotorjih, v drugem pa analiza vibracij sesalnih enot. Peto poglavje služi opisu rešitev na nivoju nadzora proizvodnje. V njem so podani statistična analiza diagnostičnih rezultatov z linije, predlog uporabe Kullback-Leibler-jeve razdalje za detekcijo sprememb v časovnih vrstah ter zasnova prototipa sistema statistične kontrole. V zaključnem šestem poglavju so povzeti glavni rezultati tega dela, izpostavljeni originalni prispevki k znanosti in predlagane smernice za nadaljnje delo. Seznamu uporabljene literature sledi pet dodatkov, v katerih so podana nekatera pojasnila in slike, ki dopolnjujejo glavno besedilo disertacije z namenom boljšega razumevanja tematike.

2. Nadzor tehničnih sistemov

Pod pojmom nadzor razumemo sprotno ugotavljanje stanja tehničnega sistema (Juričić, 1998). Pri tem gre za tri pomembne vidike:

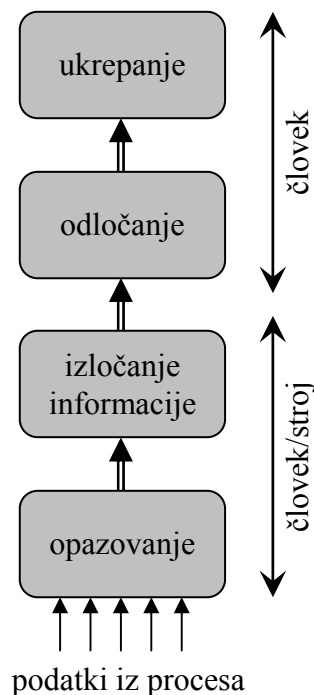
- stanje obratovanja sistema,
- stanje opreme in
- stanje izdelkov proizvodnje.

Stanje, v katerem sistem obratuje, je ponavadi določeno z nekim območjem procesnih veličin. Krmilno-regulacijski sistem poskrbi, da se procesne veličine tudi dejansko gibljejo v tem področju. Morebitno odstopanje se sporoči operaterju v obliki alarma. Včasih pa dejanskega stanja ni mogoče neposredno meriti. Zato si moramo pomagati s t.i. izpeljanimi veličinami, ki jih dobimo z matematičnimi operacijami nad dostopnimi meritvami.

Ugotavljanje stanja opreme se v tradicionalni industrijski praksi rešuje s periodičnimi pregledi oz. med rednimi remontami. Pri kritičnih tehnologijah, kjer so posledice napak lahko povezane z velikimi stroški (npr. elektrarne, železarne itd.), pa je potrebno zagotoviti sprotno ugotavljanje stanja opreme. Vsako nepravilno delovanje je potrebno odkriti dovolj zgodaj. Le tako lahko namreč preprečimo nepričakovane ustavitve proizvodnega procesa in zagotovimo ustrezno kakovost izdelkov.

Namen ugotavljanja stanja izdelkov je sprotno določanje njihove kakovosti in po možnosti odkrivanje vzrokov za morebitna odstopanja od predpisanih normativov. Problematika je precej podobna problematiki ugotavljanja stanja opreme.

V podporo izvajanju omenjenih nalog služijo naslednje operacije: zbiranje meritev iz procesa, njihovo shranjevanje v obliki baze podatkov o zgodovini delovanja procesa ter njihova predstavitev v numerični ali grafični obliki za potrebe operaterjev. Na podlagi predstavljenih podatkov iz procesa mora operater najprej izločiti pomembne informacije in nato sprejeti odločitev ter ukrepati. Opazovanje, izločanje informacije, odločanje in ukrepanje operaterja tako tvorijo nadzor procesa (Slika 2.1).



Slika 2.1: Osnovne faze pri nadzoru tehničnih sistemov

Naloge operaterja v sklopu nadzora tehničnih sistemov so (Juričić, 1998):

- opazovati prikaze s podatki o procesnih veličinah,
- pravilno oceniti stanje v primeru pomanjkljivih ali premalo natančnih podatkov,
- ugotoviti sleherno odstopanje od normalnega stanja v delovanju procesa,
- sklepati o možnih vzrokih za nepravilno delovanje,
- ukrepati v izjemnih razmerah in prevesti sistem v področje varnega in učinkovitega delovanja

Operater težko kakovostno in zanesljivo opravlja toliko nalog. Glavni problem je v tem, da ni vsak posredovani podatek tudi informacija o stanju sistema. Šele kombinacija več podatkov z upoštevanjem medsebojnih povezav daje pravo sliko o stanju sistema. Običajno mora le-to opraviti operater sam, kar zahteva veliko izkušenj, zbranosti in stalne pozornosti. Zato se od sodobnih nadzornih sistemov pričakuje, da bodo nudili tudi podporo operaterju pri izločanju pomembne informacije iz podatkov ter le-to predstavili v jasni in preprosto dosegljivi obliki. S tem operaterja razbremenimo odvečnih naporov, kar lahko ugodno vpliva na opravljanje drugih nalog, kot sta končno odločanje in ukrepanje (Slika 2.1).

Osnovne funkcije sodobnih nadzornih sistemov lahko opredelimo kot:

- zbiranje podatkov,

- generiranje poročil,
- shranjevanje podatkov,
- alarmiranje,
- prikazovanje in ročno vodenje,
- generiranje izpeljanih veličin ter
- odkrivanje napak.

Današnji SCADA (ang. Supervisory Control And Data Acquisition) sistemi praviloma obsegajo prvih pet in deloma šesto funkcijo. Avtomatsko odkrivanje napak ter generiranje zahtevnejših izpeljanih veličin nastopata bolj redko.

Pri generiranju izpeljanih veličin gre za širjenje nabora veličin, ki jih dobimo z matematičnimi operacijami nad eno ali več znanimi veličinami. Na ta način se računajo:

- trendi v statistiki procesnih veličin,
- ocene nemerljivih, a pomembnih stanj procesa,
- ocene redko vzorčenih reguliranih veličin, za katere ne obstajajo ustrezna tipala, temveč le laboratorijske analize.

Izpeljave navadno temeljijo na statističnih zakonih ali znanih fizikalnih relacijah.

Pri avtomatskem odkrivanju napak gre za sprotno odkrivanje potencialnih virov nepravilnega delovanja naprav, ki lahko pripeljejo proces iz zahtevanega območja delovanja ali celo do izpada. Znanih je veliko pristopov k odkrivanju napak v tehničnih sistemih. Izbrati pa je potrebno tak diagnostični sistem, ki s svojimi lastnostmi zadovolji postavljene zahteve.

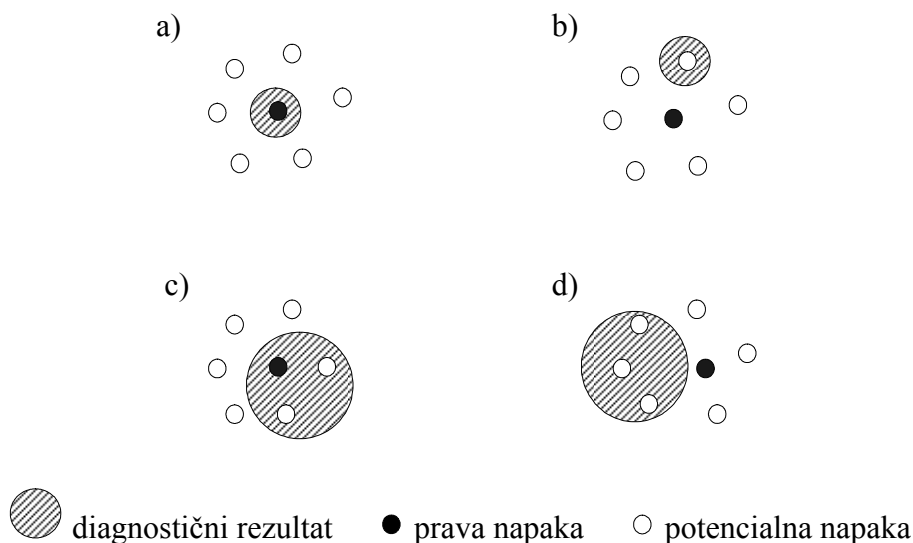
2.1 Lastnosti diagnostičnih sistemov

Diagnostični sistem lahko jemljemo kot klasični merilni instrument, ki "meri" oz. zaznava napake. Zato lahko njegove zmogljivosti opišemo z lastnostmi, kot so:

- točnost – točna diagnoza je tista, ki vsebuje pravo napako v naboru kandidatov za napako,
- ločljivost – zmožnost sistema, da na osnovi dane informacije iz sistema poda minimalno število kandidatov za napako (idealno le enega),
- robustnost – zmožnost sistema podati točno diagnozo kljub prisotnosti šuma,

- občutljivost – zmožnost sistema zaznati majhne napake, ki povzročijo le majhne spremembe simptomov,
- diagnostična stabilnost – zmožnost sistema podati nespremenjen nabor kandidatov za napako ob nespremenjenem stanju sistema,
- zanesljivost – zmožnost sistema, da poda točno diagnozo za vse napake, vključno z nepredvidenimi napakami, pri katerih ni izkušenj iz preteklosti.

Seveda si želimo čim večjo točnost, dobro ločljivost ter stabilen in zanesljiv diagnostičen rezultat. Zaradi realnih omejitev pa navadno vseh zahtev ne moremo povsem zadovoljiti. Dobra ločljivost pomeni rezultat s čim manjšim naborom možnih napak, idealno z le enim kandidatom. S tem pa se poveča možnost, da je izbrana napaka napačna, kar ima za posledico netočnost diagnoze (Slika 2.2). Podobno lahko povečana občutljivost diagnostičnega sistema ob prisotnosti šuma vodi do neprestanih sprememb diagnostičnih rezultatov (nestabilnosti) in slabe robustnosti sistema (Kramer, 1987). Zato je pri načrtovanju diagnostičnega sistema v splošnem vedno potreben kompromis. Načrtovanje diagnostičnega sistema se začne s postavitvijo zahtev v skladu z danimi realnimi možnostmi.



Slika 2.2: Točnost vs. ločljivost: a) dobra točnost in ločljivost, b) slaba točnost in dobra ločljivost, c) dobra točnost in slaba ločljivost, d) slaba točnost in ločljivost

3. Končna kontrola kakovosti sesalnih enot v Domelu

Sesalna enota je sopomenka za univerzalni elektromotor z zračno turbino, ki služi sesanju zraka pri gospodinjskih sesalnikih. Podjetje Domel Železniki je po velikosti eden izmed vodilnih evropskih proizvajalcev sesalnih enot, s katerimi oskrbuje zahtevne kupce, kot so Electrolux, Rowenta, AEG, Kärcher itd. Le-ti postopoma silijo proizvajalce k nenehnemu izboljševanju kakovosti in zanesljivosti sesalnih enot. Trendi na trgu praktično gredo v smeri zagotavljanja 100-odstotne brezhibnosti enot, s čimer bi se zmanjšali stroški servisiranja sesalnikov. Po drugi strani pa ostra konkurenca v tej branži od proizvajalcev terja stalno zniževanje stroškov proizvodnje. Tem zahtevam se lahko ugotovi z uvedbo učinkovitega sistema zagotavljanja kakovosti končnih izdelkov.


3.1 Opis sesalne enote družine 463

Sesalna enota iz družine 463, ki je prikazana na sliki 3.1, je namenjena vgradnji v sesalnike za suho sesanje. Zračno turbino enote sestavljata turbinsko kolo in pokrov turbine. Elektromotor pa sestoji iz rotorja, na katerem je nameščen tudi kolektor, statorja, ščetk in ohišja. Rotor je v ohišje vpet z dvema krogličnima ležajema.



Slika 3.1: Sesalna enota družine 463

Turbinsko kolo z devetimi lopaticami, ki je pritrjeno na os motorja, služi sesanju zraka skozi odprtino na pokrovu turbine. Ta zračni tok se nato izkoristi tudi za hlajenje motorja, zato je s pomočjo usmernikov zraka usmerjen skozi režo med rotorjem in statorjem, tako da čim bolje odvajata toploto, ki zaradi izgub nastaja predvsem na rotorju, statorju in kolektorju.



Slika 3.2: Električna shema univerzalnega elektromotorja

Elektromotor sesalne enote je enofazni komutatorski motor v serijski vezavi, katerega električno shemo vidimo na sliki 3.2. Zgradba in princip delovanja tega motorja sta enaka kot pri enosmernem elektromotorju. Magnetilni tok I skozi statorski navitji ustvari vzbujalno magnetno polje Φ . Isti tok I teče kot bremenski tok tudi skozi rotorska navitja, saj so le-ta prek ščetk in kolektorja serijsko vezana s statorskima navitjema. Na ta način je doseženo, da sta magnetilni in bremenski tok v fazi, kar zagotavlja največji vrtilni moment motorja. Sklop ščetke-kolektor ima funkcijo mehanskega stikala, ki preklaplja med rotorskimi navitji, tako da bremenski tok kljub vrtenju rotorja teče po rotorskih navitjih vedno v ustrezni smeri. S tem je zagotovljeno, da vse elektromagnetne sile, ki delujejo na rotorska navitja v vzbujalnem magnetnem polju, povzročajo moment v isti smeri. Obravnavani elektromotor se odlikuje z velikim zagonskim vrtilnim momentom, medtem ko so njegove slabosti povezane predvsem s

komutacijo, pri kateri prihaja do obrabe ščetk in kolektorja. Ker ga je mogoče priključiti tako na izmenično kot na enosmerno napetost, mu pravimo tudi univerzalni elektromotor (Chapman, 2002; Zagradišnik in Slemnik, 2001; Jereb, 1975).

3.1.1 Sesalna enota tipa 463.3.201

Znotraj družine 463 obstajajo različni tipi sesalnih enot, ki pa se med sabo bistveno ne razlikujejo. V tem podglavju so za primer podrobneje predstavljene lastnosti sesalne enote tipa 463.3.201. Njene nazivne vrednosti so podane v tabeli 3.1. Največje zagotovljene vrednosti, ki jih ta enota lahko doseže in so pomembne pri vrednotenju njene zmogljivosti oziroma učinkovitosti, pa lahko razberemo iz tabele 3.2. Zračna moč je koristen del vhodne moči, ki ga sesalna enota porablja izključno za doseganje svojega namena, to je za sesanje zraka. Definirana je kot produkt podtlaka, ki ga enota ustvari, in pretoka zraka. Izkoristek je določen z razmerjem zračne moči in vhodne moči, ki je enaka produktu napajalne napetosti in električnega toka. Izkoristek torej kaže, kolikšen delež vhodne moči, ki jo enota troši, se koristno porabi. Razlika omenjenih moči predstavlja izgube sesalne enote. Zato je prav izkoristek eden važnejših parametrov sesalnih enot.

Tabela 3.1: Nazivne vrednosti sesalne enote tipa 463.3.201

Napajalna napetost [V]	Frekvenca napajalne napetosti [Hz]	Vhodna moč [W]	Masa [kg]
230	50	1600	1.03

Tabela 3.2: Minimalne zagotovljene vrednosti pri sesalni enoti tipa 463.3.201

Podtlak [kPa]	Pretok zraka [dm ³ /s]	Zračna moč [W]	Izkoristek [%]
≥ 35.6	≥ 42	≥ 550	≥ 42

V tabeli 3.3 je prikazana karakteristika obravnavane sesalne enote posneta med obratovanjem enote pri nazivni napajalni napetosti (230 V) in pri različnih obremenitvah. Obremenitev sesalne enote določa velikost odprtine, skozi katero enota sesa zrak. Odprtina na pokrovu turbine ima premer $\phi = 40$ mm. Le-ta se lahko poljubno zmanjša s pomočjo posameznih zaslonk z izvrtanimi luknjami različnih premerov, ki jih na pokrov turbine prisesa zračni tok. Z zmanjšanjem odprtine se zmanjša tudi obremenitev. Posledica je večja hitrost vrtenja sesalne enote. Zaradi tega se na rotorskih navitjih inducira višja napetost, kar povzroči zmanjšanje električnega toka in s tem tudi vhodne moči. Nadalje je iz tabele 3.3 razvidno, da z manjšanjem zaslonke podtlak narašča, medtem ko pretok zraka pada. Zračna moč in izkoristek dotične sesalne enote dosežeta največjo vrednost pri zaslonki z odprtino premera $\phi = 16$ mm.

Tabela 3.3: Karakteristika sesalne enote tipa 463.3.201

Zaslonka ϕ [mm]	Tok [A]	Vhodna moč [W]	Hitrost vrtenja [min ⁻¹]	Podtlak [kPa]	Pretok zraka [dm ³ /s]	Zračna moč [W]	Izkoristek [%]
40	7.10	1573	39840	1.9	42.4	82	5.2
30	6.96	1541	40320	5.6	40.2	224	14.5
23	6.65	1474	41520	12.5	34.8	435	29.5
19	6.30	1395	43000	19.0	28.7	546	39.1
16	5.90	1307	44760	24.2	22.7	549	42.0
13	5.41	1198	47300	28.6	16.1	462	38.5
10	4.91	1087	50420	30.8	9.9	305	28.0
6.5	4.40	984	54040	31.9	4.3	138	14.0
0	4.70	1049	53720	35.6	0.0	0	0.0

3.1.2 Napake pri sesalnih enotah družine 463

Kljub precej visoki stopnji avtomatiziranosti proizvodne linije sesalnih enot družine 463 pa pri proizvodni prihaja do napak. Napake, ki se najpogosteje pojavljajo na končnih izdelkih, so podane v tabeli 3.4. Te lahko posredno ali neposredno vplivajo na življenjsko dobo sesalnih enot, v nekaterih primerih pa so le moteče za uporabnika (npr. hrup). Glede na njihov vpliv na delovanje sesalne enote oziroma celotnega sesalnika je določena tudi prioriteta pri njihovi detekciji. Najbolj kritične napake so neuravnoteženost vrtečih se delov enote, napake, ki povzročijo poslabšanje kvalitete komutacije, in napake v zvezi z ležaji.

V tabeli 3.4 so navedeni tudi simptomi, v katerih se našteje napake lahko odražajo. S stališča avtomatske detekcije napak opazimo, da so nekatere merljive (zaznavne) neposredno (npr. neuravnotežen rotor), o navzočnosti drugih pa lahko sklepamo le preko posrednih meritev (npr. slab stik kolektor-ščetka).

Tabela 3.4: Napake na sesalnih enotah družine 463 in njihovi simptomi

Napake \ Simptomi	Simptomi						
	Podrsavanje turbine (hrup)	Vibriranje rotorja	Vibriranje turbine	Hrup ležaja	Hrup pri izteku	Povečano iskenje	Zaznavno vizualno
Poškodba na turbini	x		x				
Neuravnotežen rotor		x	x				
Aksialna zračnost ležaja					x		
Slabo zlepljen ležaj				x			
Nepravilna lega ležaja				x	x		
Poškodba na ležajih				x	x		
Poškodovan kolektor						x	
Počene ščetke						x	x
Zatikanje ščetke v vodilu						x	
Nepravilna lega ščetk						x	
Slab stik kolektor-ščetka						x	
Slabi električni spoji						x	

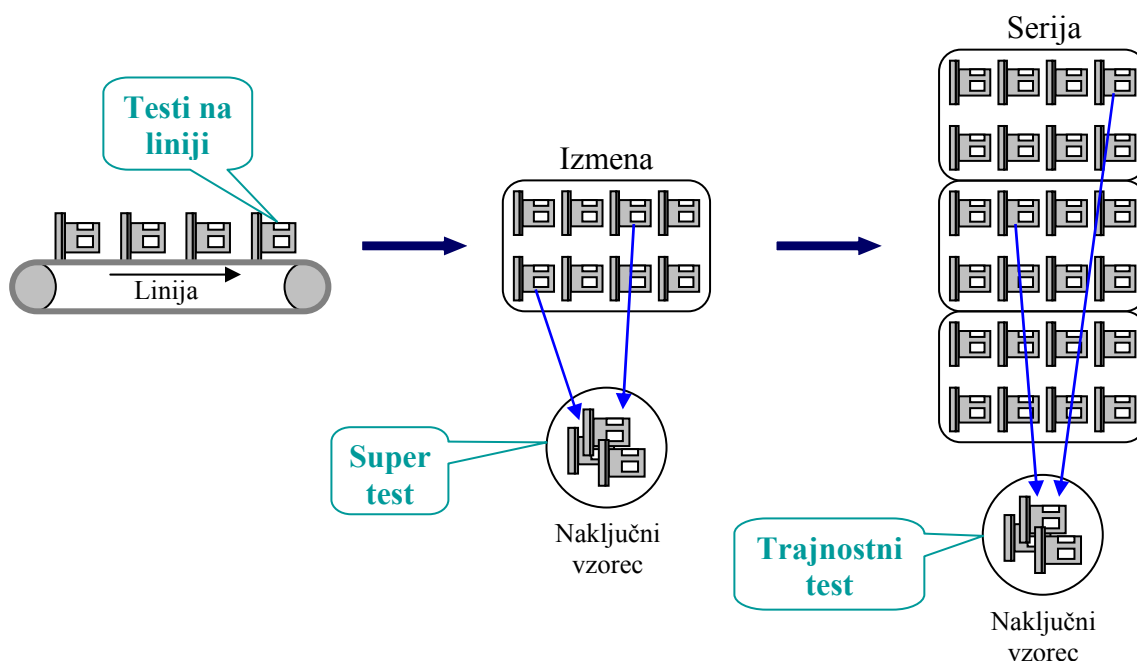
3.2 Prvotno stanje sistema kontrole končnih izdelkov

V Domelu je proces izdelave sesalnih enot sorazmerno visoko avtomatiziran. Interni sistem zagotavljanja kakovosti teh izdelkov je bil v osnovi, kot je shematsko prikazano na sliki 3.3, organiziran na treh nivojih.

Med proizvodnjo so se izvajali nekateri standardni, avtomatski testi na posameznih sklopih (npr. testiranje ovojnega stika na statorskih in rotorskih navitjih, testiranje stika med rotorskimi navitji in lamelami kolektorja itd.). Ti testi omogočajo odkrivanje nepravilnosti le na nivoju sestavnih delov. Nekatero napake, ki se pojavijo pri montaži, pa je mogoče odkriti šele na končnem izdelku. Zato je temeljita končna kontrola sesalnih enot zelo pomembna. Končni test je prvotno vključeval avtomatsko merjenje osnovne karakteristike enot (toka, električne moči in podtlaka), visokonapetostni preizkus, ročno merjenje vibracij, kontrolo hrupa ter vizualni pregled.

Drugi nivo procesa zagotavljanja kakovosti je predstavljal obsežen pregled naključno izbranih vzorcev izmenske proizvodnje (t.i. super test). V primeru odkritja katerekoli napake na enem izmed vzorcev je bila potrebna ponovna kontrola te napake na vseh sesalnih enotah izmene (do 2000 enotah).

Na tretjem nivoju se na nekaj sesalnih enotah iz vsake serije, katerih velikost se giblje med 2000 in 40000 enot, izvede test življenjske dobe.



Slika 3.3: Prvotno stanje sistema kontrole sesalnih enot

Opisani način zagotavljanja kakovosti zahteva veliko ročnega dela in posledično tudi stroškov. Zmanjšanje le-teh pa lahko dosežemo z nadomestitvijo ročnih testiranj na liniji s sistemom za temeljito avtomatsko testiranje končnih izdelkov, ki bi bil zmožen poleg odkrivanja slabih sesalnih enot določiti tudi vrsto oziroma izvor napake. Tak sistem bi obenem predstavljal pomembno podporo operaterjem pri odločanju o potrebnih ukrepih na proizvodni liniji.

Na tržišču je možno zaslediti nekaj komercialnih diagnostičnih sistemov za avtomatsko končno kontrolo pri proizvodnji elektromotorjev. Uglednejši ponudniki takšnih sistemov so že v uvodu omenjeni Schenck (2006), Vogelsang & Benning (2006) in Artesis (2006). Njihovi sistemi so sicer uporabni za različne vrste elektromotorjev, vendar pa je na ta račun omejena kvaliteta diagnosticiranja.

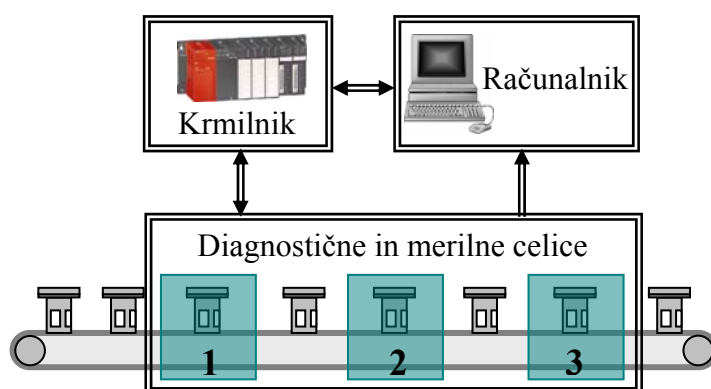
3.3 Avtomatski diagnostični sistem za končno kontrolo sesalnih enot

Sistema za avtomatsko odkrivanje napak na sesalnih enotah, ki je implementiran na proizvodni liniji v Domelu, temelji na uporabi različnih diagnostičnih algoritmov oziroma metod (Musizza in sodelavci, 2006). Bistvo takšnega pristopa k odkrivanju napak na sesalnih enotah je v tem, da vsako napako, ki se lahko pojavi, skušamo detektirati neposredno, to je z meritvijo in ustrezno obdelavo signala, v katerem se posamezna napaka oziroma njeni simptomi direktno odražajo. To sicer zahteva širok nabor merilne opreme, vendar pa po drugi strani zagotavlja večjo zanesljivost, občutljivost in diagnostično natančnost sistema. Na ta način so izpolnjeni pogoji, da se vse slabe sesalne enote izločijo iz dobave kupcem.

3.3.1 Zgradba diagnostičnega sistema

Kot je razvidno iz sheme na sliki 3.4, je diagnostični sistem sestavljen iz petih glavnih modulov (Petrovčič in sodelavci, 2005):

- treh merilnih in diagnostičnih celic,
- krmilnika za strego in
- računalnika s karticama za zajem podatkov.



Slika 3.4: Shematski prikaz zgradbe diagnostičnega sistema

Sistem temelji na zajemu desetih fizikalnih veličin in sicer: napetosti, toka, podtlaka, moči, hitrosti vrtenja, vibracij in zvoka, za korekcijo meritev pa še temperature zraka, vlažnosti in atmosferskega tlaka. Meritve se opravijo v treh merilnih celicah, ki delujejo paralelno. Paralelnost je v obravnavanem primeru potrebna iz dveh razlogov:

- zaradi razmeroma velikega števila različnih meritev, ki jih je potrebno izvesti ter
- zato, da se ujame takt proizvodne linije, ki znaša le 9 s.

Za usklajeno delovanje vseh operacij diagnostičnega sistema vključno s strego skrbi zelo zmogljiv Mitsubishi-jev krmilnik MELSEC-Q. Le-ta daje takt diagnostičnemu sistemu, ki mora ustrezati taktu ostalega dela proizvodne linije. S pomočjo informacij, ki jih dobi s pozicijskih senzorjev na liniji, ter pnevmatskih aktuatorjev skrbi za pravilno pozicioniranje in vklapljanje testiranih sesalnih enot v različnih fazah testiranja. Obenem pa nadzira tudi transport enot skozi diagnostični sistem. Uporabljeni krmilnik je z računalnikom povezan preko vodila RS 232.

Sistem za zbiranje podatkov temelji na merilnih karticah NI 6220 in NI 6221, ki služita za vzorčenje merjenih veličin. Zbrani podatki se najprej predprocesirajo, nato pa ustrezni algoritmi generirajo značilke. Vsaka značilka odraža nek aspekt kakovosti tako, da se s preverjanjem, ali se le-ta nahaja v predpisanem intervalu, sklepa o tem, ali naprava ustreza zahtevanim standardom kakovosti. Če ne ustreza, algoritem ugotovi izvor oziroma lokacijo napake. Vsa programska oprema je izdelana v grafičnem okolju LabVIEW.

3.3.2 Merilne celice in njihove funkcije


Prva merilna celica je namenjena preverjanju karakterističnih veličin sesalnih enot in kvalitete komutacije na osnovi analize napajalnega toka. Slednje bo podrobno predstavljeno v podpoglavju 4.1.2.1.

Karakteristika motorja se definira z naslednjimi podatki: električni tok motorja, električna moč, podtlak in hitrost vrtenja. Ob tem se upoštevajo tudi merilni pogoji in sicer napajalna napetost, temperatura okolice, vlažnost ter atmosferski tlak. Nato se izvedejo korekcije podtlaka glede na atmosferski tlak in temperaturo okolice. Končno pa se vse karakteristične veličine korigirajo še glede na razliko med nazivno (230 V) in dejansko napajalno napetostjo. Korekcije se naredijo kar s pomočjo linearnih funkcij, ki na omejenih področjih dovolj dobro aproksimirajo odvisnosti med omenjenimi veličinami.

Druga merilna celica služi merjenju vibracij sesalnih enot, ocenjevanju kvalitete komutacije na še en dodaten način (tj. na osnovi vrednotenja visokofrekvenčnih napetostnih motenj) in merjenju zvoka pri visokih hitrostih vrtenja enot (nazivni napajalni napetosti). Prva dva testa bosta detajlno opisana kasneje v podpoglavjih 4.2.2 oziroma 4.1.2.2.

Med obratovanjem v bližini nazivne hitrosti vrtenja se pri nekaterih sesalnih enotah pojavi "neprijeten" zvok, ki je moteč za uporabnike. Izkazalo se je, da je omenjeni zvok posledica t. i. izbijanja frekvenc, do česar pride, če sta v signalu prisotni dve

komponenti, katerih frekvenci se relativno malo razlikujeta. V frekvenčnih spektrih signala zvoka obravnavanih enot se pri 16-kratniku in 18-kratniku frekvence vrtenja (f_{16} in f_{18}) pojavita dve komponenti. Le-ti sta posledica geometrije enot (16 rež na usmerniku zraka, medtem ko je 18 dvakratnik števila lopatic turbinskega kolesa). Zaradi precej visokih frekvenc pa sta za človeško uho zelo slabo slišni. Omenjeni komponenti lahko interpretiramo tudi drugače in sicer kot posledico amplitudne modulacije dveh sinusnih signalov s frekvencama $f_{m1} = \frac{f_{16} + f_{18}}{2}$ in $f_{m2} = \frac{f_{18} - f_{16}}{2}$. Kot vemo, to v časovnem prostoru pomeni signal frekvence f_{m1} , ki ga obdaja envelope s frekvenco f_{m2} (Slika 3.5). Ko sta komponenti pri frekvencah f_{16} in f_{18} v fazi, je amplituda celotnega signala velika, ko pa prideta v protifazo, se njun prispevek h celokupnemu signalu izniči. Tudi na frekvenco f_{m1} se človeško uho bolj slabo odziva, vendar pa v primeru, kadar sta frekvenci f_{16} in f_{18} dovolj blizu skupaj, lahko zelo dobro zaznava envelope signala. Opisani pojav pride do izraza le, če sta obe komponenti pri frekvencah f_{16} in f_{18} dovolj veliki. Zato odkrivanje te napake temelji na ugotavljanju RMS (koren povprečja kvadratov, ang. root mean square) vrednosti omejenih komponent v signalu zvoka.

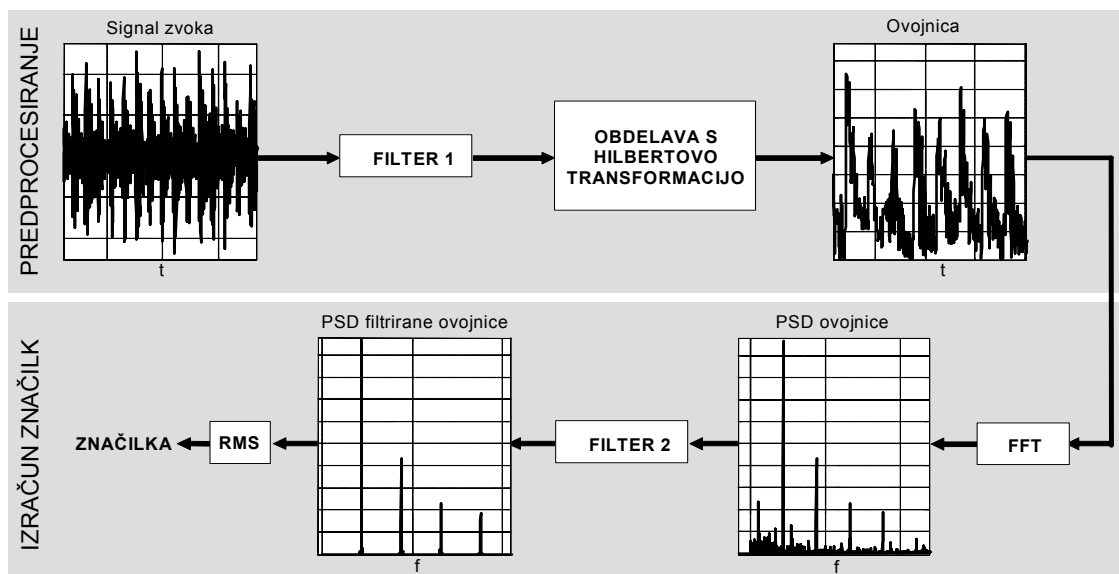


Slika 3.5: Amplitudno moduliran signal

Tretja merilna celica je namenjena merjenju zvoka sesalnih enot pri nizkih hitrostih vrtenja (okrog 40 Hz). Zaradi nizke intenzitete zvoka pri omenjenih vrtljajih je potrebno meritve izvajati v akustično izolirani komori, s čimer se zmanjša vpliv motilnega hrupa iz okolice.

Pri nizkih hitrostih vrtenja sesalnih enot pridejo v signalu zvoka do izraza značilni vzorci, ki so posledica napak v ležajih ali drgnjenja med rotirajočimi in statičnimi deli (Benko in sodelavci, 2004). Ti vzorci imajo obliko izbruhov, katerih pogostost pojavljanja je v primeru napake v ležaju odvisna od dimenzij ležaja in hitrosti vrtenja enote, v primeru drgnjenja pa ustreza frekvenci vrtenja enote oz. njenim večkratnikom (Benko in sodelavci, 2005). S pomočjo Hilbert-ove transformacije najprej določimo ovojnico signala zvoka, nato pa izračunamo njen frekvenčni spekter (Randall, 2002).

Prisotnost določene napake se odrazi v RMS vrednosti ovojnice v ustreznih frekvenčnih pasovih, ki so značilni za posamezno napako. Postopek ilustrira slika 3.6.



Slika 3.6: Obdelava signala zvoka za potrebe odkrivanja napak na ležajih in drgnjenja

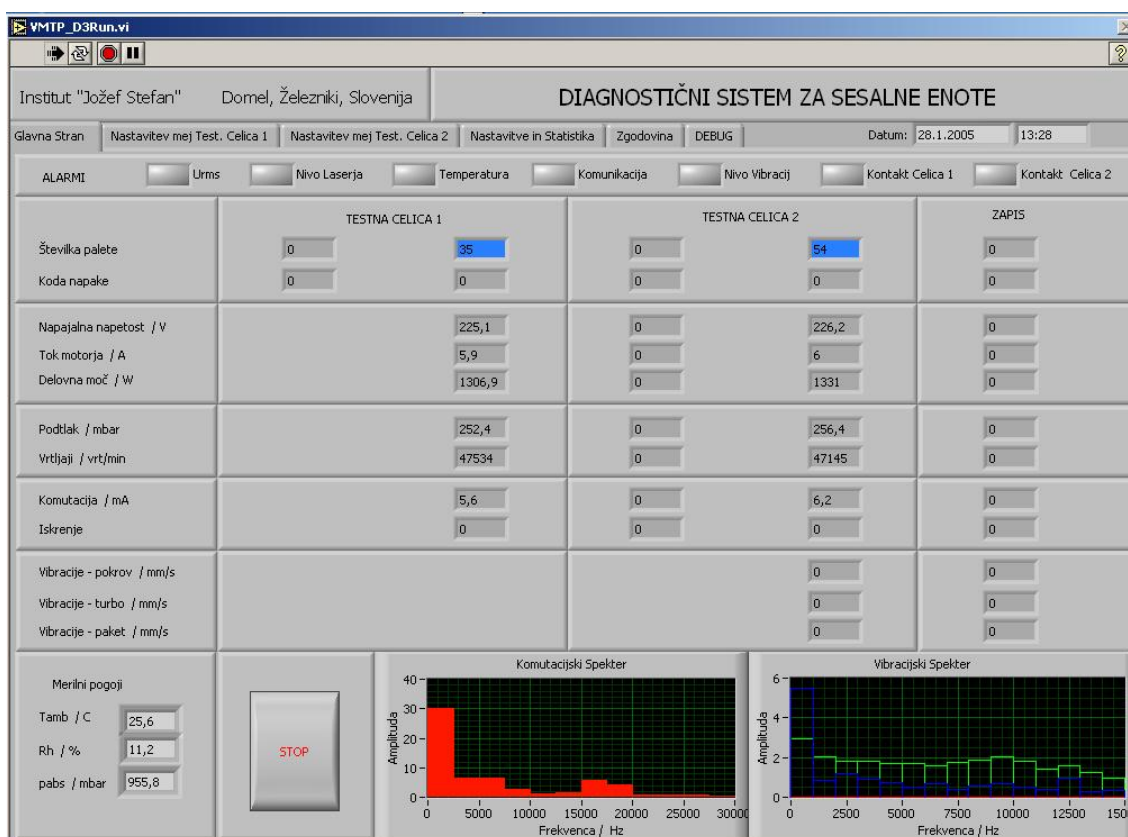
3.3.3 Delovanje diagnostičnega sistema

Na vhodu v diagnostični sistem se najprej odčita številka palete, na katero je postavljena sesalna enota. Pod to številko se nato v računalniku shranjujejo diagnostični rezultati določene sesalne enote. S tem se zagotovi sledenje enoti, ko le-ta potuje skozi posamezne merilne celice diagnostičnega sistema. Številka palete se ponovno prebere na izhodu sistema in primerja s tisto v računalniku. Če se številki ujemata, pomeni, da se je testiranje izvršilo uspešno. V nasprotnem primeru pa se sproži ustrezn alarm. V zadnji operaciji diagnostičnega sistema se v čip na paleti testirane sesalne enote vpiše, ali je le-ta brezhibna, oz. ustrezno kodo morebitne napake. Slednje so podane v tabeli 3.5. Prva številka v kodi (X) pomeni število odkritih napak na posamezni enoti, druga pa vrsto napake. V primeru večjega števila napak se na mesto druge številke zabeleži tista, ki ima najvišjo prioriteto. Vsi podatki v zvezi s testiranjem posamezne sesalne enote (tip sesalne enote, datum, čas, št. palete, št. sesalne enote, koda napake in vrednosti vseh značilk) se shranjujejo na trdi disk računalnika, trenutno v obliki ločenih tekstovnih datotek.

Tabela 3.5: Kode napak pri sesalnih enotah

Koda	Napaka
00	Ni napake
X1	Ni električnega kontakta na priključnih sponkah
X2	Povečane vibracije
X3	Slaba komutacija (analiza napajalnega toka)
X4	Odstopanje električnih parametrov (tok, moč)
X5	Prenizek podtlak
X6	Odstopanje hitrosti vrtenja
X7	Povečan hrup pri visokih vrtljajih
X8	Povečan hrup pri nizkih vrtljajih
X9	Slaba komutacija (vrednotenje visokofrekvenčnih napetostnih motenj)

Uporabniški vmesnik obravnavanega sistema, ki je prikazan na sliki 3.7, je namenjen prikazu diagnostičnih rezultatov testiranih sesalnih enot. Poleg tega pa omogoča še nastavitve mejnih vrednosti značilk v vseh treh merilnih celicah, izračun nekaterih statističnih parametrov na izmerjenih vrednostih in pregled preteklih rezultatov testiranj.



Slika 3.7: Uporabniški vmesnik

4. Detekcija in lokalizacija napak na končnih izdelkih

Najnižji oziroma osnovni nivo pri odkrivanju napak v velikoserijski proizvodnji elektromotorjev je detekcija in lokalizacija posameznih vrst napak na končnih izdelkih. Na tem nivoju se srečujemo s problemi izvedb ustreznih meritev, obdelave izmerjenih signalov z različnimi algoritmi, formulacij značilik, ki kažejo na potencialne napake, in logičnega sklepanja, s pomočjo katerega pridemo do končnega diagnostičnega rezultata. Pri meritvah imamo na voljo široko paleto senzorjev ali celo namenskih merilnih instrumentov, ki na osnovi različnih principov omogočajo merjenje številnih fizikalnih veličin. Vendar se moramo pri uporabi teh merilnih naprav zavedati tudi njihovih omejitev, saj se včasih izkaže, da omenjene naprave ne ustrezajo vsem našim potrebam oziroma zahtevam. Zato smo se v takšnih specifičnih primerih primorani poslužiti kakšnega novega načina merjenja. Pri izboru merilne opreme je s stališča diagnosticiranja zelo pomembno, da se že s samo meritvijo skušamo čim bolj neposredno približati izvoru napake. Na ta način dobljeni signal, ki vsebuje informacijo o napaki, je bolj kvaliteten. Posledično se poenostavita njegova obdelava in generiranje značilke, s katerima odpravimo motnje ter iz signala izluščimo informacijo o iskani napaki. Vse skupaj pa rezultira v boljši občutljivosti, natančnosti in robustnosti diagnostičnega postopka (Rabinovich, 2000).

V tem poglavju bosta predstavljena dva primera s področja detekcije in lokalizacije napak pri manjših, univerzalnih elektromotorjih in sicer konkretno pri sesanih enotah proizvajalca Domel.

4.1 Ocenjevanje kvalitete komutacije

Sklop ščetke-kolektor pri univerzalnih elektromotorjih predstavlja mehansko stikalo, ki preklaplja med lamelami kolektorja, na katere so priključena rotorska navitja. Na ta način je doseženo, da kljub vrtenju rotorja tok po rotorskih navitjih vedno teče v

ustrezno smer, kar zagotavlja konstantno smer momenta in s tem pravilno delovanje motorja. Omenjeni proces preklapljanja imenujemo komutacija. Že od izuma kolektorskega motorja v drugi polovici devetnajstega stoletja pa je znano, da prav komutacija predstavlja najšibkejšo točko pri teh motorjih (Moczala in sodelavci, 1998).

Zaradi elektromagnetnih pojavov pri komutaciji prihaja do iskrenja med lamelami kolektorja in ščetkami. Le-to pa ima kar nekaj predvsem negativnih posledic, ki bistveno vplivajo na lastnosti univerzalnih elektromotorjev. Zaradi iskrenja se na ščetkah pojavijo inducirane visokofrekvenčne napetostne motnje, ki jih motor oddaja v napajalno omrežje in ga tako "onesnažuje". Poleg tega povečano iskrenje pomeni hitrejšo obrabo ščetk in kolektorja ter s tem krajšo življenjsko dobo motorja. Po drugi strani pa lahko tudi prešibko iskrenje predstavlja slabost. Pri iskrenju namreč zgorevajo prašni delci, ki nastanejo zaradi mehanske obrabe ščetk (trenja med lamelami kolektorja in ščetkami). Na ta način je zagotovljeno stalno čiščenje kolektorja. V primeru nezadostnega iskrenja ali celo njegove odsotnosti se ti prašni delci začnejo nabirati v režah med lamelami kolektorja. S tem se zmanjša izolacija med lamelami, kar povzroči poslabšano delovanje motorja ali celo njegovo odpoved.

Torej, lahko rečemo, da ima kvaliteta komutacije, od katere je odvisna intenziteta iskrenja, bistven vpliv na življenjsko dobo univerzalnih elektromotorjev. Zato je objektivno ovrednotenje kvalitete komutacije, od katere je odvisna intenziteta iskrenja, zelo pomembno tako pri nadzoru omenjenih motorjev med obratovanjem, kot pri končni kontroli novih motorjev na proizvodni liniji. Z analizo in ocenjevanjem kvalitete komutacije se je predvsem v devetdesetih letih prejšnjega stoletja ukvarjalo kar nekaj avtorjev. Pri tem so se posluževali različnih pristopov, ki so jih tudi patentirali.

Za nadzor nad iskrenjem v smislu napovedovanja odpovedi ali preventivnega vzdrževanja se predvsem pri večjih strojih v obratovanju intenziteta iskrenja meri posredno preko merjenja svetlobnega toka, ki ga povzroča iskrenje. Na tem pristopu temeljijo rešitve, ki jih v svojih patentnih dokumentih predlagajo Shiozaki (1985), Shiozaki in sodelavci (1986), Nagase in sodelavci (1986) ter Yamada (1997). Prednost optičnega merjenja je v brezkontaktni meritvi, slabost pa v občutljivosti na spreminjajočo se svetlobo iz okolja, ki lahko moti meritev. Naštete patentirane rešitve se tako nanašajo predvsem na postopke izločanja optičnih vplivov okolice in sicer s sinhronizacijo optičnega signala s hitrostjo vrtenja in z uporabo usmerjenih optičnih vlaken. Te metode so zaradi potrebe po nameščanju optičnega sistema manj primerne ali celo neprimerne za končno kontrolo pri velikoserijski proizvodnji malih elektromotorjev.

Zaradi električno povzročene iskrenja v okolici kolektorja nastajajo radiofrekvenčne (RF) motnje. To omogoča, da se intenziteta iskrenja lahko meri tudi posredno preko merjenja nivoja emisije RF polja, ki ga motor oddaja. Rešitev, ki se ponuja, je postavitve merilne antene v bližino kolektorja in merjenje nivoja RF signala, ki ga sprejmemo na anteni. Takšno metodo v svojih patentih zagovarjajo številni avtorji:

Michiguchi in Ideumi (1981), Obara in Miyashita (1981), Teraguchi (1981), Watanabe (1983, 1986), Miyashita (1985), Michiguchi in Tanisaka (1986) ter Ouchi in sodelavci (1987). Osnovna prednost te metode je v brezkontaktni meritvi. Glavna slabost pa je v običajno visokem nivoju RF motenj iz okolice. Izvajanje meritev RF emisije elektromotorjev v elektromagnetno izolirani komori ni primerno za potrebe kontrole pri serijski proizvodnji. Navedeni izumi tako predstavljajo predvsem rešitve, ki na druge načine zmanjšujejo vplive zunanjih motilnih polj na meritev intenzitete iskrenja. Le-ti temeljijo na kombinaciji s pomožnimi meritvami, na postavitvi in obliki antene, kar pa zopet bistveno zmanjša njihovo praktično uporabnost za serijsko preizkušanje elektromotorjev na proizvodni liniji.

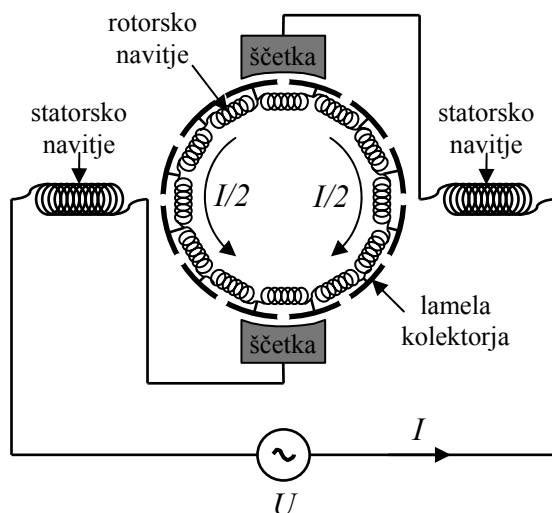
Tawara in sodelavci (1985a) ter Nagano in sodelavci (1989) rešujejo problem ovrednotenja kvalitete komutacije z uporabo pomožnih ščetk. To je pri velikih strojih (predvsem enosmernih generatorjih) morda upravičeno, pri manjših elektromotorjih pa je takšna rešitev neprimerna, saj bi pomenila občutno zvišanje proizvodnih stroškov.

Toyota in sodelavci (1980), Tanisaka in sodelavci (1982) ter Watanabe (1983) za meritev nivoja motenj, ki jih povzroča iskrenje, uporabljajo magnetni sklop, katerega sestavljata napajalni vod za motor in njemu paralelni vod. Med njima prehaja motilni signal po principu visokofrekvenčnega tokovnega transformatorja. Tak način odvzema je še posebej ustrezen pri motorjih večjih moči. Osnovna pomanjkljivost te metode pa je, da so v meritev vključene tudi motnje iz napajalnega omrežja. Zato je slednje potrebno predhodno izločiti s pomočjo močnostnih filtrov. Izkaže pa se tudi, da je nivo tako zajetega signala pri serijsko vezanih motorjih zelo nizek, saj statorska navitja delujejo kot učinkovita dušilka za motnje, ki nastajajo na ščetkah. V rešitvi, ki jo podajajo Tawara in sodelavci (1985b), je zajem motilnega signala izveden napetostno in sicer paralelno s statorskim navitjem. V tem primeru statorsko navitje zaradi svoje induktivnosti dvigne nivo motenj pri višjih frekvencah, kar rezultira v ugodnejšem nivoju signala. Zopet pa tudi ta rešitev ni imuna proti motnjam iz napajalnega omrežja.

Rešitev, ki jo v svojem patentu predlagajo Tawara in sodelavci (1985c), ima zelo ugoden zajem signala neposredno na ščetkah elektromotorja. Toda za zajem uporablja izolacijski ojačevalnik, ki nima dovolj velike pasovne širine, da bi zajel glavnino motilnega signala električne iskre. Zato gre v tej rešitvi predvsem za detekcijo tokovne spremembe, ki nastane pri komutaciji. Ta pa ni odvisna samo od intenzitete isker, temveč predvsem od trenutnega toka skozi motor. Avtorji predlagajo še kombiniranje opisanega zajema s pomožno meritvijo, npr. z merjenjem svetlobnega toka isker ali z merjenjem vibracij ščetke.

4.1.1 Komutacija pri univerzalnih elektromotorjih


Univerzalni elektromotor je elektromehanski pretvornik, ki ga lahko priključimo tako na izmenično kot na enosmerno napetost. To omogoča njegov princip delovanja, ki je razviden iz električne sheme na sliki 4.1. Serijska vezava statorskih in rotorskih navitji zagotavlja največji vrtilni moment, saj pri takšni vezavi teče isti tok skozi statorska in rotorska navitja in je zato bremenski tok v fazi z magnetilnim. Tok skozi navitja rotorja teče po dveh paralelnih vejah in sicer po vsaki veji ena polovica. Tok skozi navitja ene veje teče v nasprotni smeri kot skozi navitja druge veje. S tem je zagotovljeno, da elektromagnetne sile, ki delujejo na rotorska navitja, povzročajo moment v pravi smeri. Zaradi vrtenja rotorja pa rotorska navitja prehajajo iz ene veje v drugo, kar pomeni, da mora tok v njih spreminjati smer. Torej lahko rečemo, da je komutacija spreminjanje smeri toka v komutirajoči tuljavi (Chapman, 2002; Zagradišnik in Slemnik, 2001; Jereb, 1975).




Slika 4.1: Električna shema univerzalnega elektromotorja

Kaj se pri komutaciji dejansko dogaja, je razvidno s slike 4.2. Opazujemo navitje, ki je priključeno na lameli kolektorja označeni z 1 in 2. Najprej (Slika 4.2a) se to navitje nahaja v levi paralelni veji. Skozenj teče tok $I_{ca} = I/2$ v desno smer, ki nadaljuje pot preko lamele 1 in ščetke pod njo. V naslednjem koraku (Slika 4.2b), ko se rotor zavrti za določen kot, ščetka spoji lameli 1 in 2 in opazovano navitje je v kratkem stiku. Kot je razvidno s slike 4.3, v času komutacije T_k , to je času, ko je komutirajoče navitje kratko vezano preko dveh sosednjih lamel in ščetke, tok skozi omenjeno navitje spremeni smer. Po končani komutaciji (Slika 4.2c) se opazovano navitje nahaja v desni paralelni veji in skozenj teče tok I_{ca} v levo smer, ki nadaljuje pot preko lamele 2 in ščetke. Torej gre pri komutaciji za vkloppljanje in izkloppljanje induktivnega tokokroga, v katerem se spreminja smer toka. Naj na tem mestu še dodamo, da mora v času komutacije

komutirajoče navitje ležati v magnetno nevtralni coni. S tem dosežemo, da na njem ni inducirane napetosti, ki bi vplivala na potek spreminjanja smeri toka.




Slika 4.2: Potek komutacije



Slika 4.3: Časovni potek toka v komutirajočem navitju

Na kvaliteto komutacije bistveno vpliva potek spreminjanja smeri toka v komutirajočem navitju. V idealnem primeru bi se tok spreminjal linearno (Slika 4.4). Vendar je zaradi lastne inducirane napetosti $e_i = -L \frac{di}{dt}$, ki nasprotuje spreminjanju toka v navitju, to spreminjanje na začetku počasnejše, proti koncu komutacijskega časa, ko lamela komutatorja že zapuša ščetko, pa hitrejše (Slika 4.4). Včasih pa se lahko zgodi, da tok popolnoma še ne spremeni smeri, ko čas komutacije že poteče oziroma lamela že zapusti ščetko. V tem primeru se zaradi prekinitve induktivnega tokokroga in s tem nenadne spremembe toka v njem inducira visoka napetost, ki povzroči preskok iskre


med odhajajočo lamelo in robom ščetke. Iskra ponovno vzpostavi kratek stik, tako da se obračanje smeri toka lahko izvede do konca.




Slika 4.4: Spreminjanje smeri toka v komutirajočem navitju

Zaradi zelo majhnih stičnih površin med odhajajočimi lamelami in ščetko pa se na robu ščetke pojavlja tudi zelo visoka tokovna gostota, ki povzroča lokalna žarenja ščetkinega materiala.

Da prihaja do iskrenja le na tistem robu ščetke, kjer jo lamele zapuščajo (Slika 4.5), potrjuje tudi slika 4.6, s katere je razvidno, da je na površini ščetke, po kateri drsi kolektor, zaradi iskrenja ožgan le omenjeni rob.



Slika 4.5: Mesto pojava iskre



Slika 4.6: Ožgani rob na površini ščetke, po kateri drsi kolektor

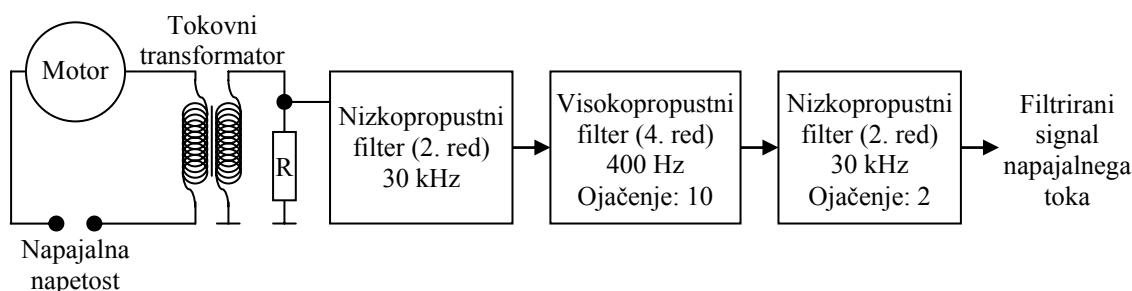
4.1.2 Opis metod za ocenjevanje kvalitete komutacije sesalnih enot

V okviru končne kontrole proizvedenih sesalnih enot se kvaliteta komutacije ocenjuje po dveh metodah. Prva temelji na analizi napajalnega toka, druga pa na vrednotenju visokofrekvenčnih napetostnih motenj.

4.1.2.1 Analiza napajalnega toka

Zaradi neidealnih razmer, katerim se je v realnem svetu skoraj nemogoče izogniti, pri komutaciji v univerzalnih elektromotorjih prihaja do nenadnega prekinjanja toka v komutirajočih rotorskih navitjih in posledično do nekaterih elektromagnetnih učinkov. Vsi omenjeni pojavi pa se v obliki motenj odražajo tudi v napajalnem toku. Ideja je, da bi z ovrednotenjem teh motenj lahko ocenili kvaliteto komutacije.

V ta namen je najprej potrebno zajeti signal napajalnega toka. Osnovna bločna shema zajema in predobdelave signala napajalnega toka je prikazana na sliki 4.7. Napajalni tok zajamemo s pomočjo izolacijskega tokovnega transformatorja s prenosnim razmerjem 500:1, ki je vključen v napajalni vod elektromotorja. Na ta način je zagotovljena tudi galvanska ločitev merilnega od močnostnega dela. Nato z uporabo upora R pretvorimo tokovni signal v napetostnega. Sledi filtriranje signala z dvema nizkopropustnima (anti-aliasing) filtroma drugega reda z mejno frekvenco 30 kHz in visokopropustnim filtrom četrtega reda z mejno frekvenco 400 Hz. Slednji služi izločanju frekvenčne komponente pri 50 Hz in nekaj njenih večkratnikov, ki so v signalu toka prisotni zaradi izmeničnega napajanja, kar pomeni, da ne vsebujejo nobene informacije o kvaliteti komutacije. Ojačenja filtrov so potrebna za dvig nivoja signala toka pri višjih (nad 400 Hz) frekvencah, saj je sicer le-ta v omenjenem frekvenčnem področju zanemarljiv v primerjavi s frekvenčno komponento pri 50 Hz. Rezultat analogne predobdelave je filtrirani signal napajalnega toka, ki ga 0.12 s vzorčimo s frekvenco 60 kHz. Meritve se opravijo pri nazivni napajalni napetosti (230 V).



Slika 4.7: Zajem in predobdelava signala napajalnega toka

Značilke, s katerimi se vrednoti nivo motenj v signalu napajalnega toka oziroma kvaliteta komutacije, so definirane kot RMS vrednosti filtriranega napajalnega toka v 12 frekvenčnih pasovih širine 2.5 kHz in sicer od 0 do 30 kHz. V nadaljevanju bomo teh 12 značilk označevali s $f_{k1}, f_{k2}, \dots, f_{k11}$ in f_{k12} .


Vrednosti v prejšnjem odstavku omenjenih značilk dobimo na naslednji način. Najprej izračunamo frekvenčni spekter filtriranega signala napajalnega toka. Nato pa iz

frekvenčnih komponent amplitudnega spektra, ki se nahajajo znotraj vsakega izmed 12 frekvenčnih pasov (Slika 4.8), izračunamo:

$$RMS_i = \sqrt{2 \sum_j x_{ij}^2} \quad (4.1)$$

pri čemer je RMS_i RMS vrednost signala v i -tem frekvenčnem pasu, z x_{ij} pa so označene amplitude vseh komponent spektra v i -tem frekvenčnem pasu.

Zgoraj opisani postopek računanja RMS vrednosti signala po posameznih frekvenčnih področjih je računsko precej manj potraten in zato hitrejši v primerjavi s filtriranjem signala z ustreznimi digitalnimi pasovnopropustnimi filtri ter naknadnim računanjem RMS vrednosti filtriranih signalov po definiciji. Prednosti predstavljenega postopka so se izkazale kot zelo koristne pri implementaciji v proizvodnji, saj je proizvodni cikel, znotraj katerega se mora poleg številnih ostalih operacij izvesti tudi obravnavani izračun, omejen.




Slika 4.8: Frekvenčni pasovi filtriranega napajalnega toka


Na sliki 4.9 je prikazan primer diagnostičnega rezultata ocenjevanja kvalitete komutacije na osnovi analize napajalnega toka. Vidimo, da ima največjo vrednost značilka f_{kl} , katera je definirana kot RMS vrednost filtriranega signala napajalnega toka v frekvenčnem področju od 0 Hz do 2500 Hz. Tako velika vrednost te značilke je posledica izmeničnega napajanja, saj kljub uporabi visokopropustnega filtra četrtega reda z mejno frekvenco 400 Hz nekatere višje harmonske komponente osnovne frekvence napajanja (50 Hz) še vedno ostanejo v signalu napajalnega toka, nekatere pa se pojavljajo celo pri frekvencah višjih od 400 Hz, zato jih omenjeni filter ne odstrani (Slika 4.10).

Naslednja po velikosti je značilka f_{k7} . Le-ta ustreza RMS vrednosti filtriranega signala napajalnega toka v frekvenčnem področju od 1.5 kHz do 1.75 kHz. Omenjeno frekvenčno področje zajema tudi frekvenco, ki je enaka frekvenci vrtenja sesalne enote (cca 750 Hz) pomnoženi s številom lamel na kolektorju (v primeru obravnavane sesalne enote iz družine 463 je to 22). Pri tej frekvenci je v filtriranem signalu napajalnega toka prisotna izrazita komponenta, katera največ prispeva k vrednosti obravnavane značilke. Omenjena komponenta je posledica impulzov, ki se v napajalnem toku pojavljajo zaradi sekiranja toka na kolektorju, do katerega prihaja, ko posamezne lamele kolektorja zapuščajo ščetke, tj. ob vsakem zaključku komutacijskega cikla v posameznem rotorskem navitju. S slike 4.11 je razvidno, da je obravnavana frekvenčna komponenta amplitudno modulirana s signalom frekvence 50 Hz. Tudi ta pojav je posledica izmeničnega napajanja. Ko je namreč na priključnih sponkah univerzalnega elektromotorja napetost 0 V, izginejo tudi vsi učinki komutacije.


Ostale značilke za ocenjevanje kvalitete komutacije na podlagi analize napajalnega toka imajo manjše vrednosti, poleg tega pa tudi ne poznamo razlage njihovega fizikalnega ozadja.



Slika 4.9: Primer vrednosti značilk za ocenjevanje kvalitete komutacije na osnovi analize napajalnega toka



Slika 4.10: Izsek iz frekvenčnega spektra filtriranega signala napajalnega toka (od 0 do 2500 Hz)



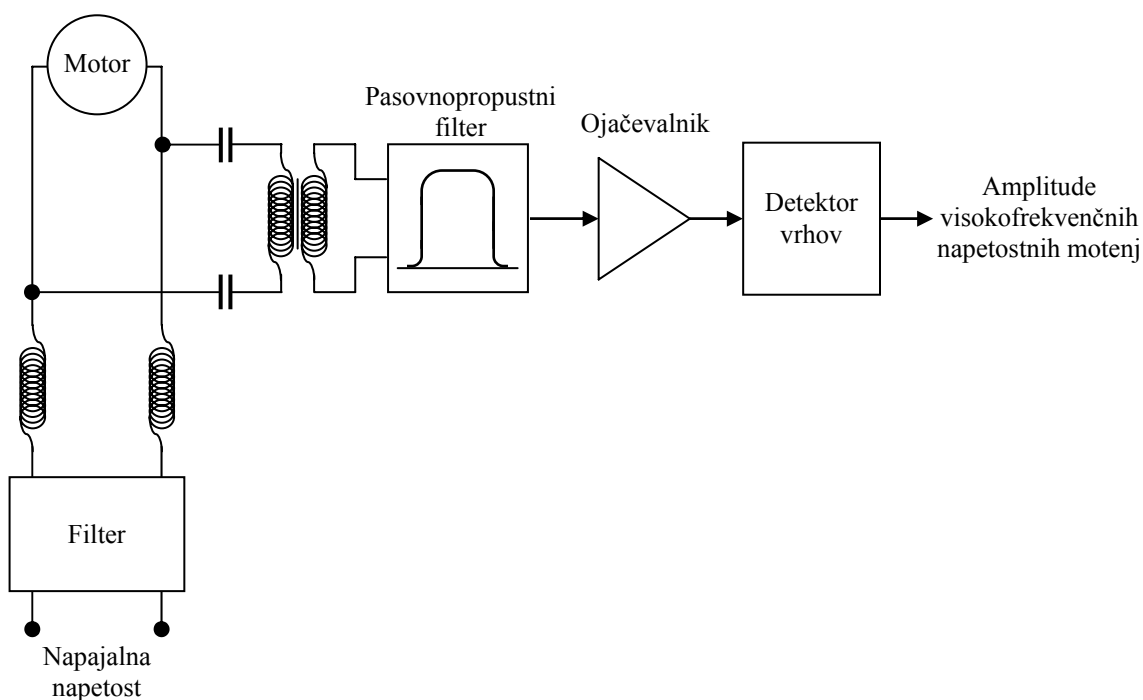
Slika 4.11: Izsek iz frekvenčnega spektra filtriranega signala napajalnega toka (od 1.5 kHz do 1.75 kHz)

4.1.2.2 Vrednotenje visokofrekvenčnih napetostnih motenj

Pri univerzalnih elektromotorjih se kvaliteta komutacije odraža tudi v intenziteti iskrenja med kolektorjem in ščetkami. Le-to pa povzroča induciranje visokofrekvenčnih električnih motenj na ščetkah, ki jih motor preko priključnih sponk oddaja v napajalno omrežje. Torej bi tudi z ovrednotenjem teh motenj lahko sklepali na kvaliteto komutacije.

Osnovna bločna shema zajema visokofrekvenčnih napetostnih motenj na priključnih sponkah univerzalnega elektromotorja je prikazana na sliki 4.12. Motor je napaján preko filtra, ki izloči morebitne visokofrekvenčne motnje iz napajalnega omrežja, katere bi lahko vplivale na meritev. Omenjene motnje dodatno zadušita tuljavi v napajalnem

vodu. Hkrati pa ti dve tuljavi predstavljata veliko impedanco za motnje, ki jih preko priključnih sponk oddaja motor in jih želimo meriti. Napetostni signal zajamemo neposredno na priključnih sponkah elektromotorja in ga vodimo preko dveh kondenzatorjev, ki v bistvu predstavljata visokopropustni filter. Le-ta izloči nizkofrekvenčne komponente signala, tj. komponento pri osnovni frekvenci napajalnega omrežja (50 Hz) in njenih prvih nekaj harmonskih komponent, ki za meritev intenzitete iskrenja niso relevantne. Sledi visokofrekvenčni izolacijski transformator. Njegova naloga je galvanska ločitev merilne naprave od testiranega elektromotorja. Nato signal nadaljuje pot preko pasovnopropustnega filtra z mejnima frekvencama pri 2 MHz in 20 MHz, ki prepušča le tisti del frekvenčne vsebine signala, katera je karakteristična za iskrenje na kolektorju. Ker pa pri univerzalnih elektromotorjih visokofrekvenčne motnje, ki se inducirajo na kolektorju in ščetkah, na poti do priključnih sponk močno zadušita serijsko vezani statorski navitji, ima signal na izhodu pasovnopropustnega filtra zelo nizek nivo. Zato ga je potrebno dodatno ojačiti. Na izhodu ojačevalnika dobimo signal impulzne oblike, pri čemer impulzi sovpadajo s pojavljanjem isker, ki povzročajo posamezne izbruhe visokofrekvenčnih motenj. Ta signal vodimo preko detektorja vrhov, da dobimo amplitude omenjenih impulzov, katere so proporcionalne intenziteti isker med kolektorjem in ščetkami.




Slika 4.12: Zajem visokofrekvenčnih napetostnih motenj

Amplitude visokofrekvenčnih napetostnih motenj se nato s pomočjo A/D pretvornika pretvarjajo v digitalno obliko ter se v času trajanja ene meritve (2 s)

razvrščajo v histogram. Iz oblike tako dobljenega histograma pa lahko nadalje sklepamo na kvaliteto komutacije.

Na sliki 4.13 sta shematsko prikazana histograma amplitud visokofrekvenčnih napetostnih motenj za dobro sesalno enoto in enoto s povečanim iskrenjem. Pri obeh enotah ima večina izbruhov visokofrekvenčnih napetostnih motenj manjše amplitude, tj. do cca 40. Le-ti so posledica manjših, neškodljivih isker, ki se pojavljajo pri normalni komutaciji. Z meritvami na več sesalnih enotah je bilo ugotovljeno, da se obravnavani histogrami v omenjenem področju manjših amplitud pri posameznih enotah lahko razlikujejo po obliki, vendar pa iz teh oblik ni možno sklepati na kvaliteto komutacije. Bistvena razlika med histogramom dobre sesalne enote (Slika 4.13a) in enote s povečanim iskrenjem (Slika 4.13b), ki omogoča njuno ločevanje v smislu intenzitete iskrenja, je prisotnost visokofrekvenčnih napetostnih motenj z amplitudami nad cca 80 pri enoti s povečanim iskrenjem. Le-te se pojavijo zaradi velikih isker med kolektorjem in ščetkami oziroma poslabšane komutacije. S slike 4.13b je še razvidno, da je teh visokofrekvenčnih napetostnih motenj relativno malo (Petrovčič in sodelavci, 2004).



Slika 4.13: Shematski prikaz histograma amplitud visokofrekvenčnih napetostnih motenj: a) za dobro sesalno enoto, b) za sesalno enoto s povečanim iskrenjem


Na osnovi histogramov amplitud visokofrekvenčnih napetostnih motenj smo definirali dve značilki za ocenjevanje intenzitete iskrenja oziroma kvalitete komutacije.

Glede na to, da se visokofrekvenčne napetostne motenja z večjimi amplitudami pogosteje pojavljajo le pri sesalnih enotah s povečanim iskrenjem, je prva značilka intenzitete iskrenja, katero bomo v nadaljevanju označevali s f_{il} , definirana kot število izbruhov visokofrekvenčnih napetostnih motenj (isker) z amplitudo večjo od neke empirično določene meje v_{0l} (Enačba 4.2):

$$f_{il} = \sum_{k=0}^{\infty} h(v_{0l} + k \cdot \Delta v) \quad (4.2)$$


kjer h predstavlja število vzorcev v posameznem stolpcu histograma amplitud visokofrekvenčnih napetostnih motenj, z Δv pa je označena širina omenjenih stolpcev. V obravnavanem primeru sesalnih enot iz družine 463 je meja v_{0l} postavljena na vrednost 80.

Pri formulaciji druge značilke intenzitete iskrenja oziroma kvalitete komutacije f_{i2} smo upoštevali, da so iskre z večjo intenziteto bolj škodljive. Zato je le-te smiselno bolj poudariti, tako da več prispevajo k vrednosti značilke. To smo naredili z utežitvijo histograma amplitud visokofrekvenčnih napetostnih motenj z linearno funkcijo, kot je shematsko prikazano na sliki 4.14.



Slika 4.14: Utežitev histograma amplitud visokofrekvenčnih napetostnih motenj z linearno funkcijo

Rezultat utežitve histogramov s slike 4.13 lahko vidimo na sliki 4.15. Razlika med uteženim histogramom za dobro sesalno enoto (Slika 4.15a) in enoto s povečanim iskrenjem (Slika 4.15b) je očitna.



Slika 4.15: Utežen histogram amplitud visokofrekvenčnih napetostnih motenj: a) za dobro sesalno enoto, b) za sesalno enoto s povečanim iskrenjem

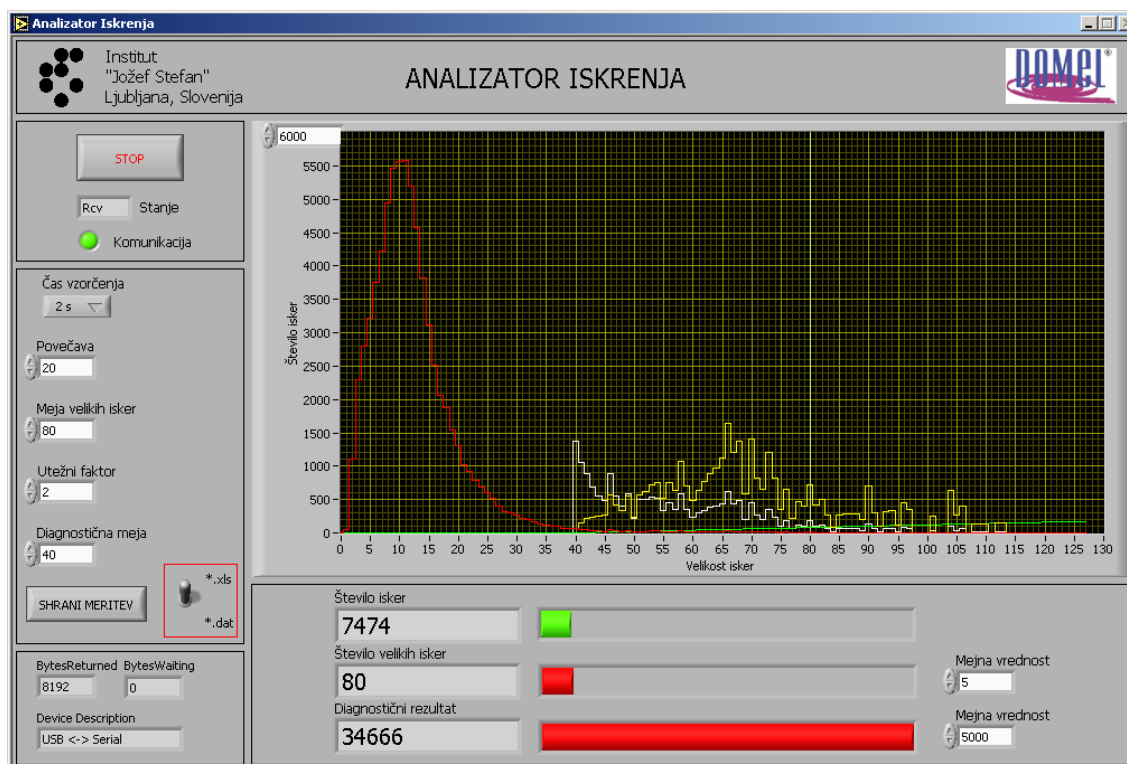
Na podlagi predstavljenih dognanj smo značilko intenzitete iskrenja f_{i2} definirali kot površino uteženega histograma amplitud visokofrekvenčnih napetostnih motenj (Enačba 4.3).

$$f_{i2} = \Delta v \cdot \sum_{k=0}^{\infty} h(v_{02} + k \cdot \Delta v) \cdot (k \cdot \Delta v) \quad (4.3)$$

pri čemer je pomen simbolov h ter Δv enak kot v enačbi 4.2, konstanta v_{02} pa je ponovno določena empirično in ima v primeru obravnavanih sesanih enot vrednost 40.

Slika 4.16 prikazuje uporabniški vmesnik sistema za merjenje intenzitete iskrenja oziroma kvalitete komutacije na podlagi vrednotenja visokofrekvenčnih napetostnih motenj. Na njem je viden primer diagnostičnih rezultatov, ki smo jih dobili pri testiranju sesalne enote s povečanim iskrenjem. Meritev in izračuna značilk so bili izvedeni pod pogoji, ki jih določajo parametri na levi strani vmesnika. Čas vzorčenja oziroma meritve je bil 2 s. Povečava je parameter, ki služi le nastavitvi grafičnega prikaza. Njegova vloga bo razložena kasneje pri opisu grafa. Meja velikih isker predstavlja mejo v_{01} , ki jo potrebujemo pri določanju vrednosti značilke f_{i1} . Utežni faktor določa naklon premice, s katero utežimo histogram amplitud visokofrekvenčnih napetostnih motenj pri računanju značilke f_{i2} . Diagnostična meja pomeni konstanto v_{02} , ki jo prav tako rabimo za izračun vrednosti f_{i2} . Na grafu na desni strani vmesnika je z rdečo krivuljo izrisan histogram amplitud visokofrekvenčnih napetostnih motenj. Bela krivulja na istem grafu prikazuje le povečan rep omenjenega histograma (od vrednosti v_{02} naprej), ki je sicer zaradi majhnega števila vzorcev v tem delu histograma zelo slabo viden. Faktor povečave je določen z že omenjenim parametrom povečava. Zelena črta na obravnavanem grafu je premica, s katero se uteži histogram, medtem ko je utežen histogram prikazan z rumeno

krivuljo. Svetlozelena navpičnica pa predstavlja mejo v_{01} . V spodnjem delu vmesnika so v številčni obliki in grafično podani vrednosti značilk f_{i1} (Število velikih isker) in f_{i2} (Diagnostični rezultat). Mejne vrednosti obeh značilk so postavljene empirično.



Slika 4.16: Uporabniški vmesnik sistema za merjenje intenzitete iskrenja s primerom diagnostičnega rezultata

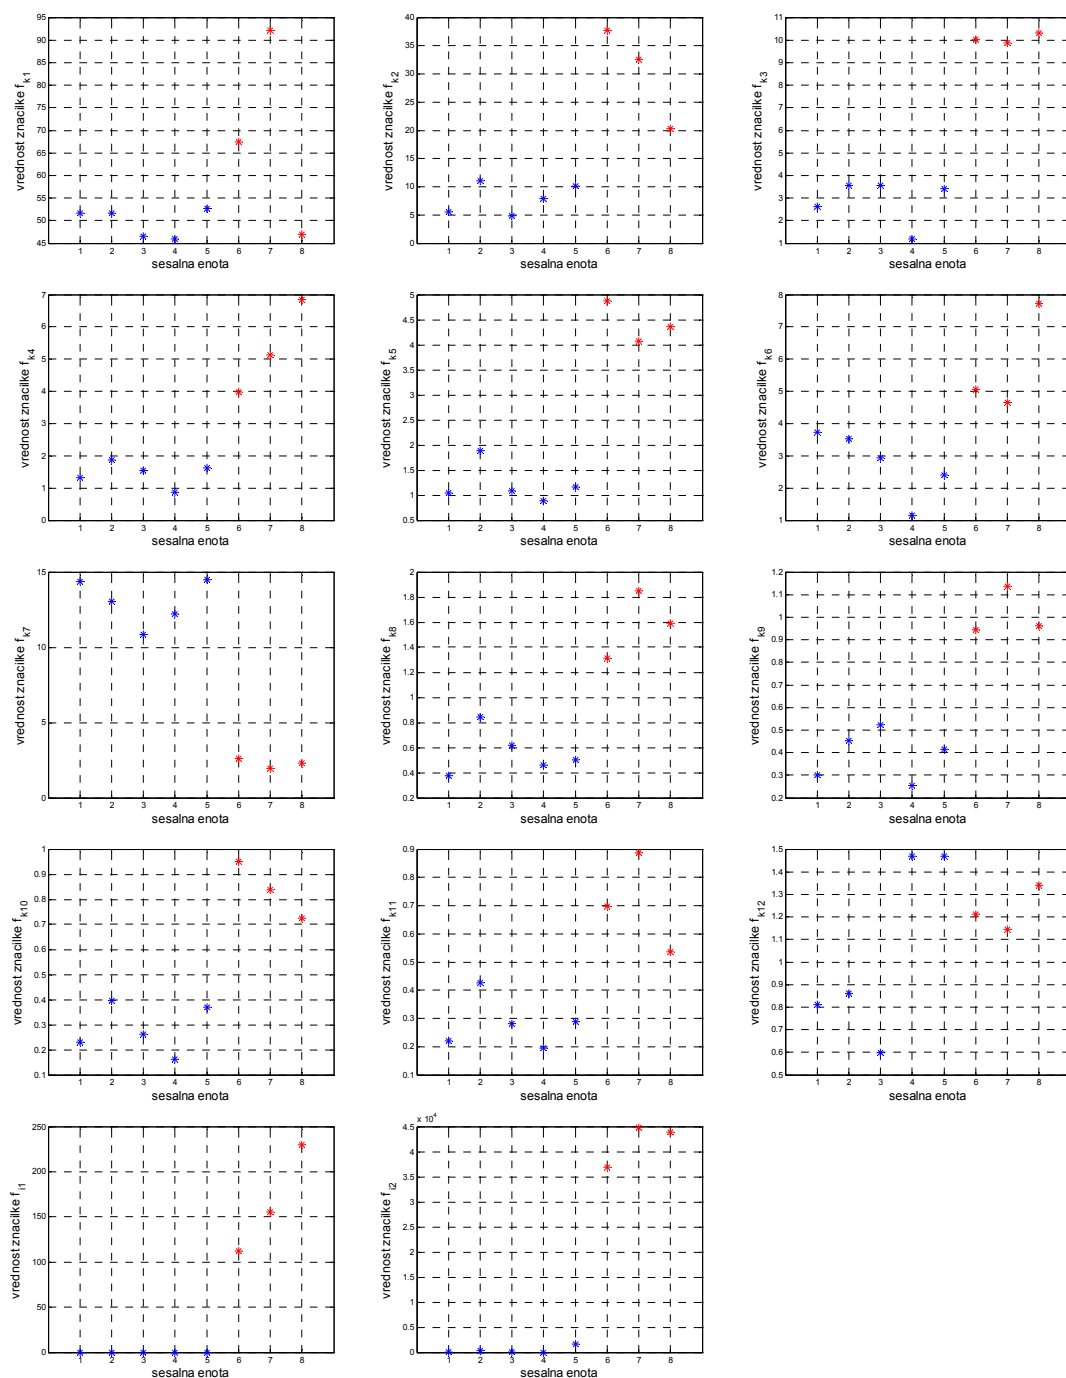
4.1.3 Analiza občutljivosti značilk kvalitete komutacije

Občutljivost vseh 14 značilk kvalitete komutacije $f_{k1}, f_{k2}, \dots, f_{k12}, f_{i1}$ in f_{i2} , ki smo jih definirali v prejšnjem podpoglavju, smo najprej preverili z meritvami na pet dobrih sesalnih enotah in treh enotah, pri katerih smo prekinili stik med eno lamelo kolektorja in rotorskim navitjem. Z omenjeno, namenoma vgrajeno, napako smo simulirali izrazito poslabšanje komutacije, ki se je odražalo v močno povečanem iskrenju (vizualna ocena). Rezultati testiranj so za posamezne značilke predstavljeni na grafih slike 4.17. Vrednosti značilk so za dobre sesalne enote prikazane z modrimi zvezdicami (sesalne enote označene s števkami od 1 do 5), za enote z vgrajeno napako pa z rdečimi (sesalne enote označene s števkami od 6 do 8).


Vidimo, da skoraj vse značilke omogočajo zanesljivo ločevanje med dobrimi sesalnimi enotami in enotami z izrazito poslabšano komutacijo. Izjemi sta značilki f_{k1} ter f_{k12} in sta zato neprimerni za vrednotenje kvalitete komutacije.

Naslednje nepričakovane rezultate smo dobili pri značilki f_{k7} . Na podlagi le-te sicer lahko ločimo obravnavani skupini sesalnih enot, vendar pa bi glede na njeno definicijo (RMS vrednost motenj v napajalnem toku v frekvenčnem področju od 15 kHz do 17.5 kHz) njene vrednosti pri dobrih enotah morale biti nižje v primerjavi z vrednostmi pri enotah s poslabšano komutacijo. Kot je razvidno s slike 4.17, pa je dejansko stanje ravno obratno. Ugotovljeno je bilo, da neposreden vzrok temu pojavu ni razlika v kvaliteti komutacije, temveč sprememba v hitrosti vrtenja sesalnih enot. Iz podpoglavja 4.1.2.1 vemo, da se zaradi nenadnega prekinjanja toka na kolektorju v frekvenčnem spektru napajalnega toka pojavi izrazita komponenta pri 22-kratniku frekvence vrtenja sesalnih enot. Vrednosti slednjih so prikazane na sliki 4.18 in sicer za dobre enote z modrimi krogi, za tiste z vgrajeno napako pa z rdečimi. Pri dobrih enotah omenjena komponenta pade v frekvenčni pas od 15 kHz do 17.5 kHz in zato signifikantno prispeva k vrednosti značilke f_{k7} . Če se hitrost vrtenja sesalne enote iz kateregakoli vzroka zmanjša, se obravnavana komponenta lahko preseli v frekvenčni pas med 12.5 kHz in 15 kHz, na katerem pa je definirana značilka f_{k6} . Posledično se vrednost le-te poveča, vrednost značilke f_{k7} pa zmanjša. S tem se postavi pod vprašaj tudi smiselnost značilke f_{k6} , saj ne moremo ločiti deleža, katerega k povečanju njene vrednosti prispeva morebitna selitev komponente pri 22-kratniku hitrosti vrtenja, od deleža, ki ga prispevajo ostale motnje, katere se v dotičnem frekvenčnem področju napajalnega toka pojavijo izključno zaradi poslabšanja kvalitete komutacije. V obravnavanih primerih je do zmanjšanja hitrosti vrtenja sesalnih enot prišlo zaradi poslabšane komutacije, vendar slednja ni edini možen vzrok za zmanjšanje hitrosti vrtenja in posledično za spremembe vrednosti značilk f_{k6} ter f_{k7} . Zato lahko tudi ti dve značilki označimo kot neprimerni za vrednotenje kvalitete komutacije.

Pri tem je potrebno opozoriti, da se na splošno opisani učinek zaradi zmanjšanja hitrosti vrtenja vedno ne odraža v značilkah f_{k6} in f_{k7} , temveč v kakšnem drugem paru značilk, ki sta definirani na drugem frekvenčnem področju. Produkt hitrosti vrtenja in števila lamel na kolektorju se namreč lahko pri različnih modelih univerzalnih elektromotorjev močno razlikuje.



Slika 4.17: Meritve kvalitete komutacije na pet dobrih sesalnih enotah in treh enotah s prekinjenim stikom med eno lamelo kolektorja in rotorskim navitjem.



Slika 4.18: 22-kratniki hitrosti vrtenja sesalnih enot pri meritvah kvalitete komutacije na dobrih enotah in enotah z vgrajeno napako

V naslednjem koraku analize občutljivosti značilk kvalitete komutacije $f_{k1}, f_{k2}, \dots, f_{k12}, f_{i1}$ in f_{i2} smo le-te preverili še z meritvami na desetih dobrih sesalnih enotah in petih enotah s povečanim iskrenjem. Slednje so bile izločene pri končni kontroli na proizvodni liniji in sicer na podlagi vizualne ocene intenzitete iskrenja. S tem smo skušali na čim bolj realen način ovrednotiti vseh 14 značilk. Rezultati testiranj so za posamezne značilke predstavljeni na grafih slike 4.19. Ponovo so vrednosti značilk za dobre sesalne enote prikazane z modrimi zvezdicami (sesalne enote označene s številkami od 1 do 10), za enote s povečanim iskrenjem pa z rdečimi (sesalne enote označene s številkami od 11 do 15).

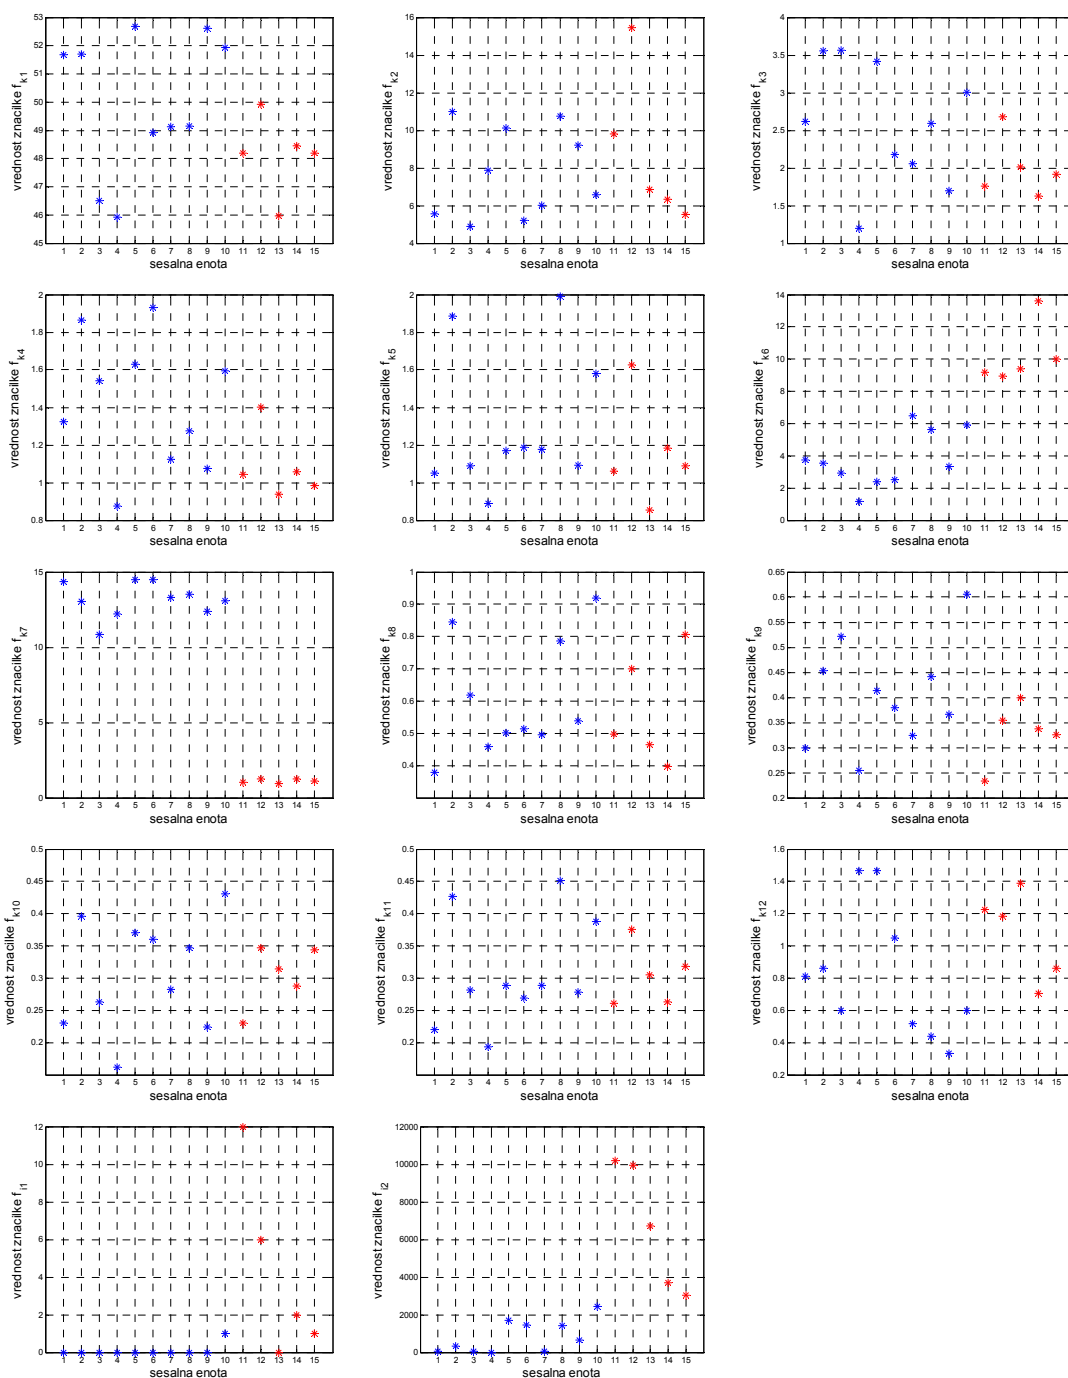
Pri značilkah f_{k6} in f_{k7} spet lahko opazimo že opisani učinek zaradi zmanjšanja hitrosti vrtenja pri sesalnih enotah s povečanim iskrenjem. Le-to potrjuje tudi graf na sliki 4.20, kjer so z modrimi krogi prikazani 22-kratniki hitrosti vrtenja pri dobrih sesalnih enotah, z rdečimi pa pri enotah s povečanim iskrenjem.

Vrednosti ostalih značilk, ki temeljijo na analizi napajalnega toka, so raztrošene po nekem območju neglede na to, ali je sesalna enota dobra ali ima povečano iskrenje. Zato lahko sklepamo, da so neprimerne za vrednotenje kvalitete komutacije.


Nadalje opazimo, da značilka f_{i1} omogoča le delno ločevanje med dobrimi sesalnimi enotami in tistimi s povečanim iskrenjem.

Druga značilka, ki temelji na vrednotenju visokofrekvenčnih napetostni motenj, f_{i2} pa je edina, s pomočjo katere lahko zanesljivo ločimo dobre sesalne enote od tistih s povečanim iskrenjem. Pri tem mejna vrednost značilke znaša približno 3000.

Ob primerjavi grafov s slike 4.17 in tistih s slike 4.19 lahko opazimo, da so vrednosti značilk kvalitete komutacije pri sesalnih enotah z vgrajeno napako v večini primerov precej višje od vrednosti pri enotah, ki so bile izločene na proizvodni liniji zaradi povečanega iskrenja.



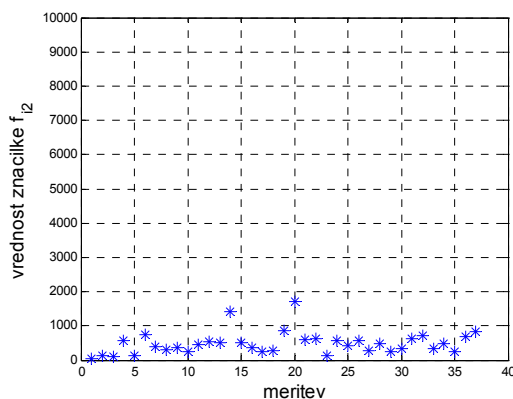
Slika 4.19: Meritve kvalitete komutacije na desetih dobrih sesalnih enotah in petih enotah s povečanim iskrenjem



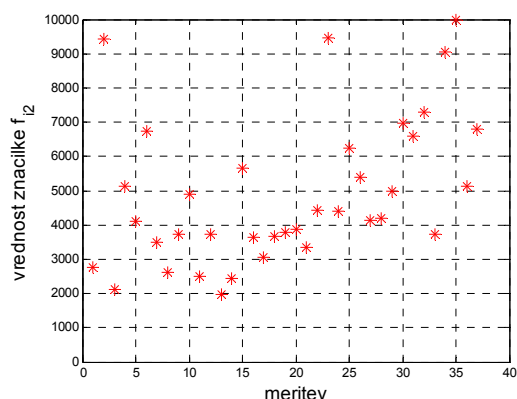
Slika 4.20: 22-kratniki hitrosti vrtenja sesalnih enot pri meritvah kvalitete komutacije na dobrih enotah in enotah s povečanim iskrenjem

Ponovljivost značilk kvalitete komutacije smo preverili na dveh sesalnih enotah (eni dobri in eni s povečanim iskrenjem), na katerih smo meritve izvedli po 37-krat. Na tem mestu bodo predstavljeni rezultati meritev le za značilko f_{i2} , ki se je izkazala za najboljšo pri ocenjevanju kvalitete komutacije, medtem ko so rezultati za vseh ostalih 13 značilk kvalitete komutacije podani v dodatku A.

Dobljene vrednosti značilke f_{i2} so za dobro sesalno enoto prikazane na sliki 4.21, za enoto s povečanim iskrenjem pa na sliki 4.22. Vidimo, da je pri dobri sesalni enoti raztros glede na absolutne vrednosti, ki jih zavzame značilka, kar precejšen (standardna deviacija znaša približno 336). Toda značilka nikoli ne preseže mejne vrednosti. Pri sesalni enoti s povečanim iskrenjem je omenjeni raztros še dosti večji (standardna deviacija znaša približno 2138). Vendar pa obravnavani raztros ni posledica merilnega postopka, ampak same narave pojava, ki ga merimo. Intenziteta iskrenja se med delovanjem sesalnih enot namreč tudi dejansko zelo spreminja (vizualna ocena).



Slika 4.21: Ponovljivost značilke f_{i2} pri dobri sesalni enoti



Slika 4.22: Ponovljivost značilke f_{12} pri sesalni enoti s povečanim iskrenjem

4.1.4 Statistična analiza značilk kvalitete komutacije


Statistično analizo značilk kvalitete komutacije smo opravili na diagnostičnih rezultatih, ki so bili pridobljeni pri testiranju sesalnih enot na koncu proizvodne linije in sicer v obdobju enega meseca. V tem času je bilo opravljenih natanko 114233 uspešnih testiranj, pri čemer je bilo zaradi neustrezne komutacije izločenih 655 enot.

4.1.4.1 Statistika pojavljanja sesalnih enot z neustrezno komutacijo

Ob zgoraj navedenem podatku se postavlja pomembno vprašanje, kakšna je verjetnost, da se bo pojavila sesalna enota s poslabšano komutacijo čez določeno število proizvedenih enot. Če predpostavimo medsebojno neodvisnost dogodkov pojavljanja enot z neustrezno komutacijo, se omenjena verjetnost podreja geometrijski porazdelitvi (Enačba 4.4) (Wasserman, 2005; Stark in Woods, 2002):


$$P(n) = (1 - p)^{n-1} p \quad (4.4)$$

kjer je $P(n)$ verjetnost, da se nek dogodek pojavi po natanko n realizacijah, če je verjetnost tega dogodka pri posamezni realizaciji enaka p . V obravnavanem primeru analize značilk kvalitete komutacije p znaša približno 0.0057 (št. sesalnih enot z neustrezno komutacijo / št. vseh proizvedenih sesalnih enot). Geometrijska porazdelitev pri tej vrednosti p ima obliko, kot je prikazana na sliki 4.23.



Slika 4.23: Verjetnost pojava sesalne enote z neustrezno komutacijo po n proizvedenih enotah – teoretičen izračun

Na sliki 4.24 pa so predstavljene verjetnosti pojavov sesalnih enot z neustrezno komutacijo po določenem številu (n) proizvedenih enot, ki smo jih izračunali na osnovi realnih podatkov s pomočjo relativne frekvenca. Pri primerjavi slik 4.23 in 4.24 opazimo, da se le-ti ne ujemata. Vzrok temu je nepravilnost predpostavke o neodvisnosti pojavljanja sesalnih enot z neustrezno komutacijo.



Slika 4.24: Verjetnost pojava sesalne enote z neustrezno komutacijo po n proizvedenih enotah – določena na osnovi relativne frekvenca

Zgornjo trditev potrjuje tudi naslednji test. Če je namreč pojav sesalne enote z neustrezno komutacijo neodvisen dogodek, mora biti verjetnost pojava sesalne enote z neustrezno komutacijo (slabe) pri pogoju, da je bila pred le-to izdelana dobra sesalna enota, enaka verjetnosti pojava sesalne enote z neustrezno komutacijo (slabe) pri pogoju, da je bila pred le-to izdelana sesalna enota z neustrezno komutacijo (slaba) (Enačba 4.5):

$$P(SE_i = \textit{slaba} \mid SE_{i-1} = \textit{dobra}) = P(SE_j = \textit{slaba} \mid SE_{j-1} = \textit{slaba}) \quad (4.5)$$

Tu je z *SE* označena sesalna enota, *i* in *j* pa sta poljubni številki proizvedenih enot. Levo in desno stran enačbe 4.5 izračunamo po formuli za pogojno verjetnost:


$$P(A \mid B) = \frac{P(AB)}{P(B)} \quad (4.6)$$

kjer sta *A* in *B* poljubna dogodka. S ponovno uporabo podatkov testiranja in pristopa relativne frekvence dobimo za levo stran enačbe 4.5 vrednost 0.0054, za desno pa 0.0641. Vrednosti se bistveno razlikujeta, zato lahko rečemo, da pri proizvodnji sesalnih enot pojavljanje takšnih z neustrezno komutacijo ni neodvisen dogodek. Večja je verjetnost pojava dveh zaporedoma proizvedenih sesalnih enot s poslabšano komutacijo, kar je konec koncev tudi pričakovan rezultat.

4.1.4.2 Korelacija med značilkami kvalitete komutacije

Ali se vseh 14 značilk kvalitete komutacije $f_{k1}, f_{k2}, \dots, f_{k12}, f_{i1}$ in f_{i2} odziva na dejansko stanje sesalne enote, lahko sklepamo tudi s slike 4.25, kjer so z barvami prikazane vrednosti korelacijskih koeficientov med posameznimi značilkami. Kot bo podrobneje razloženo v podpoglavju 5.1.1.1, korelacijski koeficient služi ocenjevanju linearne odvisnosti med dvema naključnima spremenljivkama. Z večanjem njegove absolutne vrednosti proti 1 se večja tudi linearna odvisnost.

Na sliki 4.25 so značilke kvalitete komutacije nanizane v naslednjem vrstnem redu: $f_{k1}, f_{k2}, \dots, f_{k12}, f_{i1}$ in f_{i2} . Vidimo, da obstaja precejšnja stopnja koreliranosti med značilkama f_{i1} in f_{i2} , ki temeljita na vrednotenju visokofrekvenčnih napetostni motenj. Korelecija z ostalimi 12 značilkami $f_{k1}, f_{k2}, \dots, f_{k12}$, ki temeljijo na analizi napajalnega toka, pa je zelo šibka. Torej lahko rečemo, da sta za ocenjevanje kvalitete komutacije najprimernejši značilki f_{i1} in f_{i2} . Pri značilki f_{k7} pa v obliki negativnih vrednosti korelacijskih koeficientov ponovno pride do izraza že predstavljeni učinek zmanjšanja hitrosti vrtenja.



Slika 4.25: Korelacijski koeficienti med posameznimi značilkami kvalitete komutacije

4.2 Merjenje vibracij

Težnje po čim boljših izkoristkih sesalnih enot in čim nižjih materialnih stroških proizvodnje silijo proizvajalce h konstruiranju in izdelovanju enot z zelo velikimi nazivnimi hitrostmi vrtenja ter k optimizaciji mas vgrajenih materialov. Oba ukrepa pa sta neugodna s stališča vibracij enot. Zaradi večjih hitrosti vrtenja se namreč povečajo nekatere sile, ki povzročajo vibracije, manjša masa, predvsem ohišij, pa ima za posledico slabše dušenje teh vibracij. Povečan nivo vibracij pomeni večjo obremenitev ležajev in nekaterih drugih sestavnih delov sesalne enote, kar lahko privede do bistvenega skrajšanja njene življenjske dobe. Zato je kontrola nivoja vibracij bistvenega pomena. Dodaten razlog za omejevanje nivoja vibracij sesalnih enot je hrup. Povečane vibracije sesalne enote namreč povzročajo tresenje velikih površin ohišja sesalnika, v katerega je le-ta vgrajena. Posledica tega pa je nastanek nezaželenega hrupa, ki je moteč za uporabnike. Razlog za merjenje vibracij je tudi, da so v signalu vibracij vsebovane informacije o določenih potencialnih napakah na sesalnih enotah. Tako lahko diagnostika nekaterih napak sesalnih enot temelji na ustrezni analizi tega signala.

Z analizo vibracij za potrebe diagnosticiranja različnih vrst rotacijskih strojev so se v preteklosti ukvarjali številni avtorji. Pri tem so se posluževali najrazličnejših metod. V nadaljevanju bo naštetih nekaj v literaturi pogosteje obravnavanih pristopov. Le-ti v večini temeljijo na transformaciji signala vibracij v frekvenčni prostor.

Spektralne analize vibracij (poleg hrupa in napajalnega toka) se za diagnosticiranje napak pri indukcijskih motorjih poslužujejo Payne in sodelavci (2000b). Ob tem predlagajo še uporabo analize "cepstrum-ov" za odkrivanje pojavov, ki se v signalu vibracij ponavljajo.

Del Castillo in sodelavci (2002) poskušajo s statistično metodo analize rojev ločiti frekvenčne spektre vibracij, ki so značilni za dobre kroglične ležaje od takšnih z različnimi vrstami poškodb, tj. s poškodovanim notranjim kanalom, poškodovanim zunanjim kanalom in poškodovano kroglico. Isto napako Worden in sodelavci (2000) odkrivajo s pomočjo analize izrednih dogodkov (ang. outlier analysis). Praktično oceno metode za odkrivanje poškodb na krogličnih ležajih, ki temelji na frekvenčni analizi ovojnice signala vibracij, pa podaja Courrech (2000).

Z analizo frekvenčnih spektrov signalov vibracij sta se ukvarjala tudi Peng in Kessissoglou (2003). Osredotočila sta se na stranske komponente nosilnih frekvenc, ki se v spektru signala pojavijo zaradi amplitudne modulacije. Omenjene komponente so tipične pri obrabi zobniških prenosov.

Brotherton in sodelavci (1999) ter Chandroth in sodelavci (1999) za klasifikacijo frekvenčnih spektrov signalov vibracij, v katerih se odraža stanje stroja, predlagajo uporabo nevronske mreže, medtem ko Meesad in Yen (2000) zagovarjata kombinacijo nevronske mreže in mehkega sklepanja.

Zelo razširjena metoda, s katero lahko signal preslikamo v časovno-frekvenčni prostor, je valčna transformacija. Z apliciranjem le-te na signal vibracij Luo in sodelavci (2000) poskušajo odkrivati spremembe v lastnih frekvencah opazovanega stroja, ki naj bi bile posledica sprememb na stroju samem. Koo in Kim (2000) pa analizirata signal vibracij s pomočjo Wigner-jeve porazdelitve. To je še ena izmed metod za predstavitev v časovno-frekvenčnem prostoru. Pri nadaljnjem razvrščanju si pomagata z nevronske mreže. V tem odstavku omenjena pristopa sta zelo prikladna v primerih, ko imamo opravka z nekonstantno hitrostjo vrtenja stroja oziroma ko je potrebno opazovati komponente signala, ki se časovno spreminjajo.

Pri klasifikacij frekvenčnih spektrov vibracij Tax in sodelavci (1999) predlagajo predobdelavo podatkov z metodo "Support Vector Data Description" (SVDD). Na ta način dobimo bolj natančen in kompakten opis podatkov, kar rezultira v zmanjšanju šuma in posledično olajša nadaljnje sklepanje. Isti avtorji v še enem prispevku (Ypma in sodelavci, 1999) poskušajo z uporabo večjega števila senzorjev vibracij, ki omogočajo istočasen zajem signalov na več različnih mestih, in analize neodvisnih komponent (ang. Independent Component Analysis, ICA) odkriti dejanske izvire vibracij na opazovanem stroju. Omenjena metoda je namreč iz nabora signalov sposobna poiskati statistično neodvisne vire, ki linearno prispevajo k obravnavanim signalom. Za nadaljnjo obdelavo podatkov pa se avtorji ponovno poslužujejo metode SVDD.

Večina komponent signala vibracij, ki so mehanskega izvora, je pri rotacijskih strojih tesno povezanih s hitrostjo vrtenja. Zato Blough (2003) ter Persson in Gustafsson (2001) v svojih delih predlagajo, da signal vibracij na časovni osi skaliramo glede na kot zasuka stroja. S tem izločimo vpliv hitrosti vrtenja in tako dobimo bolj čisto sliko

prej omenjenih komponent. Takšen pristop je zelo uporaben v primerih, ko je hitrost vrtenja stroja nekonstantna, in sicer za odkrivanje mehanskih izvorov vibracij.

Pri širjenju vibracij od izvorov do merilnega mesta na površini stroja prihaja tudi do različnih nelinearnih transformacij. Po drugi strani pa so lahko sami izvori kaotičnega značaja. Zato se v izmerjenem signalu vibracij pojavlja tudi kompleksno dinamično obnašanje. Proučevanja teh pojavov so se Jiang in sodelavci (1999) lotili z uporabo metod za analizo nelinearnih dinamičnih sistemov.


Za vrednotenje vibracij na elektromotorjih obstaja standard IEC 34-14. V njem so definirane zahteve za merilno opremo, merjena veličina, merilne točke, način vpetja merjenja med izvajanjem meritev in mejne vrednosti izmerjene veličine. Vendar pa ta standard velja le za večje elektromotorje z manjšimi hitrostmi vrtenja (do 3600 vrtljajev na minuto), zato je za sesalne enote neustrezen.

4.2.1 Pojasnitev izvorov vibracij pri sesalnih enotah

Iz časovnih posnetkov vibracij sesalne enote le težko sklepamo o njenih lastnostih. Zato je potrebno izmerjeni signal vibracij ustrezno obdelati, tako da iz njega lahko izluščimo čim več informacij. Klasičen pristop, ki se uporablja pri obdelavi signalov, je Fourierjeva transformacija. Le-ta signal iz časovnega prostora preslika v frekvenčni prostor, v katerem so razvidne amplitude posameznih frekvenčnih komponent signala. V primeru signala vibracij sesalne enote se v omenjenih komponentah odražajo določene lastnosti enote.

Glede na lastnosti spektralne analize, ki so predstavljene v dodatku B, frekvenčne spektre signalov vibracij računamo kot povprečje več spektrov, katere dobimo z diskretno Fourierjevo transformacijo (DFT) časovnih izsekov posameznega obravnavanega signala. Omenjeni izseki so izbrani tako, da se medsebojno prekrivajo za dve tretjini, in so uteženi s Hanningovim oknom. Velikost posamezne frekvenčne komponente, ki nas zanima, pa se določi kot integral spektra na določenem frekvenčnem področju v okolici te komponente. Velikost karakterističnih frekvenčnih komponent lahko ocenimo tudi z določanjem RMS vrednosti signala vibracij v ustreznem frekvenčnem pasu.

V frekvenčnih spektrih signala vibracij vseh sesalnih enot se pri nazivnem obratovanju pojavljajo določene značilne frekvenčne komponente, v katerih se odražajo posamezni izvori vibracij (Tinta in sodelavci, 2005). Le-te so označene na sliki 4.26, kjer je na spodnjo abscisno os nanosena frekvenca v Hz, zgornja abscisna os pa je normirana s frekvenco vrtenja enote. V predstavljenem primeru je bil signal vibracij zajet s pomočjo piezoelektričnega senzorja, ki zaznava pospešek vibracij, in sicer na ohišju sesalne enote v radialni smeri.




Slika 4.26: Primer frekvenčnega spektra signala vibracij za dobro sesalno enoto. Pomembne komponente v spektru so posledica: 1 – nihajočega navora elektromotorja, 2 – neuravnoteženosti vrtečih delov, 3 – sunkov zraka turbinskega kolesa in 4 – poskakovanja ščetk po lamelah kolektorja.

Spremenljiv navor elektromotorja

Prva izmed omenjenih komponent je pri frekvenci 100 Hz. Ta je predvsem posledica spremenljivega navora elektromotorja (Enačba 4.7), ki zaradi izmenične napajalne napetosti niha s frekvenco 100 Hz (Slika 4.27) (Chapman, 2002; Zagradišnik in Slemnik, 2001):

$$\begin{aligned}
 M(t) &= k_m \Phi(t)i(t) \\
 &= \frac{k_m}{2} \hat{\Phi} \hat{I} (\cos \varphi' - \cos(2\omega t - \varphi'))
 \end{aligned}
 \tag{4.7}$$


kjer je z $M(t)$ označen navor, s k_m konstrukcijska konstanta navora, s $\hat{\Phi}$ amplituda magnetnega fluksa, z \hat{I} amplituda toka, s φ' fazni premik med $\Phi(t)$ in $i(t)$, ω pa je frekvenca napajalne napetosti.



Slika 4.27: Moment univerzalnega elektromotorja pri izmeničnem napajanju

Magnetostrikcija

Manjši delež pa h komponenti pri 100 Hz prispeva tudi magnetostrikcija, ki povzroča širjenje in krčenje materiala v izmeničnem vzbujalnem magnetnem polju motorja. To komponento oziroma njena vzroka bi lahko izločili s priključitvijo sesalne enote na enosmerno napajalno napetost (Slika 4.28).




Slika 4.28: Frekvenčni spekter signala vibracij sesalne enote pri: a) izmeničnem napajanju in b) enosmernem napajanju

Sunki zraka turbinskega kolesa

Najbolj izrazita frekvenčna komponenta se pojavi pri devetkratniku frekvence vrtenja sesalne enote (Slika 4.26). Ta je posledica sunkov zraka, ki jih povzroča turbinsko kolo s svojimi devetimi lopaticami (Slika 4.29). Zaradi velike hitrosti vrtenja sesalne enote so ti sunki zraka tako močni, da omenjena komponenta prevladuje v signalu vibracij. Zato je neponovljivost amplitude prav te komponente glavni vzrok za neponovljivost meritev signala vibracij. Ker pa je ta komponenta posledica konstrukcije sesalne enote in neizogibnega sesanja zraka, nanjo ne moremo vplivati. V spektrih vibracij je izrazit še dvakratnik obravnavane komponente (to je frekvenčna komponenta pri

osemnajstkratniku frekvence vrtenja), pri nekaterih sesalnih enotah pa tudi njen trikratnik.



Slika 4.29: Sunki zraka turbinskega kolesa

Dršenje ščetk po lamelah kolektorja

Frekvenčna komponenta pri dvaindvajsetkratniku frekvence vrtenja sesalne enote (Slika 4.26) je posledica drsenja ščetk po dvaindvajsetih lamelah kolektorja (Slika 4.30). Ker so le-te med sabo izolirane, ščetke ob vsakem prehodu na novo lamelo rahlo odskočijo in tako povzročajo vibracije.



Slika 4.30: Dršenje ščetke po lamelah kolektorja

Neuravnoveženost vrtečih delov

S stališča klasifikacije sesalnih enot je v spektru vibracij (Slika 4.26) zelo pomembna komponenta pri frekvenci vrtenja enote. V njej se odražajo vse neuravnoveženosti vrtečih delov sesalne enote (Slika 4.31). Med delovanjem enote se namreč zaradi omenjenih neuravnoveženosti pojavijo centrifugalne sile, ki povzročajo vibracije vrtečih delov. Le-te pa se preko ležajev prenašajo na preostale sestavne dele enote. Zaradi velike nazivne hitrosti vrtenja pridejo do izraza že zelo majhne neuravnoveženosti. Povečana amplituda te komponente je lahko posledica neuspešnega uravnoveženja, napak pri montaži ali slabše kakovosti nekaterih sestavnih delov. Pri nekaterih sesalnih enotah se pojavi tudi komponenta pri dvakratniku frekvence vrtenja, ki pa je amplitudno precej manjša.



Slika 4.31: Vrteči deli sesalne enote

Potrebno je še povedati, da se vibracije iz naštetih izvorov na različne načine širijo po vsej sesalni enoti in pri tem povzročajo tudi valovanja njenega ohišja oziroma pokrova turbine. Zato k izmerjenemu signalu vibracij ne prispeva samo tresenje celotne sesalne enote, ampak tudi omenjena valovanja.

Drugi viri vibracij, ki pridejo do izraza pri specifičnih režimih delovanja sesalne enote, so še:


- Različne resonančne frekvence, ki se vzbudijo med zagonom in ustavljanjem sesalne enote. Te se precej razlikujejo od enote do enote. Doslej ni bilo ugotovljene nobene povezave med temi izvori vibracij in kakovostjo sesalnih enot.
- Nihanje rotorja v aksialni smeri med ustavljanjem sesalne enote, ki se pojavi pri enotah z zračnostjo v ležajih. To je sicer napaka, katero je potrebno odkriti, vendar se za njeno detekcijo lahko uporabljala preprostejša metoda, ki ne temelji na obdelavi signala vibracij. Zato podrobnejša analiza tega izvora vibracij ni bila opravljena.
- Okvara ležaja. Tresljaje, ki jih povzroča okvarjen ležaj, najlažje zaznamo pri nižjih hitrostih vrtenja sesalne enote (~40 Hz). Vendar pa je informacija o stanju ležaja v signalu vibracij precej popačena, saj zaradi konstrukcije enote vibracij ni možno izmeriti direktno na ležaju samem. Zato se za detekcijo te napake kot primernejša izkaže metoda na osnovi analize hrupa.

- Nihanje ščetk v tangencialni smeri pri ustavljanju sesalne enote. Zaradi nepravilnosti v stiku ščetka-kolektor ali nepravilne lege ščetk v njenem vodilu, se včasih zgodi, da ščetka pri zaustavljanju enote zaniha. To povzroča nezaželene vibracije celotne sesalne enote, zato je potrebno takšne enote detektirati. Težava je v tem, da se tangencialno nihanje ščetk pojavlja pri različnih hitrostih vrtenja, poleg tega pa lahko zaradi obrabe ščetk po določenem času obratovanja izgine.

Našteti izvori vibracij razen tistega zaradi sunkov zraka turbinskega kolesa se pojavljajo pri vseh manjših univerzalnih elektromotorjih. Zato predstavljajo osnovo pri analizi vibracij omenjenih motorjev. Seveda so amplitude in frekvenčna območja teh izvorov odvisni od fizikalnih lastnosti konkretnih motorjev.

4.2.2 Opis merilnega postopka merjenja vibracij v Domelu


Glede na zahteve proizvajalca Domel in njihovih kupcev, je vibracije pri sesalnih enotah potrebno izmeriti v treh točkah in sicer: na turbini v aksialni smeri, na turbini v radialni smeri ter na ohišju sesalne enote v radialni smeri (točke 1, 2 in 3 na sliki 4.32).



Slika 4.32: Merilne točke na sesalni enoti

Meritev vibracij na proizvodni liniji (Slika 4.33) poteka na naslednji način (Petrovčič in sodelavci, 2005). Najprej posebne klešče primejo sesalno enoto. S tem jo vibracijsko ločijo od okolice (palete) in tako preprečijo, da bi na meritev vplivale vibracije, ki jih povzroča proizvodna linija. Vibracije enot se merijo s pomočjo laserskega merilnika Ometron VQ-500-D, ki zaznava hitrost vibracij. Le-ta je pritrjen na pozicionirni mehanizem, katerega poganja koračni motor. Pozicionirni mehanizem omogoča vertikalno premikanje merilnika, ki meri vibracije v horizontalni smeri (radialni smeri sesalne enote). Meritev v aksialni smeri enote (vertikalni smeri) se izvede s pomočjo zrcala, ki laserski žarek preusmeri v omenjeno smer. Nato pozicionirni mehanizem premakne laserski merilnik v še dve točki, tako da se lahko


izmerijo še vibracije v radialni smeri in sicer na turbini ter na ohišju. Po končanih meritvah se laserski merilnik vrne v začetni položaj, klešče pa izpustijo sesalno enoto.



Slika 4.33: Merjenje vibracij

Signal vibracij na izhodu laserskega merilnika najprej filtriramo z nizkopropustnim (anti-aliasing) filtrom drugega reda z mejno frekvenco 20 kHz, nato pa ga 0.12 s vzorčimo s frekvenco 60 kHz. Sledi še eno filtriranje z digitalnim nizkopropustnim filtrom drugega reda z mejno frekvenco 15 kHz.

Značilke, s katerimi se vrednoti nivo vibracij pri sesalnih enotah, so definirane kot RMS vrednosti treh filtriranih signalov vibracij v 15 frekvenčnih pasovih širine 1 kHz in sicer od 0 do 15 kHz. V nadaljevanju jih bomo označevali s $f_{va1}, f_{va2}, \dots, f_{va14}$ in f_{va15} za vibracije na turbini v aksialni smeri, s $f_{vl1}, f_{vl2}, \dots, f_{vl14}$ in f_{vl15} za vibracije na turbini v radialni smeri ter s $f_{vo1}, f_{vo2}, \dots, f_{vo14}$ in f_{vo15} za vibracije na ohišju sesalne enote v radialni smeri. Vrednosti značilke za posamezne merilne točke izračunamo po frekvenčnih pasovih v amplitudnih spektrih signalov vibracij (npr. slika 4.34) na enak način, kot značilke kvalitete komutacije v podpoglavju 4.1.2.1. Slabost tako definiranih značilke so fiksne meje frekvenčnih pasov, ki so postavljene ne glede na lego značilnih frekvenčnih komponent v spektrih vibracij. Problem je v tem, da tiste izmed omenjenih komponent, ki so vezane na hitrost vrtenja, zaradi odstopanj slednje lahko "prehajajo" med sosednjimi pasovi. To pa signifikantno vpliva na vrednosti značilke, kar pomeni, da imamo opravka s slabo robustnostjo.



Slika 4.34: Frekvenčni pasovi signala vibracij na turbini v radialni smeri

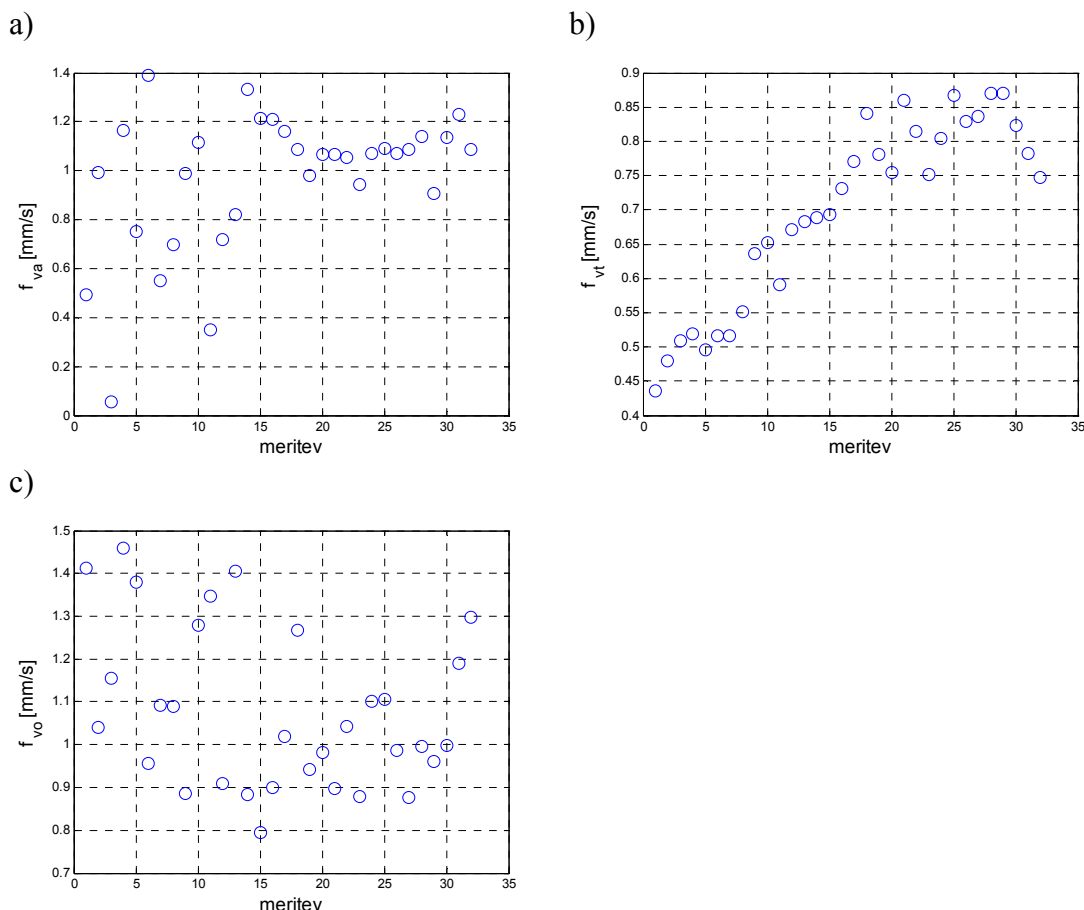
Dodatne tri značilke za vrednotenje vibracij v treh merilnih točkah na sesalnih enotah so definirane kot RMS vrednosti signalov vibracij v frekvenčnem področju v okolici frekvence vrtenja enot. S temi tremi značilkami namreč želimo oceniti nivo vibracij, ki se pojavijo zaradi morebitne neuravnoteženosti vrtečih delov sesalnih enot. Označevali jih bomo s f_{va} za vibracije na turbini v aksialni smeri, s f_{vt} za vibracije na turbini v radialni smeri in s f_{vo} za vibracije na ohišju sesalne enote v radialni smeri. Njihove vrednosti dobimo tako, da filtriran signal vibracij dodatno filtriramo z digitalnim pasovnopropustnim filtrom četrtega reda z mejnima frekvencama pri 600 Hz in 800 Hz ter po definiciji izračunamo RMS vrednost rezultirajočega signala.

4.2.3 Analiza značilk za vrednotenje vibracij pri sesalnih enotah

Kot je bilo razloženo v podpoglavju 4.2.1, k vibracijam na površini sesalnih enot, kjer le-te merimo, prispevajo različni izvori, pri čemer na intenziteto nekaterih izmed njih zelo težko vplivamo oziroma jo nadziramo (npr. sunki zraka). Zato je skorajda nemogoče simulirati napake, ki bi kontrolirano vplivale na posamezne značilke vibracij. Po drugi strani pa za sesalne enote ne obstaja nek "etalon", ki bi predpisoval vrednosti značilk vibracij. Vse to pomeni, da ni mogoče na klasičen način preverili občutljivosti v prejšnjem podpoglavju definiranih značilk za vrednotenje vibracij – opazovati spremembe vrednosti posamezne značilke (izhoda) pri nadzorovani spremembi vzrokov vibracij (vhoda).

Ponovljivost meritev vibracij smo preverili tako, da smo na eni dobri sesalni enoti meritve izvedli 32-krat. Rezultati meritev za značilke f_{va} , f_{vt} in f_{vo} , ki odražajo

neuravnoteženost vrtečih delov sesalne enote, so prikazani na grafih slike 4.35. Vidimo, da je v predstavljenem primeru raztros značilke f_{va} (vibracij na turbini v aksialni smeri) glede na njene absolutne vrednosti najprej zelo velik, nato pa se njena vrednost precej ustali okrog nekoliko višje srednje vrednosti (Slika 4.35a). Pri značilki f_{vt} (vibracijah na turbini v radialni smeri) opazimo trend naraščanja, ki pa se po določenem času umiri (Slika 4.35b). Gledano relativno je raztros v tem primeru manjši kot pri značilki f_{va} . Vzrokov za predstavljene spremembe vibracij na turbini žal ne poznamo. Vrednosti značilke f_{vo} (vibracij na ohišju v radialni smeri) se pri ponavljanju meritev naključno spreminjajo znotraj nekega območja (Slika 4.35c). Tudi v tem primeru je raztros gledano relativno manjši v primerjavi z značilko f_{va} . Ob tem povejmo, da nobena od predstavljenih značilk ne preseže empirično določenih mejnih vrednosti. V tabeli 4.1 so podane še srednje vrednosti in standardne deviacije (kot ocena raztrosa) za obravnavane tri značilke. V vseh treh primerih so raztrosi gledano relativno na absolutne vrednosti značilk precej veliki. Vzrok temu ni slaba ponovljivost temveč majhne absolutne vrednosti značilk, saj so bile meritve opravljene na dobro uravnoteženi sesalni enoti.

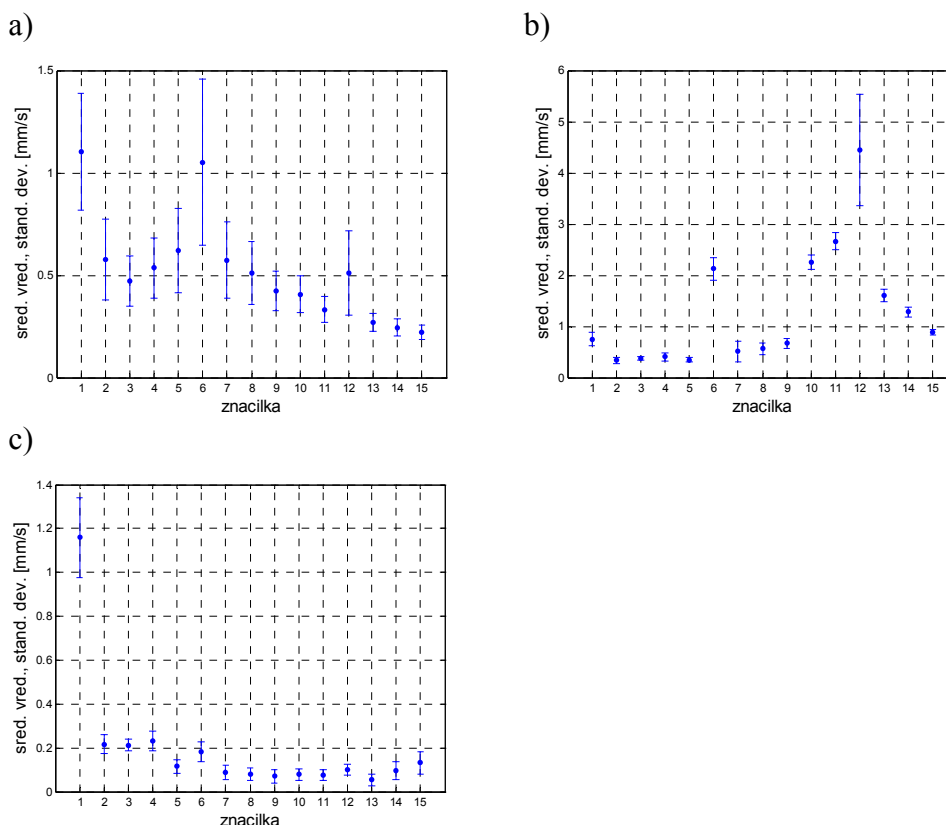


Slika 4.35: Ponovljivost značilk vibracij: a) f_{va} , b) f_{vt} , c) f_{vo}

Tabela 4.1: Srednja vrednost in standardna deviacija značilnk f_{va} , f_{vt} in f_{vo}

značilka	srednja vrednost [mm/s]	standardna deviacija [mm/s]
f_{va}	0.97	0.29
f_{vt}	0.70	0.14
f_{vo}	1.08	0.19


Za ostale značilke vibracij, tj. RMS vrednosti treh (različne merilne točke) signalov vibracij v posameznih frekvenčnih pasovih ($f_{va1}, f_{va2}, \dots, f_{va15}, f_{vt1}, f_{vt2}, \dots, f_{vt15}, f_{vo1}, f_{vo2}, \dots, f_{vo14}$ in f_{vo15}), pa so na tem mestu (grafi slike 4.36) predstavljene le njihove srednje vrednosti in standardne deviacije. Vrednosti omenjenih značilnk pri posameznih ponovitvah meritev lahko vidimo v dodatku C. Grafi na sliki 4.36 se nanašajo na tri merilne točke in sicer na turbini v aksialni smeri (Slika 4.36a), na turbini v radialni smeri (Slika 4.36b) in na ohišju v radialni smeri (Slika 4.36c). Pri tem se številke na abscisnih oseh grafov ujemajo z indeksi posameznih značilnk. Na splošno lahko rečemo, da je raztros vibracij na turbini nekoliko večji od tistega na ohišju sesalne enote. Vzrok temu so najverjetneje sunki zraka, katerih vpliv pride na turbini bolj do izraza.



Slika 4.36: Srednje vrednosti in standardne deviacije značilnk vibracij: a) na turbini v aksialni smeri ($f_{va1}, f_{va2}, \dots, f_{va15}$), b) na turbini v radialni smeri ($f_{vt1}, f_{vt2}, \dots, f_{vt15}$), c) na ohišju v radialni smeri ($f_{vo1}, f_{vo2}, \dots, f_{vo15}$)

Statistično analizo značilk vibracij smo opravili na isti množici diagnostičnih rezultatov kot analizo značilk kvalitete komutacije v podpoglavju 4.1.4. Izmed 114233 uspešno testiranih sesalnih enot je bilo 185 takšnih s povečanimi vibracijami (vsaj ena izmed značilk vibracij je presegla empirično določeno mejno vrednost).

Kakšna je verjetnost, da se bo pojavila sesalna enota s povečanimi vibracijami čez določeno število proizvedenih enot lahko razberemo z grafa na sliki 4.37. Le-tega smo dobili z računanjem relativnih frekvenc v obravnavanem nizu podatkov. Na enak način kot za sesalne enote z neustrezno komutacijo v podpoglavju 4.1.4.1 (enačba (4.5)) je bilo tudi za enote s povečanimi vibracijami ugotovljeno, da v proizvodnji pojavljanje slednjih niso neodvisni dogodki.



Slika 4.37: Verjetnost pojava sesalne enote s povečanimi vibracijami po n proizvedenih enotah – določena na osnovi relativne frekvence

Pri isti množici diagnostičnih rezultatov smo preverili še korelacijske koeficiente (njihova podrobna razlaga je podana v podpoglavju 5.1.1.1) med posameznimi značilkami vibracij. Le-ti so prikazani na sliki 4.38, kjer so značilke razporejene po naslednjem vrstnem redu: $f_{va}, f_{va1}, f_{va2}, \dots, f_{va15}, f_{vt}, f_{vt1}, f_{vt2}, \dots, f_{vt15}, f_{vo}, f_{vo1}, f_{vo2}, \dots, f_{vo14}$ in f_{vo15} .


Najprej opazimo, da so na splošno značilke vibracij za posamezno merilno točko bolj korelirane med seboj kot z značilkami za ostali merilni točki. To je še posebej izrazito pri značilkah za merilno točko na turbini v aksialni smeri (prvih 16 značilk na sliki 4.38).

Nadalje lahko rečemo, da je v večini primerov stopnja koreliranosti med značilkami, ki so definirane na sosednji frekvenčnih pasovih, nekoliko višja od tiste med značilkami na signifikantno različnih frekvenčnih področjih.

Zelo močno sta med seboj korelirani značilki f_{va} in f_{va1} . Enako velja za para značilki f_{vt} in f_{vt1} ter f_{vo} in f_{vo1} . To je pričakovan rezultat, saj v frekvenčnem pasu, kjer so definirane značilke f_{va1}, f_{vt1} in f_{vo1} , (od 0 do 1 kHz) prevladuje komponenta pri frekvenci

vrtenja sesalne enote, v kateri se odražajo neuravnoteženosti vrtečih delov enote in služi kot osnova za izračun značilnik f_{va} , f_{vt} in f_{vo} . Slednje so definirane na frekvenčnem področju v ožji okolici omenjene komponente (med 600 in 800 Hz).

Povečano koreliranost opazimo tudi med značilkami f_{vt} oz. f_{vtl} in f_{vo} oz. f_{vol} . Skupni lastnosti teh štirih značilnik sta, da se odzivajo na vibracije v radialni smeri ter, da k njihovim vrednostim največ prispeva komponenta vibracij, ki je posledica neuravnoteženosti vrtečih delov sesalne enote in je najbolj izražena prav v omenjeni smeri. Razlika je le, da sta prvi dve značilki namenjeni vrednotenju vibracij na turbini, drugi dve pa na ohišju. Torej ocenjujejo neuravnoteženost na različnih delih sesalne enote. Dejstvo je, da neuravnoteženost, ki se lahko pojavi v različnih točkah vzdolž enote, povzroča vibracije, katerih jakost se v omenjeni smeri zmanjšuje z oddaljevanjem od izvora. Zato se ob njenem pojavu v večji ali manjši meri (odvisno na katero merilno točko ima večji vpliv) nanjo odzivata oba para značilnik.



Slika 4.38: Korelacijski koeficienti med posameznimi značilkami vibracij

5. Nadzor proizvodnje

Z implementacijo avtomatskega sistema za kontrolo kakovosti končnih izdelkov na proizvodni liniji se odprejo nove možnosti v smislu nadzora proizvodnje. Diagnostični rezultati testiranja namreč predstavljajo vir informacij o stanju celotne proizvodnje, na podlagi katerih se sprejemajo odločitve o potrebnih ukrepih na liniji, da se izboljša njeno delovanje. Spremljanje in obdelava podatkov s proizvodne linije za potrebe nadzora spada v področje t.i. statistične kontrole procesov.

Pri statistični kontroli procesov gre za splošno orodje za nadzor kvalitete. Služi prikazovanju statističnih parametrov procesov in odkrivanju vzrokov za morebitne upade kvalitete, čemur sledi ustrezno ukrepanje. Vse to seveda temelji na predhodni izvedbi meritev. Osnovna struktura statistične kontrole procesov je torej enaka kot pri sistemu avtomatskega vodenja kateregakoli procesa. Zato včasih prihaja do zamenjave namenov oz. ciljev omenjenih dejavnosti. Glavne razlike med njima so (Olsson in Newell, 1999):

- Statistična kontrola procesov in avtomatsko vodenje navadno delujeta na različnih časovnih skalah. Avtomatsko vodenje procesov je veliko hitreje v primerjavi s statistično kontrolo procesov.
- Pri statistični kontroli procesov lahko meritve in ustrezne ukrepe izvede operater "ročno", medtem ko avtomatsko vodenje temelji na avtomatskih merilnikih in regulatorjih, ki delujejo v realnem času. Zato statistično kontrolo procesov lahko označimo tudi kot vodenje s pomočjo operaterja.
- Avtomatsko vodenje procesov izvaja regulacijske akcije z namenom zmanjšanja učinka motenj, ki vplivajo na proces. Ob tem ne poskuša izločiti motenj v smislu, da bi se le-te v prihodnosti ne pojavljale več. Po drugi strani pa statistična kontrola procesov služi odkrivanju vzrokov motenj in njihovi eliminaciji.
- Glavni namen statistične kontrole procesov je ločevati naključne spremembe (običajne vzroke) od izrednih dogodkov (posebnih vzrokov) in se odzivati le na slednje. Nasprotno, se avtomatsko vodenje procesov odziva na vse spremembe.

Tako v določenih razmerah, posebno, če je ojačenje regulatorja preveliko, lahko avtomatski regulator dejansko ojači šum, kar povzroči še večja odstopanja v procesu.

Statistična kontrola procesov zagotovi, da procesi ustrezajo standardom. Kontrola je potrebna, ker so procesi podvrženi določeni stopnji variabilnosti. Pri tem je potrebno razlikovati med običajnimi in posebnimi vzroki za to. Nekateri omenjene vzroke variabilnosti označujejo kot "naravne" in "sistematske". Proces obratuje v skladu z zahtevami statistične kontrole, ko je edini vir variabilnosti običajni (naravni) vzrok. Z odkritjem in eliminacijo posebnih (sistematskih) vzrokov variabilnosti je potrebno proces najprej pripeljati v stanje obratovanja, ki je skladno z zahtevami statistične kontrole. S tem postane njegovo delovanje predvidljivo, kar omogoča oceno njegove sposobnosti ustrežanja zahtevam (Olsson in Newell, 1999).

Naključen signal oz. časovno vrsto meritev na stohastičnem procesu lahko opišemo z njegovo verjetnostno porazdelitvijo. Če se le-ta s časom ne spreminja, je signal (proces) stacionaren. V veliko praktičnih primerih lahko porazdelitve aproksimiramo z normalno (Gauss-ovo) porazdelitvijo, zato je dovolj, če jih opišemo s pričakovano vrednostjo (μ) in varianco (σ^2) oz. standardno deviacijo (σ). Pri klasični statistični kontroli procesov se predpostavlja, da so podatki (meritve) pridobljeni v ustaljenem stanju procesa in da se podrejajo normalni porazdelitvi.

Nekatera enostavnejša orodja, ki se uporabljajo za prikazovanje delovanja procesov v okviru statistične kontrole so (Olsson in Newell, 1999):

- Pareto analiza,
- diagram poteka,
- histogram,
- diagram odvisnosti med dvema spremenljivkama,
- časovni potek in
- kontrolni diagram.

Pareto analiza je poimenovana po italijanskem ekonomistu Vilfredu Paretu (1848-1923), ki je znan po hipotezi, da 80% vseh svetovnih dobrin poseduje samo 20% ljudi. Ta princip velja tudi v mnogo drugih primerih. Za potrebe statistične kontrole procesov ga lahko interpretiramo na naslednji način: 80% težav na procesu je posledica 20% vseh možnih vzrokov. S Pareto analizo ločimo nekaj bolj pogostih vzrokov težav od množice manj pogostih vzrokov. Analizo izvedemo po naslednjih korakih:

1. odkrijemo vzrok posamezne težave,
2. določimo pogostost posameznih vzrokov,
3. razvrstimo vzroke po padajočem vrstnem redu glede na pogostost,

4. izračunamo delež vsakega vzroka glede na celotno število vzrokov in
5. narišemo graf relativne frekvence v odvisnosti od vzrokov.

Dobljeni diagram je odvisen od izbire vzrokov, kar lahko rezultira v nekoliko popačeni sliki. Zato je bolje, da pred urejanjem po velikosti in risanjem frekvenco posameznih vzrokov pomnožimo s stroški, ki jih ti vzroki težav povzročajo. S tem povečamo prioriteto težavam, ki povzročajo več škode.

Diagrami poteka so uporabni za grafično predstavitev poteka vseh veličin v procesu. Lahko jih uporabimo tudi za prikaz odločitev operaterjev pri vodenju procesa. Iz njih so lepo razvidne povezave med posameznimi procesnimi koraki.

Histograme uporabljamo za ocenjevanje porazdelitev podatkov, ki jih opazujemo. Če porazdelitev ni blizu normalni, pomeni, da je v procesu prišlo do težav. S tem je kršena tudi ena od predpostavk analize s pomočjo kontrolnih diagramov. Histograme uporabljamo še pri ugotavljanju količine podatkov znotraj določenih meja procesa.

Vzorec iz točk v *diagramu odvisnosti med dvema spremenljivkama* lahko razkrije, če med spremenljivkama obstaja kakšna korelacija. Pri interpretaciji obravnavanih diagramov pa moramo biti previdni. Le-ti namreč ne razkrijejo informacije o povezavah med vzroki in posledicami, saj so slednje lahko enake ob različnih vzrokih.

Časovni poteki so prikazi spremenljivk v odvisnosti od časa. Njihova odlika je ta, da omogočajo hitro primerjavo novih podatkov s preteklim delovanjem.

Ideja pri *kontrolnih diagramih* je prikazovati podatke kot funkcijo časa ter zgornjo in spodnjo kontrolno mejo. Pri tem je potrebno poudariti, da se kontrolne meje ne ujemajo z mejami, ki so specificirane za sam proces, temveč so določene na podlagi podatkov izmerjenih na procesu. Ker se izrisujeta zgornja in spodnja kontrolna meja, lahko operater enostavno sodi o delovanju procesa. Kadarkoli se meritve približajo ali presežejo meje, obstaja razlog za ukrepanje.

Podatke lahko testiramo glede na različne lastnosti (npr. prekoračitev mej, raztros,...), pri čemer je pomembno odkriti naključna nihanja okrog srednje vrednosti in identificirati prisotnost trendov. Pogosto operater sodi na podlagi svojih izkušenj, če so podatki normalni ali ne. Obstajajo pa tudi nekateri preprosti standardni testi za detekcijo zgoraj omenjenih pojavov v časovnih vrstah (Olsson in Newell, 1999):

- ena vrednost preko zgornje ali spodnje kontrolne meje (nepravilno delovanje),
- devet zaporednih vrednosti nad ali pod pričakovano vrednostjo (trajno poslabšano delovanje),
- šest zaporednih vrednosti, ki monotono naraščajo ali padajo (trend),
- štirinajst zaporednih vrednosti, ki močno nihajo gor in dol (šumno obnašanje).

Zgornja in spodnja kontrolna meja sta ponavadi postavljeni na $\mu \pm 2\sigma$ ali $\mu \pm 3\sigma$. Pri Gaussovi porazdelitvi pričakujemo, da 68% vseh vzorcev leži znotraj območja $\mu \pm \sigma$. V 95.4% časa morajo biti vzorci znotraj področja $\mu \pm 2\sigma$. Če vzorec na diagramu pade izven območja $\mu \pm 3\sigma$, smo lahko 99.7% prepričani, da se je opazovani proces spremenil.

Kontrolni diagrami lahko včasih prikazujejo filtrirane podatke. Pogosto se namesto posameznih prikazujejo povprečja skupin meritev (vzorcev). Le-ta imajo veliko manjšo varianco, saj se s povprečenjem odstrani nekaj šuma. Zato morajo biti kontrolne meje za povprečene vrednosti "strožje" od tistih za posamezne meritve. Več meritev (vzorcev) kot povprečimo, bolj skupaj moramo postaviti meje.

Še en parameter, ki ga je koristno spremljati, je razlika med dvema zaporednima meritvama (vzorcema) $|X_i - X_{i-1}|$. Prevelike vrednosti te razlike lahko pomenijo nepravilno delovanje procesa.

Naslednja možnost je prikazovanje kumulativnih vsot. Le-te so zelo primerne za odkrivanje majhnih sprememb v srednjih vrednostih (Basseville in Nikiforov, 1993).

S prikazovanjem delovanja in nadzorom proizvodnje so se v preteklosti ukvarjali že številni avtorji. Pri tem so se posluževali tudi bolj zahtevnih in zmogljivejših orodij kot so analiza glavnih komponent (ang. Principal Component Analysis – PCA), metoda parcialnih najmanjših kvadratov (ang. Partial Least Squares – PLS), analiza rojev itd. Omenimo najprej pregledni članek Lee-ja (1995), v katerem omenja različne metode za odkrivanje in lokalizacijo napak na proizvodni opremi. Spremljanje stanja le-te pa predstavlja osnovo za računalniško podporo vzdrževanje.

Ündey in sodelavci (2003) v svojem članku predstavljajo programsko opremo za nadzor šaržnih procesov. Le-ta temelji na uporabi ekspertnih sistemov na osnovi pravil in statističnih metod PCA ter PLS. Načrtovanje sistema (strojne in programske opreme) za avtomatsko prikazovanje stanja proizvodne opreme v procesih montaže pa opisuje Piérard (1995).

Mnogi se za nadzor predvsem šaržnih procesov poslužujejo različnih inačic analize glavnih komponent prirejenih za konkretne primere. Lane in sodelavci (2001) se ukvarjajo s procesi, v katerih se proizvaja več različnih produktov. Lee in sodelavci (2003) predlagajo sprotno popravljanje PCA modela glede na najnovejše podatke iz procesa. Misra in sodelavci (2002) pa uporabljajo analizo glavnih komponent v kombinaciji z valčki.

Za nadzor in prikazovanje delovanja fleksibilne proizvodnje si Feldmann in Colombo (1999) pomagata s Petri-jevimi mrežami. Istega orodja se poslužujeta tudi Odrey in Mejía (2003), s katerim ob morebitnem pojavu napake na neki proizvodni enoti ponovno razvrščata vsa opravila, ki jih je potrebno izvesti.

Dey in Stori (2005) za potrebe nadzora predlagajo uporabo širokega nabora senzorjev na proizvodni liniji, kar omogoča zanesljivejše odkrivanje vzrokov za spremembe v delovanju proizvodnega procesa. Odkrivanje progresivnih napak (tj. napak, ki se postopoma večajo) z namenom preprečevanja izpadov v proizvodnji je predmet raziskovanja tudi Ly-a in sodelavcev (2000). Njihov pristop spremljanja "napredovanja" napak na proizvodnem procesu temelji na posrednem opazovanju in sicer preko stanja proizvedenih izdelkov.

Z namenom načrtovanja sistema za podporo pri nadzoru linije na podlagi diagnostičnih rezultatov proizvedenih sesalnih enot bo v nadaljevanju tega poglavja najprej opravljena statistična analiza diagnostičnih rezultatov z linije, nato pa bodo predlagane rešitve za izvedbo omenjenega sistema.

5.1 Statistična analiza diagnostičnih rezultatov z linije

Statistično analizo diagnostičnih rezultatov smo opravili na množici podatkov, ki so bili pridobljeni pri testiranju sesalnih enot na koncu proizvodne linije in sicer v obdobju enega meseca. V tem času je bilo opravljenih 114233 uspešnih testiranj, pri čemer je bilo zaradi prisotnosti vsaj ene napake izločenih 1454 enot.

Vsak diagnostični rezultat za posamezno sesalno enoto vsebuje naslednje podatke: tip sesalne enote (v imenu datoteke), datum, čas, številko palete, zaporedno številko proizvedene sesalne enote v eni izmeni, kodo napake (gl. tabelo 3.5), vrednosti merilnih pogojev in vrednosti značilk, na podlagi katerih sklepamo o prisotnosti napak na enoti. V tabeli 5.1 so naštetih merilni pogoji, ki se preverjajo pri testiranju sesalnih enot. Seznam vseh 77 značilk z njihovimi opisi pa lahko vidimo v tabeli 5.2. Prvih 9 služi kontroli nazivnih veličin sesalnih enot. Ker je v praksi skorajda nemogoče zagotoviti konstantne nazivne napajalne napetosti, je glede na odstopanje le-te potrebno korigirati vse nazivne veličine. Izmerjeni podtlak sesalne enote pa se korigira še glede na merilne pogoje v oklici (temperaturo in atmosferski tlak). Značilke za vrednotenje kvalitete komutacije in vibracij so podrobno opisane v podpoglavjih 4.1.2.1, 4.1.2.2 in 4.2.2. Značilke, ki temeljijo na analizi zvoka, pa so namenjene odkrivanju drgnjenja med rotirajočimi in statičnimi deli sesalne enote ter napak na ležajih.


Tabela 5.1: Merilni pogoji pri testiranju sesalnih enot

oznaka	opis
f_{nU}	RMS napajalne napetosti
f_{oT}	temperatura okolice
f_{op}	atmosferski tlak
f_{oh}	relativna vlažnost

Tabela 5.2: Značilke za vrednotenje kakovosti sesalnih enot

oznaka	opis
f_{nI}	RMS toka
f_{nIk}	f_{nI} korigirana glede na f_{nU}
f_{nP}	električna moč
f_{nP_k}	f_{nP} korigirana glede na f_{nU}
f_{np}	podtlak
f_{npk}	f_{np} korigiran glede na f_{oT} in f_{op}
f_{npkk}	f_{npk} korigiran glede na f_{nU}
f_{nv}	hitrost vrtenja
f_{nvk}	f_{nv} korigirana glede na f_{nU}
$f_{k1}, f_{k2}, \dots, f_{k12}$	kvaliteta komutacije (analiza toka – RMS na 12 različnih frekvenčnih pasovih), gl. podpogl. 4.1.2.1
f_{i1}	kvaliteta komutacije (visokofrekvenčne napetostne motnje – število velikih isker), gl. podpogl. 4.1.2.2
f_{i2}	kvaliteta komutacije (visokofrekvenčne napetostne motnje – površina uteženega histograma), gl. podpogl. 4.1.2.2
f_{va}	vibracije na turbini v aksialni smeri (neuravnoveženost – RMS na frekvenčnem pasu v okolici frekvence vrtenja), gl. podpogl. 4.2.2
$f_{va1}, f_{va2}, \dots, f_{va15}$	vibracije na turbini v aksialni smeri (RMS na 15 različnih frekvenčnih pasovih), gl. podpogl. 4.2.2
f_{vt}	vibracije na turbini v radialni smeri (neuravnoveženost – RMS na frekvenčnem pasu v okolici frekvence vrtenja), gl. podpogl. 4.2.2
$f_{vt1}, f_{vt2}, \dots, f_{vt15}$	vibracije na turbini v radialni smeri (RMS na 15 različnih frekvenčnih pasovih), gl. podpogl. 4.2.2
f_{vo}	vibracije na ohišju v radialni smeri (neuravnoveženost – RMS na frekvenčnem pasu v okolici frekvence vrtenja), gl. podpogl. 4.2.2
$f_{vo1}, f_{vo2}, \dots, f_{vo15}$	vibracije na ohišju v radialni smeri (RMS na 15 različnih frekvenčnih pasovih), gl. podpogl. 4.2.2
f_{zd1}, f_{zd2}	zvok (drgnjenje)
$f_{zl1}, f_{zl2}, f_{zl3}, f_{zl4}$	zvok (napaka na ležaju)

Histogram na sliki 5.1 prikazuje, koliko je bilo posameznih vrst napak v obravnavani množici sesalnih enot. Vidimo, da je bilo največ enot izločenih zaradi neustrezne komutacije, sledijo pa napake na ležajih.



Slika 5.1: Število sesalnih enot s posameznimi napakami (kode napak so podane v tabeli 3.5)

Dve glavni vprašanji, na kateri bomo skušali odgovoriti v tem podpoglavju, sta:

- Ali so vse značilke pomembne (informativne)?
- Ali je možno iz diagnostičnih rezultatov izluščiti še kakšne dodatne informacije, ki bi jih lahko uporabili v okviru statistične kontrole kvalitete na proizvodni liniji?

V ta namen bomo najprej preverili statistično neodvisnost značilk, nato pa bomo analizirali njihove porazdelitve.

5.1.1 Analiza odvisnosti značilk

Analiza odvisnosti značilk je koristna iz dveh razlogov. Če namreč obstaja odvisnost vsaj med nekaterimi značilkami, to pomeni, da imamo v naboru značilk redundantne informacije. Zato ob poznavanju omenjene odvisnosti lahko nekatere (redundantne) značilke izločimo, brez da bi pri tem izgubili kakšne pomembne informacije. Če pa ugotovimo, da so značilke med sabo neodvisne, lahko pri njihovi statistični obdelavi obravnavamo vsako posebej, kar zelo poenostavi delo. Odvisnost med značilkami smo preverili s korelacijsko analizo, z dekompozicijo po singularnih vrednostih in s χ^2 statističnim testom. Pri tem velja poudariti, da v primeru ugotovitve odvisnosti med značilkami s prvima dvema metodama lahko sklepamo na statistično odvisnost značilk, v nasprotnem primeru pa v splošnem ne moremo trditi, da so značilke statistično neodvisne.

5.1.1.1 Korelacijska analiza

Korelacijska analiza je statistično orodje, s katerim lahko ocenjujemo stopnjo linearne odvisnosti med dvema naključnima spremenljivkama. Mera za koreliranost med dvema spremenljivkama je korelacijski koeficient r , ki je za naključni spremenljivki x in y definiran na naslednji način (Papoulis, 1991):

$$r = \frac{SS_{xy}}{\sqrt{SS_{xx}SS_{yy}}} \quad (5.1)$$

kjer so:


$$SS_{xy} = \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) \quad (5.2)$$

$$SS_{xx} = \sum_{i=1}^n (x_i - \bar{x})^2 \quad (5.3)$$

$$SS_{yy} = \sum_{i=1}^n (y_i - \bar{y})^2 \quad (5.4)$$


\bar{x} in \bar{y} pa sta pričakovani vrednosti spremenljivk x oz. y . Z besedami povedano je to količnik med kovarianco in produktom standardnih deviacij dveh naključnih spremenljivk.

Vrednost korelacijskega koeficienta blizu ali enaka 0 pomeni, da med naključnima spremenljivkama ni linearne odvisnosti (Slika 5.2a). Z naraščanjem le-te pa se absolutna vrednost korelacijskega koeficienta začne približevati vrednosti 1 (Slika 5.2b).



Slika 5.2: Realizaciji dveh naključnih spremenljivk pri različnih korelacijskih koeficientih: a) $r \rightarrow 0$, b) $r \rightarrow 1$

Korelacijski koeficienti značilke kvalitete komutacije in vibracij so bili že predstavljeni v podpoglavjih 4.1.4.2 oz. 4.2.3. Zato bodo na tem mestu (Slika 5.3) prikazani le korelacijski koeficienti med preostalimi značilkami iz tabele 5.2 in merilnimi pogoji iz tabele 5.1. Na sliki 5.3 so omenjene značilke in merilni pogoji nanizani v naslednjem vrstnem redu: napajalna napetost; napajalni tok; korigiran napajalni tok; električna moč; korigirana električna moč; podtlak; podtlak korigiran glede na temperaturo in atmosferski tlak; podtlak korigiran glede na temperaturo, atmosferski tlak in napajalno napetost; hitrost vrtenja; korigirana hitrost vrtenja; temperatura okolice; atmosferski tlak; relativna vlažnost in 6 značilk, ki temeljijo na analizi zvoka. Opazimo, da so napajalni tok, električna moč, podtlak ter hitrost vrtenja precej korelirane z napajalno napetostjo. Po opravljeni korekciji omenjenih veličin (glede na napajalno napetost) pa po pričakovanju ta koreliranost znatno pade. Razumljivo je, da so med seboj korelirani napajalni tok in električna moč ter podtlak in hitrost vrtenja sesalne enote. Povečano koreliranost opazimo še med značilkama f_{zd1} in f_{zd2} . Tudi to je pričakovan rezultat, saj obe služita odkrivanju iste napake (drgnjenja med rotirajočimi in statičnimi deli sesalne enote).



Slika 5.3: Korelacijski koeficienti med različnimi značilkami in merilnimi pogoji (f_{nU} , f_{nI} , f_{nIk} , f_{nP} , f_{nPk} , f_{nP} , f_{nPk} , f_{nPk} , f_{nv} , f_{nvk} , f_{oT} , f_{op} , f_{oh} , f_{zd1} , f_{zd2} , f_{zl1} , f_{zl2} , f_{zl3} , f_{zl4})

5.1.1.2 Dekompozicija po singularnih vrednostih

Odvisnost med značilkami lahko preverimo tudi s t.i. dekompozicijo po singularnih vrednostih. Ta metoda matriko A dimenzij $m \times n$, pri čemer mora biti $m > n$, razstavi na produkt treh matrik U , D in V (Enačba 5.5).

$$A_{m \times n} = U_{m \times m} D_{m \times n} V_{n \times n}^T \quad (5.5)$$

Matriki U in V sta ortogonalni matriki dimenzij $m \times m$ oz. $n \times n$. Matrika D pa je diagonalna matrika enakih dimenzij kot matrika A ($m \times n$) (Enačba 5.6). Diagonalni elementi matrike D so singularne vrednosti matrike A . Na podlagi le-teh lahko sklepamo o linearni odvisnosti stolpcev v matriki A . Število singularnih vrednosti, ki so enake 0, namreč ustreza številu linearno odvisnih stolpcev v matriki A .


$$\begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ a_{31} & a_{32} & \cdots & a_{3n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mn} \end{bmatrix} = \begin{bmatrix} u_{11} & u_{12} & \cdots & u_{1m} \\ u_{21} & u_{22} & \cdots & u_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ u_{m1} & u_{m2} & \cdots & u_{mm} \end{bmatrix} \begin{bmatrix} d_{11} & 0 & 0 & 0 \\ 0 & d_{22} & 0 & 0 \\ 0 & 0 & \ddots & \vdots \\ 0 & 0 & \cdots & d_{nn} \\ \vdots & \vdots & \cdots & \vdots \\ 0 & 0 & \cdots & 0 \end{bmatrix} \begin{bmatrix} v_{11} & v_{12} & \cdots & v_{1n} \\ v_{21} & v_{22} & \cdots & v_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ v_{n1} & v_{n2} & \cdots & v_{nn} \end{bmatrix}^T \quad (5.6)$$

V primerjavi s korelacijsko analizo, ki ocenjuje stopnjo linearne odvisnosti le med dvema naključnima spremenljivkama, dekompozicija po singularnih vrednostih daje odgovor na vprašanje, ali obstajajo linearne odvisnosti med več spremenljivkami (stolpci matrike A) hkrati. V primeru obstoja odvisnosti, pa ta metoda žal ne razkrije, katere spremenljivke (stolpci) so med sabo odvisne.


Za potrebe ugotavljanja odvisnosti med značilkami matriko A tvorimo tako, da v njene vrstice zapovrstjo vnašamo diagnostične rezultate (le vrednosti značil) posameznih sesalnih enot, pri čemer vsak stolpec predstavlja eno značilko. Na ta način dobimo v stolpcih matrike zaporedne vrednosti posameznih značil, ki si jih lahko predstavljamo kot časovne vrste. Preden se lotimo računanja singularnih vrednosti, je potrebno še vse značilke (stolpce) normirati, tj. odšteti pričakovane vrednosti in deliti s standardnimi deviacijami. S tem dosežemo, da imajo vse enako moč. Kajti izkaže se, da pri ugotavljanju odvisnosti med časovnimi vrstami niso pomembne vrednosti amplitud vzorcev, temveč le dinamika sprememb v vrstah.

Singularne vrednosti matrike, ki je sestavljena iz že predstavljenih diagnostičnih rezultatov, so prikazane na sliki 5.4. Vidimo, da je šest singularnih vrednosti enakih 0 (zelo blizu). Torej je izmed 77 značil 6 linearno odvisnih. S sklepanjem glede na fizikalna ozadja definicij posameznih značil in s sistematskim izločanjem različnih značil pri večkratnih ponovitvah izračunov singularnih vrednosti smo odkrili eno izmed možnih skupin linearno odvisnih značil. Le-to tvorijo značilke f_{nl} , f_{nP} , f_{np} , f_{va} , f_{vt} in f_{vo} . Razumljivo je, da so vse korigirane nazivne veličine odvisne od njihovih izmerjenih vrednosti. V podpoglavju 4.2.3 pa je bilo že razloženo, da k vrednostim značil f_{va} , f_{vt} in f_{vo} največ prispeva ista napaka (neuravnoveženost) kot k vrednostim značil f_{va1} , f_{vt1} in f_{vo1} . Singularne vrednosti izračunane na podlagi diagnostičnih

rezultatov brez omenjenih šestih značilik so podane na sliki 5.5. Vidimo, da se vse signifikantno razlikujejo od 0. Torej med preostalimi značilkami ni nobena več linearno odvisna od ostalih.



Slika 5.4: Singularne vrednosti pri upoštevanju vseh značilik



Slika 5.5: Singularne vrednosti po izločitvi značilik f_{nl} , f_{nP} , f_{np} , f_{va} , f_{vt} in f_{vo}

5.1.1.3 χ^2 test neodvisnosti

χ^2 test je neparametrični test statistične neodvisnosti med dvema naključnima spremenljivkama x in y . Predpostavimo, da imamo n parov vzorcev (x_k, y_k) . Področje, ki

ga pokriva spremenljivka x razdelimo na p intervalov A_1, A_2, \dots, A_p , področje, ki ga pokriva y pa na r intervalov B_1, B_2, \dots, B_r . Pri tem velja tako za intervale $A_i, i = 1, 2, \dots, p$, kot za intervale $B_j, j = 1, 2, \dots, r$, da so lahko različno dolgi. Z O_{ij} označimo število parov $(x_k, y_k), k = 1, 2, \dots, n$, ki pripadajo področju $A_i \times B_j$. Sedaj lahko tvorimo tabelo frekvenc dobljenih iz podatkov (Tabela 5.3).

Tabela 5.3: Frekvence dobljene iz podatkov

	B_1	B_2	...	B_r	
A_1	O_{11}	O_{12}	...	O_{1r}	$\sum O_{1j}$
A_2	O_{21}	O_{22}	...	O_{2r}	$\sum O_{2j}$
\vdots	\vdots	\vdots	\ddots	\vdots	\vdots
A_p	O_{p1}	O_{p2}	...	O_{pr}	$\sum O_{pj}$
	$\sum O_{i1}$	$\sum O_{i2}$...	$\sum O_{ir}$	n

Na osnovi tabele 5.3 z uporabo enačbe 5.7 (Rohatgi, 1976; Rabinovich, 2000) določimo elemente E_{ij} tabele pričakovanih frekvenc (Tabela 5.4).

$$E_{ij} = \frac{\sum_{u=1}^r O_{iu} \sum_{v=1}^p O_{vj}}{n} \quad (5.7)$$

Tabela 5.4: Pričakovane frekvence

	B_1	B_2	...	B_r
A_1	E_{11}	E_{12}	...	E_{1r}
A_2	E_{21}	E_{22}	...	E_{2r}
\vdots	\vdots	\vdots	\ddots	\vdots
A_p	E_{p1}	E_{p2}	...	E_{pr}

Vrednost χ^2 izračunamo po enačbi 5.8:

$$\chi^2 = \sum_i \sum_j \frac{(E_{ij} - O_{ij})^2}{E_{ij}} \quad (5.8)$$

Nazadnje primerjamo izračunano vrednost χ^2 s tabelirano vrednostjo $\chi_{df,\alpha}^2$ pri danem številu prostostnih stopenj $df = (p - 1)(r - 1)$ in izbrani stopnji nezanesljivosti α (običajno $\alpha = 0.05$). Če izračunana vrednost χ^2 presega tabelirano, potem zavržemo ničo hipotezo, da sta naključni spremenljivki x in y neodvisni.

V tabeli 5.5 so prikazani rezultati testiranja statistične neodvisnosti med nekaterimi značilkami za ocenjevanje kakovosti sesalnih enot s pomočjo χ^2 testa, pri čemer smo za stopnjo nezanesljivosti izbrali $\alpha = 0.05$. Izpuščene so nekorigirane nazivne veličine sesalnih enot ter značilke, ki temeljijo na merjenju RMS vrednosti napajalnega toka in signalov vibracij v različnih frekvenčnih pasovih.

Tabela 5.5: Statistična odvisnost med nekaterimi značilkami za ocenjevanje kakovosti sesalnih enot (\surd – značilki sta odvisni)

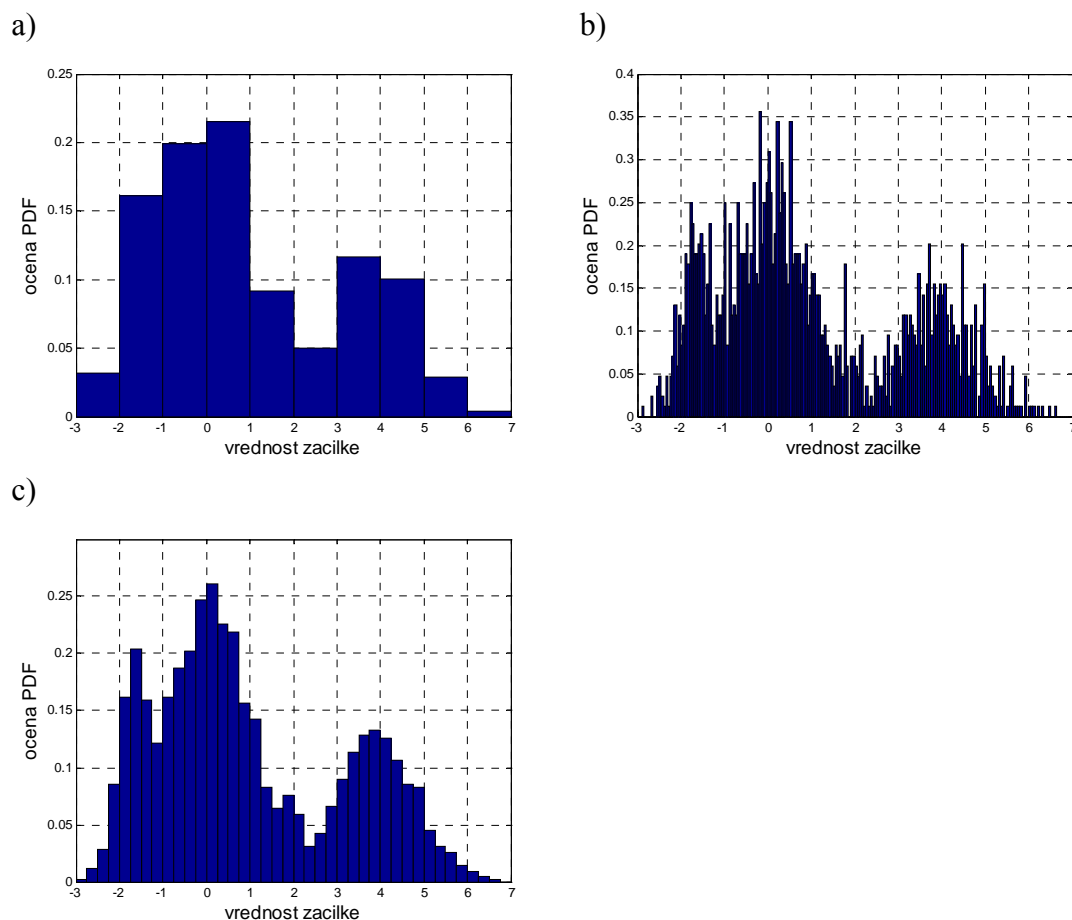
	f_{nlk}	f_{nPk}	f_{npkk}	f_{nvk}	f_{i1}	f_{i2}	f_{va}	f_{vt}	f_{vo}	f_{zd1}	f_{zd2}	f_{z11}	f_{z12}	f_{z13}	f_{z14}
f_{nlk}	\surd	\surd													
f_{nPk}	\surd	\surd													
f_{npkk}			\surd	\surd				\surd	\surd						
f_{nvk}			\surd	\surd				\surd	\surd						
f_{i1}					\surd	\surd									
f_{i2}					\surd	\surd									
f_{va}							\surd	\surd	\surd						
f_{vt}			\surd	\surd			\surd	\surd	\surd						
f_{vo}			\surd	\surd			\surd	\surd	\surd						
f_{zd1}										\surd	\surd				
f_{zd2}										\surd	\surd				
f_{z11}												\surd			
f_{z12}													\surd	\surd	\surd
f_{z13}													\surd	\surd	\surd
f_{z14}													\surd	\surd	\surd

5.1.2 Porazdelitev značilk

Kljub temu, da so nekatere značilke odvisne med seboj (gl. podpoglavje 5.1.1), pa bomo porazdelitve obravnavali za vsako značilko posebej. Razloga za to sta dva. Prvič, vsaka značilka je definirana na osnovi bolj ali manj znanega fizikalnega ozadja in služi odkrivanju točno določene napake. Glede na to so postavljene tudi njene mejne vrednosti. Zato jo je smiselno obravnavati ločeno, pa čeprav je morda odvisna od še katerih drugih značilk. Drugi razlog je povezan z odkrivanjem sprememb v

porazdelitvah značilk za potrebe statistične kontrole proizvodne linije. Spremembe je zaželeno odkriti čim prej. To pomeni, da moramo za oceno porazdelitev uporabiti čim manjše število vzorcev (diagnostičnih rezultatov zapovrstjo proizvedenih sesalnih enot). Z manjšanjem števila vzorcev pa se slabša ocena porazdelitev. Če pri tem upoštevamo še odvisnost med značilkami, kar pomeni, da moramo opazovati porazdelitve v večdimenzionalnem prostoru, dobimo pri enakem (omejenem) številu vzorcev še slabšo oceno porazdelitev in posledično manj zanesljivo detektiranje sprememb.

Neparametrično oceno porazdelitev značilk (rezultatov končnih testiranj sesalnih enot) oziroma njihovih funkcij gostote verjetnosti (ang. probability density function – PDF) smo dobili s pomočjo histogramov. Pri tvorjenju le-teh je potrebno abscisno os, na kateri so nanesene vrednosti značilk, razdeliti na odseke. Rezultat je odsekoma konstantna funkcija, katere vrednost je proporcionalna številu vzorcev na posameznem odseku. Pri tem lahko število odsekov (stolpcev) oziroma njihovo širino obravnavamo kot nek parameter glajenja. Če izberemo premajhno število stolpcev, je glajenje preveliko in zato dobimo popačen histogram (Slika 5.6a). V nasprotnem primeru je glajenje premajhno, kar rezultira v preveliki spremenljivosti histograma (Slika 5.6b). Da dobimo dobro oceno porazdelitve (Slika 5.6c), moramo z ustrezno izbiro števila stolpcev v histogramu poiskati neko ravnovesje med popačenostjo in spremenljivostjo (varianco) (Wasserman, 2005; Wasserman, 2006).



Slika 5.6: Ocena porazdelitve s histogramom: a) premajhno število stolpcev, b) preveliko število stolpcev, c) ustrezno število stolpcev

Funkcijo gostote verjetnosti označimo z g , njeno oceno (histogram) pa z \tilde{g}_n . Kriterijsko funkcijo za razliko med g in \tilde{g}_n izberemo kot integral kvadrata napake (ang. integrated squared error – *ISE*) (Enačba 5.9):

$$ISE(g, \tilde{g}_n) = \int_{-\infty}^{\infty} (g(x) - \tilde{g}_n(x))^2 dx \quad (5.9)$$

Pričakovana vrednost integrala kvadrata napake *MISE* (ang. mean integrated squared error) je:

$$MISE(g, \tilde{g}_n) = \mathbf{E}(ISE(g, \tilde{g}_n)) \quad (5.10)$$

pri čemer $\mathbf{E}(\cdot)$ pomeni pričakovano vrednost. *MISE* lahko zapišemo tudi kot:

$$MISE(g, \tilde{g}_n) = \int_{-\infty}^{\infty} b^2(x) dx + \int_{-\infty}^{\infty} v(x) dx \quad (5.11)$$

kjer:


$$b(x) = \mathbf{E}(\tilde{g}_n(x)) - g(x) \quad (5.12)$$

predstavlja popačenost $\tilde{g}_n(x)$ in:

$$v(x) = \mathbf{V}(\tilde{g}_n(x)) = \mathbf{E}((\tilde{g}_n(x) - \mathbf{E}(\tilde{g}_n(x)))^2) \quad (5.13)$$

varianco $\tilde{g}_n(x)$.

Z večanjem glajenja (manjšanjem števila stolpcev v histogramu) raste vrednost izraza za popačenost, medtem ko varianca pada. Poiskati optimalno glajenje (ravnovesje med popačenostjo in varianco) pomeni najti minimum funkcije *MISE* (Slika 5.7).



Slika 5.7: Vpliv glajenja na popačenost in varianco

Naj vzorci naključne spremenljivke s porazdelitvijo g ležijo na intervalu $[0, 1]$. S tem nič ne izgubimo na splošnosti, saj podatke lahko vedno skaliramo na ta interval. Če m predstavlja število stolpcev v histogramu, se omenjeni interval razdeli na naslednje odseke:

$$B_1 = [0, \frac{1}{m}), B_2 = [\frac{1}{m}, \frac{2}{m}), \dots, B_m = [\frac{m-1}{m}, 1] \quad (5.14)$$

katerih širina je:

$$h = \frac{1}{m} \quad (5.15)$$

Nadalje naj bo n število vseh vzorcev, n_j pa število vzorcev na odseku B_j . Če izrazimo še \tilde{p}_j kot:

$$\tilde{p}_j = \frac{n_j}{n} \quad (5.16)$$

potem je histogram $\tilde{g}_n(x)$ definiran z enačbo 5.17:

$$\tilde{g}_n(x) = \begin{cases} \tilde{p}_1/h & x \in B_1 \\ \tilde{p}_2/h & x \in B_2 \\ \vdots & \vdots \\ \tilde{p}_m/h & x \in B_m \end{cases} \quad (5.17)$$

Ob upoštevanju zgornjih predpostavk lahko za popačenost b in varianco v zapišemo:

$$\int_0^1 b^2(x) dx \approx \frac{h^2}{12} \int_0^1 (g'(x))^2 dx \quad (5.18)$$

in

$$\int_0^1 v(x) dx \approx \frac{1}{nh} \quad (5.19)$$

Vidimo, da se z večanjem širine odsekov h večja tudi vrednost integrala kvadrata popačenosti, medtem ko se vrednost integrala variance zmanjšuje.

Če velja $\int_0^1 (g'(x))^2 dx < \infty$, lahko z upoštevanjem izrazov 5.18 in 5.19 $MISE(g, \tilde{g}_n)$ izrazimo kot:

$$MISE(g, \tilde{g}_n) \approx \frac{h^2}{12} \int_0^1 (g'(x))^2 dx + \frac{1}{nh} \quad (5.20)$$

Širina odseka h^* , ki minimizira enačbo 5.20 je (Wasserman, 2005):

$$h^* = \frac{1}{n^{1/3}} \left(\frac{6}{\int_0^1 (g'(x))^2 dx} \right)^{1/3} \quad (5.21)$$

S tako izbranim h enačba 5.20 dobi naslednjo obliko:

$$MISE(g, \tilde{g}_n) \approx \frac{C}{n^{2/3}} \quad (5.22)$$

kjer je:

$$C = (3/4)^{2/3} \left(\int_0^1 (g'(x))^2 dx \right)^{1/3} \quad (5.23)$$

Iz enačbe 5.22 je razvidno, da pri optimalni izbiri širine odsekov vrednost $MISE$ pada proti 0 s hitrostjo $n^{-2/3}$. Formula 5.21 za izračun optimalne širine odsekov je zanimiva le s teoretičnega stališča, v praksi pa je neuporabna, saj vsebuje neznano (iskano) funkcijo gostote verjetnosti $g(x)$.

Praktičen način določanja širine odsekov h temelji na ocenjevanju funkcije $MISE$ in minimiziranju le-te glede na parameter h . Kriterijsko funkcijo ISE (Enačba 5.9) zapišimo kot funkcijo h :

$$\begin{aligned} ISE(h) &= \int_0^1 (\tilde{g}_n(x) - g(x))^2 dx \\ &= \int_0^1 \tilde{g}_n^2(x) dx - 2 \int_0^1 \tilde{g}_n(x) g(x) dx + \int_0^1 g^2(x) dx \end{aligned} \quad (5.24)$$

Zadnji člen v enačbi 5.24 ni odvisen od h , zato z minimizacijo funkcije $MISE$ dobimo isti rezultat, kot če minimiziramo pričakovano vrednost naslednjega izraza:

$$J(h) = \int_0^1 \tilde{g}_n^2(x) dx - 2 \int_0^1 \tilde{g}_n(x) g(x) dx \quad (5.25)$$

Ocena $MISE$ (brez upoštevanja konstantnega člena $\int_0^1 g^2(x) dx$) je definirana z:

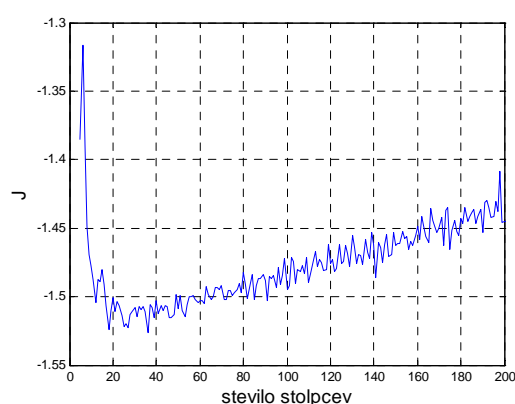
$$\tilde{J}(h) = \int_0^1 \tilde{g}_n^2(x) dx - \frac{2}{n} \sum_{i=1}^n \tilde{g}_{(-i)} x_i \quad (5.26)$$

kjer je $\tilde{g}_{(-i)}$ histogram dobljen na podatkih brez i -tega vzorca (x_i).

Pri iskanju minimuma izraza 5.26 moramo za vsako vrednost h histogram določiti n -krat. Zato raje uporabljamo naslednjo poenostavljeno formulo (Wasserman, 2005):


$$\tilde{J}(h) = \frac{2}{(n-1)h} - \frac{n+1}{(n-1)h} \sum_{j=1}^m \tilde{p}_j^2 \quad (5.27)$$

Kot primer je za podatke ($n = 1700$ vzorcev), ki so bili uporabljeni za risanje slike 5.6, na sliki 5.8 prikazana ocena $MISE$ (\tilde{J}) v odvisnosti od širine odsekov h oziroma števila stolpcev v histogramu m . Vidimo, da se za konkreten niz podatkov optimalno število stolpcev giblje med 20 in 40.




Slika 5.8: Ocena $MISE$ (\tilde{J}) v odvisnosti od števila stolpcev m

Na tem mestu bodo za primer predstavljene porazdelitve le nekaterih izmed značilk, ki smo jih definirali v podpoglavjih 4.1.2.2 in 4.2.2. Porazdelitve smo ocenili na podlagi že omenjenih diagnostičnih rezultatov s proizvodne linije (114233 vzorcev). Porazdelitve vseh ostalih značilk iz tabele 5.2 lahko vidimo v dodatku D. Na sliki 5.9 je prikazana ocena porazdelitve značilke kvalitete komutacije f_{i2} , na sliki 5.10 pa porazdelitev značilk vibracij f_{va} , f_{vt} in f_{vo} . Pri značilki f_{i2} pade večina vzorcev v prvih nekaj stolpcev histograma, ostali pa imajo tudi za faktor skoraj 30 večje vrednosti. To je posledica zelo velike občutljivosti značilke f_{i2} na prisotnost napake, kajti njena vrednost ob pojavu le-te močno naraste. Opisana lastnost je s stališča klasifikacije zelo zaželena.



Slika 5.9: Porazdelitev značilke kvalitete komutacije f_{12}

Porazdelitve značilk f_{va} , f_{vt} in f_{vo} (Slika 5.10) so v primerjavi s porazdelitvijo značilke f_{12} bolj strnjene. Vzrok temu je narava napake (neuravnoteženost sesalne enote), ki jo omenjene značilke detektirajo. Neuravnoteženosti različnih sesalnih enot se med seboj bistveno ne razlikujejo. Po drugi strani pa večja podobnost obravnavanih treh porazdelitev z normalno (Gauss-ovo) porazdelitvijo kaže na to, da vzrok za omenjeno napako ni sistematski temveč naključen.




Slika 5.10: Porazdelitve značilk vibracij: a) f_{va} , b) f_{vt} , c) f_{vo}

Ali je neka značilka res "prava" značilka, tj. se dejansko odziva na neko stanje sesalne enote, lahko sklepamo tudi iz oblike njene porazdelitve. Le-ta mora namreč imeti nek roj ali t.i. dolgi rep, v katerem se nahajajo vzorci (sesalne enote) neustrezne kvalitete. V nasprotnem primeru to pomeni, da se značilka ne odziva na nič, kar bi bilo relevantno za kvaliteto enot. To je seveda le potreben pogoj, ki omogoča klasifikacijo.

Po definiciji mora rep pri porazdelitvi z dolgim repom imeti naslednjo obliko (Downey, 2005):

$$p(x) \sim cx^{-\alpha} \quad (5.28)$$

kjer je x naključna spremenljivka, c parameter pozicije in α parameter oblike, ki mora biti manjši od 2 ($\alpha < 2$). Nekaj tipičnih primerov porazdelitev z dolgimi repi je predstavljenih v dodatku E. Omenjeni avtor predlaga tudi uporabo grafične metode za ugotavljanje, ali ima neka porazdelitev dolgi rep. Po tej metodi je na graf, katerega abscisna in ordinatna os sta prikazani v logaritemski skali, potrebno narisati komplementarno kumulativno porazdelitveno funkcijo (1-CDF, kjer je CDF kumulativna porazdelitvena funkcija – ang. cumulative distribution function). V primeru porazdelitve z dolgim repom ima narisan graf pri večjih vrednostih naključne spremenljivke obliko premice (npr. Slika 5.11).



Slika 5.11: Komplementarna kumulativna porazdelitvena funkcija log-normalne porazdelitve ($\mu=0$, $\sigma=0.5$)

Ob ponovnem pregledu porazdelitev značilk za vrednotenje kvalitete sesalnih enot (Sliki 5.9 in 5.10 ter dodatek D) vidimo, da imajo vse bolj ali manj izrazite repe.

5.2 Zaznavanje sprememb v kakovosti izdelkov

Na začetku tega poglavja je bilo omenjeno, da klasična statistična kontrola procesov temelji na predpostavki normalne porazdelitve opazovanih podatkov. Kot vemo iz podpoglavja 5.1.2 in dodatka D pa se večina značilnk, ki jih dobimo pri končni kontroli sesalnih enot, ne podreja normalni porazdelitvi. Če torej želimo spremljati stanje proizvodnje na podlagi omenjenih značilnk, moramo uporabiti drugačen pristop. Nekateri avtorji (Chen in sodelavci, 2005; Choi in sodelavci, 2004) se v ta namen poslužujejo Gauss-ovih mešanic. Še ena možnost je uporaba Kullback-Leibler-jeve razdalje za ocenjevanje sprememb v porazdelitvah (časovnih vrstah) značilnk, v katerih se odražajo spremembe v proizvodnem procesu.

5.2.1 Lastnosti Kullback-Leibler-jeve razdalje

Kullback-Leibler-jeva (KL) razdalja ali relativna entropija je mera, ki izvira s področja teorije informacij. V statistiki jo lahko interpretiramo kot razdaljo med dvema porazdelitvama naključnih spremenljivk, nekako analogno z Evklid-ovo razdaljo. Za porazdelitvi $p(x)$ in $q(x)$ je definirana na naslednji način (Enačba 5.29 oz. 5.30) (Cover in Thomas, 1991; Krishnamurthy in sodelavci, 2005):

$$KL(p, q) = \int_{-\infty}^{\infty} p(x) \log \frac{p(x)}{q(x)} dx \quad (5.29)$$

oziroma v diskretni obliki:

$$KL(p, q) = \sum_x p(x) \log \frac{p(x)}{q(x)} \quad (5.30)$$

Kullback-Leibler-jeva razdalja je vedno nenegativna ($KL(p, q) \geq 0$) in je enaka nič ($KL(p, q) = 0$), če in samo če $p(x) = q(x)$. Po definiciji ni prava razdalja, saj je v splošnem primeru asimetrična ($KL(p, q) \neq KL(q, p)$) in ne zadošča pogoju trikotniške neenakosti ($KL(p, r) \leq KL(p, q) + KL(q, r)$). Vendar se vseeno pogosto uporablja kot mera za razdaljo med dvema porazdelitvama, pri čemer pa se je potrebno zavedati njenih posebnosti.

Kullback-Leibler-jevo razdaljo lahko izrazimo tudi kot (Enačba 5.31):

$$KL(p, q) = H(p, q) - H(p) \quad (5.31)$$

kjer sta:

$$H(p, q) = -\sum_x p(x) \log q(x) \quad (5.32)$$

križna entropija porazdelitev $p(x)$ in $q(x)$ ter:

$$H(p) = -\sum_x p(x) \log p(x) \quad (5.33)$$

entropija porazdelitve $p(x)$. Entropija je merilo negotovosti naključne spremenljivke oz. merilo količine informacije, ki je v povprečju potrebna za opis naključne spremenljivke z znano porazdelitvijo ($p(x)$). Križna entropija pa je merilo količine informacije, ki je v povprečju potrebna za opis naključne spremenljivke, če namesto njene (nepoznane) prave porazdelitve $p(x)$ predpostavimo, da je le-ta enaka $q(x)$. Kullback-Leibler-jeva razdalja je torej količina dodatne informacije, ki jo v povprečju potrebujemo za opis naključne spremenljivke zaradi nepoznavanja njene prave porazdelitve (Cover in Thomas, 1991).

V nadaljevanju si bomo ogledali lastnosti Kullback-Leibler-jeve razdalje na primeru določanja razdalje med dvema normalnima porazdelitvama $p_n(x)$ in $q_n(x)$ (Kulhavý, 1996):

$$p_n(x) = \frac{1}{\sigma_p \sqrt{2\pi}} \exp\left(-\frac{1}{2\sigma_p^2} (x - \mu_p)^2\right) \quad (5.34)$$

in

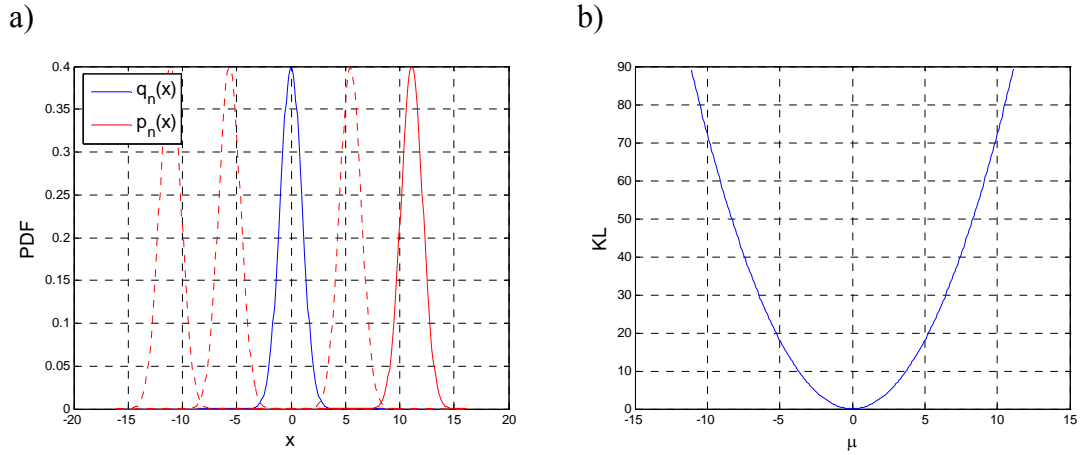
$$q_n(x) = \frac{1}{\sigma_q \sqrt{2\pi}} \exp\left(-\frac{1}{2\sigma_q^2} (x - \mu_q)^2\right) \quad (5.35)$$

Po upoštevanju izrazov 5.34 in 5.35 v enačbi 5.29 dobimo:

$$KL(\mu_p, \sigma_p, \mu_q, \sigma_q) = \log \frac{\sigma_q}{\sigma_p} + \frac{\log e}{2} \left[\left(\frac{\sigma_p}{\sigma_q}\right)^2 + \left(\frac{\mu_p - \mu_q}{\sigma_q}\right)^2 - 1 \right] \quad (5.36)$$

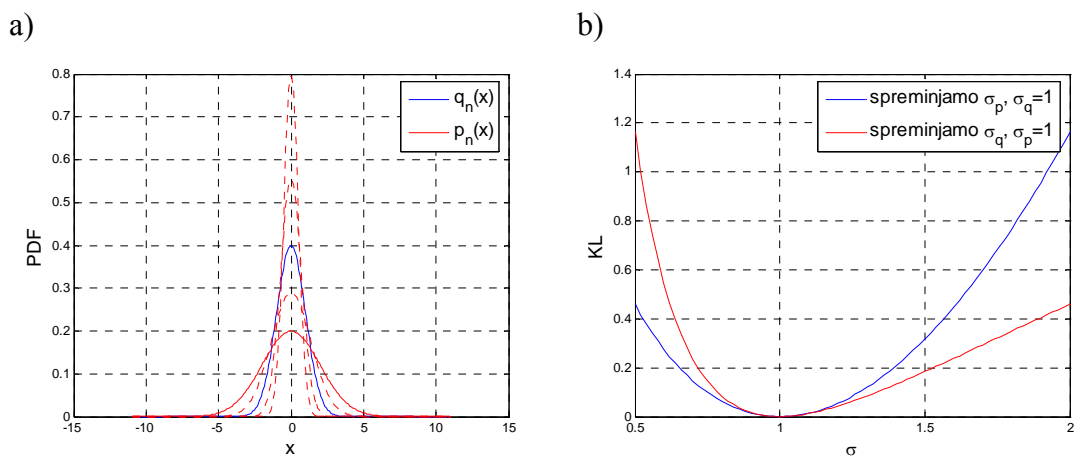
Iz enačbe 5.36 lahko razberemo, da je pri spreminjanju le srednjih vrednosti μ_p ali μ_q obravnavanih porazdelitev KL razdalja simetrična in narašča proporcionalno s kvadratom razlike med μ_p in μ_q . To ugotovitev potrjuje tudi slika 5.12. na kateri so

prikazane vrednosti KL razdalje (Slika 5.12b) pri primerjavi porazdelitev $q_n(x)$ s $\sigma_q = 1$ in $\mu_q = 0$ ter $p_n(x)$ s $\sigma_p = 1$ in μ_p , ki teče od -11 do 11 (Slika 5.12a).

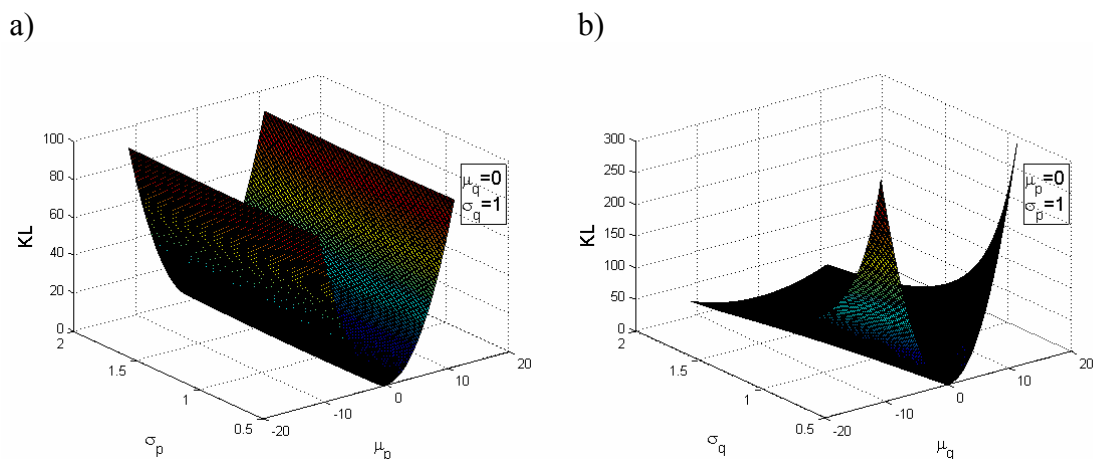


Slika 5.12: a) $q_n(x)$ in spreminjanje $p_n(x)$, b) KL razdalja med $q_n(x)$ in $p_n(x)$

Kako sprememba standardne deviacije (Slika 5.13a) vpliva na vrednost KL razdalje, je razvidno s slike 5.13b. Na tej sliki so z modro barvo prikazane vrednosti KL razdalje ob spreminjanju σ_p (od 0.5 do 2), z rdečo pa ob spreminjanju σ_q . Pri tem sta bila μ_p in μ_q enaka 0. Vidimo, da je KL razdalja asimetrična mera. Vrednosti KL razdalje pri hkratnem spreminjanju srednje vrednosti in standardne deviacije normalnih porazdelitev lahko razberemo s slike 5.14. Slika 5.14a prikazuje vrednosti KL razdalje ob spreminjanju $p_n(x)$, slika 5.14b pa ob spreminjanju $q_n(x)$. Zlasti pri spreminjanju $p_n(x)$ ima na vrednost KL razdalje veliko večji vpliv sprememba srednje vrednosti μ_p kot pa sprememba standardne deviacije σ_p .



Slika 5.13: a) spreminjanje standardne deviacije, b) KL razdalja pri spreminjanju σ_p oziroma σ_q

Slika 5.14: KL razdalja pri spreminjanju: a) $p_n(x)$, b) $q_n(x)$

Pri numeričnem računanju KL razdalje v praksi lahko naletimo še na dve težavi, ki sta vezani na določanje porazdelitev podatkov in omejeno računsko natančnost. Porazdelitvi $p(x)$ in $q(x)$ dveh nizov realnih podatkov, ki ju želimo primerjati, navadno neparametrično ocenimo s pomočjo histogramov. Glede na enačbi 5.29 in 5.30 morata biti omenjeni porazdelitvi definirani na istem področju. Tako se pogosto zgodi, da v nekaterih točkah (območjih) dobimo $q(x)=0$, kar običajno ne odraža dejanskega stanja. Iz zgoraj navedenih enačb pa je razvidno tudi, da tam, kjer je $q(x)=0$, le-ti nista definirani (vrednost KL razdalje postane neskončna). Zato je smiselno v $q(x)$ vrednosti 0 nadomestiti z neko zelo majhno vrednostjo ε , ki povzroči velik porast KL razdalje. S tem bistveno ne vplivamo rezultat. Namreč, tudi v primeru, ko je $q(x)$ dejansko enaka 0, prave vrednosti KL razdalje ($KL = \infty$) zaradi omejitev pri numeričnem računanju tako ali tako ne moremo dobiti.

V prejšnjem odstavku opisani problem ilustrira naslednji primer. Podatke (1000 vzorcev) smo dobili s pomočjo generatorja naključnih števil z normalno porazdelitvijo. Nato smo s spreminjanjem parametrov μ_p , σ_p , μ_q , σ_q in sicer na enak način kot pri risanju slik 5.12, 5.13 in 5.14 ter določanjem histogramov ocenjevali porazdelitvi $p(x)$ in $q(x)$. Sledili so izračuni vrednosti KL razdalj po definiciji (Enačba 5.30). Za ε smo izbrali vrednost $2.22 \cdot 10^{-16}$ (po absolutni vrednosti najmanjše število, ki ga pozna MATLAB, v katerem so potekale simulacije). Rezultati so prikazani na slikah 5.15 in 5.16.

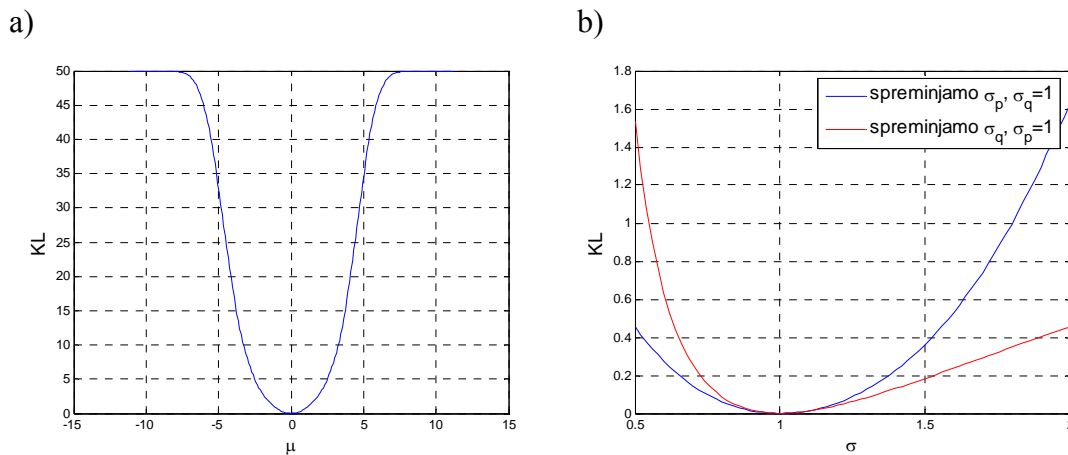
Vpliv spreminjanja srednje vrednosti μ_p oz. μ_q na vrednost numerično izračunane KL razdalje je razviden s slike 5.15a. Pri primerjavi z analitično dobljenimi rezultati (Slika 5.12b) vidimo, da se vrednosti KL razdalj dobro ujemajo dokler je razlika med srednjima vrednostma ($\mu_p - \mu_q$) po absolutni vrednosti manjša od približno 6. Z večanjem te razlike pa pride do izraza nadomeščanje 0 v $q(x)$ z ε . Ko območje naključne

spremenljivke, na katerem je $q(x) = \varepsilon$, v celoti pokrije območje, kjer je $p(x) \neq 0$, se vrednost KL razdalje po pričakovanju ustali.

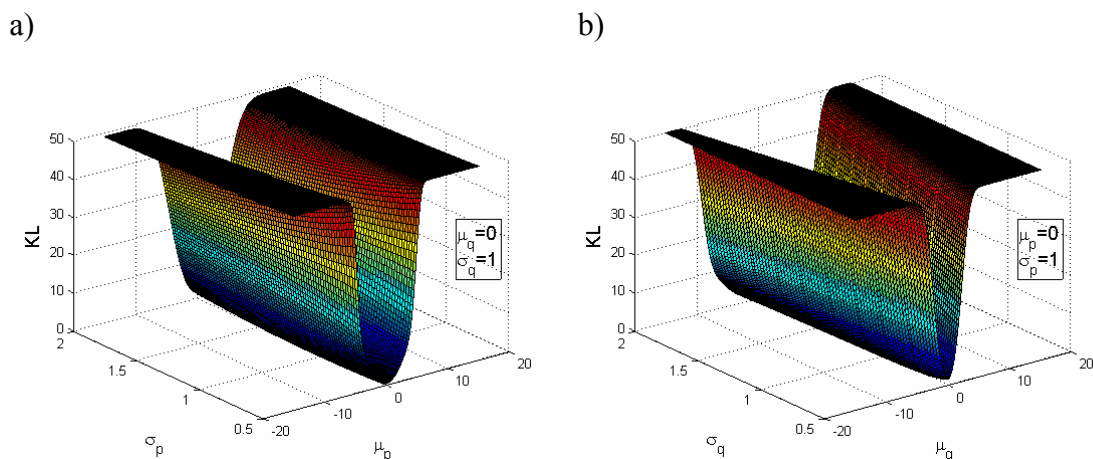
Na sliki 5.15b je prikazano, kako spreminjanje standardnih deviacij σ_p in σ_q vpliva na vrednosti numerično izračunanih KL razdalj. S primerjavo z analitičnimi rezultati na sliki 5.13b ugotovimo naslednje razlike. Z večanjem σ_p od 1 navzgor (modra krivulja) vrednost KL razdalje hitreje narašča pri numeričnem izračunu. Enak učinek opazimo pri manjšanju σ_q od 1 navzdol (rdeča krivulja).

Slika 5.16 združuje sliki 5.15a in 5.15b. Prikazuje namreč vrednosti KL razdalje pri hkratnem spreminjanju srednje vrednosti in standardne deviacije. Na sliki 5.16a je predstavljen primer, ko spreminjamo $p(x)$, na sliki 5.16b pa, ko spreminjamo $q(x)$.

Predstavljenim težavam pri numeričnem določanju vrednosti KL razdalj se lahko do določene mere izognemo s parametrično oceno porazdelitev $p(x)$ in $q(x)$. Ena takšna možnost je uporaba mešanic različnih porazdelitev (Mendes in Lopes, 2004).



Slika 5.15: Numeričen izračun KL razdalje med dvema normalnima porazdelitvama pri spreminjanju: a) srednje vrednosti μ_p oz. μ_q , b) standardne deviacije σ_p oz. σ_q



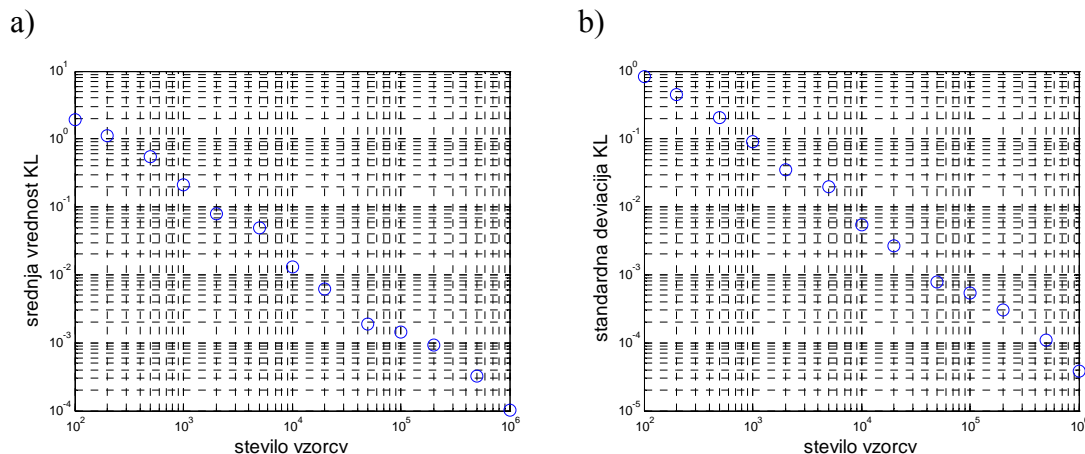
Slika 5.16: Numerično izračunane KL razdalje pri spreminjanju: a) $p(x)$, b) $q(x)$

Še en problem, s katerim se srečamo pri ugotavljanju sprememb v časovnih vrstah s pomočjo KL razdalji, je izbira ustreznega števila vzorcev, ki jih uporabljamo za določitev histogramov kot ocen porazdelitev $p_n(x)$ in $q_n(x)$. Vemo, da je za verodostojno oceno porazdelitev potrebno vzeti čim večje število vzorcev. Po drugi strani pa želja po čim hitrejšem odkrivanju sprememb v porazdelitvah zahteva uporabo čim manjšega števila vzorcev. Zato smo analizirali, kako število vzorcev posredno zaradi popačenja histogramov vpliva na vrednost KL razdalje.

Najprej smo z generatorjem naključnih števil z Gauss-ovo porazdelitvijo ($\mu = 0$, $\sigma = 1$) generirali niz 100 vzorcev in določili njegov histogram kot oceno porazdelitve $q(x)$. Z istim generatorjem naključnih števil smo generirali še 100 nizov s po 100 vzorci, na podlagi katerih smo ocenili 100 porazdelitev $p(x)$. Nato smo izračunali 100 KL razdalj med $q(x)$ in vsako posamezno $p(x)$ ter določili srednjo vrednost in standardno deviacijo omenjenih razdalj. Celoten postopek smo ponovili še za nize s po 200, 500, 1000, ..., 500000 in 1000000 vzorci. Rezultati simulacij so prikazani na sliki 5.17.

S slik 5.17a in 5.17b lahko razberemo, da srednja vrednost KL razdalj med histogrami tvorjenimi iz nizov z le po 100 vzorci, ki sicer pripadajo isti normalni porazdelitvi, znaša skoraj 2, njihova standardna deviacija pa skoraj 1. V idealnem primeru bi ti dve vrednosti morali biti enaki 0. Iz tega lahko sklepamo, da ima popačena ocena porazdelitve s histogramom iz le 100 vzorcev na vrednost KL razdalje enak vpliv kot sprememba srednje vrednosti za približno 1 pri primerjanju dveh normalnih porazdelitev (Slika 5.15a). Z večanjem števila vzorcev v nizih pa tako srednja vrednost kot standardna deviacija KL razdalj po pričakovanju padata, saj z večjim številom vzorcev dobimo bolj verodostojne ocene porazdelitev.

V praksi imamo običajno na razpolago omejeno število vzorcev. Zato se moramo zavedati možnih odstopanj izračunanih KL razdalj od pravih vrednosti, kot je to prikazano na primeru Gauss-ove porazdelitve.




Slika 5.17: Vpliv števila vzorcev v histogramu na vrednost KL razdalje: a) srednje vrednosti KL razdalj, b) standardne deviacije KL razdalj

5.2.2 Uporaba Kullback-Leibler-jeve razdalje pri zaznavanju sprememb v kakovosti izdelkov

S pomočjo Kullback-Leibler-jeve razdalje želimo detektirati spremembe v časovnih vrstah, ki jih tvorijo zaporedne meritve na opazovanem procesu. Odstopanja porazdelitev podatkov iz omenjenih vrst od referenčne porazdelitve, ki jo ocenimo iz podatkov pridobljenih pri normalnem delovanju procesa, namreč kažejo na neke spremembe v proizvodnem procesu, na katere želimo biti opozorjeni. Glede na definicijo KL razdalje (Enačba 5.29 oz. 5.30) je v obravnavanem primeru smiselno, da za porazdelitev $q(x)$ izberemo referenčno porazdelitev, za $p(x)$ pa porazdelitev, ki jo primerjamo (porazdelitev niza zadnjih vzorcev v časovni vrsti). Takšna izbira daje velik odziv, ko opazovana porazdelitev $p(x)$ pade na področje, kjer je referenčna porazdelitev enaka nič oz. zelo majhna. Ali bo odziv reagiral na počasnejše ali hitrejše spremembe v procesu pa lahko uravnavamo z večanjem oz. manjšanjem števila vzorcev, na podlagi katerih ocenjujemo $p(x)$. Pri tem se moramo zavedati v prejšnjem podpoglavju opisanih omejitev.


Najprej bo uporaba KL razdalje za odkrivanje sprememb v časovnih vrstah demonstrirana na dveh simulacijskih zgledih. V prvem je časovno vrsto tvorilo 1200 vzorcev, ki smo jih dobili s pomočjo generatorja naključnih števil z normalno porazdelitvijo ter standardno deviacijo 1. Pri tem je bila pričakovana vrednost prve polovice vzorcev enaka 0, za preostalih 600 pa smo jo povišali na 1.5 (Slika 5.18a). Referenčno porazdelitev $q(x)$ smo določili na podlagi prvih 600 vzorcev, $p(x)$ pa smo ocenjevali na oknu 400 vzorcev, ki smo ga s korakom 10 vzorcev premikali preko celotne časovne vrste. Rezultati izračunov KL razdalj so prikazani na sliki 5.18b.

Vidimo, da se po 600-tem vzorcu, ko v opazovano okno pade vedno več vzorcev iz množice s pričakovano vrednostjo 1.5, vrednosti KL razdalji začnejo opazno večati. Po 1000-em vzorcu pa se vrednosti KL razdalji ustalijo, saj so takrat že vsi vzorci v opazovanem oknu iz množice s pričakovano vrednostjo 1.5.




Slika 5.18: Detekcija stopnice v časovni vrsti: a) vzorci časovne vrste, b) vrednosti KL razdalje

Z drugim zgledom smo preverili odziv KL razdalje na trend v časovni vrsti. V ta namen smo najprej generirali niz 1200 normalno porazdeljenih vzorcev s pričakovano vrednostjo 0 in standardno deviacijo 1 ter vzorcem od 600-tega dalje prišteli vrednosti, ki so linearno naraščale od 0 do 1.5 (Slika 5.19a). Porazdelitvi $q(x)$ in $p(x)$ ter vrednosti KL razdalj smo določali na enak način kot v prejšnjem primeru. Rezultati so prikazani na sliki 5.19b. Tudi v tem primeru opazimo, da se po 600-tem vzorcu, ko se v časovni vrsti pojavi trend, vrednosti KL razdalji začnejo večati. Po pričakovanju je omenjeno večanje počasnejše kot v prejšnjem primeru (Slika 5.18b), saj se odstopanje pričakovane vrednosti vzorcev od 0 povečuje postopoma (linearno).



Slika 5.19: Detekcija trenda v časovni vrsti: a) vzorci časovne vrste, b) vrednosti KL razdalje

Za spremljanje delovanja proizvodne linije sesalnih enot želimo uporabiti diagnostične rezultate, ki jih dobimo pri kontroli končnih izdelkov. V nadaljevanju bo kot primer ilustrirana uporaba KL razdalje za odkrivanje sprememb v porazdelitvi značilke kvalitete komutacije f_{i2} . Pri tem bodo uporabljeni v podpoglavju 5.1 že predstavljeni podatki, ki so bili pridobljeni pri enomesečnem testiranju sesalnih enot na proizvodni liniji. Referenčno porazdelitev $q(f_{i2})$ smo določili na podlagi vrednosti značilke pri vseh dobrih enotah. Porazdelitev $p(f_{i2})$ smo ocenjevali na oknu 400 vzorcev, kolikor jih dobimo v obdobju približno ene ure (proizvodni cikel je 9 s). Omenjeno okno smo s korakom 10 vzorcev (90 s) selili preko celotnega niza podatkov in računali KL razdalje. Rezultati so prikazani na sliki 5.20. Z rdečo obarvane vrednosti predstavljajo primere, ko je bil v oknu 400 vzorcev vsaj en takšen, ki je presegal mejno vrednost značilke. Vidimo, da se je v takšnih primerih vrednost KL razdalje vedno povečala. Včasih (npr. okrog 72 ure) pa pride do opaznega povečanja KL razdalje, ki je lahko tudi večje kot pri prej omenjenih primerih (npr. okrog 52 ure), čeprav so v oknu 400 vzorcev same dobre sesalne enote. To je posledica sprememb v procesu proizvodnje, ki povzročijo spremembe v porazdelitvi opazovane značilke, pri čemer pa slednja ne gre preko dopustne meje. Zato omenjene spremembe s stališča nadzora proizvodnje niso tako kritične.



Slika 5.20: Detekcija sprememb v porazdelitvi značilke f_{i2} s pomočjo KL razdalje

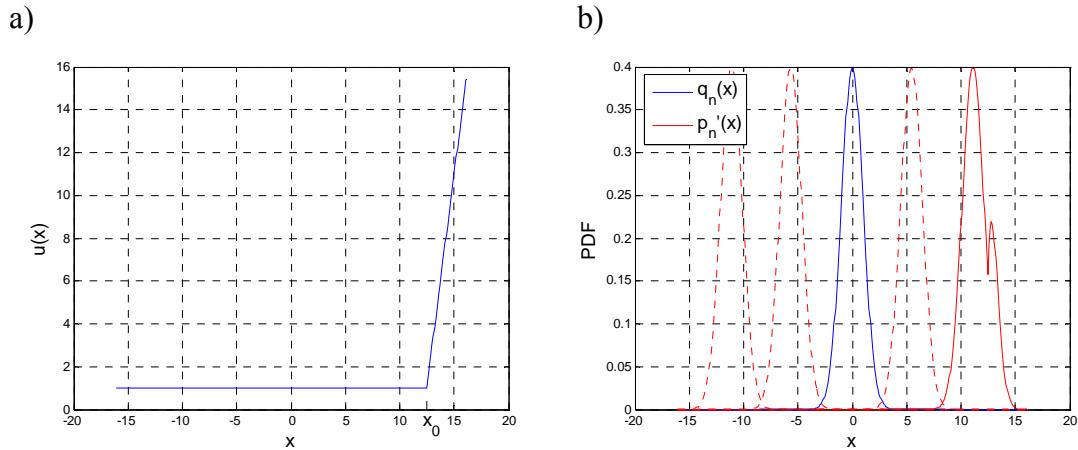
Da je odziv (KL razdalja), ko opazovana porazdelitev $p(f_{i2})$ preseže mejno vrednost značilke, vedno večji kot tisti pri spreminjanju $p(f_{i2})$ le na dopustnem območju značilke, lahko dosežemo z ustrezno utežitvijo porazdelitve $p(f_{i2})$. Nato "novo" KL razdaljo izračunamo ponovno z uporabo enačbe 5.29 oz. 5.30, s tem da $p(x)$ zamenjamo s $p'(x)$, ki je enaka produktu $p(x)$ in utežitvene funkcije $u(x)$ ($p'(x) = p(x) \cdot u(x)$). Ena izmed možnih utežitvenih funkcij je naslednja:

$$u(x) = \begin{cases} 1; & \text{za } x < x_0 \\ k(x - x_0) + 1; & \text{za } x \geq x_0 \end{cases} \quad (5.37)$$


kjer je k naklon premice, s katero utežimo opazovano porazdelitev pri vrednostih večjih od x_0 . Parameter k določimo empirično tako, da dosežemo zelen odziv. Za x_0 navadno vzamemo kar mejno vrednost značilke. Če pa želimo, da se KL razdalja intenzivneje odzove že pri pomikanju porazdelitve proti mejni vrednosti značilke, izberemo nekoliko manjši x_0 . Na ta način dobimo neko mero, ki je močno občutljiva na prekoračitve mejne vrednosti, hkrati pa ohrani informacijo o spreminjanju porazdelitve na območju znotraj dopustnih meja.

Učinek utežitve porazdelitve $p(x)$ pri določanju KL razdalje najprej prikažimo na istem zgledu kot v podpoglavju 5.2.1, kjer smo primerjali dve normalni porazdelitvi, pri čemer smo eni izmed njih ($p_n(x)$) spreminjali srednjo vrednost od -11 do 11, druga ($q_n(x)$) pa je imela srednjo vrednost enako 0. Standardni deviaciji obeh porazdelitev sta bili 1. Na sliki 5.21a je prikazana utežitvena funkcija $u(x)$, katere izbrani parametri so x_0

= 12.5 in $k = 4$, na sliki 5.21b pa porazdelitev $q_n(x)$ ter spreminjanje utežene porazdelitve $p_n(x)$. Rezultati izračuna KL razdalj med $q_n(x)$ in uteženo $p_n(x)$ so podani na sliki 5.22. Pri primerjavi s sliko 5.12b iz podpoglavja 5.2.1 lahko ugotovimo, da zaradi utežitve vrednost KL razdalje po $\mu > 10$ začne hitreje naraščati.

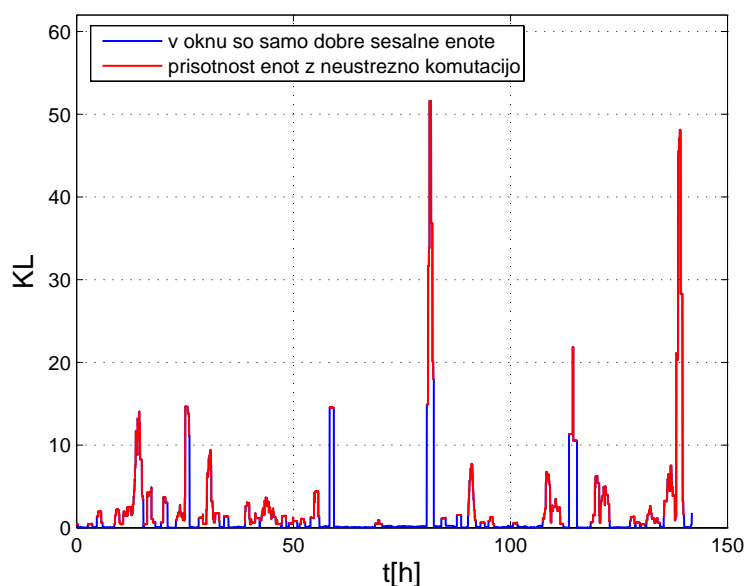


Slika 5.21: a) utežitvena funkcija, b) utežitev porazdelitve $p_n(x)$



Slika 5.22: KL razdalja med $q_n(x)$ in uteženo $p_n(x)$

Na sliki 5.23 so za potrebe nadzora sprememb v porazdelitvi značilke kvalitete komutacije f_{i2} prikazane vrednosti KL razdalj med referenčno porazdelitvijo $q(f_{i2})$ in uteženimi porazdelitvami $p'(f_{i2})$. Vidimo, da je v vseh primerih, ko je v opazovanem oknu 400 vzorcev prisotna vsaj ena sesalna enota s poslabšano komutacijo (rdeče obarvana krivulja), vrednost KL razdalje vedno večja kot v primerih, ko imamo v oknu same dobre enote (modra krivulja).



Slika 5.23: Detekcija sprememb v porazdelitvi f_{i2} s pomočjo KL razdalj (utežena $p(f_{i2})$)

5.3 Zasnova sistema statistične kontrole

V tem podpoglavju bo predstavljena zasnova sistema statistične kontrole in sicer na primeru proizvodnje sesalnih enot v Domelu. Sistem je še v fazi razvoja, zato so trenutno funkcionalne le nekatere operacije.

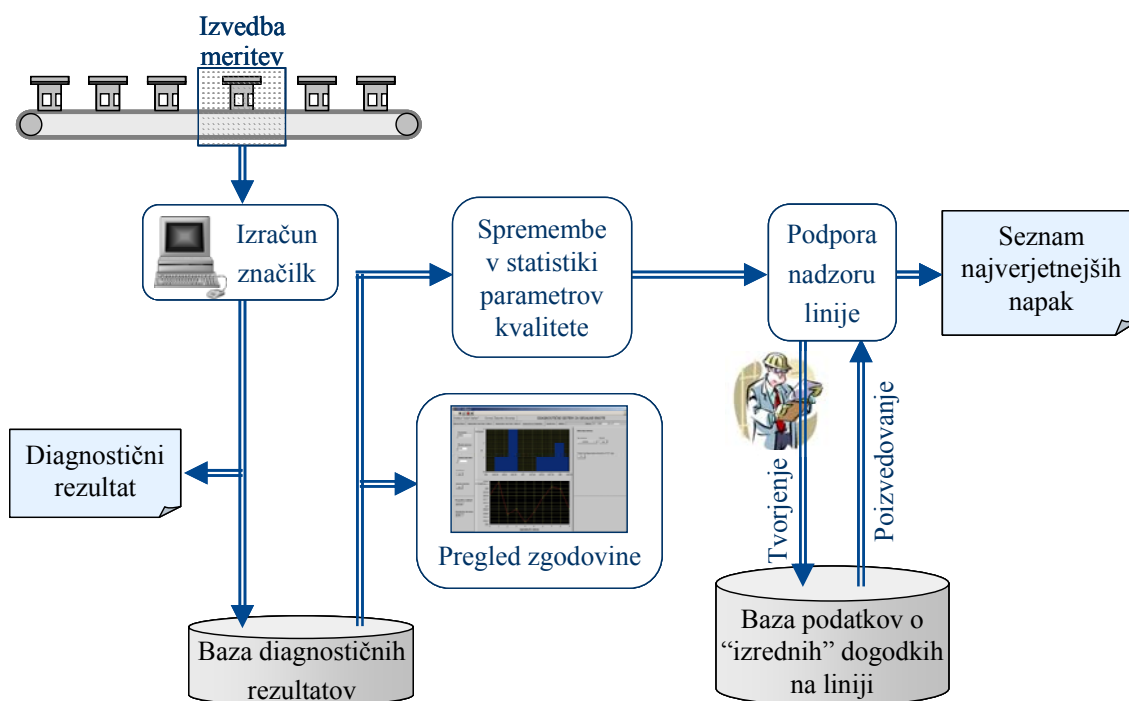
5.3.1 Analiza zahtev in izvedba

Obstoječa aplikacija sistema za končno kontrolo sesalnih enot v Domelu shranjuje diagnostične rezultate proizvedenih enot v ločene tekstovne datoteke in omogoča pregled rezultatov preteklih testiranj (gl. podpoglavje 3.3.3). Rokovanje s tako shranjenimi podatki za potrebe njihove nadaljnje obdelave in različnih analiz pa je sila nepripravno. Zato se je pokazala potreba po nadgradnji omenjenega sistema, tako da bi dobil naslednje dodatne funkcionalnosti:

- zapis podatkov v podatkovno bazo,
- prikaz podatkov glede na različne kriterije (npr.: čas proizvodnje, neustrezna komutacija itd.),
- prikaz statističnih parametrov podatkov in ustreznih grafov,
- spremljanje trendov in

- dostop do aplikacije preko interneta z možnostjo omejitve izbranih funkcionalnosti različnim uporabnikom.

Na sliki 5.24 je prikazana blokovna shema celotnega sistema. Na osnovi rezultatov avtomatsko izvedenih meritev se za vsako izdelano sesalno enoto izračunajo vrednosti značilk, v katerih se odraža njena kakovost. Diagnostični rezultati se shranijo v podatkovno bazo. Omogočeno je tudi pregledovanje le-teh. Dodatne funkcije bi omogočale ugotavljanje sprememb v statistiki parametrov kvalitete in podporo operaterjem pri nadzoru oz. upravljanju proizvodne linije. Slednja bi temeljila na bazi podatkov o "izrednih" dogodkih, ki so se pri proizvodnji v preteklosti že dogodili, pripadajočih statistikah parametrov kvalitete in znanjih o proizvodnem procesu. S primerjanjem omenjenih podatkov in trenutnih statistik parametrov kvalitete bi sistem ob nastopu povečanega serijskega ali naključnega izmeta sugeriral na vzrok za degradacijo kvalitete izdelkov, tj. podal bi seznam najverjetnejših napak na proizvodni liniji oz. sestavnih delih.



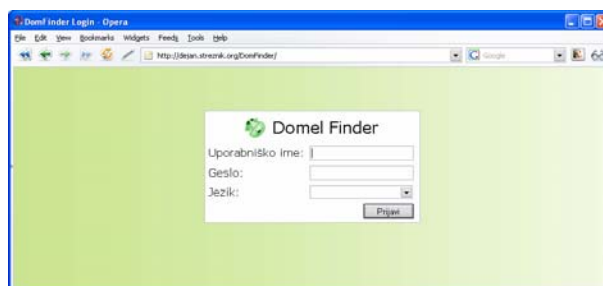
Slika 5.24: Blokovna shema sistema končne kontrole

Zasnova prototipa sistema statistične kontrole sestoji iz dveh ločenih programov. Prvi služi avtomatskemu prepisu podatkov iz obstoječega datotečnega sistema v podatkovno bazo. Napisan je v programskem jeziku C# in uporablja Microsoft-ovo ogrodje .NET Framework 1.1. Trenutno podpira podatkovno bazo MS SQL, vendar bi bil lahko z manjšimi spremembami uporaben tudi za večino ostalih baz.

Drugi program je spletna aplikacija, ki omogoča sortiranje podatkov, izrisovanje grafov ipd. Tudi ta je napisana v programskem jeziku C# in uporablja Microsoft-ovo ogrodje .NET Framework 2.0. Njena trenutna funkcionalnost bo predstavljena v naslednjem podpoglavju.

5.3.2 Prikaz delovanja

Obstoječa verzija prototipa sistema statistične kontrole omogoča izvedbo več operacij. Ob pričetku dela z aplikacijo se je najprej potrebno prijaviti v sistem (Slika 5.25). Pri tem si lahko izberemo tudi jezik, v katerem želimo delati. Prijava z geslom je potrebna s stališča varovanja podatkov, po drugi strani pa se na osnovi le-te lahko različnim uporabnikom dodeli različne pavice.

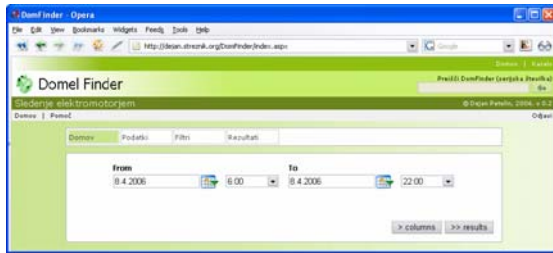


Slika 5.25: Prijava v sistem

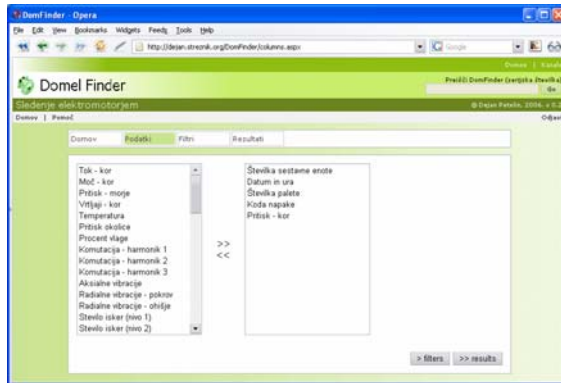
V osnovnem oknu ("Domov") (Slika 5.26a) najprej izberemo sesalne enote, ki jih želimo opazovati. Izbor se izvede glede na čas proizvodnje. V naslednjem oknu ("Podatki") (Slika 5.26b) določimo, kateri podatki o izbranih enotah nas zanimajo. Nadalje (v oknu "Filtri") (Slika 5.26c) lahko omejimo izbor glede na vrednosti podatkov. Izpis iskanih podatkov lahko vidimo v tabeli v zadnjem oknu ("Rezultati") (Slika 5.26d), kjer vsaki sesalni enoti pripada ena vrstica. Dobljene podatke lahko enostavno prikažemo tudi grafično. Pri tem (Slika 5.27) dobimo dva grafa: histogram in časovni potek izbrane spremenljivke. Na grafu časovnega poteka je s črno črto označena še povprečna vrednost spremenljivke (μ), rdeči črtkani črti pa omejujeta območje $\mu \pm \sigma$, kjer σ predstavlja standardno deviacijo. Vrednosti, ki padejo znotraj omenjenega območja so prikazane z modro, tiste, ki so zunaj pa z rdečo barvo.

Iz opisa lahko razberemo, da trenutna aplikacija omogoča predvsem pregledovanje diagnostičnih rezultatov. Zato jo bo v prihodnosti potrebno razširiti še z dodatnimi funkcionalnostmi. Ena izmed njih je zagotovo spremljanje trendov in drugih sprememb v statističnih parametrih značilke, pri čemer se predvideva implementacija tudi algoritmov predstavljenih v podpoglavju 5.2.2.

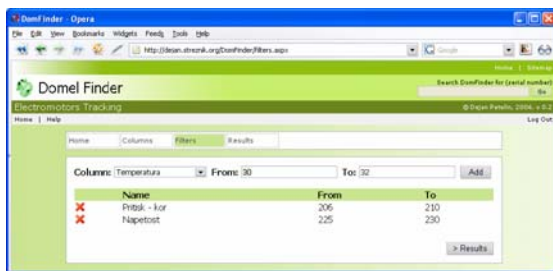
a)



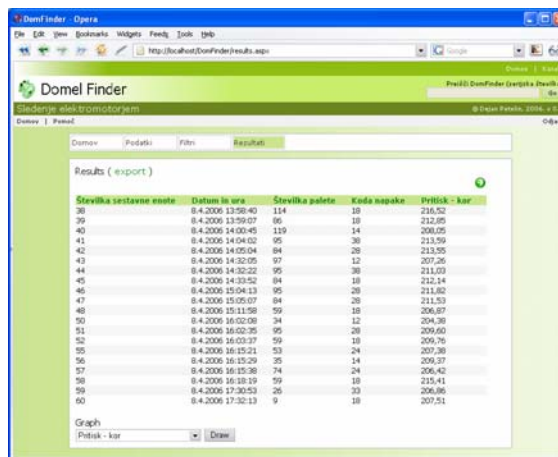
b)




c)



d)



Slika 5.26: a) osnovno okno, b) izbira podatkov, c) omejevanje vrednosti podatkov, d) izpis podatkov.



Slika 5.27: Grafični prikaz podatkov

6. Zaključek

Težnja velikoserijskih proizvajalcev elektromotorjev je vzpostavitev zanesljivega sistema zagotavljanja kakovosti produktov, ki je sposoben odkriti sleheren slab izdelek in ga izločiti iz dobave kupcem ter na podlagi analiz meritev na končnih izdelkih nudi podporo pri nadzoru proizvodnje. V ta namen je bil za konkreten primer proizvodnje sesalnih enot v Domelu razvit in tudi uspešno implementiran sistem za avtomatsko odkrivanje napak na omenjenih enotah. Le-ta temelji na zajemu več signalov in njihovi obdelavi z različnimi algoritmi za sintezo značilk, na osnovi katerih se nadalje sklepa na prisotnost in lokacijo potencialnih napak. Širok nabor meritev in algoritmov za njihovo obdelavo zagotavlja dobro občutljivost in diagnostično natančnost sistema. Kvantifikacija nekaterih kriterijev kvalitete, ki so bili prej podvrženi subjektivni oceni, pa omogoča njihovo objektivno vrednotenje (npr. intenzitete iskrenja). Nadalje je bila raziskana še možnost dopolnitve oz. nadgradnje obstoječega sistema za kontrolo končnih izdelkov v smislu boljše podpore pri spremljanju delovanja in upravljanju proizvodne linije.

V tem delu sta bili podrobneje obravnavani dve rešitvi na nivoju detekcije in lokalizacije napak, ki sta implementirani v prej omenjenem diagnostičnem sistemu za testiranje sesalnih enot. To sta ocenjevanje kvalitete komutacije in merjenje vibracij. Na nivoju nadzora proizvodnje pa so bile predlagane rešitve za spremljanje statistik diagnostičnih rezultatov izdelanih enot. V spremembah le-teh se namreč odražajo spremembe v proizvodnem procesu.

Kvaliteta komutacije se ocenjuje na dva načina. Prvi temelji na vrednotenju RMS vrednosti napajalnega toka po različnih frekvenčnih pasovih. S tem se vrednotijo motnje, ki se v toku pojavijo zaradi "sekanja" le-tega na kolektorju. Drugi način ocenjevanja kvalitete komutacije temelji na vrednotenju visokofrekvenčnih napetostnih motenj, katere se na priključnih sponkah univerzalnih elektromotorjev pojavijo zaradi induciranih napetosti med ščetkami in kolektorjem. Ustrezni značilki sta določeni na podlagi histograma amplitud izbruhov omenjenih motenj, ki jih meri v ta namen razvita naprava. Analiza občutljivosti značilk kvalitete komutacije je pokazala, da drugi način ocenjevanja daje mnogo bolj verodostojne rezultate.

V sklopu merjenja vibracij so analizirani glavni izvori vibracij pri sesalnih enotah, določen je primeren merilni postopek, definirane pa so tudi ustrezne značilke, ki kažejo na določene potencialne napake na enotah. Pri tem gre v prvi vrsti za odkrivanje neuravnoteženosti rotirajočih delov enot. Kočno sledi analiza omenjenih značilk, s katero se preverja predvsem ponovljivost meritev vibracij.

Z namenom nadgradnje obstoječega diagnostičnega sistema za potrebe spremljanja delovanja proizvodnega procesa je bila najprej opravljena statistična analiza rezultatov testiranj sesalnih enot na koncu proizvodne linije. Pri tem gre predvsem za porazdelitve posameznih značilk. Za detekcijo sprememb v porazdelitvah, ki kažejo na neke spremembe v proizvodnji, je uporabljena Kullback-Leibler-jeva razdalja. Predlagana je tudi utežitev opazovane porazdelitve, saj tako omenjena mera postane bolj občutljiva, ko se porazdelitev začne premikati proti mejni vrednosti značilke. Nazadnje je predstavljena zasnova prototipa sistema statistične kontrole. Le-ta je še v fazi razvoja, zato je njena trenutna funkcionalnost omejena. Obstoječa verzija omogoča predvsem pregledovanje in prikazovanje diagnostičnih rezultatov glede na različne kriterije.

Pomembnejše originalne prispevke disertacije lahko strnemo v naslednjih točkah:

- *Uvedba dveh značilk za ocenjevanje intenzitete iskrenja in s tem kvalitete komutacije, ki temelji na meritvah visokofrekvenčnih napetostnih motenj*

Osnovo za definicijo omenjenih značilk predstavlja histogram (porazdelitev) amplitud visokofrekvenčnih napetostnih motenj. Slednje se inducirajo zaradi iskrena med kolektorjem in ščetkami. Glede na to, da se visokofrekvenčne napetostne motenje z večjimi amplitudami pogosteje pojavljajo le pri sesalnih enotah s povečanim iskrenjem, je prva značilka intenzitete iskrenja definirana kot število amplitud z vrednostjo večjo od neke empirično določene meje. Pri formulaciji druge značilke smo upoštevali, da so iskre z večjo intenziteto bolj škodljive in jih je zato smiselno bolj poudariti, tako da več prispevajo k vrednosti značilke. V ta namen smo histogram amplitud utežili z linearno funkcijo, značilko pa definirali kot površino uteženega histograma.

- *Določitev značilk za vrednotenje vibracij, ki so prilagojene posameznim izvorom vibracij*

S frekvenčno analizo signala vibracij je bilo ugotovljeno, da k vibracijam sesalnih enot največ prispevajo štirje izvori: spremenljiv navor elektromotorja, neuravnoteženost vrtečih delov, sunki zraka turbinskega kolesa in drsenje ščetk po lamelah kolektorja. Intenziteto posameznih izvorov ovrednotimo z opazovanjem signala vibracij v ustreznem frekvenčnem področju. S stališča zagotavljanja kakovosti sesalnih enot je najpomembnejše odiranje

neuravnoteženosti vrtečih delov. Slednja se odraža v velikosti frekvenčne komponente pri hitrosti vrtenja enote.

- *Predlog uporabe Kullback-Leibler-jeve razdalje in njene modificirane različice za detekcijo sprememb v porazdelitvah posameznih značilk, ki kažejo na spremembe v proizvodni liniji*

Na osnovi odkrivanja sprememb v porazdelitvah značilk, ki jih dobimo pri končni kontroli izdelkov, lahko sklepamo tudi na spremembe v proizvodnji liniji. Klasični pristopi pri tem predpostavljajo normalno porazdelitev značilk, kar pa vedno ne drži. Zato je za odkrivanje sprememb med referenčno in "trenutno" porazdelitvijo značilke predlagana uporaba Kullback-Leibler-jeve razdalje. To je neparametrična ocena za podobnost med dvema poljubnima porazdelitvama. Z modifikacijo KL razdalje smo dosegli, da se le-ta izraziteje poveča, ko se "trenutna" porazdelitev značilke začne približevati njeni mejni vrednosti.

- *Zasnova prototipa sistema statistične kontrole pri velikoserijski proizvodnji elektromotorjev*

Prototip sistema statistične kontrole temelji na bazi podatkov diagnostičnih rezultatov, ki jih dobimo pri končni kontroli kakovosti izdelkov. Omogoča enostavno pregledovanje in prikazovanje podatkov. Dodatne funkcije bi služile ugotavljanju sprememb v statistiki parametrov kvalitete (npr. z uporabo KL razdalje) in s tem pomoči operaterjem pri nadzoru proizvodne linije. Slednja bi lahko bila podprta še z dodatno bazo o "izrednih" dogodkih na liniji, ki so se v preteklosti že zgodili.

Pri obravnavi v pričujoči disertaciji opisane problematike so se pokazala še nekatera nerešena vprašanja, ki predstavljajo zanimivo raziskovalno izhodišče in kažejo na možnost nadaljnjega dela. V sklopu analize vibracij ostaja nepojasnjena prisotnost še nekaterih komponent v frekvenčnem spektru signala vibracij. Ali so le-te posledica morebitnih drugih še nepoznanih virov vibracij ali pa so zgolj stohastične narave? Pri reševanju tega problema naj bi se uporabile metode za analizo nelinearnih dinamičnih sistemov. Nove ugotovitve bi predstavljale koristen vir informacij za konstruktorje sesalnih enot.

Veliko odprtih možnosti pa je še pri načrtovanju in izdelavi končne verzije sistema statistične kontrole. Tu gre za uporabo najrazličnejših statističnih metod, ki bi bile iz diagnostičnih rezultatov sesalnih enot sposobne izluščiti dodatne informacije o stanju proizvodnega procesa. Obstaja možnost, da bi bazo diagnostičnih rezultatov dopolnili z ekspertnimi znanji (mnenji), kar bi bilo v dodatno pomoč operaterjem pri upravljanju proizvodne linije. Nenazadnje pa obstaja tudi interes za implementacijo tako izpopolnjenega sistema.

Literatura

- Albas, E., Arikan, T. in Kuzkaya, C. (2006). In-process motor testing results using model based fault detection approach. URL: www.maintenanceworld.com/Articles/albasArikankuzkaya/emcw_2001_artesis_paper.pdf.
- Albas, E., Durakbasa, T. in Eroglu, D. (2000). Application of a New Fault Detection Technology for Quality Improvement of Appliance Motors. URL: www.artesis.com/Products/Mqm/iatc_2000_artesis_paper.pdf.
- Artesis (2006). Motor Quality Monitor. URL: www.artesis.com/mqm.asp.
- Atay, F.M., Durakbasa, T. in Duyar, A. (2001). A Novel Method for Fault Detection in Electrical Motors. *Sound and Vibration*, **35**, 2, 26-29.
- Basseville, M. in Nikiforov, I. (1993). *Detection of Abrupt Changes, Theory and Applications*. Prentice-Hall, Englewood Cliffs, NY.
- Benko, U., Petrovčič, J., Juričič, Đ., Tavčar, J. in Rejec, J. (2005). An approach to fault diagnosis of vacuum cleaner motors based on sound analysis. *Mechanical Systems and Signal Processing*, **19**, 2, 427-445.
- Benko, U., Petrovčič, J., Juričič, Đ., Tavčar, J., Rejec, J. in Stefanovska, A. (2004). Fault diagnosis of a vacuum cleaner motor by means of sound analysis. *Journal of Sound and Vibration*, **276**, 3-5, 781-806.
- Blough, J.R. (2003). A survey of DSP methods for rotating machinery analysis, what is needed, what is available. *Journal of Sound and Vibration, 2001 India-USA Symposium on Emerging Trends in Vibration and Noise Engineering*, Columbus, OH, USA, **262**, 3, 707-720.
- Brotherton, T., Chadderdon, G. in Grabill, P. (1999). Automated Rule Extraction for Engine Vibration Analysis. *Proceedings of the 1999 IEEE Aerospace Conference*, Aspen, 1-11.
- Burnett, R., Watson, J.F. in Elder, S. (1996). The application of modern signal processing techniques for use in rotor fault detection and location within three-phase induction motors. *Signal Processing*, **49**, 1, 57-70.

- Chandroth, G.O., Sharkey, A.J.C. in Sharkey, N.E. (1999). Cylinder Pressures and Vibration in Internal Combustion Engine Condition Monitoring. *Proceedings of COMADEM '99 (12th International Congress and Exhibition on Condition monitoring and Diagnostic Engineering Management)*, Sunderland, UK.
- Chapman, S.J. (2002). *Electric machinery and power systems fundamentals*. McGraw-Hill, New York, USA, 367-382.
- Chen, T., Morris, J. in Martin, E. (2005). Bayesian Control Limits for Statistical Process Monitoring. *Proc. IEEE 5th International Conference on Control and Automation (ICCA2005)*, Budapest, 409-414.
- Choi, S.W., Park, J.H. in Lee, I.B. (2004). Process monitoring using a Gaussian mixture model via principal component analysis and discriminant analysis. *Computers & Chemical Engineering*, **28**, 8, 1377-1387.
- Courrech, J. (2000). Envelope analysis for effective rolling-element fault detection-facts or fiction. *Up Time Magazine*, **8**, 1, 14-17.
- Cover, T.M. in Thomas, J.A. (1991). *Elements of Information Theory*. John Wiley & Sons, Inc., NY.
- Del Castillo, L., Artés, M. in García-Prada, J.C. (2002). Rotating machinery failure detection using different vibration analysis techniques. *Proceedings of ISMA 2002 – International Conference on Noise and Vibration Engineering*, **4**, 1539-1544.
- Dey, S. in Stori, J.A. (2005). A Bayesian network approach to root cause diagnosis of process variations. *International Journal of Machine Tools and Manufacture*, **45**, 1, 75-91.
- Downey, A.B. (2005). Lognormal and Pareto distributions in the Internet. *Computer Communications*, **28**, 7, 790-801.
- Edwards, S., Lees, A.W. in Friswell, M.I. (1998). Fault diagnosis of rotating machinery. *Shock and Vibration Digest*, **30**, 1, 4-13.
- Feldmann, K. in Colombo, A.W. (1999). Monitoring of flexible production systems using high-level Petri net specifications. *Control Engineering Practice*, **7**, 12, 1449-1466.
- Filbert, D. in Gühmann, C. (1994). Fault Diagnosis on Bearings of Electric Motors by Estimating the Current Spectrum. *IFAC/IMACS Symposium on Fault Detection Supervision and Safety for Technical Process – Safeprocess '94*, Helsinki, 714-719.
- Gühmann, C. in Filbert, D. (1991). Fault diagnosis of electric low-power motors by analyzing the current signal. *Prepr. IFAC Symp. Safeprocess*, Baden-Baden, **1**, 67-72.

- Isermann, R. (1984). Process fault detection based on modelling and estimation methods: a survey. *Automatica*, **20**, 4, 387-404.
- Jereb, P. (1975). *Osnove električnih strojev*. Fakulteta za elektrotehniko, Ljubljana, 238-287.
- Jiang, J.D., Chen, J. in Qu, L.S. (1999). The Application of Correlation Dimension in Gearbox Condition Monitoring. *Journal of Sound and Vibration*, **223**, 4, 529-541.
- Juričić, Đ. (1998). Nadzor procesov. v Strmčnik, S. in soavtorji. *Celostni pristop k računalniškemu vodenju procesov*. Fakulteta za elektrotehniko Univerze v Ljubljani, 214-240.
- Koo, I.S. in Kim, W.W. (2000). The development of reactor coolant pump vibration monitoring and a diagnostic system in the nuclear power plant. *ISA Transactions*, **39**, 3, 309-316.
- Kramer, M.A. (1987). Malfunction diagnosis using quantitative models with non-Boolean reasoning in expert systems. *AIChE Journal*, **33**, 1, 130-140.
- Krishnamurthy, B., Madhyastha, H.V. in Venkatasubramaniam, S. (2005). On stationarity in internet measurements through an information-theoretic lens. *Proc. of 1st IEEE International Workshop on Networking meets Databases (NetDB)*, Tokyo, Japan.
- Kulhavý, R. (1996). *Recursive Nonlinear Estimation: A Geometric Approach (Lecture Notes in Control and Information Sciences 216)*. Springer, London.
- Lane, S., Martin, E.B., Kooijmans, R. in Morris, A.J. (2001). Performance monitoring of a multi-product semi-batch process. *Journal of Process Control*, **11**, 1, 1-11.
- Lee, J. (1995). Modern computer-aided maintenance of manufacturing equipment and systems: Review and Perspective. *Computers & Industrial Engineering*, **28**, 4, 793-811.
- Lee, J.M., Yoo, C. in Lee, I.B. (2003). On-line batch process monitoring using a consecutively updated multiway principal component analysis model. *Computers & Chemical Engineering*, **27**, 12, 1903-1912.
- Luo, G.Y., Osypiw, D. in Irle, M. (2000). Real-time condition monitoring by significant and natural frequencies analysis of vibration signal with wavelet filter and autocorrelation enhancement. *Journal of Sound and Vibration*, **236**, 3, 413-430.
- Ly, F., Toguyeni, A.K.A. in Craye, E. (2000). Indirect predictive monitoring in flexible manufacturing systems. *Robotics and Computer-Integrated Manufacturing*, **16**, 5, 321-338.
- Mathur, A., Cavanaugh, K.F., Pattipati, K.R., Willett, P.K. in Galie, T.R. (2001). Reasoning and Modeling Systems in Diagnosis and Prognosis. *Proc. SPIE* –

- Component and Systems Diagnostics, Prognosis, and Health Management*, **4389**, 194-203.
- Meesad, P. in Yen, G.G. (2000). Pattern classification by a neurofuzzy network: application to vibration monitoring. *ISA Transactions*, **39**, 3, 293-308.
- Mendes, B.V.M. in Lopes, H.F. (2004). Data driven estimates for mixtures. *Computational Statistics & Data Analysis*, **47**, 3, 583-598.
- Michiguchi, Y. in Ideumi, S. (1981). Spark detector for rotary electric machine current collector. Patent št. JP56148125.
- Michiguchi, Y. in Tanisaka, S. (1986). Spark monitor device for current collectors. Patent št. US4577151.
- Misra, M., Yue, H.H., Qin, S.J. in Ling, C. (2002). Multivariate process monitoring and fault diagnosis by multi-scale PCA. *Computers & Chemical Engineering*, **26**, 9, 1281-1293.
- Miyashita, I. (1985). Spark detecting device in current collector. Patent št. JP60152252.
- Moczala, H., Draeger, J., Kraus, H., Shock, H. in Tillner, S. (1998). *Small electric motors*. The Institution of Electrical Engineers, London, UK, 111-115.
- Musizza, B., Petrovčič, J., Tinta, D., Tavčar, J., Dolanc, G., Koblar, J. in Juričič, Đ. (2006). Izvedba sistema za avtomatsko končno kontrolo kakovosti elektromotorjev – Implementation of a System for the Automatic End-Quality Assessment of Vacuum-Cleaner Motors. *Strojniški vestnik – Journal of Mechanical Engineering*, Fakulteta za strojništvo Univerze v Ljubljani, **52**, 3, 170-180.
- Nagano, S. in sodelavci (1989). Collector ring spark monitor for rotary electric machine. Patent št. JP1160315.
- Nagase, K. in sodelavci (1986). Commutation spark detector. Patent št. JP61170255.
- Nandi, S. in Toliyat, H.A. (1999). Condition Monitoring and Fault Diagnosis of Electrical Machines - A Review. *Proc. IEEE-IEMDC Conference*, Seattle, WA.
- Obara, S. in Miyashita, I. (1981). Spark detector for current collector. Patent št. JP56147382.
- Odrey, N.G. in Mejía, G. (2003). A re-configurable multi-agent system architecture for error recovery in production systems. *Robotics and Computer-Integrated Manufacturing*, **19**, 1-2, 35-43.
- Olsson, G. in Newell, B. (1999). *Wastewater Treatment Systems: Modelling, Diagnosis and Control*. IWA Publishing, London.
- Oppenheim, A.V. in Schafer R.W. (1999). *Discrete-time signal processing*. 2nd edition, Prentice-Hall, Upper Saddle River, 771-772.

- Ouchi, S. in sodelavci (1987). Spark monitor for collector. Patent št. JP62118731.
- Papoulis, A. (1991). *Probability, Random Variables and Stochastic Processes*. 3rd edition, McGraw-Hill, New York, USA.
- Payne, B.S., Ball, A.D. in Gu, F. (2000a). An Investigation into the Ways and Means of Detecting, Locating and Assessing the Severity of Incipient Turn-to-turn Stator Shorting Faults in 3-phase Induction Motors. *Proceedings of the 13th International Congress on Condition Monitoring and Diagnostic Engineering Management (COMADEM 2000)*, Texas, USA, 195-202.
- Payne, B.S., Ball, A.D., Gu, F. in Li, W. (2000b). A Head-to-head Assessment of the Relative Fault Detection and Diagnosis Capabilities of Conventional Vibration and Airborne Acoustic Monitoring. *Proceedings of the 13th International Congress on Condition Monitoring and Diagnostic Engineering Management (COMADEM 2000)*, Texas, USA, 233-242.
- Peng, Z. in Kessissoglou, N. (2003). An integrated approach to fault diagnosis of machinery using wear debris and vibration analysis. *Wear, 14th International Conference on Wear of Materials*, Washington, DC, USA, **255**, 7-12, 1221-1232.
- Persson, N. in Gustafsson, F. (2001). Event-based sampling with application to monitoring pressure in pneumatic tires. *Proceedings of IEEE International Conference on Acoustics, Speech, and Signal Processing ICASSP 2001*, Salt Lake City, USA, 3885-3888.
- Petrovčič, J., Dolanc, G., Musizza, B., Grom, J., Štrubelj, M., Nastran, D., Leban, A. in Koblar, J. (2005). Diagnostični sistem za sesalne enote tipa 463 – Tehnična dokumentacija. IJS delovno poročilo št. 9120.
- Petrovčič, J., Juričić, Đ. in Tinta, D. (2004). Detektorski sklop in naprava za merjenje intenzitete iskrenja kolektorskih motorjev. Patent št. 21381.
- Piérard, E. (1995). Reference architecture for car assembly monitoring. *Computers in Industry*, **27**, 2, 203-213.
- Rabinovich, S.G. (2000). *Measurement Errors and Uncertainties: Theory and Practice*. 2nd edition, Springer, New York.
- Randall, R.B. (1987). *Frequency analysis*. 3rd edition, Brüel & Kjær, Copenhagen, 153-176.
- Randall, R.B. (2002). State of the art in monitoring rotating machinery. *Proceedings of ISMA 2002*, **4**, 1457-1477.
- Rohatgi, V.K. (1976). *An Introduction to Probability Theory and Mathematical Statistics*. John Wiley & Sons.

- Röpke, K. in Filbert, D. (1994). Unsupervised Classification of Universal Motors using modern Clustering Algorithms. *IFAC Symposium on Fault Detection Supervision and Safety for Technical Process – Safeprocess '94*, Helsinki, 720-725.
- Sasi, A.B., Payne, B., York, A., Gu, F. in Ball, A. (2001). Condition Monitoring of Electric Motors Using Instantaneous Angular Speed. *Electronic Proceedings of the 5th Annual Maintenance and Reliability Conference (MARCON 2001)*, Gatlinburg, Tennessee, USA.
- Schenck (2006). Testing and Diagnostic System for Vacuum Cleaner Blowers. URL: www.schenck-ind.com/balance4.html.
- Shiozaki, J. (1985). Commutation spark detector of DC machine. Patent št. JP60059940.
- Shiozaki, J. in sodelavci (1986). Commutation spark monitoring apparatus for rotary electric machine. Patent št. JP61004440.
- Stark, H. in Woods, J.W. (2002). *Probability and Random Processes with Applications to Signal Processing*. 3rd edition, Prentice-Hall, Upper Saddle River, New Jersey.
- Tanisaka, S. in sodelavci (1982). Spark detector for current collector. Patent št. JP57189072.
- Tawara, K. in sodelavci (1985a). Rectifying spark monitor. Patent št. JP60226739.
- Tawara, K. in sodelavci (1985b). Rectified state detector of commutator machine. Patent št. JP60022495.
- Tawara, K. in sodelavci (1985c). Commutation spark monitor. Patent št. JP60210152.
- Tax, D.M.J., Ypma, A. in Duin, R.P.W. (1999). Support vector data description applied to machine vibration analysis. *Proceedings of the Fifth Annual Conference of the Advanced School for Computing and Imaging (ASCI)*, Delft, 398-405.
- Teraguchi, K. (1981). Spark monitoring device for current collector. Patent št. JP56081063.
- Tinta, D., Petrovčič, J., Benko, U., Juričić, Đ., Rakar, A., Žele, M., Tavčar, J., Rejec, J. in Stefanovska, A. (2005). Fault diagnosis of vacuum cleaner motors. *Control Engineering Practice*, **13**, 2, 177-187.
- Toyoda, T. in sodelavci (1980). Method and device for rectification spark detection of direct current motor. Patent št. JP55062374.
- Ündey, C., Tatar, E. in Çınar, A. (2003). Real-time batch process supervision by integrated knowledge-based systems and multivariate statistical methods. *Engineering Applications of Artificial Intelligence*, **16**, 5-6, 555-566.
- Vetter, T., Weber, H. in Grossehelweg, J. (1994). Vollautomatische Fehlerdiagnose in der Serienfertigung von Elektromotoren. *VDI-Tagung: "Überwachung und Fehlerdiagnose"*, Darmstadt.

- Vogelsang & Benning (2006). Routine test system for vacuum cleaner fans. URL: www.vogelsangbenning.de/en/index.html.
- Wasserman, L. (2005). *All of Statistics: A Concise Course in Statistical Inference*. Springer, New York, USA.
- Wasserman, L. (2006). *All of Nonparametric Statistics*. Springer, New York, USA.
- Watanabe, T. (1983). Spark supervisory device for current collector. Patent št. JP58015452.
- Watanabe, T. (1986). Spark monitor of current collector. Patent št. JP61009139.
- Worden, K., Manson, G. in Fieller, N.R.J. (2000). Damage detection using outlier analysis. *Journal of Sound and Vibration*, **229**, 3, 647-667.
- Yamada, K. (1997). Commutation spark tendency controller. Patent št. JP9140101.
- Yang, D.M. in Penman, J. (2000). Intelligent detection of induction motor bearing faults using current and vibration monitoring. *Proceedings of COMADEM 2000*, Houston, 461-470.
- Ypma, A., Tax, D.M.J. in Duin, R.P.W. (1999). Robust Machine Fault Detection with Independent Component Analysis and Support Vector Data Description. *Proc. of the 1999 IEEE Signal Processing Society Workshop on Neural Networks for Signal Processing*, Madison, Wisconsin, USA, 67-76.
- Zagradišnik, I. in Slemnik, B. (2001). *Električni rotacijski stroji*. Fakulteta za elektrotehniko, računalništvo in informatiko, Maribor, 246-313.

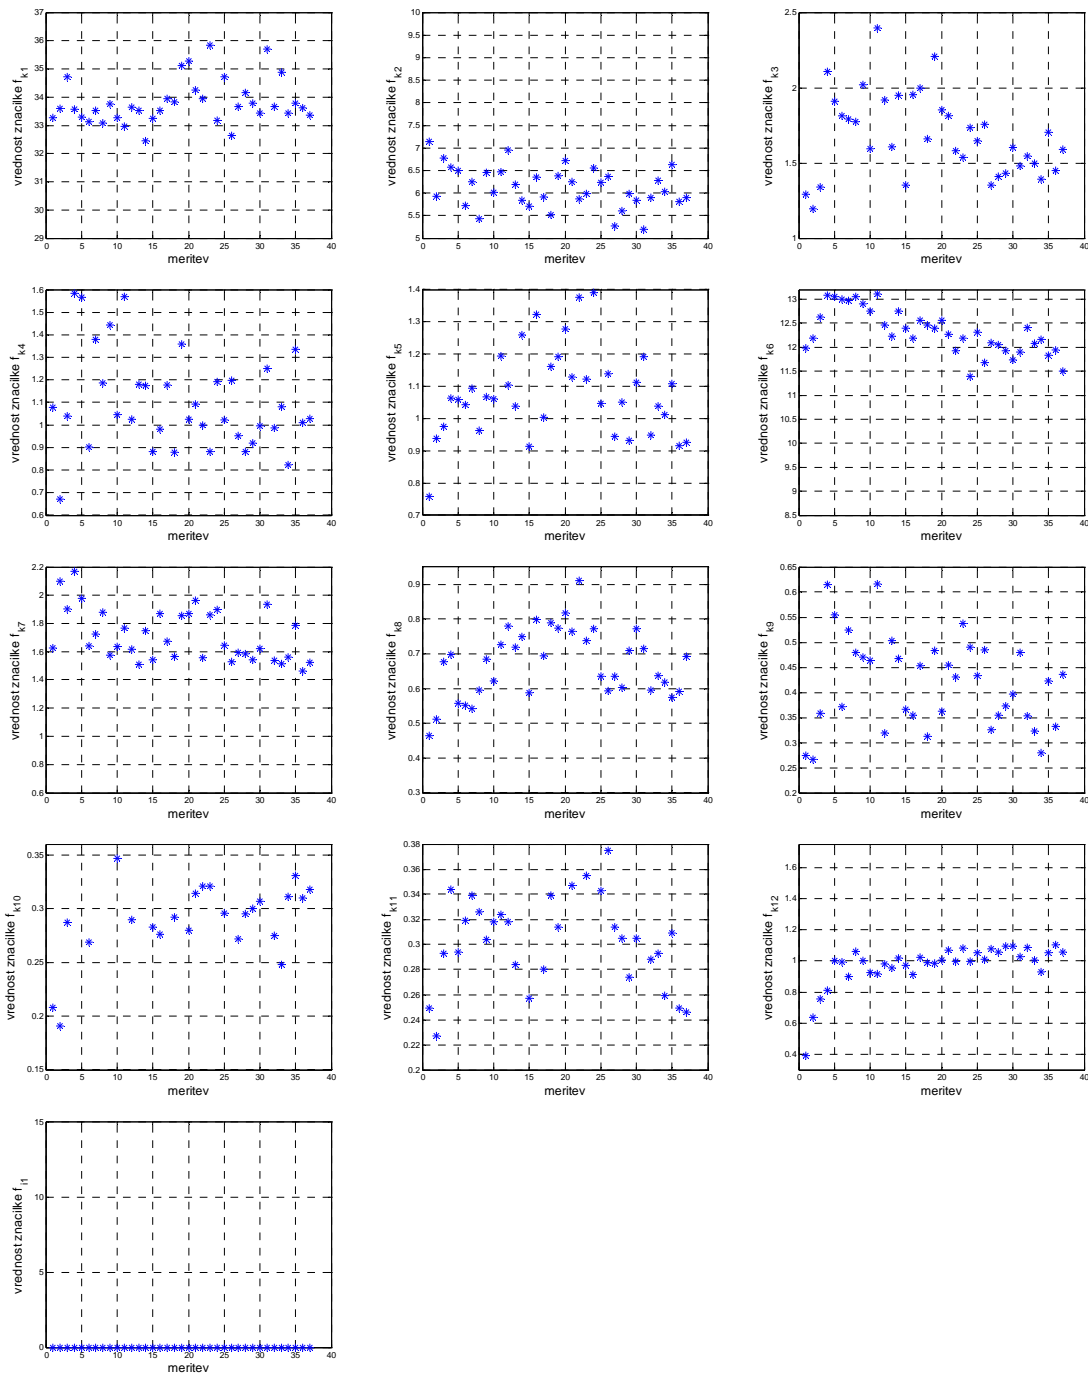
Dodatek A

Ponovljivost značilk kvalitete komutacije

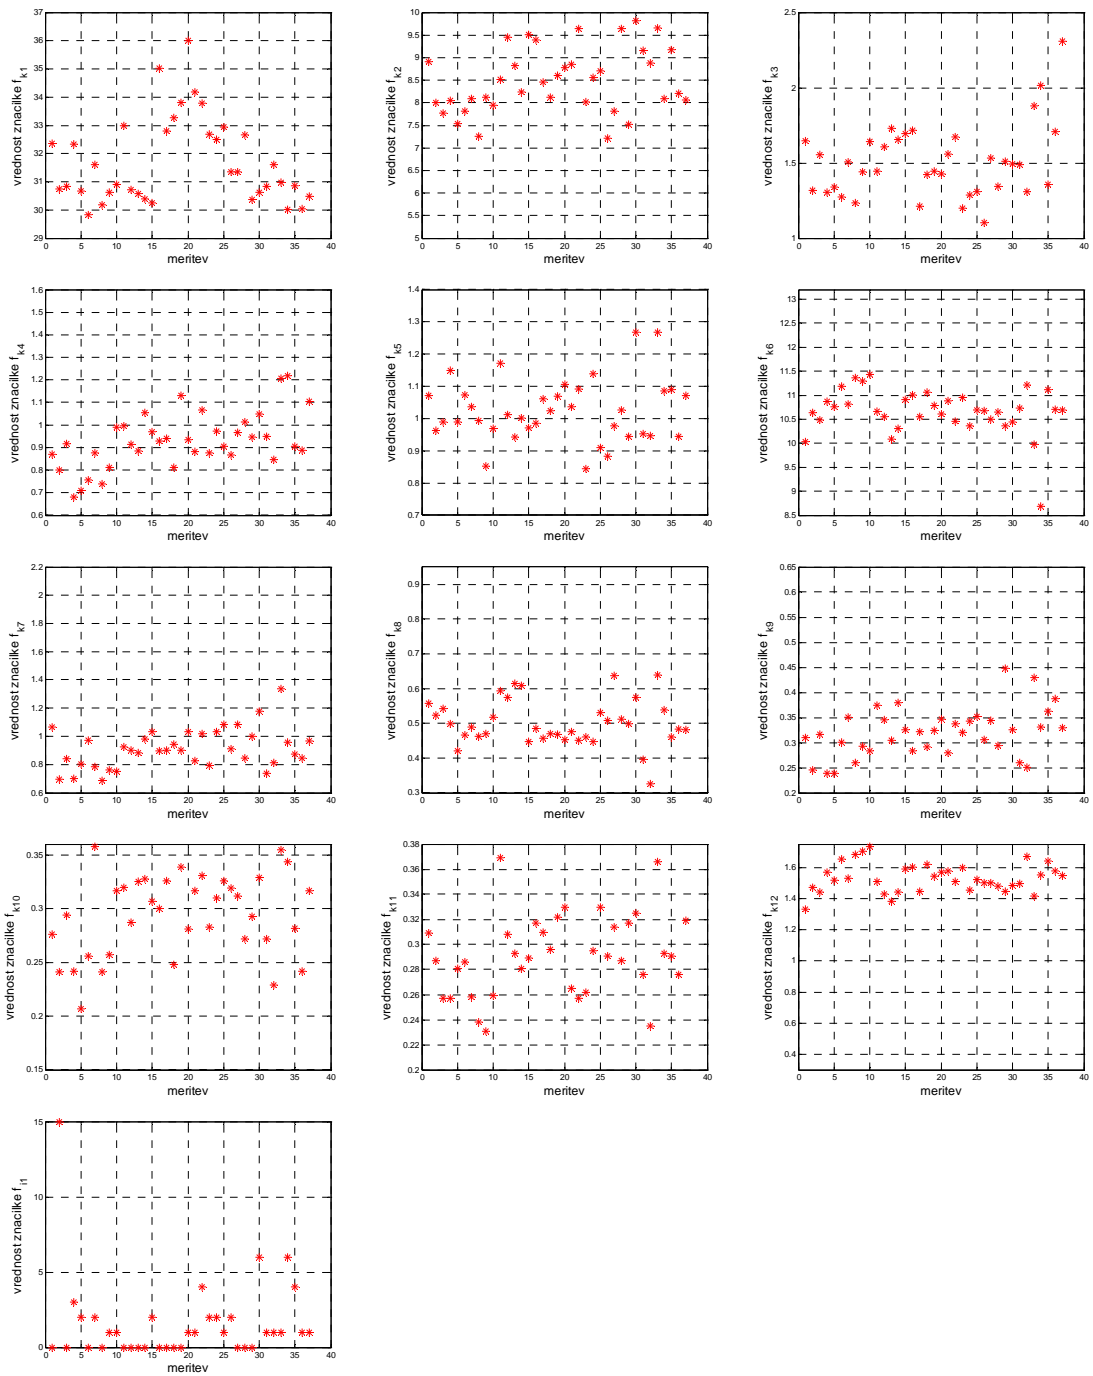
Ponovljivost značilk kvalitete komutacije smo preverili z meritvami na dveh sesalnih enotah in sicer eni dobri in eni s povečanim iskrenjem. Na vsaki smo meritve izvedli po 37-krat. V tem dodatku so podani rezultati le za značilke $f_{k1}, f_{k2}, \dots, f_{k12}$ in f_{i1} , medtem ko so bili rezultati za značilko f_{i2} že predstavljeni v podpoglavju 4.1.3.

Dobljene vrednosti značilk kvalitete komutacije so za dobro sesalno enoto prikazane na sliki 1, za enoto s povečanim iskrenjem pa na sliki 2. Kot merilo za raztros obravnavanih značilk so v tabeli 1 podane še standardne deviacije le-teh in sicer za obe enoti. Vidimo, da se pri dobri sesalni enoti raztrosi glede na absolutne vrednosti, ki jih zavzamejo posamezne značilke, nekoliko spreminjajo od značilke do značilke. Podobno velja za sesalne enote s povečanim iskrenjem. Pri primerjavi raztrosov značilk pri dobri enoti s tistimi pri enoti s povečanim iskrenjem ugotovimo, da so le-ti v nekaterih primerih večji, v nekaterih pa manjši. Kot neka posebnost je značilka f_{i1} , ki ima v predstavljenem primeru dobre sesalne enote raztros 0.

V splošnem pa lahko sklenemo, da so tako pri dobri kot pri sesalni enoti s povečanim iskrenjem raztrosi značilk $f_{k1}, f_{k2}, \dots, f_{k12}$ in f_{i1} (gledano relativno na njihove absolutne vrednosti) manjši v primerjavi z raztrosom značilke f_{i2} , ki je bila obravnavana v podpoglavju 4.1.3.



Slika 1: Ponovljivost značilk kvalitete komutacije pri dobri sesalni enoti



Slika 2: Ponovljivost značilk kvalitete komutacije pri sesalni enoti s povečanim iskrenjem

Tabela 1: Standardna deviacija značilke kvalitete komutacije pri dobri in sesalni enoti s povečanim iskrenjem

značilka	standardna deviacija	
	dobra sesalna enota	sesalna enota s povečanim iskrenjem
f_{k1}	0.78	1.52
f_{k2}	0.45	0.72
f_{k3}	0.27	0.24
f_{k4}	0.22	0.12
f_{k5}	0.14	0.10
f_{k6}	0.46	0.48
f_{k7}	0.18	0.14
f_{k8}	0.10	0.07
f_{k9}	0.09	0.05
f_{k10}	0.07	0.04
f_{k11}	0.05	0.03
f_{k12}	0.14	0.09
f_{i1}	0	2.8

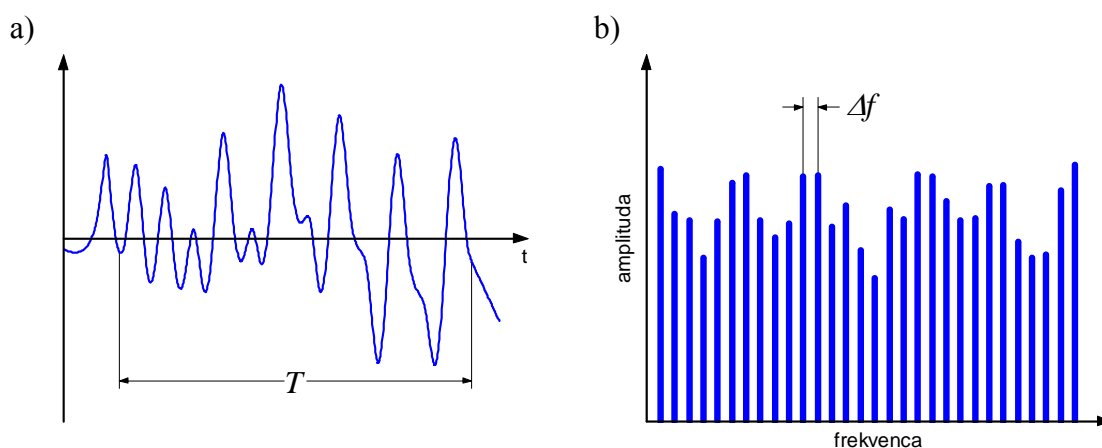
Dodatek B

Lastnosti spektralne analize

Pri določanju frekvenčnih spektrov realnih signalov s pomočjo diskretne Fourier-jeve transformacije (DFT) se moramo zavedati nekaterih njenih lastnosti, ki vplivajo na verodostojnost rezultata. Potemtakem je tudi smiselno, da že pri izračunu uporabimo nekatere računske postopke, ki zmanjšajo nezaželen vpliv omenjenih lastnosti (Randall, 1987; Oppenheim in Schaffer, 1999).

Pri računanju DFT realnega signala imamo na voljo le določen časovni izsek tega signala, katerega dolžino T pogojuje čas opazovanja oziroma meritve. Omenjena dolžina signala v časovnem prostoru pa določa prirastek frekvence med dvema zaporednima vzorcema v frekvenčnem prostoru Δf (Slika 1):


$$\Delta f = 1/T \quad (1)$$



Slika 1: a) dolžina signala T , b) frekvenčna resolucija Δf


Omejitev dolžine signala pomeni isto kot, da bi signal v časovnem prostoru utežili s pravokotnim oknom višine 1 in dolžine T (Slika 2):

$$w(t) = \begin{cases} 1; & 0 \leq t \leq T \\ 0; & \text{sicer} \end{cases} \quad (2)$$



Slika 2: Pravokotno okno


Pri tem je dolžina okna T lahko večkratnik periode posamezne frekvenčne komponente signala (Slika 3a) ali pa tudi ne (Slika 3b). V praksi imamo največkrat opravka s slednjim primerom, saj navadno ne poznamo frekvenčne vsebine obravnavanega signala, na podlagi katere bi lahko prilagodili dolžino okna.



Slika 3: Sinusni signal: a) dolžina okna je večkratnik periode signala, b) dolžina okna ni večkratnik periode signala

Po tej definiciji je DFT uporabna le za frekvenčno analizo periodičnih signalov, pri čemer mora biti dolžina okna enaka periodi signala ali njenemu večkratniku. Rezultat DFT je namreč frekvenčni spekter signala, katerega dobimo z nizanem časovnega izseka, ki je uporabljen za izračun. Kaj to pomeni, je za primer sinusnega signala prikazano na sliki 4. Če se dolžina časovnega izseka (okna) ujema z večkratnikom periode obravnavanega signala, je niz časovnih izsekov enak obravnavanemu signalu

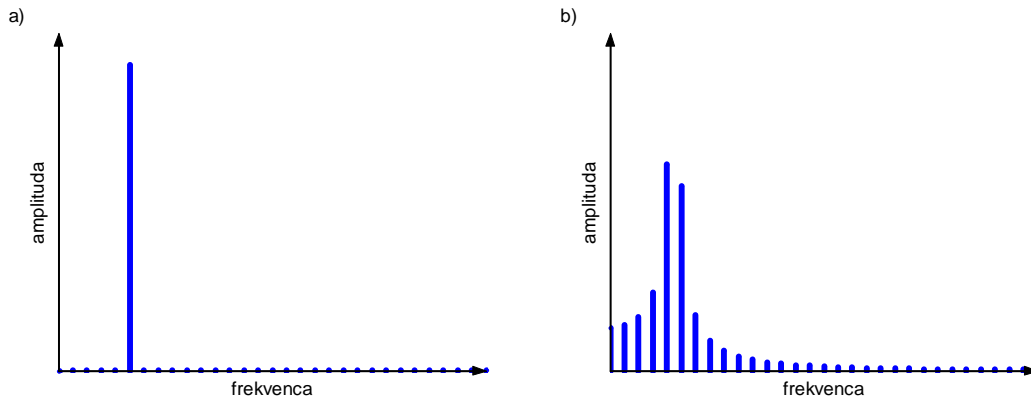
(Slika 4a). V nasprotnem primeru pa to ne velja več (Slika 4b) in zato tudi rezultat DFT ni korekten. S stališča frekvenčne analize so najbolj kritične nezveznosti odvoda, ki nastanejo pri nizanju izsekov, saj se zaradi njih v spektru pojavijo visokofrekvenčne komponente.



Slika 4: Niz časovnih izsekov sinusnega signala: a) dolžina okna je večkratnik periode signala, b) dolžina okna ni večkratnik periode signala

Kako ujemanje oziroma neujemanje dolžine okna z večkratnikom periode signala vpliva na rezultat DFT, je za primer sinusnega signala razvidno s slike 5. Če je dolžina okna večkratnik periode signala, v spektru dobimo le komponento pri frekvenci obravnavanega signala (Slika 5a), kar tudi ustreza dejanskemu stanju.


Z DFT signala s slike 3b, pri katerem se izbrana dolžina okna ne ujema z večkratnikom periode signala, pa dobimo spekter, ki je prikazan na sliki 5b. Pri tem je potrebno opozoriti, da je oblika tega spektra odvisna od razlike med dolžino okna in najbližjim večkratnikom periode signala. Neglede na to pa je zanj značilno, da se v njem pojavi več frekvenčnih komponent, katerim z oddaljevanjem od frekvence obravnavanega signala amplituda pada. Učinek je enak, kot da bi se energija signala porazdelila z dejanske na sosednje frekvenčne komponente v spektru (ang. leakage).



Slika 5: Frekvenčni spekter sinusnega signala izračunan z DFT: a) dolžina okna je večkratnik periode signala, b) dolžina okna ni večkratnik periode signala


Pravkar opisano popačenje spektra zaradi neujemanja dolžine okna z večkratnikom periode signala lahko zmanjšamo z uporabo kakšnega drugega okna namesto pravokotnega. Najpogosteje se poslužujemo Hanningovega okna (Slika 6). Le-tega tvori ena perioda kosinusnega signala, ki je dvignjena, tako da ima minimalno vrednost 0:

$$W(t) = \begin{cases} 1 - \cos \frac{2\pi}{T}t; & 0 \leq t \leq T \\ 0; & \text{sicer} \end{cases} \quad (3)$$




Slika 6: Hanningovo okno

Na sliki 7 sta prikazana signala s slike 3 utežena s Hanningovim oknom. Ta utežitev gladko potlači signal na začetku in koncu okna na vrednost 0. S tem se izognemo nezveznostim odvodov, ki bi sicer nastale pri nizanju časovnega izseka, katerega dolžina ni večkratnik periode signala (Slika 8b). Cena za to pa je nepotrebno preoblikovanje tudi niza izsekov, katerih dolžina se ujema z večkratnikom periode signala (Slika 8a).




Slika 7: Utežitev sinusnega signala s Hanningovim oknom: a) dolžina okna je večkratnik periode signala, b) dolžina okna ni večkratnik periode signala




Slika 8: Niz časovnih izsekov sinusnega signala uteženih s Hanningovim oknom: a) dolžina okna je večkratnik periode signala, b) dolžina okna ni večkratnik periode signala

Rezultati DFT sinusnega signala uteženega s Hanningovim oknom so prikazani na sliki 9. V primeru ujemanja dolžine okna z večkratnikom periode signala se zaradi utežitve spekter (Slika 9a) nekoliko popači glede na tistega s slike 5a. Poleg komponente pri dejanski frekvenci signala se namreč pojavijo še nekatere sosednje komponente, ki pa imajo manjše amplitude. Pri neujemanju dolžine okna z večkratnikom periode signala pa je dobljeni spekter (Slika 9b) precej bolj podoben dejanskemu spektru obravnavanega signala, kot pa tisti, ki ga dobimo, če uporabimo pravokotno okno (Slika 5b).




Slika 9: Rezultat DFT sinusnega signala uteženega s Hanningovim oknom: a) dolžina okna je večkratnik periode signala, b) dolžina okna ni večkratnik periode signala

Rezultat določanja frekvenčnih spektrov realnih signalov s pomočjo DFT lahko izboljšamo s povprečenjem več spektrov, ki jih izračunamo na različnih časovnih izsekih obravnavanega signala. Na ta način namreč izločimo šumne komponente naključnega izvora. V primeru, ko so omenjeni časovni izseki posnetka signala, ki ga imamo na voljo, dobljeni z uporabo Hanningovih oken, ki si sledijo eno za drugim (Slika 10), pride do izgube podatkov oziroma informacij, saj je signal na začetku in koncu posameznega izseka potlačen. Torej določeni deli signala manj prispevajo k povprečju.




Slika 10: Zaporedje Hanningovih oken

Pravkar opisanemu pojavu se lahko izognemo z dvotretjinskim medsebojnim prekrivanjem zaporednih izsekov signala v časovnem prostoru (Slika 11). S stališča izgube podatkov to pomeni isto, kot da bi signal utežili z oknom, ki je prikazano na sliki 12. Le-to zagotavlja enakovredno zastopanost večjega dela signala.




Slika 11: Dvotretjinsko prekrivanje Hanningovih oken



Slika 12: Učinek dvotretjinskega prekrivanja Hanningovih oken

Zaradi diskretizacije v frekvenčnem prostoru pride do tako imenovanega ograjnega učinka (Slika 13). Z DFT namreč dobimo vrednosti frekvenčnega spektra signala le v določenih ekvidistantnih točkah. O poteku spektra med omenjenimi točkami pa nimamo nobenih informacij. Zato v primeru neujemanja frekvence, pri kateri računamo DFT, in frekvence, pri kateri dejansko obstaja določena značilna komponenta, ne dobimo amplitude omenjene komponente, temveč nekoliko nižjo vrednost. Poleg tega pa ne moremo ugotoviti točne frekvence te komponente. Nezaželenim posledicam ograjnega učinka se do določene mere lahko izognemo s povečanjem resolucije v frekvenčnem prostoru, kar pa zahteva daljši čas opazovanja signala v časovnem prostoru.



Slika 13: Ograjni učinek

Dodatek C

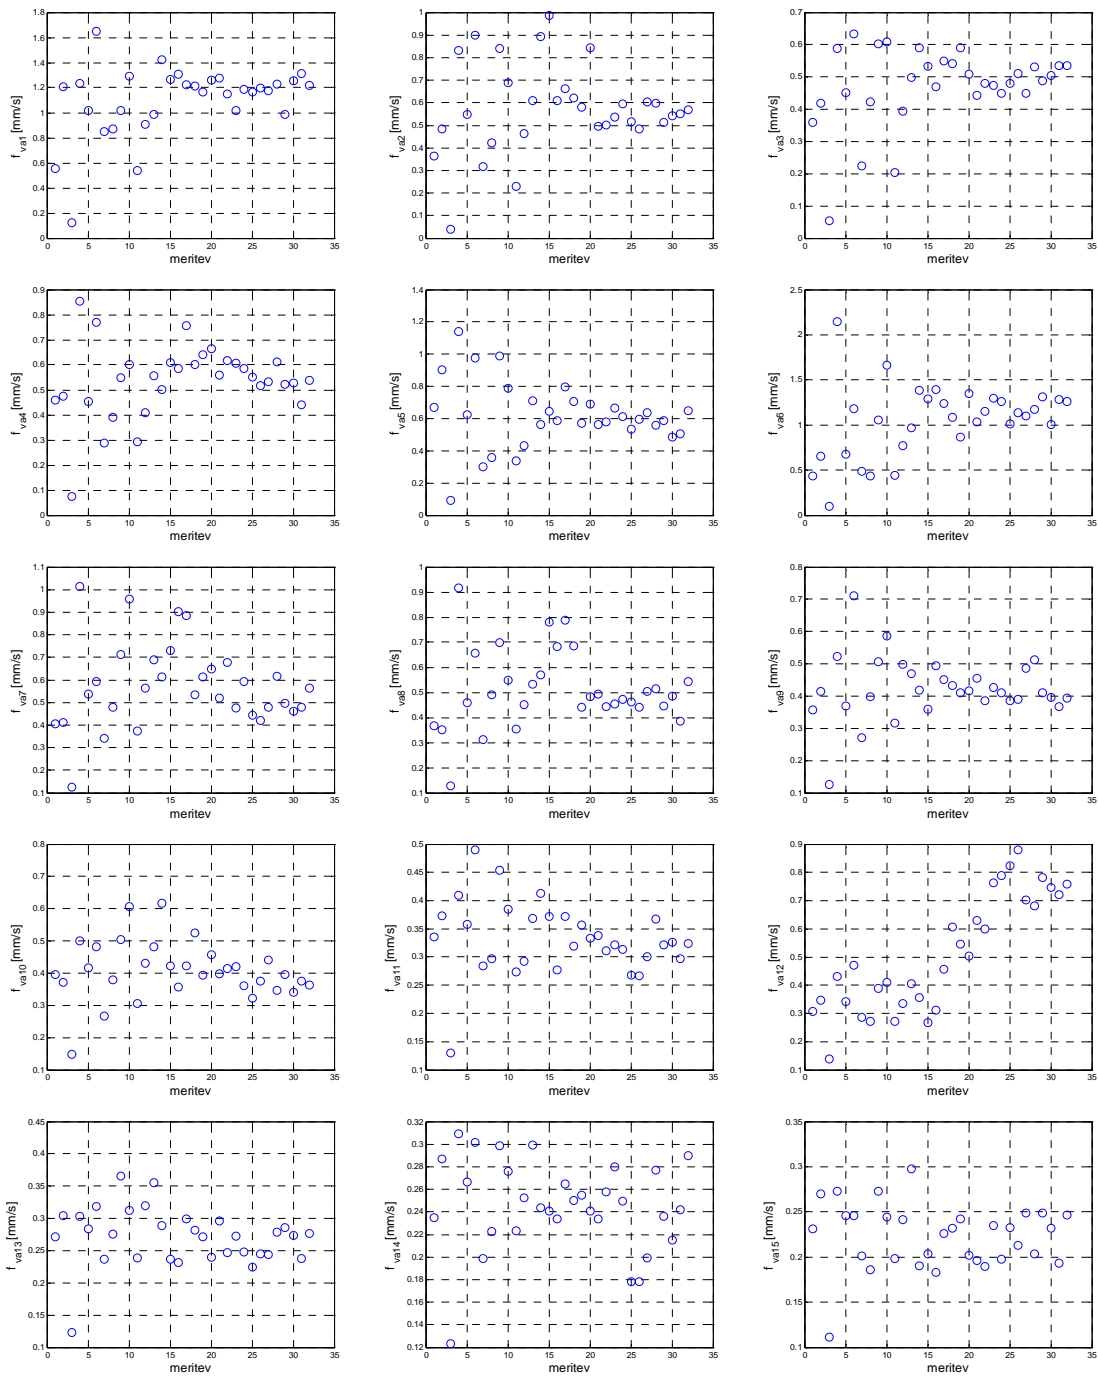
Ponovljivost značilk vibracij

Ponovljivost značilk vibracij smo preverili z izvedbo 32 ponovitev meritev vibracij na eni dobri sesani enoti. V tem dodatku so predstavljeni le rezultati za značilke ($f_{va1}, f_{va2}, \dots, f_{va15}, f_{vt1}, f_{vt2}, \dots, f_{vt15}, f_{vo1}, f_{vo2}, \dots, f_{vo14}$ in f_{vo15}), medtem ko so bili rezultati za značilke f_{va}, f_{vt} in f_{vo} , ki odražajo neuravnoteženost vrtečih se delov sesalne enote, že podani v podpoglavju 4.2.3.

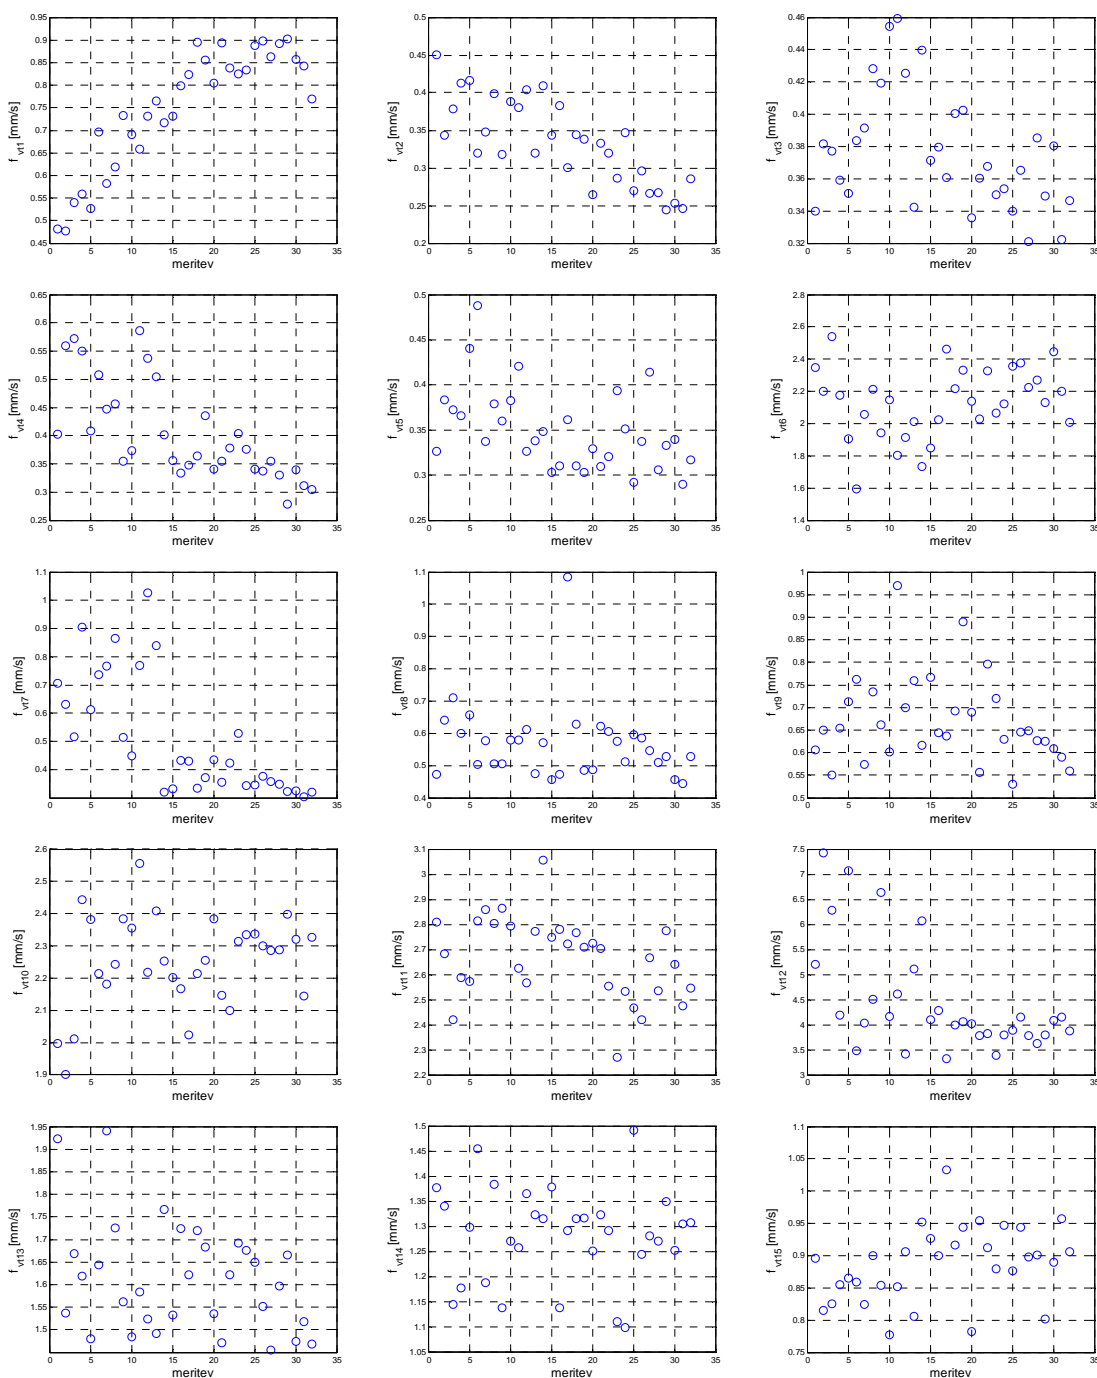
Na grafih slik 1, 2 in 3 so prikazane vrednosti značilk za vrednotenje vibracij na turbini v aksialni smeri ($f_{va1}, f_{va2}, \dots, f_{va15}$), vibracij na turbini v radialni smeri ($f_{vt1}, f_{vt2}, \dots, f_{vt15}$) in vibracij na ohišju v radiani smeri ($f_{vo1}, f_{vo2}, \dots, f_{vo15}$).

Prvi značilen vzorec, ki ga lahko opazimo pri nekaterih značilkah (npr.: $f_{va1}, f_{va2}, \dots, f_{va11}, f_{vt7}, f_{vt12}$ ali f_{vo2}), je zmanjšanje raztrosa po določenem času. Pri nekaterih značilkah (npr.: $f_{va12}, f_{vt1}, f_{vt2}, f_{vt4}, f_{vt7}, f_{vt12}, f_{vo6}$ ali f_{vo15}) pa lahko zaznamo trend naraščanja oziroma padanja. Omenjena vzorca se pogosteje pojavita pri značilkah, ki vrednotijo vibracije na turbini.

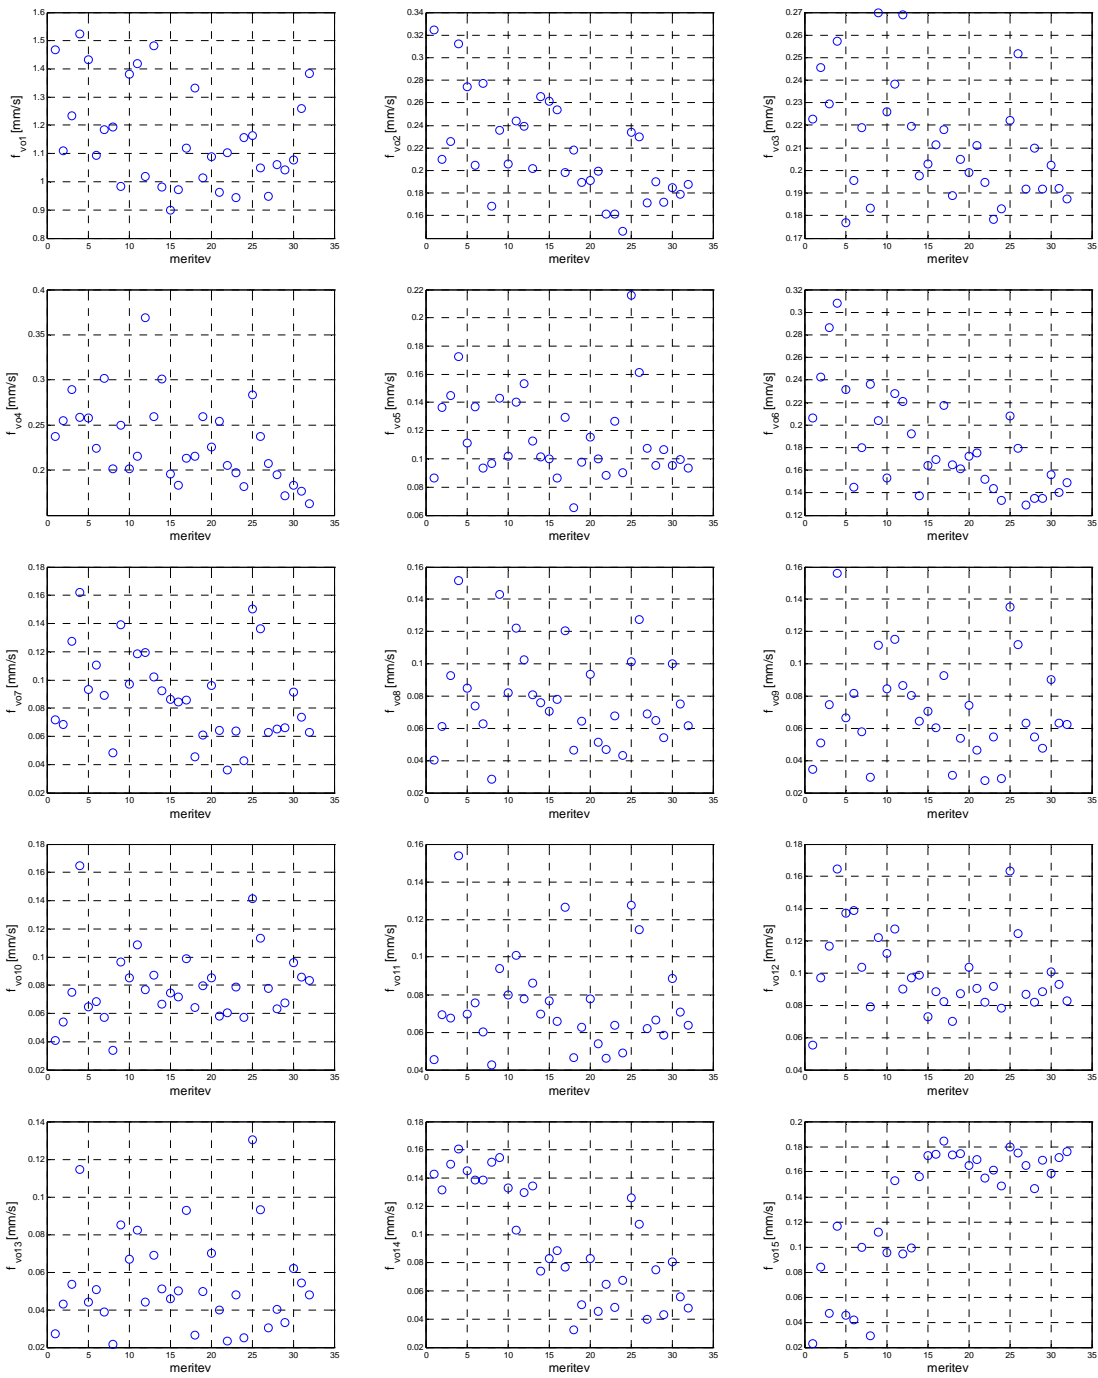
Pri značilkah f_{va1}, f_{vt1} in f_{vo1} dobimo zelo podobne rezultate kot pri značilkah f_{va}, f_{vt} in f_{vo} v podpoglavju 4.2.3. To je tudi razumljivo, saj frekvenčni pas, na katerem so definirane značilke f_{va1}, f_{vt1} in f_{vo1} , (od 0 do 1 kHz) vsebuje tudi komponento pri frekvenci vrtenja sesalne enote. Ta komponenta, ki odraža neuravnoteženosti vrtečih delov enote in zato predstavlja osnovo pri določanju značilk f_{va}, f_{vt} ter f_{vo} , pa v omenjenem frekvenčnem pasu prevladuje.



Slika 1: Ponovljivost značilnih vibracij na turbini v aksialni smeri ($f_{va1}, f_{va2}, \dots, f_{va15}$)



Slika 2: Ponovljivost značilnih vibracij na turbini v radialni smeri ($f_{vt1}, f_{vt2}, \dots, f_{vt15}$)



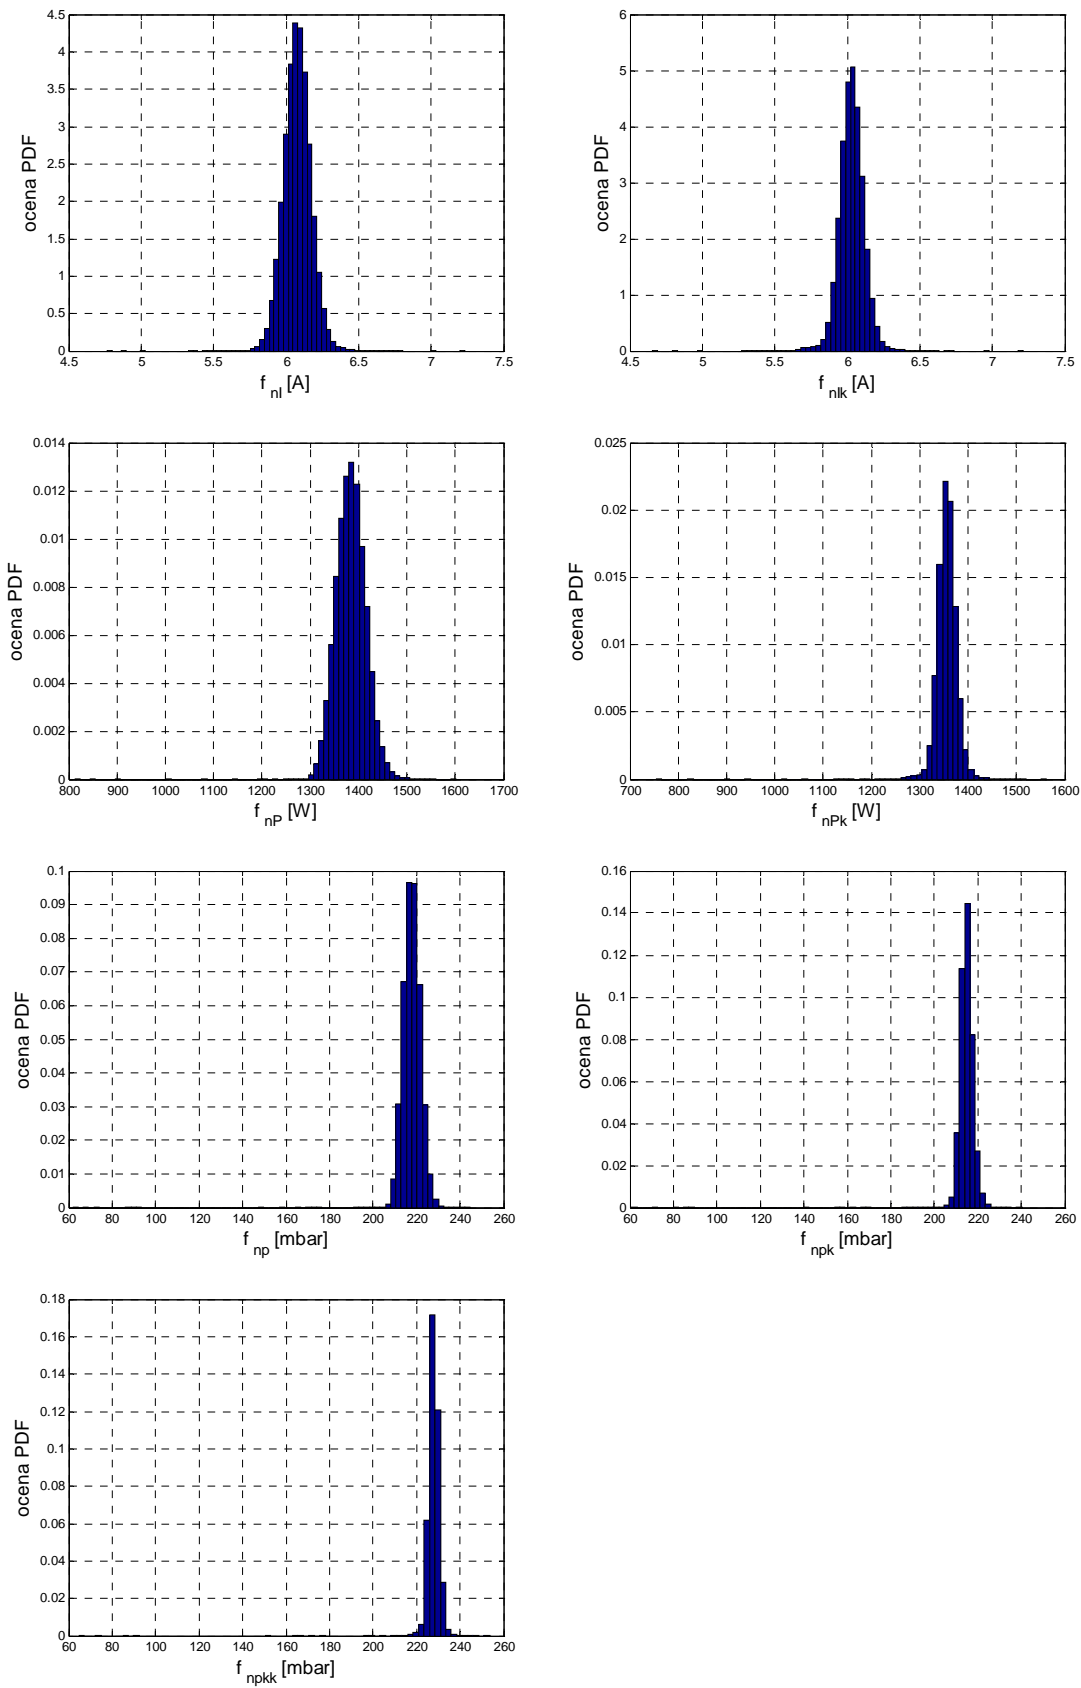
Slika 3: Ponovljivost značilik vibracij na ohišju v radiani smeri ($f_{vo1}, f_{vo2}, \dots, f_{vo15}$)

Dodatek D


Porazdelitve značilk

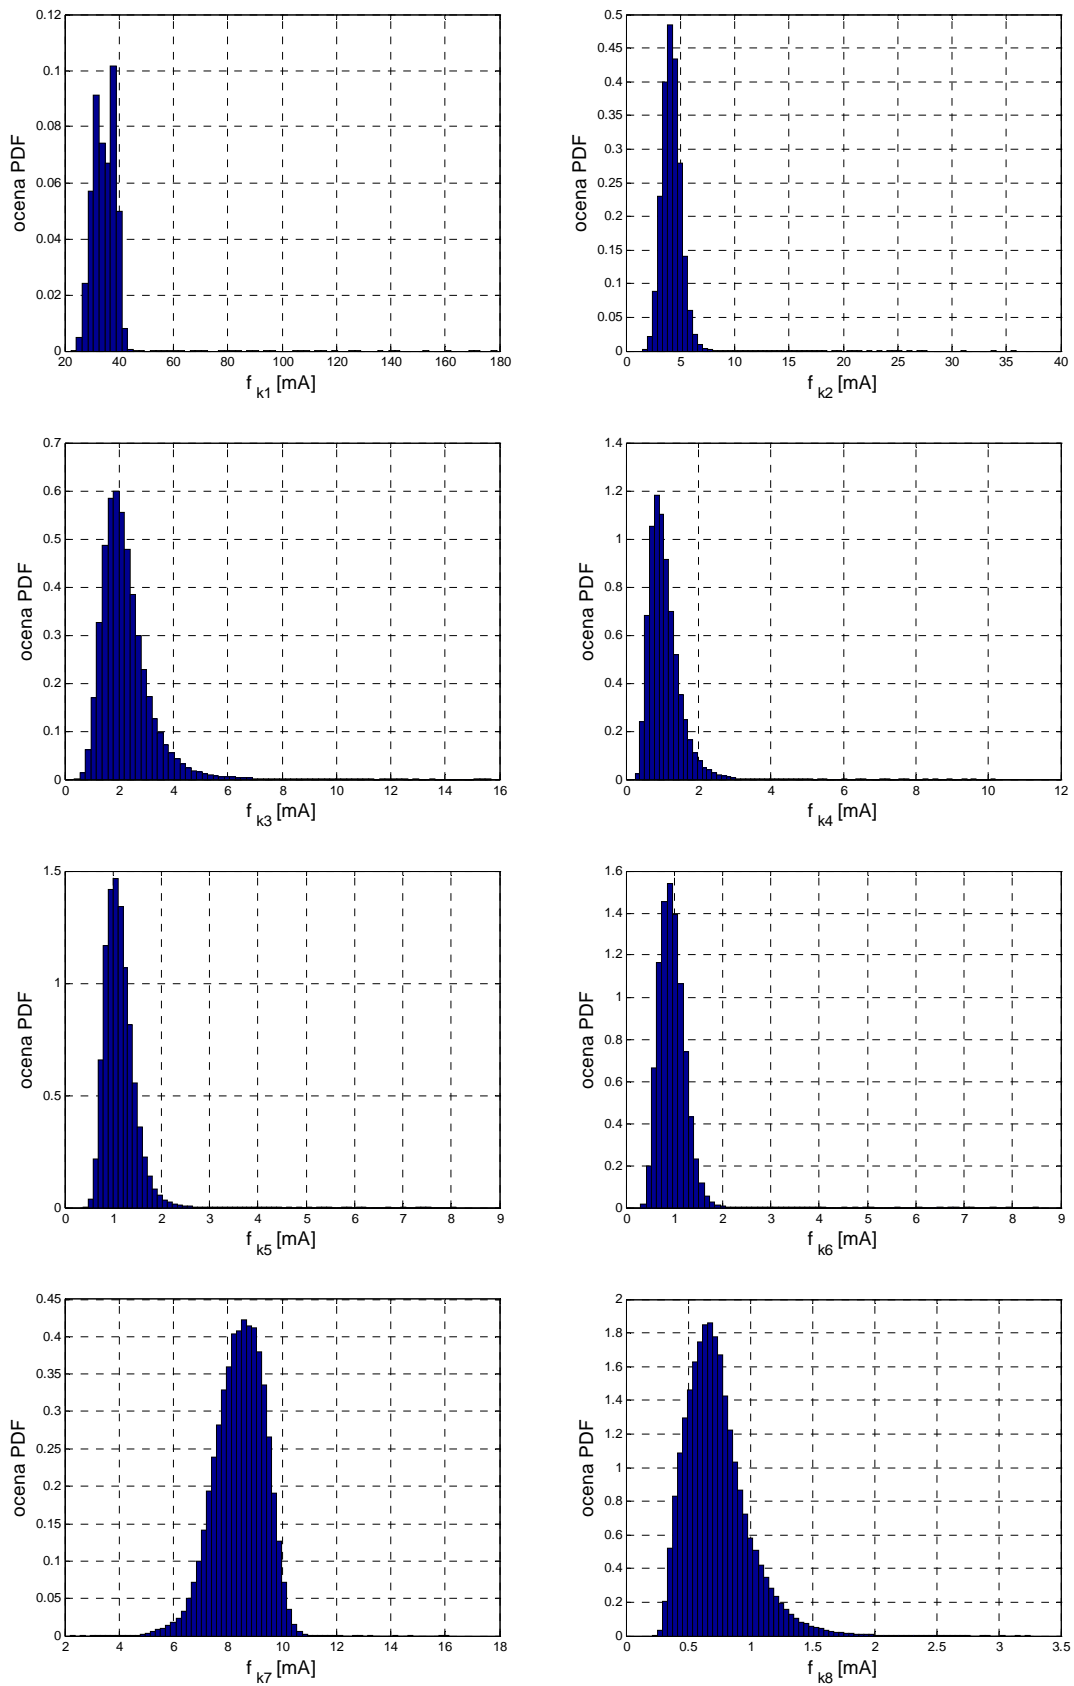
Kot ocene porazdelitev so na slikah od 1 do 12 prikazani histogrami značilk iz tabele 5.2, razen značilk f_{i2} , f_{va} , f_{vt} in f_{vo} . Porazdelitve slednjih so predstavljene v podpoglavju 5.1.2 na slikah 5.9 in 5.10. Histograme smo določili na podlagi podatkov, ki so bili pridobljeni pri končnem testiranju sesalnih enot na proizvodni liniji. Množica podatkov obsega 114233 vzorcev (rezultatov testiranja proizvedenih sesalnih enot).

Ob pregledu porazdelitev značilk prikazanih v tem dodatku opazimo dva značilna vzorca. Porazdelitve nekaterih značilk (npr. značilke nazivnih veličin, kvalitete komutacije in zvoka) so strnjene okrog določene vrednosti. Pri nekaterih izmed teh pa se pojavi tudi bolj ali manj izrazit t.i. dolgi rep. Drug značilen vzorec, tj. porazdelitev z dvema ali več izrazitimi vrhovi, lahko opazimo predvsem pri nekaterih značilkah vibracij. Ta je posledica še nepoznanih sistematskih vzrokov. Ob tem je potrebno povedati, da omenjeni vrhovi ležijo znotraj dopustnih meja posameznih značilk.




Slika 1: Porazdelitev značilnik nazivnih veličin: f_{nI} , f_{nIk} , f_{nP} , f_{nPk} , f_{np} , f_{nPk} , f_{nkk}

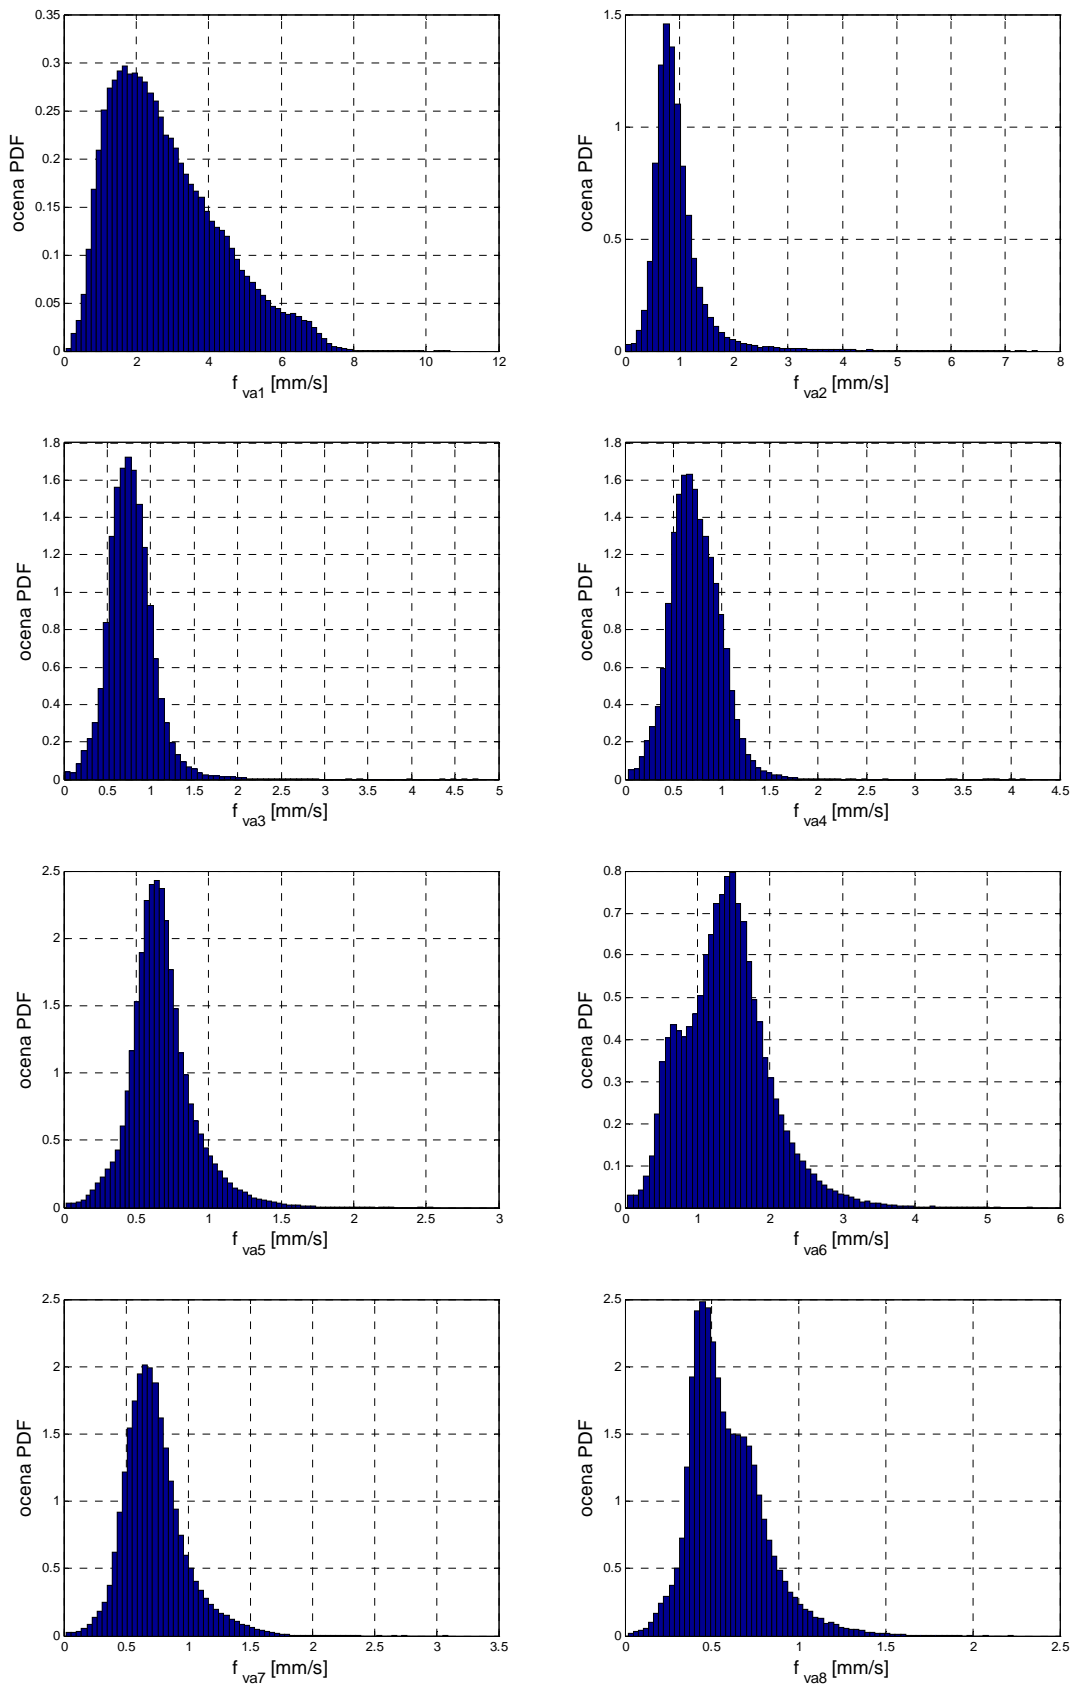
Slika 2: Porazdelitev značilk nazivnih veličin: f_{nv} , f_{nvk}



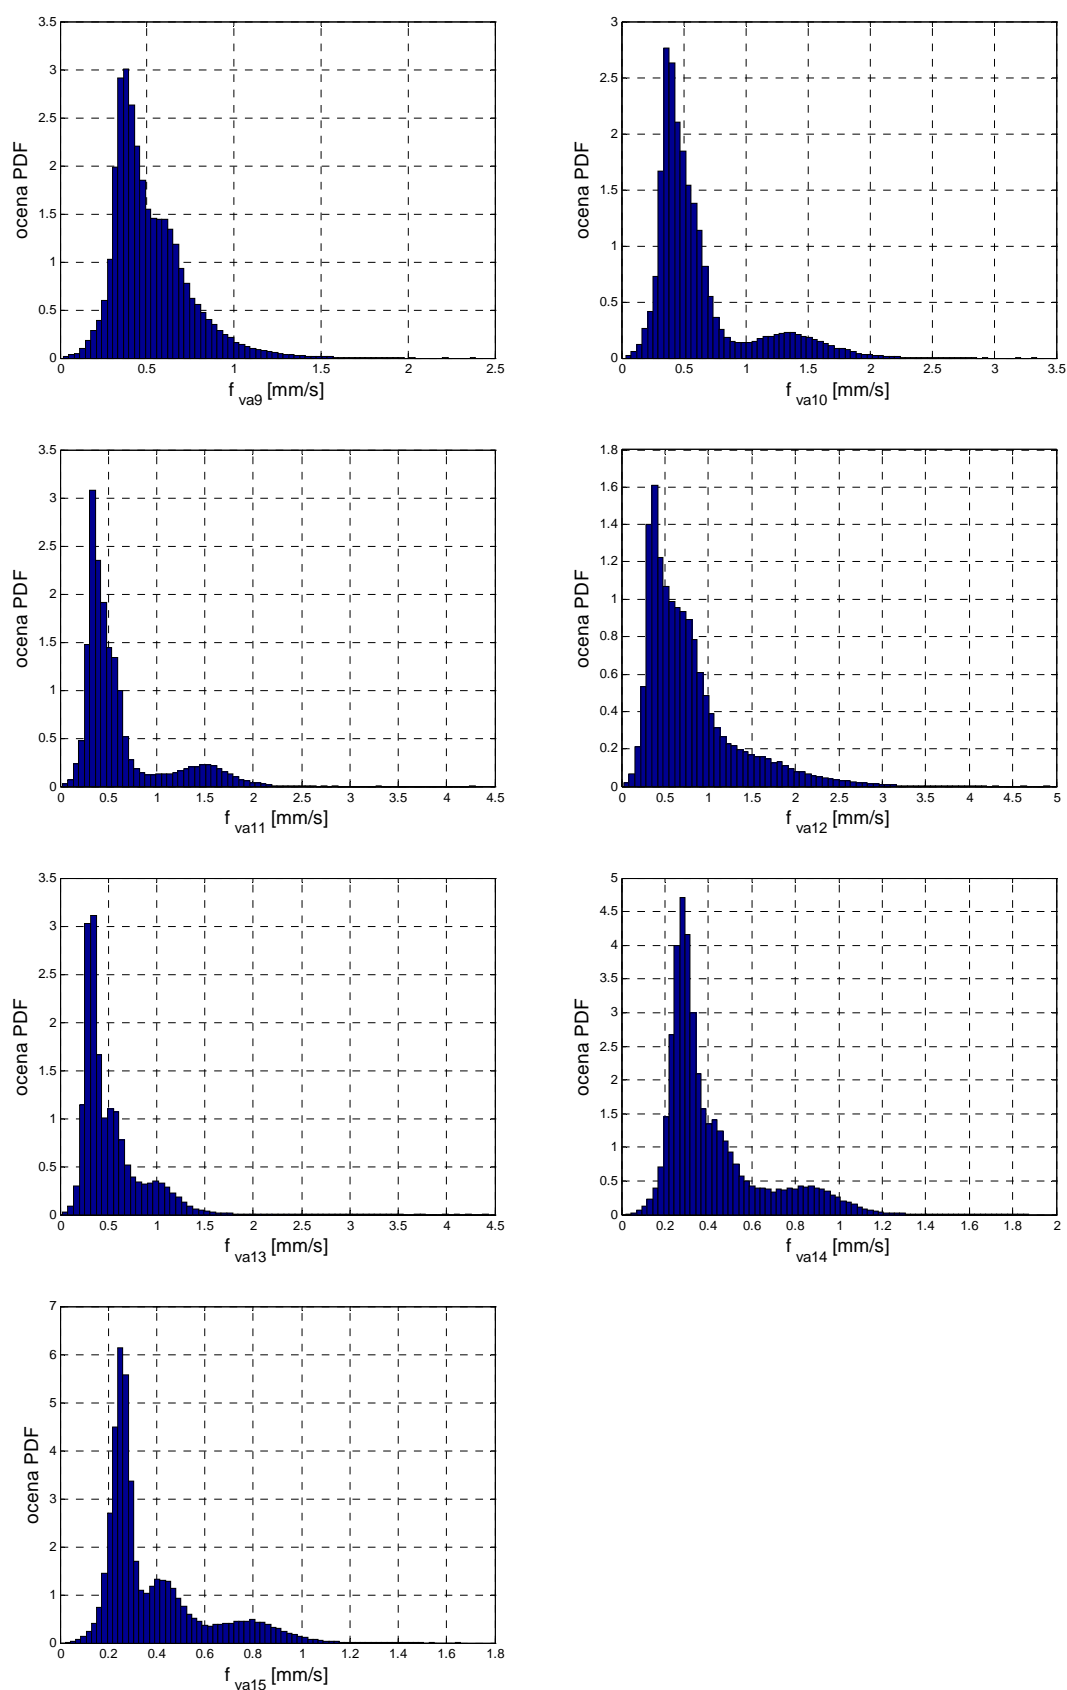
Slika 3: Porazdelitev značilk kvalitete komutacije: $f_{k1}, f_{k2}, \dots, f_{k8}$



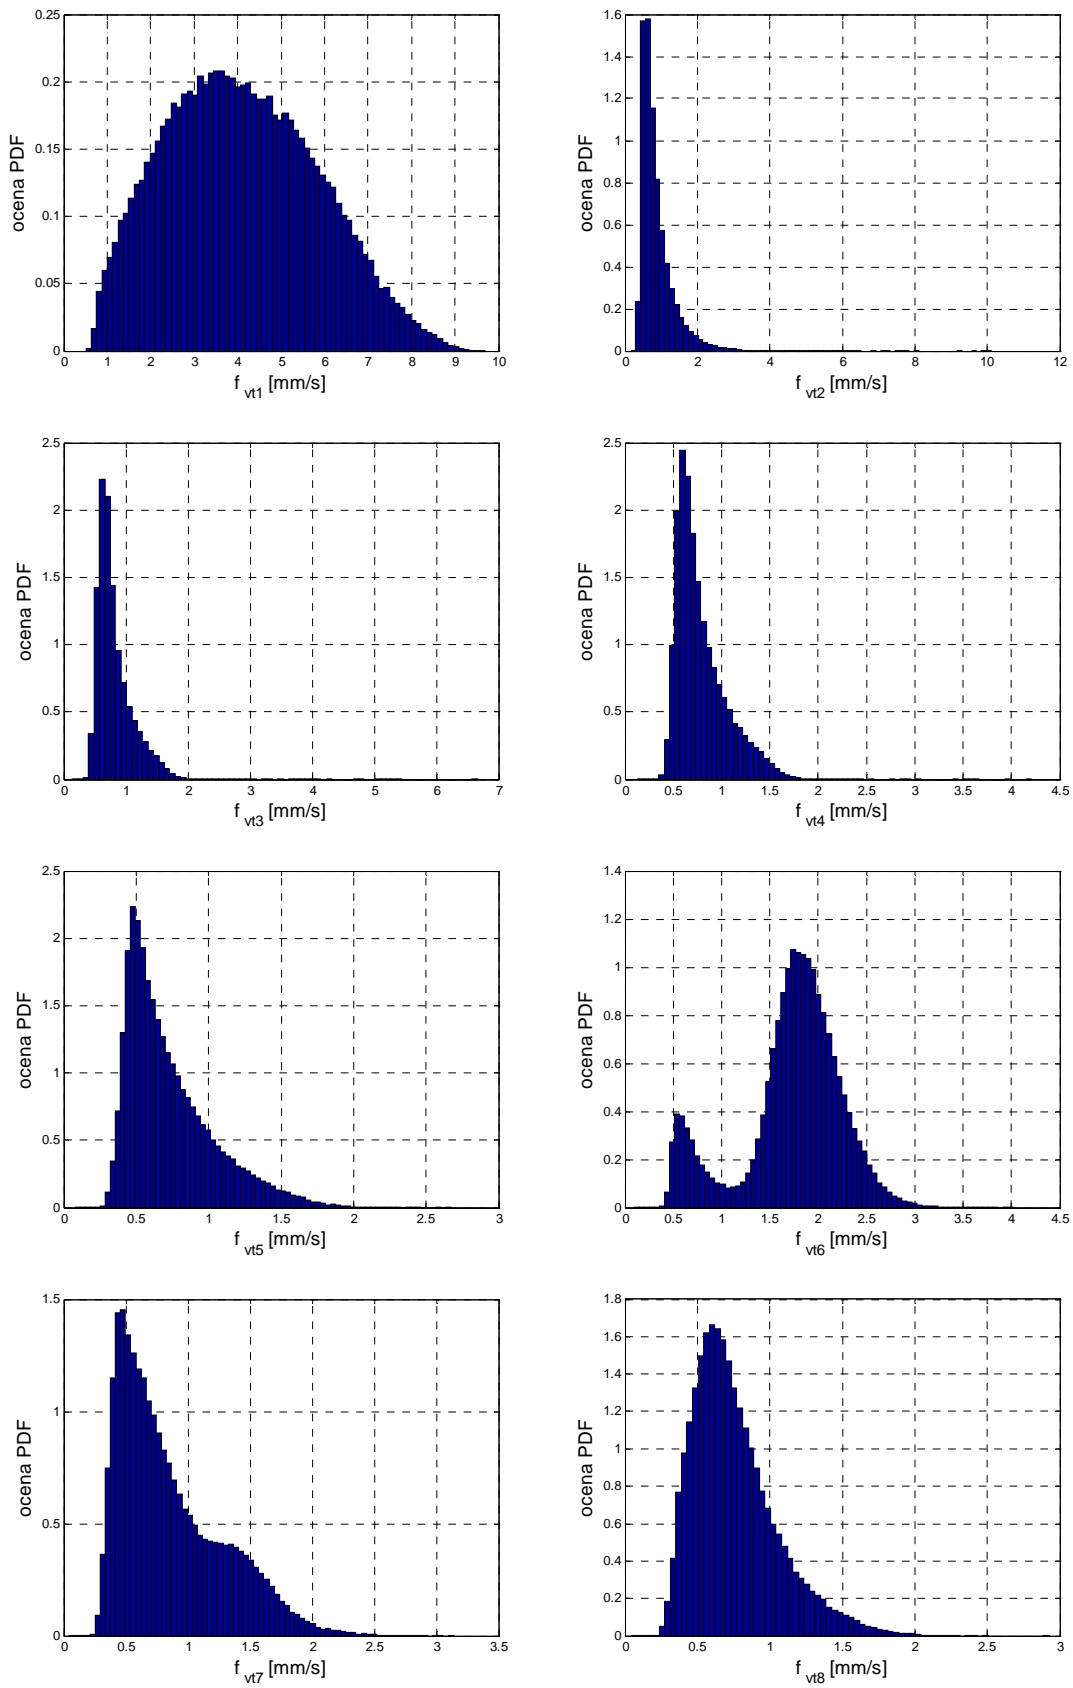
Slika 4: Porazdelitev značilk kvalitete komutacije: f_{k9} , f_{k10} , f_{k11} , f_{k12} , f_{i1}



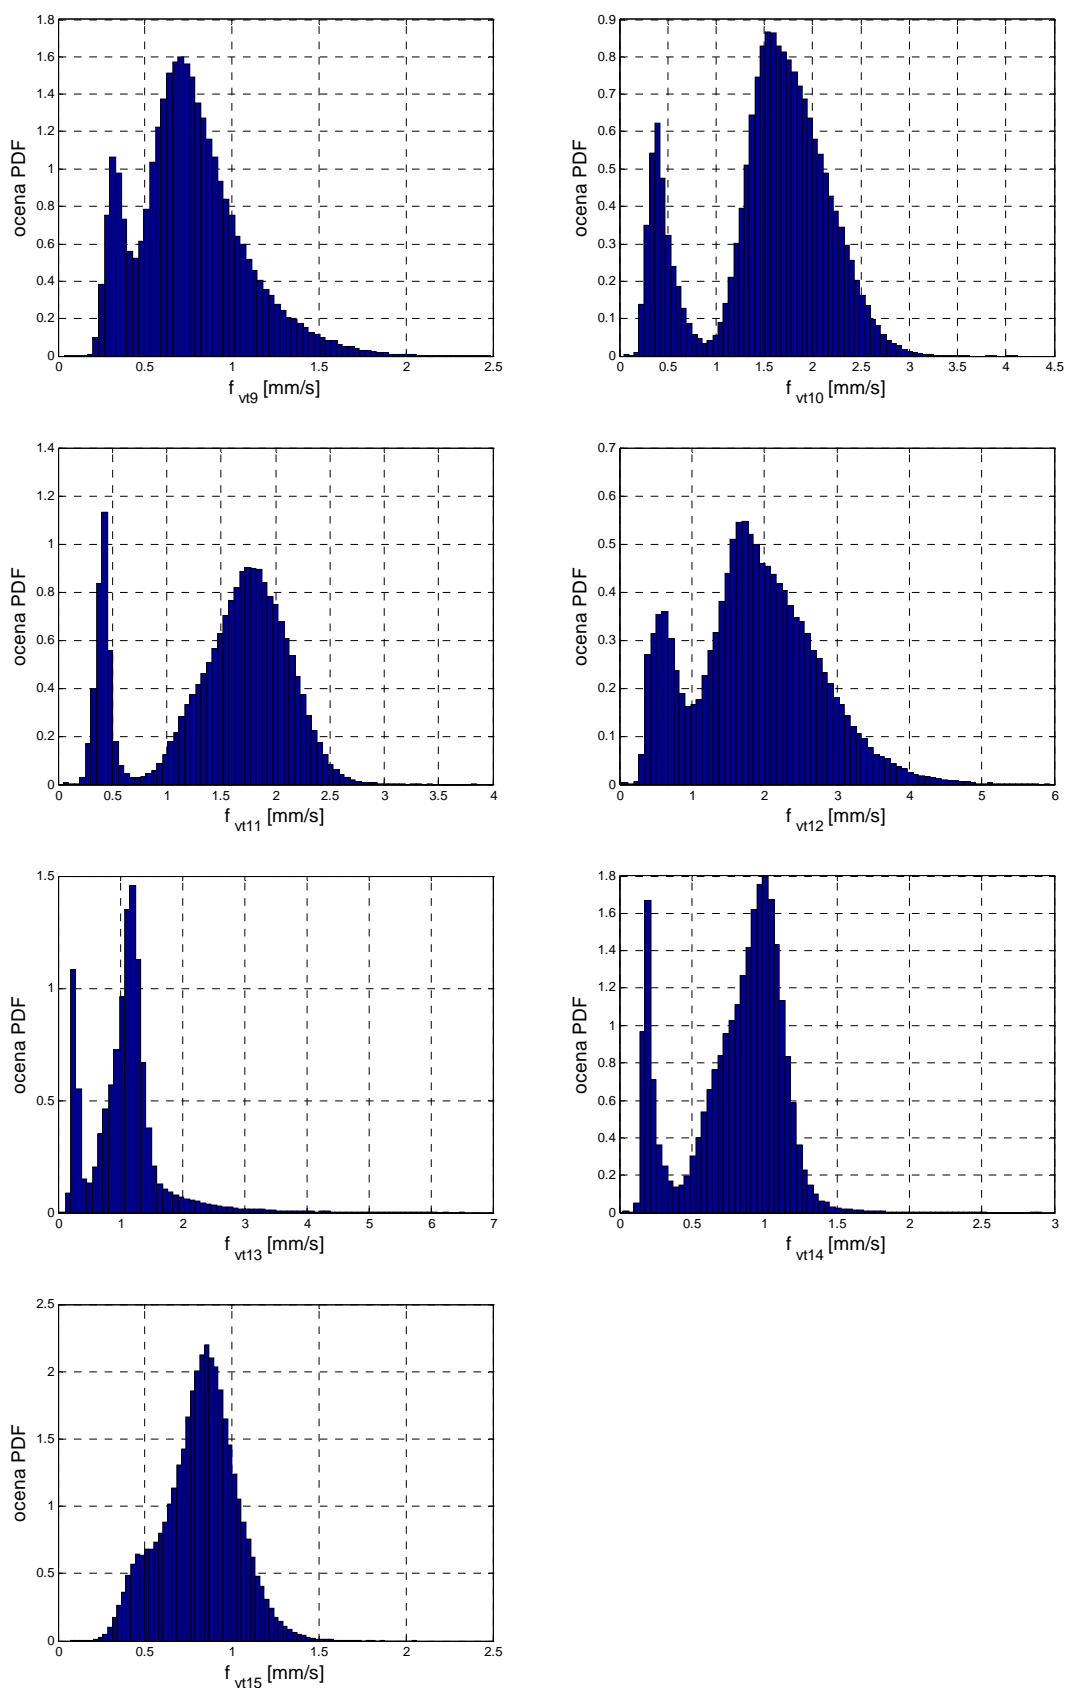
Slika 5: Porazdelitev značilk vibracij: $f_{va1}, f_{va2}, \dots, f_{va8}$



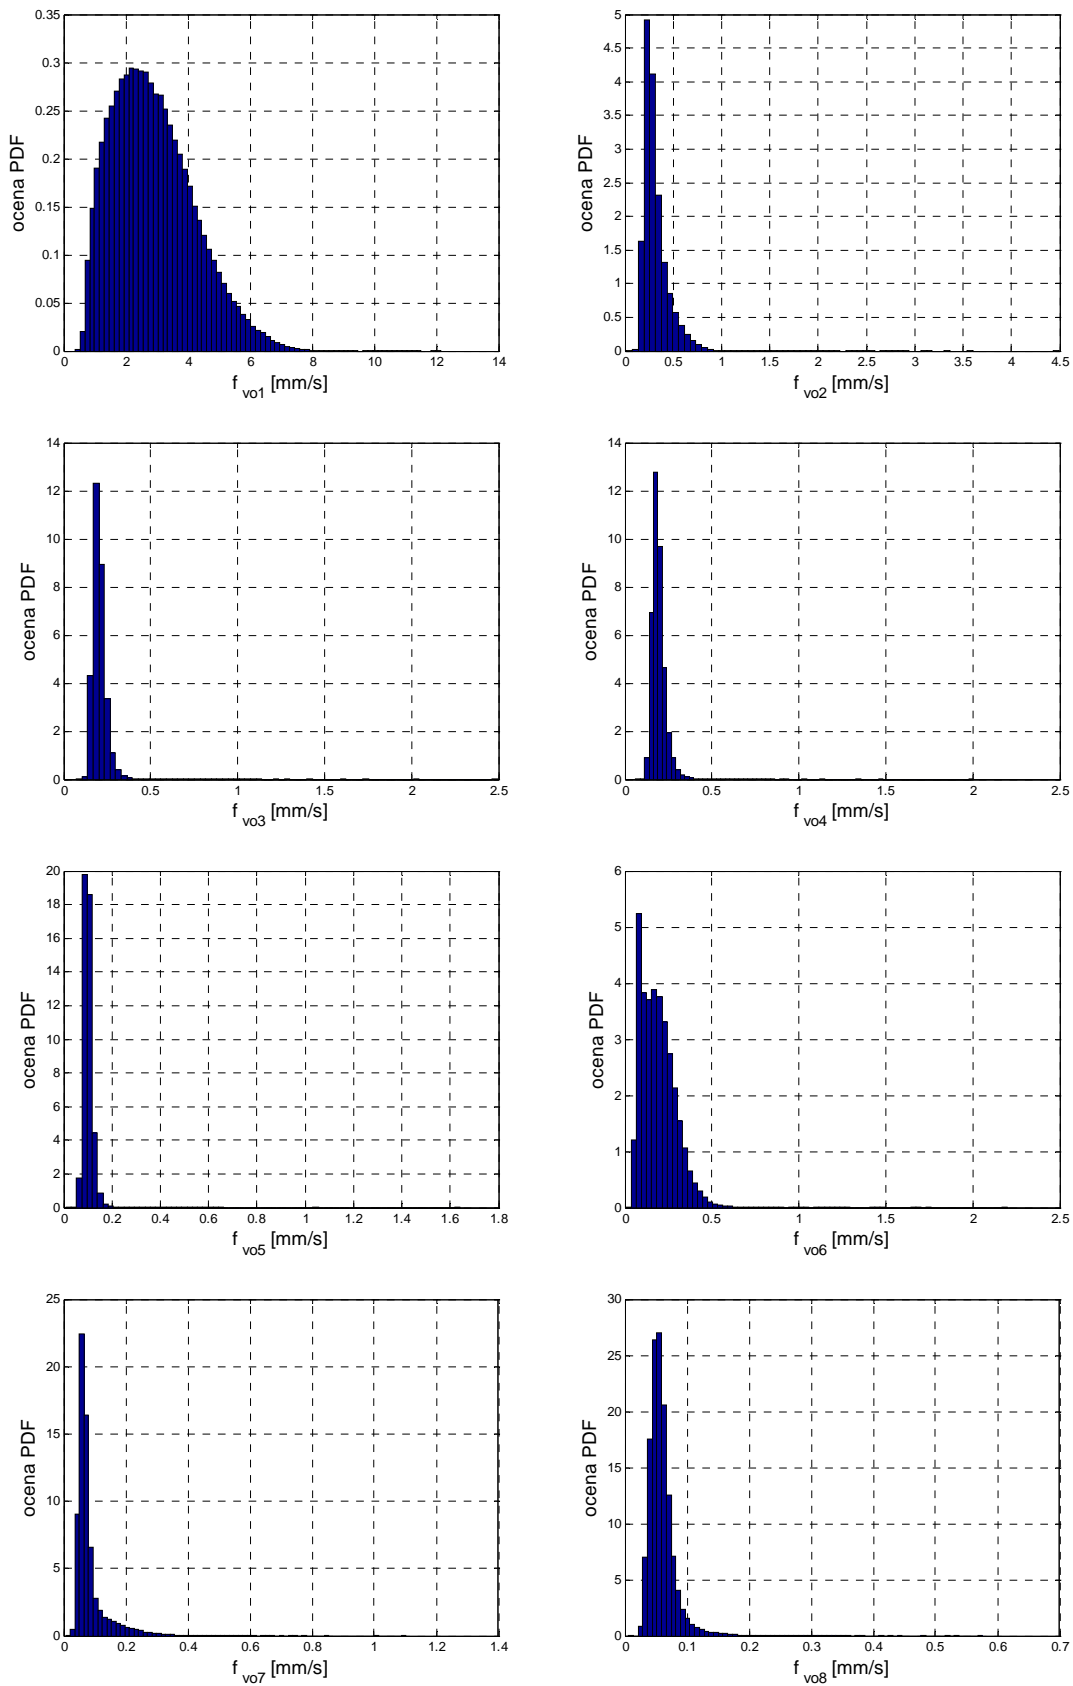
Slika 6: Porazdelitev značilik vibracij: $f_{va9}, f_{va10}, \dots, f_{va15}$



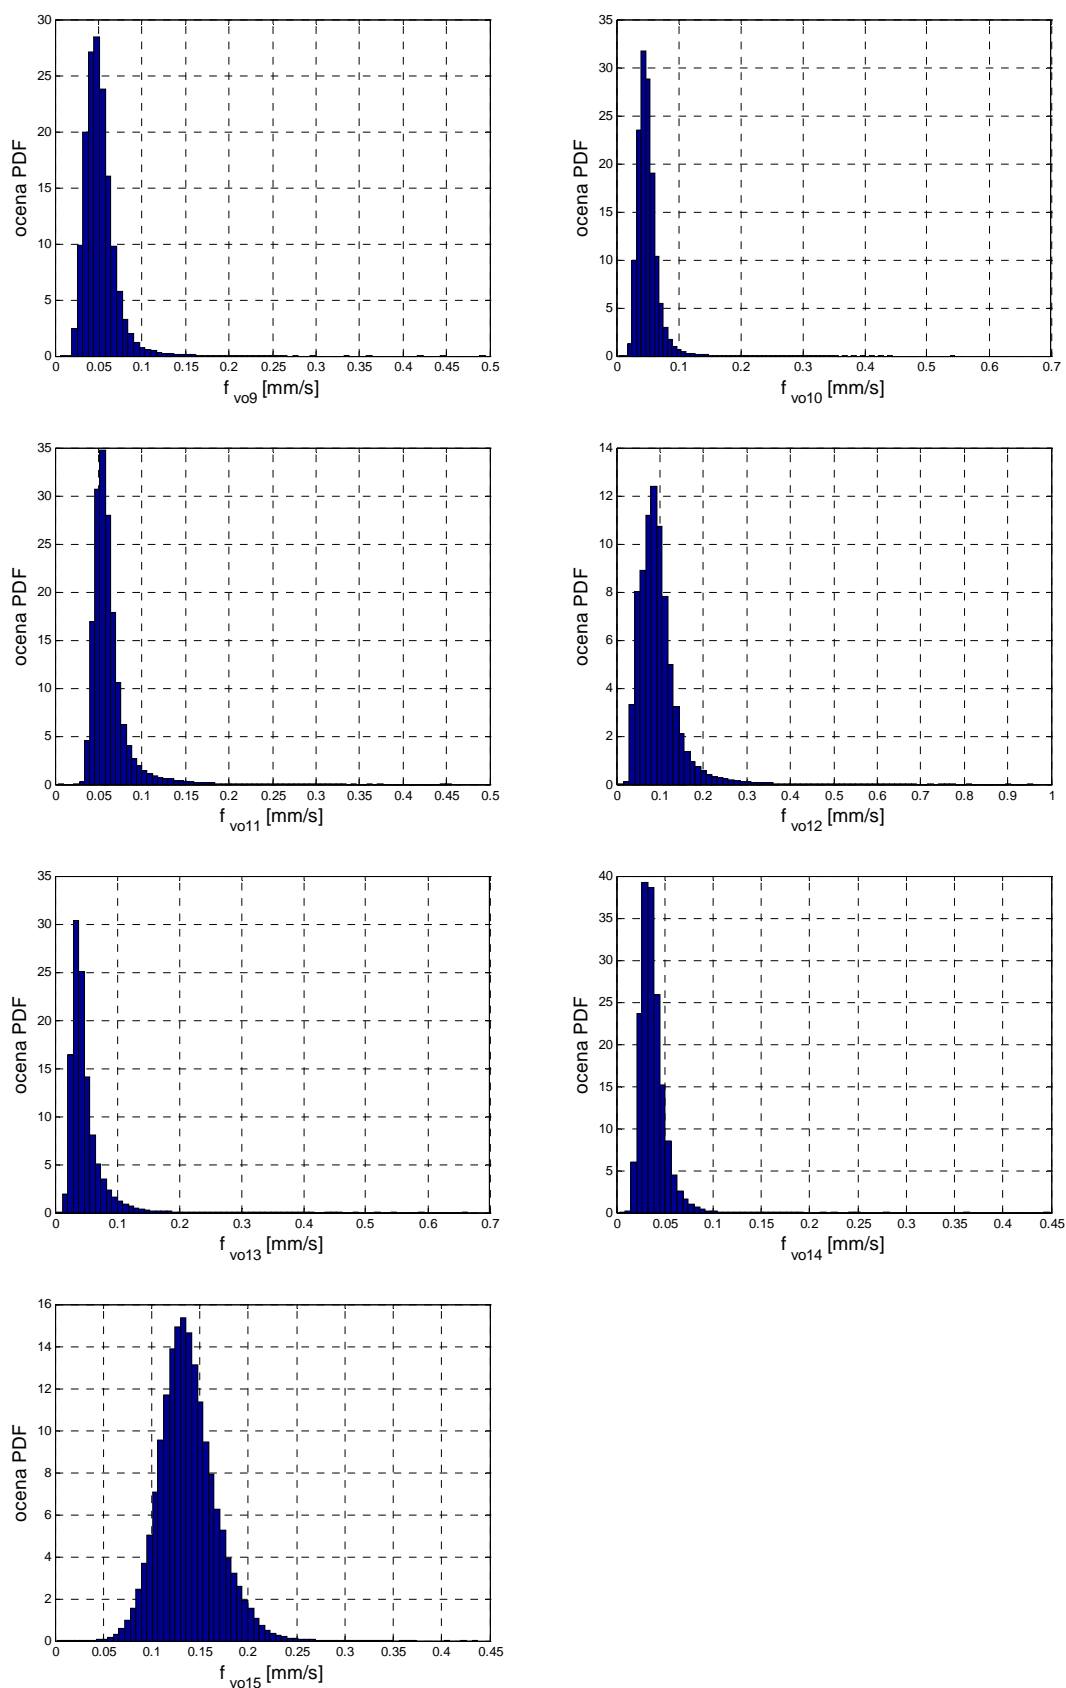
Slika 7: Porazdelitev značilik vibracij: $f_{vt1}, f_{vt2}, \dots, f_{vt8}$




Slika 8: Porazdelitev značilnik vibracij: $f_{vt9}, f_{vt10}, \dots, f_{vt15}$




Slika 9: Porazdelitev značilk vibracij: $f_{vo1}, f_{vo2}, \dots, f_{vo8}$



Slika 10: Porazdelitev značilik vibracij: $f_{vo9}, f_{vo10}, \dots, f_{vo15}$



Slika 11: Porazdelitev značilk zvoka (drgnjenje): f_{zd1}, f_{zd2}



Slika 12: Porazdelitev značilk zvoka (napaka na ležaju): $f_{zl1}, f_{zl2}, f_{zl3}, f_{zl4}$

Dodatek E

Primeri porazdelitev z dolgimi repi

V tem dodatku so predstavljeni trije tipični primeri porazdelitev z dolgimi repi in sicer Pareto porazdelitev, log-normalna porazdelitev ter eksponentna porazdelitev.

Pareto porazdelitev


Funkcija gostote verjetnosti (*pdf*) in kumulativna porazdelitvena funkcija (*cdf*) Pareto porazdelitve sta definirani z naslednjima enačbama:

$$pdf = \frac{kx_m^k}{x^{k+1}} \quad (1)$$

in

$$cdf = 1 - \left(\frac{x_m}{x}\right)^k \quad (2)$$

kjer sta x_m parameter pozicije ter k parameter oblike. Funkcija gostote verjetnosti obravnavane porazdelitve je za $x_m = 1$ in različne vrednosti parametra k prikazana na sliki 1.



Slika 1: PDF Pareto porazdelitve ($x_m = 1, k = 0.5, 1, 2, 3$)

Log-normalna porazdelitev

Pri log-normalni porazdelitvi sta funkcija gostote verjetnosti (*pdf*) in kumulativna porazdelitvena funkcija (*cdf*) definirani z naslednjima enačbama:

$$pdf = \frac{1}{x\sigma\sqrt{2\pi}} e^{-(\ln x - \mu)^2 / 2\sigma^2} \quad (3)$$


in

$$cdf = \frac{1}{2} + \frac{1}{2} \operatorname{Erf}\left(\frac{\ln x - \mu}{\sigma\sqrt{2}}\right) \quad (4)$$

kjer je

$$\operatorname{Erf}(z) = \frac{2}{\sqrt{\pi}} \int_0^z e^{-t^2} dt \quad (5)$$

μ in σ pa sta pričakovana vrednost in standardna deviacija logaritma naključne spremenljivke x . Slika 2 prikazuje funkcijo gostote verjetnosti log-normalne porazdelitve pri $\mu = 0$ in različnih vrednostih parametra σ .



Slika 2: PDF log-normalne porazdelitve ($\mu = 0$, $\sigma = 0.25, 0.5, 1, 1.5$)

EkspONENTNA PORAZDELITEV


Funkcija gostote verjetnosti (*pdf*) in kumulativna porazdelitvena funkcija (*cdf*) pri eksponentni porazdelitvi sta:

$$pdf = \lambda e^{-\lambda x} \quad (6)$$

in

$$cdf = 1 - e^{-\lambda x} \quad (7)$$

Za različne vrednosti parametra razmerja λ je funkcija gostote verjetnosti eksponentne porazdelitve prikazana na sliki 3.



Slika 3: PDF eksponentne porazdelitve ($\lambda = 0.5, 1, 1.5, 2$)

Izjava

Izjavljam, da sem doktorsko disertacijo izdelal samostojno pod vodstvom mentorja doc. dr. Đanija Juričiča. Izkazano pomoč ostalih sodelavcev sem v celoti navedel v zahvali.

Ljubljana, 2006

mag. Dejan Tinta