

KAUNO TECHNOLOGIJOS UNIVERSITETAS

JUSTINAS TILINDIS

**GAMYBOS NAŠUMO OPTIMIZAVIMAS
MODELIUOJANT RANKINIUS SURINKIMO
PROCESUS**

Daktaro disertacijos santrauka
Technologijos mokslai, mechanikos inžinerija (09T)

Kaunas, 2016

Disertacija rengta 2011–2015 metais Kauno technologijos universiteto, Panevėžio technologijų ir verslo fakultete, Technologijų katedroje.

Mokslinis vadovas:

Prof. dr. Vytautas KLEIZA (Kauno technologijos universitetas, technologijos mokslai, mechanikos inžinerija – 09T).

Mechanikos inžinerijos mokslo krypties disertacijos gynimo taryba:

Doc. dr. Giedrius JANUŠAS (Kauno technologijos universitetas, technologijos mokslai, mechanikos inžinerija – 09T) – **pirmininkas**

Prof. dr. Rimvydas GAIDYS (Kauno technologijos universitetas, technologijos mokslai, mechanikos inžinerija – 09T);

Prof. dr. Volodymyr HUTSAYLYUK (Karinis technologijos universitetas, technologijos mokslai, mechanikos inžinerija – 09T);

Prof. dr. Artūras ŠTIKONAS (Vilniaus universitetas, fiziniai mokslai, informatika – 09P).

Kalbos redaktorius

Virginija Stankevičienė

Disertacija bus ginama viešame Mechanikos inžinerijos mokslo krypties tarybos posėdyje 2016 m. birželio 9 d. 13 val. Kauno technologijos universitete, centrinių rūmų disertacijų gynimo salėje.

Adresas: K. Donelaičio g. 73-403, LT-44249 Kaunas. Tel. (+370) 37 300042, faksas (+370) 37 324144, el. paštas doktorantura@ktu.lt

Disertacijos santrauka išsiųsta 2016 m. gegužės 9 d.

Su disertacija galima susipažinti internete (adresu <http://ktu.edu>), Kauno technologijos universiteto (K. Donelaičio g. 20, Kaunas) ir Aleksandro Stulginskio universiteto (Studentų g. 11, Akademija, Kauno raj.) bibliotekose.

KAUNAS UNIVERSITY OF TECHNOLOGY

JUSTINAS TILINDIS

**PRODUCTION EFFICIENCY OPTIMIZATION BY
MODELLING MANUAL ASSEMBLY PROCESSES**

Summary of Doctoral Dissertation
Technological Science, Mechanical Engineering (09T)

Kaunas, 2016

Dissertation was prepared between 2011–2015 at the Department of technologies of Kaunas University of Technology, Panevėžys Faculty of Technologies and Business.

Scientific supervisor:

Prof. Dr. Vytautas KLEIZA (Kaunas University of Technology, Technological Sciences, Mechanical Engineering – 09T).

Dissertation Defense Board of Mechanical Engineering Science Field:

Doc. Dr. Giedrius JANUŠAS (Kaunas University of Technology, Technological Sciences, Mechanical Engineering – 09T) – **chairman**

Prof. Dr. Rimvydas GAIDYS (Kaunas University of Technology, Technological Sciences, Mechanical Engineering – 09T);

Prof. Dr. Volodymyr HUTSAYLYUK (Military University of Technology, Technological Sciences, Mechanical Engineering – 09T);

Prof. Dr. Artūras ŠTIKONAS (Vilnius University, Physical Sciences, Informatics – 09P).

Language editor

Virginija Stankevičienė

The official defense of the dissertation will be held at 1 p.m. on 9th of June, 2016 at the public meeting of Mechanical Engineering Science Field Board in the Dissertation Defense Hall at the Central Building of Kaunas University of Technology.

Address: K. Donelaičio st. 73-403, LT-44249 Kaunas, Lithuania. Tel. (+370) 37 300042, fax (+370) 37 324144, e-mail: doktorantura@ktu.lt

The Summary of the Dissertation is send on 9th May, 2016.

The dissertation is available on the internet (<http://ktu.edu>) and at the libraries of Kaunas University of Technology (K. Donelaičio st. 20, Kaunas) and Aleksandras Stulginskis University (Studentų st. 11, 53361 Akademija, Kaunas dist.).

IVADAS

Rankinis surinkimas, kaip gamybos technologija, yra dažnai keičiamas robotizuotu surinkimu ar automatinėmis surinkimo linijomis, tačiau paminėtina tai, kad daugelyje gamybos sričių mechaninis žmogaus darbas yra neišvengiamas dėl įvairių priežasčių: darbo ir įrangos kainų, gamybos kiekių, operacijų sudėtingumo ir t. t. Nepaisant gamybos srities, dauguma surinkimo operacijų yra standartinės, o pagrindinis rodiklis, apibrėžiantis našumą bei galutinę operacijos kainą – operacijos laikas. Todėl vienas pagrindinių metodų procesams gerinti yra šių standartinių operacijų pertvarkymas bei pergrupavimas. Yra žinoma, kad surinkimo laikas priklauso ne tik nuo standartinių operacijų komplekto. Kadangi surinkimą atlieka žmogus, surinkimo laikas labai priklauso nuo kognityvinių faktorių, kitaip tariant mokymosi. Kai operatorius išmoksta operaciją ir pagerina savo darbo įgūdžius operacijos atlikimo trukmė laipsniškai mažėja. Toks surinkimo laiko mažėjimas matematiškai apibrėžiamas mokymosi (gali būti proceso ar progreso) kreive. Ši mažėjimo tendencija yra nustatyta gana seniai, tačiau pirmiausia ji buvo taikoma surinkimo laikui prognozuoti masinėje gamyboje. Tačiau masinėje gamyboje, mokymasis baigiamas pradinėje gamybos fazėje. Kalbant apie šiuolaikinės gamybos tendencijas, reikia paminėti, kad jos išsiskiria keliais svarbiais bruožais. Pirmiausia – tai yra masinės gamybos pasitraukimas ir masinės individualizacijos plitimas. Gamyboje tai reiškia mažus užsakymo kiekius, vis didėjančią gaminių įvairovę ir trumpesnę gaminio pateikimo klientui laiką. Todėl įmonėse, kuriose yra taikomas rankinis surinkimas, maži kiekiai, nevienodi gamybos užsakymai lemia tai, kad gamyba nuolat vyksta mokymosi fazėje, t. y. proceso kreivės pradžioje. Kitaip tariant, užsakymo kiekiai per maži, kad būtų visiškai išmoktos surinkimo operacijos. Todėl surinkimo laikas yra nevienodas, svyruojantis ir daug didesnis negu nustatytas standartinis proceso laikas. Taip pat, esami proceso kreivių modeliai, gali būti nepakankamai adekvatūs naujai gamybinei aplinkai. Tai yra pagrindinė priežastis, dėl kurios mokymosi tyrimai vėl tapo aktualūs gamybos inžinerijoje. Reikia paminėti, kad pastaruoju metu šia tema publikuojama nemažai straipsnių.

Šiame darbe analizuojama gamybos technologija: rankinis, mažomis partijomis vykdomas surinkimo procesas bei modeliuojamas pagrindinis šios technologijos indikatorius – *proceso laikas*. Kadangi surinkimo laikas tokioje gamybinėje aplinkoje yra stipriai veikiamas kognityvinių faktorių, mokymosi kreivės (toliau – MK) analizė ir modeliavimas yra šios disertacijos problematika. Siekiant patikrinti pasiūlytų modelių adekvatumą, jie buvo išbandyti rankinį surinkimą atliekančioje gamybinėje įmonėje.

Darbo tikslas –

modeliuojant rankinio surinkimo proceso parametrus optimizuoti (padidinti) jo našumą.

Darbo uždaviniai

1. Apibrėžti ir pasirinkti reikiamą tyrimo metodą.
2. Sukurti ir pritaikyti matematinius mokymosi modelius, adekvačiai aprašančius gamybos proceso laiko kitimą.
3. Sudaryti metodiką MK parametrų nustatyti iš ribotų gamybinių duomenų.
4. Apibrėžti, suformuluoti ir išspręsti rankinio surinkimo proceso našumo optimizavimo uždavinį, naudojantis darbe pasiūlytais MK modeliais.
5. Atlikti gamybinių duomenų matavimus ir jų pagrindu įvertinti pasiūlytų modelių adekvatumą.

Mokslinis naujumas

1. Sukurti nauji matematiniai MK modeliai.
2. Pasiūlytas naujas MK parametrų atstatymo metodas.
3. Kitų autorių atliktuose tyrimuose buvo siekiama tik apskaičiuoti ir prognozuoti mokymosi laiką. Šiame darbe pasiūlytas metodas jam sumažinti.

Praktinė svarba

Mažėjant užsakymų kiekiams ir didėjant produkcijos įvairovei bei mažėjant gaminio gyvavimo laikui, būtina mažinti gamybos procesų trukmę, kad būtų galima greičiau reaguoti į besikeičiančius vartotojų poreikius. Darbe išspręsta problema tiesiogiai susijusi su gamybos proceso trukmės mažinimu.

Ginamieji teiginiai

1. Sukurti ir pagrįsti nauji MK modeliai, visiškai tenkinantys bendrąsias MK savybes ir tiksliau aprašantys mokymosi procesus.
2. MK parametrai gali būti nustatomi naudojant deterministinius (ne statistinius) metodus.
3. Sudėtingo rankinio surinkimo proceso našumas didėja jį skaidant į tam tikrą (optimalų), paprastesnių procesų skaičių.

Disertacijos struktūra

Disertacija susideda iš įvado, 4 skyrių ir išvadų. Įvade pateikta darbo idėja ir motyvacija, tikslas, pagrindiniai uždaviniai, naujumas ir svarba, ginamieji teiginiai. Disertacijos pabaigoje pateiktas naudotos literatūros sąrašas, autoriaus publikacijų bei konferencijų sąrašai.

Disertacijos puslapių skaičius yra 118, numeruotų formulių skaičius – 179, paveikslų skaičius – 101, lentelių – 12. Naudotos literatūros sąrašą sudaro 134 šaltiniai.


1. NEAUTOMATIZUOTŲ GAMYBOS PROCESŲ MODELIAVIMO APŽVALGA

1.1. Operacijų ir proceso modeliavimas

Rankinis surinkimo procesas yra bene seniausias gamybos būdas, todėl jo modeliavimas yra išsamiai ištirtas. Kalbant apie rankinio surinkimo modeliavimą, reikia išskirti dvi pagrindines modeliavimo kryptis: surinkimo operacijų modeliavimą ir surinkimo proceso modeliavimą. Operacijų modeliavimo esmė yra tokia, kad reikia taip išdėstyti mechaninių surinkimo operacijų tvarką, kad surinkimo laikas būtų kuo trumpesnis. Dažnai tai yra susiję ir su gaminio dizaino pakeitimais siekiant sumažinti tam tikrų komponentų kiekių ar juos integruoti, taip paprastinant surinkimo procesą. Pagrindinis tikslas sumažinti galutinę kainą. Šiam tikslui pasiekti yra du būdai:

- didinti užsakymo kiekius (masinė gamyba);
- pakeisti, supaprastinti ar perprojektuoti surinkimo ir gamybos operacijas.

Kaip jau minėta, masinė gamyba laipsniškai yra pakeičiama masine individualizacija, todėl vienintelis, įmanomas būdas šiame kontekste didinti proceso efektyvumą ir mažinti galutinę kainą yra antrasis.



1.1 pav. DFMA taikymo rezultatai (Šaltinis: Boothroyd, Dewhurst, 2002)

Yra du standartiniai metodai šiam būdai realizuoti: gamybos ir surinkimo projektavimas (DFMA) ir vertės analizė / vertės inžinerija (VAVE). Šių priemonių esmė – iš naujo pertvarkyti esamo produkto gamybą, kad būtų sumažintas surinkimo laikas ir kaina. Tokio pertvarkymo pavyzdys pateiktas 1.1 paveiksle. Šiame pavyzdyje pertvarkyto gaminio surinkimo laikas buvo sumažintas nuo 160 iki 46 sekundžių.

Nors tam tikrais atvejais, operacijų modeliavimas duoda gana gerų rezultatų (kaip prieš tai pateiktame pavyzdyje), tačiau daug didesnę įtaką efektyvumui ir

galutiniam surinkimo laikui turi proceso modeliavimas. Taip yra todėl, kad net ir efektyviai surenkamo gaminio surinkimą, gali išžesti neteisingai parinktas technologinis surinkimo procesas. Šiuo metu egzistuoja daugybė įvairių surinkimo technologijų: surinkimo linija vienam gaminiui, surinkimo linija keletui gaminių, U formos surinkimo linija, surinkimo stotelių tinklas ir pan. Tinkamo proceso parinkimas organizuojant gamybą yra labai svarbus sprendimas, kuris dažniausiai priimamas remiantis šiais faktoriais: planuojamas gamybos kiekis, dabartinė gamybos situacija, turima patirtis bei skaičiavimai ir prielaidos. Skaičiavimai turėtų padėti nuspręsti, koks surinkimo tipas turėtų būti taikomas (lygiagretus, nuoseklus ar pan.) ir kiek surinkimo darbo vietų turėtų būti projektuojama. Nors literatūroje yra pasiūlyta analitinių metodų šiems skaičiavimams atlikti (Abdullah *ir kt.*, 2003), tačiau šie metodai nėra efektyvūs esant nestabiliui, mokymosi faktorių iškreiptai gamybos situacijai (t. y. tokiai, kuri yra nagrinėjama šioje disertacijoje), todėl yra akivaizdus metodų, sprendžiančių procesų kaštų mažinimą, esant nestabiliui gamybai, poreikis. Tai gali būti realizuojama taikant proceso kreives modeliavimą.

1.2. MK ir jų taikymas

Surinkimo laikas laipsniškai mažėja, kai surinkimo ciklas kartojamas. Matematiškai šis ciklo numerio ir surinkimo laiko ryšys apibrėžiamas tam tikra funkcija – laipsnine kreive, kuri apibrėžia surinkimo laiko (ar kainos) mažėjimą su kiekviena pakartota operacija. Šis fenomenas pirmą kartą buvo paminėtas Wright'o (Wright, 1936), kuris išanalizavo surinkimo laiko trukmę lėktuvams. Po šios publikacijos, MK tapo svarbus įrankis gamybos inžinerijoje ir buvo pradėtas taikyti gamybos kaštų prognozėms, našumo ir efektyvumo analizei ir kontrolei ne tik individualiems žmonėms, bet grupėms bei organizacijoms. Be to, toks taikymas iš gamybos išplito į šias sritis, pvz.: sveikatos priežiūrą, karybą ir karo pramonę, mokslo ir studijų įstaigas ir kitas sritis. Tačiau reikia paminėti, kad, gamyba (ypač rankinis surinkimas) yra ta sritis, kurioje MK taikomos plačiausiai.

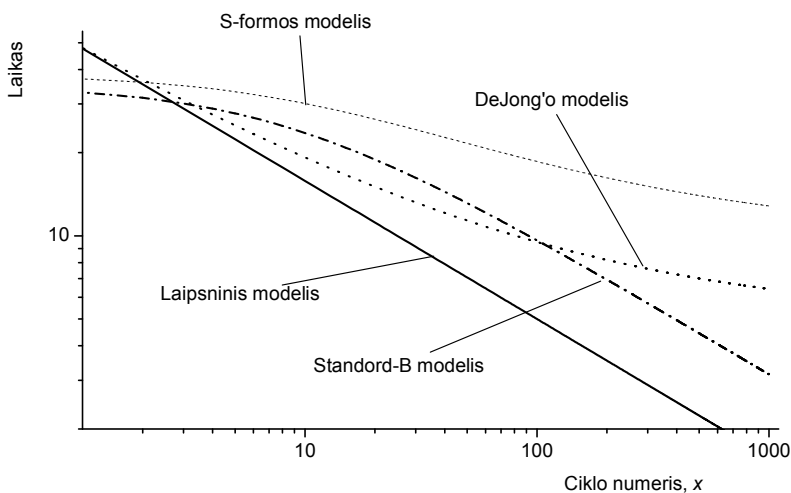
Pradžioje MK buvo naudojamos nuspėti ir prognozuoti gamybos kaštų mažėjimą didėjant užsakymo kiekiams (Bevis *ir kt.*, 1970). Kaip jau minėta, užsakymo kiekių mažėjimas lemia, kad surinkimas vyksta MK pradžioje, t. y. surinkimo operatorius taip ir „neišmoksta“ savo atliekamos operacijos, nes produkcijos kiekis yra tiesiog per mažas. Taigi mokymosi laikas, kuris gali būti apskaičiuojamas naudojant MK, sudaro didžiąją dalį gaminio surinkimo laiko, todėl tai atveria naują proceso kreivių taikymo gamyboje galimybę, kuri pastaruoju metu gan aktyviai tiriama mokslinėje literatūroje (Fogliato, Anzanello, 2011). MK taikomos gamybai optimizuoti, (Kumar, Goswami 2015), planuoti (Gabel, Riedmiller, 2012), gamybos svyravimams sinchronizuoti (Glock *ir kt.*, 2012). Reikia paminėti, kad minėtuose tyrimuose, mokymosi laikas yra

tiesiog įskaičiuojamas, tačiau nėra laikomas faktoriumi, kuris galėtų būtų mažinamas.

Literatūroje pateikta daug įvairių MK. Wright'as pasiūlė (Wright, 1936) laipsninę funkciją, kuri yra dažniausiai taikoma mokymuisi apibrėžti:

$$y(x) \equiv f(x, \alpha, \beta) = \beta x^{-\alpha}, \quad (1.1)$$

kur $y(x)$ – vienetinis x -tojo gaminio surinkimo laikas (C modelis) arba x gaminių surinkimo laiko vidurkis (W modelis), α – mokymosi parametras, β – laikas pirmajam gaminiui surinkti ($\beta = x_1^\alpha y_1$, jei $x_1 = 1, \beta = y_1$). Nors laipsninė funkcija yra bene pati populiariausia iš visų naudojamų proceso kreivių, tačiau yra ir kitų, specializuotų kreivių (Heizer, Render, 2006). Įvairių kreivių iliustracijos pateiktos 1.2 paveiksle.



1.2 pav. Įvairūs MK modeliai log-log skalėje.

Logaritmė skalė padeda stebėti akivaizdžius skirtumus, esančius tarp skirtingų modelių. Laipsninis modelis yra pats paprasčiausias, tai tiesė 1.2 paveiksle. Sudėtingesni modeliai – tai kreivės, todėl jų taikymas realioje gamybos situacijoje yra gerokai sudėtingesnis. Reikia paminėti, kad dauguma pasiūlytų naujų modelių yra paremti laipsnine funkcija, tačiau naudoja daugiau papildomų parametru. Nors pateikiama ir kito tipo kreivių, tokių kaip hiperbolinė ar eksponentinė funkcijos, tačiau jos taikomos rečiau. Taikant MK realioje situacijoje, didesnis parametru skaičius kelia tam tikrų keblumų, kadangi šiuos parametrus nustatyti gana sudėtinga, ypač esant nestabiliai gamybos aplinkai.

Apibendrinant gamybos procesų MK modelius akivaizdu, kad jų dauguma yra pagrįsti stabilia, didelius užsakymo kiekius gaminančia gamybos sistema, todėl pastarieji gali būti nepakankamai adekvatūs naujoje gamybos aplinkoje, kuri yra nagrinėjama šioje disertacijoje.

1.3. Literatūros apžvalgos rezultatai ir išvados

Remiantis paskutinėmis tendencijomis gamyboje, galima išvelgti aiškų, negrįžtamą užsakymų kiekio mažėjimo ir produkcijos įvairovės augimo procesą. Automatizuotoje gamyboje egzistuoja daugybė įvairių priemonių šiai situacijai suvaldyti. Neautomatizuotame (rankiniame) surinkime, techninės priemonės, tokios kaip DFMA, VAVE ir kt. pasirodo nėra pajėgios suvaldyti surinkimo procese vykstantį mokymąsi. Todėl mokymosi faktorių ir proceso kreivių tyrimai iš naujo tapo aktualia gamybos inžinerijos tema.

Daug autorių pažymi sėkmingą MK pritaikymą. Dauguma modelių yra skirti dideliems gamybos kiekiams ir gali visiškai netikti didelės įvairovės gaminių gamybai, turinčiai mažus užsakymų kiekius. Taip pat paminėtina, kad dauguma pasiūlytų modelių yra specializuoti, todėl jų taikymas yra ribotas, ne universalus.

Pastaruoju metu nemažas dėmesys yra skiriamas ergonominiams faktoriams gamyboje, nes tai tiesiogiai turi įtaką surinkimo laikui ir našumui. Tačiau yra mažai mokslinių tyrimų, skirtų ergonominių faktorių, operacijos sudėtingumo ir surinkimo laiko integravimui, kas yra viena iš MK tyrimo spragų (Fogliato, Anzanello, 2011).

Daugumoje MK taikymų gamyboje, mokymosi laikas yra laikomas sudėtine proceso dalimi, nors realiai tai yra nereikalinga, nes tai yra pridėtinės vertės nekurianti operacija ir todėl ji turėtų būti eliminuojama ar bent sumažinama modeliuojant surinkimo procesą.

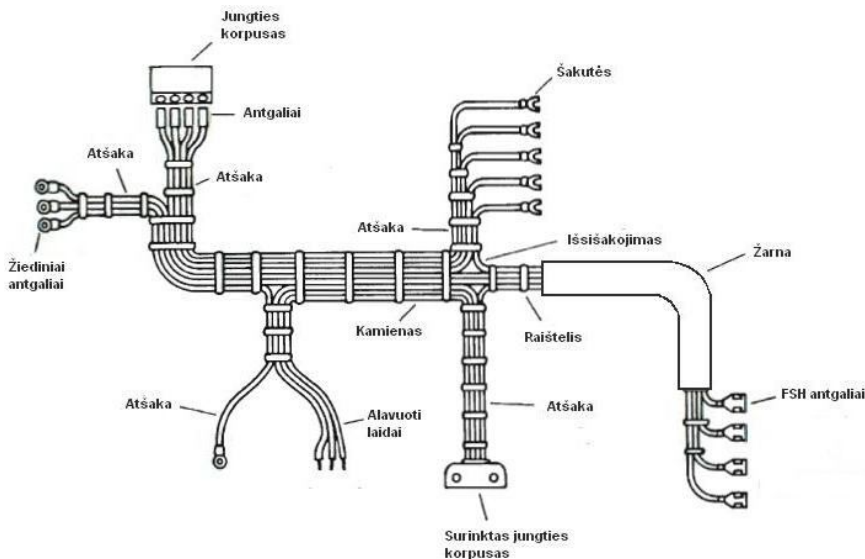
2. TYRIMŲ METODIKA

2.1. Rankinis elektros instaliacijos komponento – laidų pynės surinkimas

Elektros instaliacijos komponentų – laidų pynių surinkimas yra vienas iš daugiausiai laiko užimančių gamybos procesų. Surenkant pynes yra taikomos tiek standartinės surinkimo operacijos (įdėjimai, tvirtinimai, veržimai ir t. t.), tiek specifinės, tik šiai gamybos sričiai būdingos operacijos (laidų dėliojimai, vyniojimai ir pan.). Todėl tai yra išskirtinis ir pakankamai reprezentatyvus rankinio surinkimo būdas. Dėl tokio išskirtinumo, šis gaminių surinkimo būdas pasirinktas nagrinėti disertacijoje. Pynės atlieka elektrinės grandinės funkciją automobilyje, laive, autobuse, lėktuve ar buities įrenginyje, t. y. apjungia įvairius, tame įtaise naudojamus elektrinius komponentus. Nors pynės funkcija yra sujungti elektros grandinę, pats pynės surinkimas yra grynai mechaninis, rankinis, pusiau rankinis arba automatinis, priklausomai nuo gamybos užsakymo kiekio. Reikia paminėti, kad šiame darbe nagrinėjamas pusiau automatinis pynių

surinkimas, t. y. dalis operacijų (laidų karpymas ir antgalių montavimas), kurių viena dalis atliekama automatinio įrenginiu, o kita dalis atliekama rankiniu būdu (galutinis pynės surinkimas).

Remiantis pynės apibrėžimu (Boothroyd, Dewhurst 2002), pagrindiniai pynės komponentai yra laidai, kabeliai ir jungties korpusai. Visa reikalinga informacija (schema, ilgiai, komponentai ir t. t.) yra pateikiama pynės brėžinyje (žr. 2.1 pav.).



2.1 pav. Pynę sudarantys komponentai bei jų terminologija

Dažniausiai pynė sudaryta iš kamieno, per kurį pereina pagrindiniai, pynę sudarantys laidai. Iš pagrindinio kamieno atsišakoja įvairios atšakos, kurių pabaigoje gali būti montuojami palaidi antgaliai bei antgaliai, kurie vėliau montuojami į jungties korpusus ir pan. Pynės atšakų apsaugai ir sutvirtinimui gali būti naudojami raišteliai arba laidai, kurie gali būti perveriami per žarnas ar apvyniojami izoliacine juosta. Be šių, išvardintų komponentų, pynėse, priklausomai nuo jos tipo, gali pasitaikyti įvairiausių papildomų komponentų: nestandartinių dalių ir pan.

Pynė surenkama ant surinkimo stendo. T. y., operatorius-surinkėjas, atlikdamas mechanines surinkimo procedūras, visus, pynę sudarančius komponentus, surenka į galutinį gaminį. Galima išskirti tris pagrindines operacijų grupes (žingsnius):

- instaliavimas, laidai yra išdėstomi ant stendo brėžinio pagal reikiamą planą;

- sutvirtinimas, laidai ir kabeliai sutvirtinami tarpusavyje raišteliais, izoliacija ar paveriami per žarnas;
- fiksavimas, antgaliai įstatomi į jungties korpusus, tvirtinami papildomi komponentai, klijuojami lipdukai ir pan.

Skirtingos pynės gali turėti visiškai kitokią laidų išsidėstymą ir visiškai kitokią elektrinę schemą, tačiau mechaninės operacijos bus tokios pačios. Kitaip tariant, egzistuoja apibendrintas operacijų sąrašas, kuriame bus visos, pynėse pasitaikančios standartinės operacijos. Tai yra labai svarbi prielaida pynės standartiniam surinkimo laikui nustatyti. Taigi turime operacijų vektorių:

$$\mathbf{D} = (t_1 \quad t_2 \quad t_3 \quad \dots \quad t_m), \quad (2.1)$$

kur t_i yra tam tikros operacijos laikas, m yra suminis visu galimų operacijų skaičius. Operacijų laiko tyrimo metu, kiekviena operacija buvo kruopščiai įvertinta keliems skirtingiems produktams ir atlikta kelis šimtus kartų, taip užtikrinant, kad standartinis laikas (operacija visiškai išmokta) būtų pasiektas.

Kiekviena pynė turi skirtingus operacijų kiekius, t. y. turi savo operacijų vektorių:

$$\mathbf{W} = (q_1 \quad q_2 \quad q_3 \quad \dots \quad q_m), \quad (2.2)$$

kur q_i yra i -tosios operacijos kiekis konkrečioje pynėje. Jei konkretus gaminyš neturės tam tikros operacijos, kiekis q bus lygus nuliui. Taigi, jei turime abu vektorius \mathbf{D} ir \mathbf{W} , galime suskaičiuoti standartinį pynės surinkimo laiką:

$$T_C = (\mathbf{D}, \mathbf{W}). \quad (2.3)$$

Šis laikas yra ir stabilizacijos laikas, t. y. toks, kuris yra pasiekiamas visiškai išmokus operacijas (nebėra mokymosi laiko).

2.2. Surinkimo efektyvumo optimizavimo uždavinys

Vienas ir pagrindinių proceso našumo rodiklių yra efektyvumas, t. y. pagamintos (surenkamos), naudingos produkcijos kiekio ir viso darbo laiko santykis. Šiuo atveju standartinis laikas T_C yra šios naudingos produkcijos rodiklis. Esant nevienodai gamybai, realus surinkimo laikas gerokai padidėja dėl mokymosi laiko, todėl procesas ir operacijos turi būti modeliuojamos taip, kad surinkimo laikas būtų minimalus. Bendru atveju, visuminis proceso efektyvumas (OEE) nusakomas trimis faktoriais:

$$OEE = A_{eff} P_{eff} Q_{eff} = \frac{T_{OP}}{T_{PL}} \times \frac{T_C}{T_{OP}} \times \frac{Q_{OP} - Q_D}{Q_{OP}}, \quad (2.4)$$

kur A_{eff} – eksploatacinės parengties efektyvumas, P_{eff} – našumo efektyvumas, Q_{eff} – kokybės efektyvumas, T_{OP} – faktinis gamybos darbo laikas, T_{PL} – eksploatacinė parengtis, Q_{OP} – produkcijos kiekis pagamintas per faktinį gamybos sistemos darbo laiką, Q_D – brokuotų gaminių skaičius pagamintų per faktinį gamybos sistemos darbo laiką.

Mokymosi laikas įeina į bendrą darbo laiką, tačiau nesukuria produkcijos:

$$T_{OP} = T_C + T_A + T_L, \quad (2.5)$$

kur T_L – integruotas mokymosi laikas, T_A – papildomas laikas dėl kitų neefektyvumo priežasčių. Apjungus (2.4) ir (2.5) gaunama tokia galutinė efektyvumo išraiška:

$$F(T_L) = \frac{T_{OP}}{T_{PL}} \times \frac{T_C}{T_C + T_A + T_L} \times \frac{Q_{OP} - Q_D}{Q_{OP}}. \quad (2.6)$$

Efektyvumo maksimumas:

$$\max_{T_L} F(T_L) = F\left(\min_{\alpha, \beta, T_C} T_L\right), \quad (2.7)$$

tada galutinis optimizavimo uždavinys formuluojamas taip:

$$\min_{\alpha, \beta, T_C} T_L(\alpha, \beta, T_C), \quad (2.8)$$

esant apribojimams:

$$\alpha > 0, \beta > 0, T_C > 0. \quad (2.9)$$

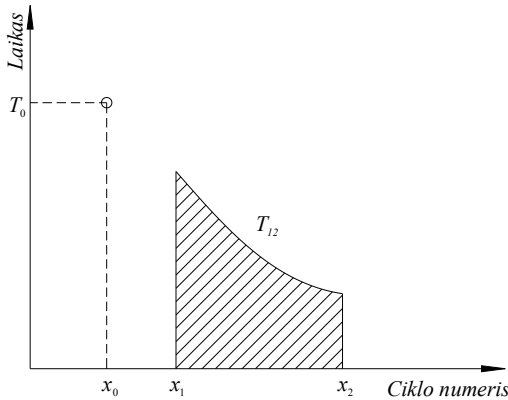
Reikia pabrėžti, kad (2.8) yra apibendrintas optimizavimo uždavinys, t. y. papildomi apribojimai, atsirandantys modeliuojant procesą gali būti pridėti, o integruotas surinkimo laikas gali būti pakeistas sudėtinga išraiška, aprašančia konkretų surinkimo procesą.

2.3. Gamybinių duomenų stebėjimo metodika

Gamybiniai duomenys atlieka labai svarbų vaidmenį, nes jų pagrindu nustatomi reikiami modelių parametrai ir patikrinamas pasiūlytų modelių adekvatumas. Toliau pateikiama metodika gamybiniam duomenims stebėti ir surinkti. Naudoti trys duomenų surinkimo būdai:


- atskiro gaminio surinkimo laiko ir viso užsakymo surinkimo laiko matavimas;
- kelių, vienas po kito einančių užsakymų laiko matavimas;
- vienas po kito einančių gamybos ciklų laiko matavimas.

Atskiro gaminio surinkimo laiko ir viso užsakymo surinkimo laiko matavimas yra pats paprasčiausias, čia išmatuojamos šios vertės: laikas T_0 , pagaminti gamini x_0 ir laikas T_{12} , reikalingas pagaminti gaminius nuo x_1 iki x_2 . Matavimo pavyzdys pateiktas 2.2 paveiksle.



2.2 pav. Atskiro surinkimo laiko ir viso užsakymo laiko matavimas

Matuojant vienas po kito einančius gamybos užsakymus, gaunami keli suminiai užsakymų laikai ir žinoma, kiek gaminių buvo padaryta (žr. 2.3 pav.).




2.3 pav. Atskiro surinkimo laiko ir viso užsakymo laiko matavimas

Toks metodas yra sudėtingesnis ir brangesnis, nes jam reikia daugiau resursų, kurie turėtų būti skirti procesui stebėti. Tačiau toks metodas gali būti lengvai automatizuojamas, t. y. gamybos operatoriai gali fiksuoti sistemoje baigtus užsakymus ir tokiu būdu gali būti kaupiama informacija apie labai daug gamybos sistemoje esančių gaminių.

Pats brangiausias, tačiau kartu ir pats informatyviausias metodas yra trečiasis, kai yra fiksuojamas kiekvienas baigtas gamybos ciklas (žr. 2.4 pav.). Tokiu būdu gaunami šie duomenys:

$$x_i^{(k)}, y_i^{(k)}, x_i^{(k)} < x_{i+1}^{(k)}, i = 1, 2, \dots, N, k = 1, 2, \dots, K, \quad (2.10)$$

kur x – ciklo numeris, y – surinkimo laikas, N – stebėjimų skaičius, K – eksperimentų skaičius.



2.4 pav. Kiekvieno gaminio surinkimo laiko matavimas

Kai K yra pakankamai didelis, visi reikalingi statistiniai parametrai (nuokrypis, vidurkis, mediana ir t. t.) gali būti apskaičiuojami statistiniais metodais. Šiame darbe tiriami atvejai, kai $K = 1$, t. y. tik viena eksperimento realizacija yra gaunama iš ribotų (nestabilių) gamybinių duomenų.

2.4. Adekvatumo įvertinimo metodika

Analitiniais tyrimais išvestų modelių adekvatumas turi būti įvertinamas gamybiniiais duomenimis, t. y. būtina patikrinti ar pasiūlyti modeliai pakankamai tiksliai aprašo realius gamybinius duomenis. Šiam adekvatumui įvertinti, turi būti apskaičiuotos modelių paklaidos. Numatyta ribinė paklaidos vertė – 5 %.

Išmatuoti „realūs“ duomenys yra pateikti šia vektorine forma:

$$\mathbf{X} = (x^{(1)}, \dots, x^{(N)}), \quad \mathbf{Y} = (y^{(1)}, \dots, y^{(N)}), \quad x^{(i)} < x^{(i+1)}, \quad (2.11)$$

kur $x^{(i)}$ – ciklo numeris, $y^{(i)}$ – i -tojo ciklo surinkimo laikas.

Kai $\mathbf{Y}_{cal} = (f(x^{(1)}, \alpha, \beta), \dots, f(x^{(N)}, \alpha, \beta))$ (žr. (1.1)) rezultatai apskaičiuoti naudojant bet kurią pasiūlytą matematinį modelį. Taikymo tikslumas nustatomas norma (absoliučiąja paklaida):

$$\delta_{abs} = \|\mathbf{Y}_{cal} - \mathbf{Y}\|. \quad (2.12)$$

Tam tikrais atvejais, suskaičiuoti absoliučiąją paklaidą neužtenka, todėl turi būti apskaičiuojama ir santykinė paklaida:

$$\delta_{rel} = \delta_{abs} \|Y_{cal}\|^{-1}, \quad (2.13)$$

kur $\|\mathbf{Z}\| = \sqrt{\sum_{i=1}^N (z^{(i)})^2}$ jei $\mathbf{Z} = (z^{(1)}, \dots, z^{(N)})$ Hilberto-Šmito norma.

3. ANALITINIAI TYRIMAI

Šioje dalyje atliekami analitiniai MK taikymo tyrimai. Remiantis gamyboje pastebėtomis tendencijomis, suformuluotos pagrindinės analitinių tyrimų kryptys. Pirmiausia iškelta prielaida, kad surinkimo laike egzistuoja stabilizacijos fazė, t. y. surinkimo laikas stabilizuojasi. Todėl vienas iš pagrindinių uždavinių yra sukurti pagrįstą matematinį modelį, kuris aprašytų šį procesą, t. y. žinant pradinis duomenis (gamybos laikus bei stabilizacijos laiką) būtų galima iki galo apibrėžti procesą.

Pastebėta, kad esamų MK modelių neužtenka norint aprašyti nestabilius procesus, todėl reikia sukurti tokius modelius, kurie turėtų būti universalūs ir tiktų aprašyti tuos gamybinius duomenis, kuriems klasikiniai modeliai netinka. Tam tikslui, klasikinė mokymosi kreivė aprašyta (1.1) formule, yra traktuojama kaip diferencialinės lygties sprendinys tam, kad modifikuojant šią lygtį būtų galima gauti universalesnius, matematiškai pagrįstus mokymosi kreivės modelius, kurie tenkintų visas bendrąsias MK savybes bei atvertų galimybę įvertinti nuovargio įtaką rankiniam surinkimo procesui ir leistų modeliuoti nutrūkstantį (pasikartojantį) mokymąsi.

Kitas, svarbus uždavinys yra MK parametrų atstatymas turint ribotus gamybinius duomenis (tik viena atsitiktinio dydžio realizacija). Maži, dažnai besikeičiantys gamybos kiekiai leidžia stebėti tikrai ribotus duomenis, o mokymosi įtaka yra pati didžiausia tokioje gamyboje. Statistiniai metodai tokiems duomenims negali būti korektiškai taikomi, todėl galimi tik deterministiniai metodai (duomenų interpoliacija arba aproksimacija), kurie leidžia pakankamai tiksliai nustatyti kreivės parametrus iš turimų duomenų.

Visi, prieš tai minėti tyrimai, yra būtini svarbiausiam disertacijos uždaviniui ir tikslui pasiekti – surinkimo proceso sudėtingumui ir mokymosi laikui sumažinti jį modeliuojant.

3.1. Kreivės su laiko stabilizacija

Atliktas visas eksperimentas ir gauti duomenys:

$$\{x_i, y_i\}, x_i < x_{i+1}, i = 1, 2, \dots, n. \quad (3.1)$$

Toliau naudojami tik riboti duomenys, taškas (x_q, y_q) , $q \geq 1$ ir laikas $T_c = y(x_c, \alpha) = f(x_c, \alpha, x_q^\alpha y_q)$ (žr. (1.1)), kurį pasiekus, surinkimo laikas „beveik“ nesikeičia ($y(x, \alpha) \approx const$, kai $x \geq x_c$). Parametrai x_c ir α yra nežinomi. Žodis „beveik“ čia suprantamas kaip išvestinės $\partial y / \partial x$ absoliutinės vertės sumažėjimas iki adekvačiai pasirinktos vertės $\varepsilon > 0$. Įrodyta, kad parametras $\alpha = \alpha_\varepsilon$ yra vienareikšmiškai nustatomas kaip lygties

$$\left| \frac{\partial y}{\partial x} \right|_{x=x_c(T_c, \alpha)} = \varepsilon \quad (3.2)$$

sprendinys, čia $x_c(T_c, \alpha_\varepsilon) = x_q \left(y_q / T_c \right)^{\frac{1}{\alpha_\varepsilon}}$ yra mokymosi kreivės

$$y(x, \alpha_\varepsilon) = y_q \left(\frac{x}{x_q} \right)^{-\alpha_\varepsilon},$$

einančios per tašką (x_q, y_q) ir tiesės $y = T_c$ vienintelio

susikirtimo taško abscisė. Taigi, jei rasti α_ε ir $x_c(T_c, \alpha_\varepsilon)$, visiškai atstatoma mokymosi kreivė, t. y.:

$$Y(x, x_q, y_q, \alpha_\varepsilon) = \begin{cases} y_q \left(\frac{x}{x_q} \right)^{-\alpha_\varepsilon}, & \text{kai } 0 < x < x_c(T_c, \alpha_\varepsilon) \\ T_c, & \text{kai } x \geq x_c(T_c, \alpha_\varepsilon) \end{cases} \quad (3.3)$$

Taigi, radus α_ε (įrodyta, kad lygtis (3.2) turi vienintelį sprendinį), iki galo atstatoma mokymosi kreivė (3.3) ir stabilizacijos taškas $x_c(T_c, \alpha_\varepsilon)$ naudojant tik stebėjimo duomenis (x_q, y_q) ir T_c .

3.2. „Beveik mokymosi“ kreivės modelis

Šiame poskyryje pateikti klasikinės mokymosi kreivės (toliau – KMK) ir „beveik mokymosi“ kreivės (toliau – BMK) apibrėžimai. Parodyta, kad stebėjimo duomenims aproksimuoti BMK labai sumažina aproksimavimo paklaidą. Parodyta, kad KMK $y(x, \alpha) = x_1^\alpha y_1 x^{-\alpha}$, $0 < \alpha < 1$, $x_1, x \geq 1$, $y_1 > 0$ yra pradinio uždavinio

$$\begin{cases} L_\alpha(y) = 0 \\ y(x_1, \alpha) = y_1 \end{cases} \quad (3.4)$$

sprendinys, $L_\alpha(y) = y' + \alpha x^{-1}y$ ir tenkina sąlygas:

$$y \in C^{(2)}[1, +\infty), \text{ jei } x_1 \geq 1, y_1 > 0, \alpha \in (0, 1), \quad (3.5)$$

$$y(x, \alpha) > 0, y'_x(x, \alpha) \leq 0, y''_x(x, \alpha) \geq 0, \quad (3.6)$$

$$y_a = \lim_{x \rightarrow +\infty} y_h(x, \alpha) \geq 0. \quad (3.7)$$

Apibrėšime BMK kreivę kaip pradinio uždavinio

$$\begin{cases} L_\alpha(w) = \varepsilon x^{-r}, & r \geq 1, \\ y(x_1, \alpha) = y_1 \end{cases} \quad (3.8)$$

sprendinį

$$w(x, \alpha, \varepsilon, r) = x_1^{s(\alpha, r)} \left[\frac{c(\alpha, r) - \varepsilon}{s(\alpha, r)} \right] x^{-\alpha} + \frac{\varepsilon}{s(\alpha, r)} x^{1-r} \quad (3.9)$$

kur $s(\alpha, r) = \alpha + (1-r)$, $c(\alpha, r) = x_1^{r-1} y_1 s(\alpha, r)$.

Nustatytos būtinos sąlygos parametrų α , ε ir r , kurioms BMK tenkina (3.4) – (3.6). Išskirti atvejai, kai $y_a > 0$ ir $y_a = 0$ (stabilizacijos atvejais).

3.3. Vibracijų ir pasikartojančių judesių įtaka mokymosi kreivėje

Klasikinė mokymosi kreivė nusako surinkimo laiko mažėjimą priklausomai nuo pakartotų ciklų skaičiaus, todėl tokia kreivė negali apimti jokių rizikos faktorių, nes tai griežtai ir monotoniškai mažėjanti funkcija. Tam kad būtų apjungtas surinkimo laikas bei vibracijų ir pasikartojančių judesių įtaką, nedidelė laiko dalis yra pridedama prie kiekvieno pasikartojančio ciklo. Taip surinkimo laikas mažėja operatoriui mokantis, tačiau pradeda didėti, kai liga (dėl pasikartojančių judesių sindromo) pradeda plėtotis. Siekiant įtraukti vibracijų ir pasikartojančių judesių įtaką surinkimo laikui, mokymosi kreivę galima traktuoti kaip pradinio uždavinio

$$\begin{cases} L_\alpha[w] = \varepsilon, & \varepsilon > 0 \\ w(x_1) = w_1 & x_1 \geq 1, w_1 > 0 \end{cases} \quad (3.10)$$

sprendinį (BMK kreivė):

$$w(x, x_1, w_1, \alpha, \varepsilon) = (1 + \alpha)^{-1} x [\varepsilon + v(x, x_1, w_1, \alpha, \varepsilon)] \quad (3.11)$$

kur $v(x, x_1, w_1, \alpha, \varepsilon) = x_1^\alpha S(x_1, w_1, \alpha, \varepsilon) x^{-(1+\alpha)}$, $S(x_1, w_1, \alpha, \varepsilon) = (1 + \alpha) w_1 - \varepsilon x_1$, tenkinanti kitas sąlygas, nei (3.5) – (3.7), o būtent

$$w \in C^{(2)}[1, +\infty), \text{ jeigu } x_1 \geq 1, y_1 > 0, \alpha \in (0, 1) \quad (3.12)$$

$$w(x, x_1, w_1, \alpha, \varepsilon) > 0, w'_x(x, x_1, w_1, \alpha, \varepsilon) \geq 0 \quad (3.13)$$

$$w(x, x_1, w_1, \alpha, \varepsilon) \text{ turi vienintelį minimumą, kai } x \in (1, \infty) \quad (3.14)$$

$$\lim_{x \rightarrow +\infty} w(x, x_1, w_1, \alpha, \varepsilon) = +\infty \quad (3.15)$$

Nustatytos būtinos sąlygos parametrms α , ε , x_1 ir y_1 , kurioms BMK tenkina (3.12) – (3.15).

3.4. Mokymosi kreivės parametrų nustatymas

Šiame poskyryje pristatyti interpoliavimo ir / arba aproksimavimo metodai, skirti MK parametrms atstatyti. Metodo parinkimas priklauso nuo turimų duomenų struktūros, t. y., ar duomenys gauti naudojant W ar C modelius (žr. (1.1)). Kiekvienam metodui įrodyta sprendinio (atstatytų parametrų) egzistavimas ir vienatnumas.

Dviejų taškų metodas W ir C modeliams (TPC, TPW). Jei stebėti du MK taškai (x_1, y_1) , (x_2, y_2) tada MK parametrai α ir β atstatomi vienareikšmiškai:

$$\alpha = -(\ln(y_1) - \ln(y_2))(\ln(x_1) - \ln(x_2))^{-1} > 0 \text{ ir } \beta = y_1 x_1^\alpha = y_2 x_2^\alpha > 0 \quad (3.16)$$

Taško ir intervalo metodas C modeliui (PIC). Jei stebėtas laikas T_0 x_0 vieneto pagaminimui ir visas laikas T_{12} būtinas pagaminti vienetus nuo x_1 iki x_2 , ir jei $T_{12}/T_0 < x_2 - x_1$, tai MK parametrai α ir β atstatomi vienareikšmiškai kaip lygčių sistemos:

$$x_0^\alpha \int_{x_1}^{x_2} x^{-\alpha} dx = \frac{T_{12}}{T_0}, \beta = \frac{T_0}{x_0^{-\alpha}} = \frac{T_{12}}{\int_{x_1}^{x_2} x^{-\alpha} dx} \quad (3.17)$$

sprendinys, be to $\alpha > 0$, $\beta > 0$.

Dviejų intervalų metodas C modeliui (TIC). Jei stebėti visas laikas T_{12} , būtinas pagaminti vienetus nuo x_1 iki x_2 , ir visas laikas T_{34} , būtinas pagaminti vienetus nuo x_3 iki x_4 , ir jei $\frac{x_2 - x_1}{x_4 - x_3} < \frac{T_{12}}{T_{34}}$, tai MK parametrai α ir β atstatomi vienareikšmiškai kaip lygčių sistemos

$$\frac{\int_{x_1}^{x_2} x^{-\alpha} dx}{\int_{x_3}^{x_4} x^{-\alpha} dx} = \frac{T_{12}}{T_{34}}, \beta = \frac{T_{12}}{\int_{x_1}^{x_2} x^{-\alpha} dx} \quad (3.18)$$

sprendinys, be to $\alpha > 0, \beta > 0$.

Dvieju intervalų metodas modeliui W (TIW). Jei stebėti laiko, būtino pagaminti vienetus nuo x_1 iki x_2 vidurkis T_{12} ir laiko, būtino pagaminti vienetus nuo x_3 iki x_4 vidurkis T_{34} , ir, jei $1 < \frac{T_{12}}{T_{34}} < \frac{(x_4 - x_3) \ln x_2 - \ln x_1}{(x_2 - x_1) \ln x_4 - \ln x_3}$, tai MK parametrai α ir β atstatomi vienareikšmiškai kaip lygčių sistemos

$$\begin{cases} \frac{\beta(x_2^{1-\alpha} - x_1^{1-\alpha})}{x_2 - x_1} = T_{12} \\ \frac{\beta(x_4^{1-\alpha} - x_3^{1-\alpha})}{x_4 - x_3} = T_{34} \end{cases} \quad (3.19)$$

sprendinys, be to $\alpha > 0, \beta > 0$.

Invariantų metodas modeliams C ir W (INC, INW). Funkcija $y(x) = \beta x^{-\alpha}$ turi du invariantus (funkcijas, kurios yra nekintančios visoms argumentų $(x_i, y_i), (x_j, y_j), i < j$ vertėms):

$$I_1 = \alpha = -\frac{\ln(y_j) - \ln(y_i)}{\ln(x_j) - \ln(x_i)}, \quad I_2 = \ln \beta = \frac{\ln(y_i) \ln(x_j) - \ln(y_j) \ln(x_i)}{\ln(x_j) - \ln(x_i)}. \quad (3.20)$$

Tada parametru α ir β atstatymui galima taikyti išraiškas:

$$\bar{\alpha} = \frac{1}{M} \sum_{j>i}^M I_1(x_i, y_i, x_j, y_j), \quad \bar{\beta} = \frac{1}{M} \sum_{j>i}^M \exp\{I_2(x_i, y_i, x_j, y_j)\} \quad (3.21)$$

čia $M = (N^2 - N)/2$ dėmenų skaičius sumose (3.21).

3.5. Nutrukstančių procesų modeliavimas ir pasikartojantys mokymasis

Jei gaminys yra visada gaminamas vienoje surinkimo vietoje ir nėra perkeliamas į kitą gamybos vietą, mokymosi laikas skaičiuojamas remiantis formule (1.1). Bet koks gamybos pertraukimas ar perkėlimas lemia pasikartojanti mokymąsi. Šiame poskyryje bus pateiktas matematinis, tokio pasikartojančio mokymosi modelis. Kai \mathbf{m} – vektorius, apibrėžiantis gamybos perkėlimų skaičių ir kiekį, o β – vektorius, apibrėžiantis pirmojo gaminio surinkimo laiką kiekvieno perkėlimo atveju, tada pasikartojančio mokymosi modelis:

$$y(x, \alpha, \beta, \mathbf{m}) = \left[\sum_{i=1}^{N-1} F(x, m_{i-1}, m_i) \beta_{i-1} \left(\frac{x}{m_{i-1}} \right)^{-\alpha} \right] + \\ + H(x - m_{n-1}) \beta_{N-1} \left(\frac{x}{m_{n-1}} \right)^{-\alpha}, \quad (3.22)$$

kur $H(x)$ – Hevisaido funkcija, n – perkėlimų skaičius, N – suminis gamybos kiekis. Tada suminis viso gamybos kiekio N laikas skaičiuojamas taip:

$$F(x, m_{i-1}, m_i) = H(x - m_{i-1}) - H(x - m_i). \quad (3.23)$$

Modelyje daroma prielaida, kad koeficientas α yra toks pat kiekvienam pasikartojančiam mokymuisi.

3.6. Proceso skaidymo modeliavimas

Proceso skaidymas. Tegul n yra gaminamos partijos dydis, o $p = 1, 2, \dots, P$ yra proceso skaidymo dalių skaičius. Proceso skaidymas atliekamas, kai to paties produkto surinkimas išskirstomas į keletą surinkimo stotelių (surinkimo linija arba lygiagretus procesas). Kai procesas yra skaidomas, sudėtingumas mažėja, t. y., vietoj vieno sudėtingo proceso, gaunami p , ne tokie sudėtingi procesai, o tai tiesiogiai lemia visos partijos n galutinį surinkimo laiką. Tačiau, didesnis dalių skaičius sąlygoja papildomą išskaidytų dalių agregavimo laiką, t. y., egzistuoja optimalus skaidymo dalių skaičius.

MK ir jos parametrai. Skaidymo modeliavimui pasirenkamas Plato MK modelis su stabilizacijos parametru (3.3). Bus taikoma paprastesnė šio MK modelio išraiška:

$$y(x) = \begin{cases} \beta x^{-\alpha}, & x \leq x_c \\ T_c, & x > x_c \end{cases} \quad (3.24)$$

kur x – gaminio numeris, $y(x)$ – x -tojo gaminio surinkimo laikas, β – pirmojo gaminio surinkimo laikas, α – mokymosi koeficientas, T_c – standartinis surinkimo laikas, x_c – stabilizacijos ciklo numeris. Šie parametrai visiškai apibrėžia MK. Neskaidyto proceso atveju visi šie parametrai yra nekintantys.

Proceso skaidymo atveju parametrai yra kintami, todėl proceso kreivė gauna išraišką:

$$y(x, p, c_\alpha, c_T, c_{x_c}) = \begin{cases} T_c(c_T, p) x_c(c_{x_c}, p)^{\alpha(c_\alpha, p)} x^{-\alpha(c_\alpha, p)}, & x \leq x_c(c_{x_c}, p) \\ T_c(c_T, p), & x > x_c(c_{x_c}, p) \end{cases} \quad (3.25)$$

kur c_α – mokymosi parametro konstanta, c_T – stabilizacijos laiko konstanta, c_{x_c} – stabilizacijos numerio konstanta.

Optimizavimo uždavinys. Kadangi procesas yra išskaidytas, papildomas laikas yra būtinas visoms pagamintoms dalims agreguoti į galutinį gaminį. Kuo daugiau surinkimo dalių, tuo daugiau agregavimo laiko turės būti sugaišta ir tai yra funkcija nuo dalių skaičiaus p :

$$T_e(p, c_{Te}) = c_{Te}(p-1), c_{Te} > 0, \quad (3.26)$$

kur c_{Te} – agregavimo konstanta. Turint išvardytus parametrus, formuluojamas apibendrintas optimizavimo uždavinys. Tada galima apibrėžti tikslo funkciją:

$$T(p, n, c_\alpha, c_{Te}, c_T, c_{xc}) = p \int_0^n y(x, p, c_\alpha, c_T, c_{xc}) dx + T_e(p, c_{Te})p \quad (3.27)$$

ir suformuluoti optimizavimo uždavinį su apribojimais:

$$\text{minimize } T(\mathbf{r}) \quad (3.28)$$

su apribojimais

$$(p, n) \in \{p < n\} \quad (3.29)$$

$$0 < c_\alpha < 1 \quad (3.30)$$

$$c_{xc}, c_{Te}, c_T > 0 \quad (3.31)$$

čia $T(\mathbf{r})$ – tikslo funkcija, $\mathbf{r} = (p, n, c_\alpha, c_{Te}, c_{xc}, c_T)$ – sprendinių vektorius ir (3.29), (3.30), (3.31) – apribojimai, kurie apibrėžia iškilą ir jungią leistiną sritį $G \subset \mathbf{R}_+^6$, t. y. reikia nustatyti laiką T_{min} ir vektorių \mathbf{r}_0 , kad:

$$T_{min} = \min_{\mathbf{r} \in G} T(\mathbf{r}), \quad (3.32)$$

$$\mathbf{r}_0 = \text{Arg min}_{\mathbf{r} \in G} T(\mathbf{r}). \quad (3.33)$$

Jei parametrai $c_\alpha, c_{Te}, c_{xc}, c_T$ yra nustatyti iš gamybos proceso stebėjimo, optimizavimo uždavinys (3.28) virsta vieno kintamojo optimizavimo uždaviniu (partijos dydis n – fiksuotas):

$$\begin{cases} \min_p T(p, n), \\ p < n \end{cases} \quad (3.34)$$

Šio uždavinio sprendinys pateiktas poskyryje 4.6.


Tiriant normuotą tikslo funkciją

$$T^{(n)}(p, n, c_\alpha, c_{Te}, c_T, c_{xc}) = \frac{T(p, n, c_\alpha, c_{Te}, c_T, c_{xc})}{n}, \quad (3.35)$$

kai parametrai $c_\alpha, c_{Te}, c_{xc}, c_T$ yra nustatyti iš gamybos proceso stebėjimo, o p ir n nežinomi, optimizavimo uždavinys (3.28) virsta dviejų kintamojo optimizavimo uždaviniu:

$$\begin{cases} \min_{p, n} T^{(n)}(p, n), \\ (p, n) \in G \end{cases} \quad (3.36)$$

Toliau pateikiamas pavyzdys, kai sritis G yra elipsės vidus. Jungtinių gradientų metodu išspręstas optimizavimo uždavinys pateiktas 3.1 paveiksle (uždavinio sprendimas užtruko apie 1 minutę)



3.1 pav. Dviejų kintamųjų normuotos funkcijos $T^{(n)}(p, n)$ optimizavimas, kai parametru vertės: $c_\alpha = 0.3, c_{Te} = 0.3, c_{xc} = 80, c_T = 2$

4. EKSPERIMENTINIAI TYRIMAI

Visų, disertacijoje pasiūlytų modelių ir metodų adekvatumas yra patikrintas realiai gamyboje esant įvairioms situacijoms. Gamybiniai matavimai atlikti ir duomenys surinkti neautomatizuotą surinkimą atliekančioje užsienio kapitalo įmonėje. Ši Skandinavijos įmonė turi savo padalinius Europoje, Šiaurės Amerikoje ir Azijoje. Įmonė nekuria savo produkto, ji priklauso automobilių pramonės komponentių tiekimo grandinei ir gamina automobilinės instaliacijos

komponentus – laidų pynės. Produkcija turi būti gaminama pagal kliento brėžinius ir specifikacijas, jokie struktūriniai gaminio pakeitimai negalimi. Pati gamyba yra paremta užsakymais, kitaip tariant, gaminiai gaminami ne tik pagal kliento poreikius, bet ir pagal konkrečius gamybos užsakymus, t. y. nėra galimybės produkcijos gamintis į sandėlį ir taip sinchronizuoti gamybos procesus. Įmonėje gaminama per keturis tūkstančius skirtingų gaminių, jų surinkimo laikas svyruoja nuo kelių dešimčių valandų iki kelių minučių. Užsakymo kiekiai taip pat labai skirtingi kiekvienam gaminiui, nuo kelių vienetų per metus iki kelių šimtų gaminių per mėnesį.


Eksperimentinių tyrimų metu įmonės vadovybė sudarė sąlygas stebėti įvairių surinkimo procesų atlikimo trukmę (laiką) vienoje iš savo gamyklų. Šie surinkimo laikų duomenys ir bus naudojami modelių adekvatumui patikrinti. Jais bus siekiama:

- Patikrinti nestatistinius proceso kreivės parametrų atstatymo metodus.
- Įvertinti naujai pasiūlytų proceso kreivės modelių adekvatumą.
- Patikrinti pagrindinę disertacijos prielaidą apie mokymosi laiko sumažinimą skaidant ir paprastinant procesą.

Visi šie patikrinimai bus patekti toliau esančiuose poskyriuose.

4.1. Kreivės parametrų nustatymo adekvatumo įvertinimas

Naudojant analitinėje dalyje pasiūlytus parametrų nustatymo metodus bei ribotus gamybinius duomenis, buvo atstatyti mokymosi kreivės parametrai.



4.1 pav. Skirtingais metodais nustatytų parametrų palyginimas. 1 – TPW, 2 – INW, 3 – TIW, 4 – gamybiniai duomenys.

Analitinėje dalyje buvo pasiūlyti dviejų taškų, taško ir intervalo, dviejų intervalų bei invariantų metodai skirtingiems duomenų rinkiniams (kaupiamojo

vidurkio bei vienetiniams duomenims). Skaitinio eksperimento esmė – turimiems duomenims pritaikyti keletą metodų, kad būtų galima palyginti skirtingais metodais apskaičiuotus parametrus ir bendrai įvertinti jų adekvatumą.

Toliau pateiktame eksperimente buvo surinkti kaupiamojo vidurkio duomenys. Jie buvo naudojami kaip pagrindas parametrams atstatyti šiais metodais: invariantų (INW), dviejų taškų (TPW) ir dviejų intervalų (TIW). 4.1 paveiksle pateikti eksperimento rezultatai, atstatytos parametru vertės, kurios pateiktos ir 4.1 lentelėje.

Kaip matyti iš pateiktų rezultatų, panaudoti metodai rodo pakankamai tikslus parametru atstatymo rezultatus.

4.1 lentelė. Kreivės parametru ir santykinų procentinių paklaidų palyginimas

Duomenų tipas	Metodas	α	β	δ , %
Kaupiamojo vidurkio	TPW	0.144	8.046	2.475
	INW	0.126	7.548	2.636
	TIW	0.139	7.735	2.821
Vienetiniai	TIC	0.125	1.402	5.965
	TPC	0.133	1.377	3.670
	INC	0.118	1.299	3.289
	PIC	0.091	1.243	4.391

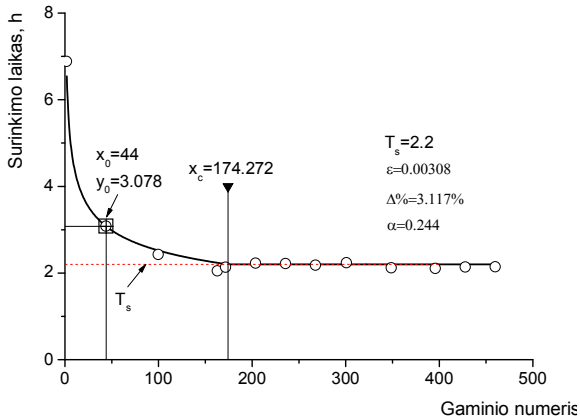
Lentelėje 4.1 taip pat yra pateikti ir kitais metodais atliktų parametru atstatymo rezultatai. Beveik visi taikyti metodai rodo pakankamą parametru atstatymo tikslumą (paklaidos ne didesnės kaip 5 %). Kaupiamuoju vidurkiu paremti metodai yra ne tokie jautrūs atsitiktinėms paklaidoms nei paremtieji vienetiniais duomenimis. Tiksliausias metodas yra invariantų, nes jis apima daugiau taškų ir jis tikrai yra prioritetas tais atvejais, kai duomenų užtenka. Tačiau taškų skaičių lemia gamybinės sąlygos, o ne metodika. Tai reiškia, kad tam tikrais atvejais ir tebus tikrai du taškai, tačiau kreivė vis tiek gali būti nustatyta iš tų ribotų gamybinių duomenų. Siekiant, kad kreivės būtų tikslesnės, reikia:

- skaičiavimui naudoti ne minimaliai reikalingą, bet didesnę duomenų kiekį (jei įmanoma);
- taikyti keletą skirtingų metodų tiems patiems ribotiems gamybos duomenims.

Naudojant šiais metodais atstatytus kreivės parametrus, buvo atliekami visi, šioje disertacijoje pateikti modeliavimo tyrimai. Be to, buvo nustatyta, kad parametrai yra skirtingi skirtingo sudėtingumo kreivėms, t. y. egzistuoja ryšys tarp pynės sudėtingumo ir mokymosi kreivės parametru.


4.2. Eksperimentinis kreivės su laiko stabilizacija tyrimas

Šiame skyrelyje pateikiamas kreivės su stabilizacijos parametru adekvatumo tyrimas.



4.2 pav. Apskaičiuota proceso kreivė su stabilizacija ir gamybiniai duomenys

Tam tikslui buvo atlikta 11 reprezentatyvių eksperimentų ir 11 atitinkamų matavimų, kuriais nustatytas pakankamas skaičius reikiamų taškų.



4.3 pav. Apskaičiuota Plato proceso kreivė ir gamybiniai duomenys – stabilizacijos prognozavimas

Standartinis laikas kiekvienam gaminiui T_c nustatytas pagal (2.3) formulę, o stabilizacijos parametras parinktas pagal gamybinės rekomendacijas $\varepsilon = 0.0016 \cdot T_c$.

Tiriant kiekvieną eksperimentą, pasirinktas taškas (x_0, y_0) iš išmatuotų gamybinių duomenų. Santykinė paklaida įvertinta pagal (2.13) formulę. Toliau yra pateikti du eksperimentai: pirmajame duomenys pasiekia stabilizacijos laiką, o antrajame stabilizacija yra tik prognozuojama.

Iš rezultatų, pateiktų 4.2 paveiksle matyti, kad pasiūlytas kreivės su stabilizacija modelis, gerai aproksimuoja realius gamybinius duomenis. Paklaida yra 3,12 %, taigi ne didesnė kaip 5 %. Kitas svarbus rezultatas yra tai, kad apskaičiavus standartinį surinkimo laiką ir pamatavus vieną tašką, iš proceso kreivės visiškai atstatomi kreivės parametrai.


Kitas reikšmingas eksperimentas iliustruoja prognozuojamą stabilizaciją, t. y. realus surinkimo laikas nepasiekia apskaičiuoto standartinio surinkimo laiko, tačiau, naudojantis pasiūlytu kreivės su stabilizacija modeliu, galima šią stabilizaciją numatyti. Situacija pateikta 4.3 paveiksle.

Iš 4.3 paveikslo matoma, kad pasiūlytas metodas dar tiksliau aproksimuoja realius gamybinius duomenis, paklaida tėra 0,75 %. ($\ll 5\%$).

Apibendrinant kreivės su stabilizacija eksperimentinius tyrimus, galima teigti, kad toks kreivės modelis yra adekvatus ir pakankamai tiksliai aprašo realius gamybinius duomenis (nustatytos paklaidos, ne didesnė kaip 5 %).

4.3. BMK kreivės modelio adekvatumas

Darbe pasiūlyti BMK kreivės modeliai analogiškai pritaikyti gamybiniėje įmonėje išmatuotiems duomenims siekiant įvertinti du svarbius dalykus: patikrinti modelių adekvatumą ir palyginti naujus modelius su standartiniu mokymosi kreivės modeliu.



4.4 pav. BMK modelis (1) ir klasikinis mokymosi kreivės modelis (2)

Kaip jau minėta, įmonėje yra naudojami keli gamybos tipai, toliau pateikta keletas pavyzdžių iliustruojančių BMK adekvatumą. Šie pavyzdžiai – tai tipinės

gamybinės situacijos: pasikartojantys užsakymai, pasikartojantys kas pakankamai ilgą laiką, prototipų užsakymai bei dideliu kiekiu gaminami užsakymai. Duomenys tyrimui pateikti pagal (2.10) formą $K = 1$, o santykinė paklaida skaičiuota pagal (2.13). 4.4 paveiksle yra pateiktas vienas iš šių eksperimentų.

Iš 4.4 paveikslo matyti, kad naujas, BMK modelis geriau aproksimuoja realius gamybinius duomenis. Visų situacijų adekvatumo tyrimai pateikti 4.2 lentelėje.

4.2 lentelė. Klasikinės MK ir BMK aproksimavimo rezultatai

Eksperimentas	Pasikartojantys užsakymai	Prototipų gamyba	Gamyba dideliu kiekiu
Gamybos kiekis	122	14	2210
α_y	0.2277	0.2961	0.5057
α_w	0.0998	0.2657	0.0000
ε_w	-6.5885	-2.4143	-28.9483
δ_y	8.80 %	2.21 %	14.91 %
δ_w	3.47 %	1.73 %	3.73 %

Remiantis 4.2 lentelėje pateiktais rezultatais matyti, kad BMK pakankamai tiksliai aprašo realius gamybinius duomenis. Santykinės paklaidos ne didesnės kaip 5 %.


4.4. „Mokymosi-nuovargio“ kreivės eksperimentinis tyrimas

Duomenys šiam tyrimui buvo surinkti tam tikrame įmonės gamybos padalinyje, kuriame gaminama iš dalies nesudėtinga produkcija, tačiau gana dideliais kiekiais. Svarbiausias šio padalinio rodiklis yra gamybos našumas, todėl surinkimo operatoriai gauna pakankamai didelį darbo krūvį. Stebėtas surinkimo laikas pasižymi tuo, kad po pradinio mažėjimo, vėliau šis laikas ima didėti, dėl vibracijų ir pasikartojančių judesių įtakos. Šiai situacijai aprašyti ir panaudotas „mokymosi-nuovargio“ modelis. Norint pritaikyti šį modelį, reikia suskaičiuoti perturbacijos parametą ε . Žinoma, kad suminis nagrinėjamo gaminio surinkimo laikas yra 0,035 valandos. Taip pat žinoma, kad 0,025 valandos dalis iš šio laiko, kelia riziką operatoriaus sveikatai dėl segmentinės vibracijos (naudojamas vibruojantis mechaninis įrankis) ir pasikartojančių judesių (gumos pervėrimas didele jėga, pakavimas). Taigi perturbacijos parametras skaičiuojamas taip:

$$\varepsilon = t_r (t_c / t_r)^{-1} = t_r^2 t_c^{-1} = (0.025)^2 900^{-1} = 6.944 \cdot 10^{-7} \quad (4.1)$$

kur t_r yra laikas, kurio metu yra keliamas pavojus operatoriaus sveikatai, t_c yra suminis darbo laikas, kai operatorius ima jausti pirmuosius pasikartojančių judesių traumos požymius.

„Mokymosi-nuovargio“ kreivės taikymo rezultatai pateikti 4.5 paveiksle.



4.5 pav. „Mokymosi-nuovargio“ kreivė (1) ir realūs gamybos duomenys (2)

Eksperimento rezultatai (žr. 4.5 pav.) patvirtina pasiūlyto metodo adekvatumą, paklaida ne didesnė kaip 5 %. Kitas svarbus rezultatas yra tai, kad egzistuoja minimalus surinkimo laiko taškas, po kurio operacijos laikas ima augti dėl pasikartojančių judesių sukeltos ligos. Tai yra labai svarbu kalbant apie taikymą praktikoje, t. y. galima numatyti, kada šias operacijas atliekantis surinkimo operatorius turėtų būti rotuojamas į kitas užduotis, kad būtų išvengta traumų atsiradimo. Be to, pasiūlytas metodas yra pakankamai paprastas, nes įtraukiamas tik vienas papildomas parametras ε .

4.5. Pasikartojančio mokymosi modelis

Užsakymais paremtoje gamybos sistemoje, planavimas visada yra gana komplikotas, ypač jei dirbama su keliais skirtingais klientais, t. y. užsakymai yra iš skirtingų užsakovų ir tuo pačiu metu. Esant tokiems kritiniams atvejams gamybos įmonėje, pasireiškia chaotiškumas planavime. Dažniausiai gaminiai yra paskirstomi į visus padalinius, kur tik yra laisvų pajėgumų. Tai papildomai komplikuoja situaciją dėl pasikartojančio mokymosi. Tokia situacija buvo stebėta tiriamoje įmonėje, kai labai sudėtingas gaminys buvo keletą kartų


perkeltas į kitus gamybos padalinius. Toliau pateikti užsakymo kiekiai skirtinguose padaliniuose:

$$\mathbf{m}^T = (1 \ 3 \ 10 \ 12 \ 22 \ 32 \ 34 \ 40 \ 64).$$

Taip pat nustatytos ir parametro β reikšmės:

$$\boldsymbol{\beta}^T = (130 \ 130 \ 95 \ 130 \ 130 \ 90 \ 130 \ 89).$$

Kreivės parametrų vertės nustatytos naudojant INC parametrų atstatymo metodą ($\alpha = 0,287$; $\beta = 130$). Skaičiavimo rezultatai pateikti 4.6 paveiksle.



4.6 pav. Standartinės mokymosi kreivės (1) ir pasikartojančio mokymosi (2) palyginimas

Kaip matoma iš rezultatų, užsakymų perkėlimas (prastas planavimas) turi didžiulę įtaką galutiniam gaminio surinkimo laikui neautomatizuotame gamybos procese. Jei gaminyt būtų gamintas tame pačiame padalinyje, laikas būtų buvęs 3443 valandos, tačiau, kadangi jis buvo perkėlinėjamas, laikas pailgėjo iki 6683 valandų tam pačiam produktui pagaminti.

Šie rezultatai ne tik patvirtina pasiūlyto pasikartojančio mokymosi modelio adekvatumą, bet ir atskleidžia, kaip techniškai gerai paruoštas ir sinchronizuotas procesas gali būti „sugadintas“ prasto planavimo. Be to, pasiūlytas modelis taip pat parodo ne techninę mokymosi kreivės taikymo svarbą.


4.6. Eksperimentinis proceso skaidymo tyrimas

Pasiūlyta ir pagrįsta sudėtingo proceso skaidymo metodologija buvo išbandyta realiai gamyboje. Eksperimentui buvo pasirinktas sudėtingas gaminyt, kurį sudaro 570 laidininkų ir kitų komponentų, kurie turi būti surenkamai ant

surinkimo stendo. Prieš atliekant patį eksperimentą, turėjo būti nustatyti papildomi parametrai:

- Standartinis surinkimo laikas T_c ;
- Stabilizacijos taškas x_c ;
- Mokymosi kreivės parametrai.

Naudojantis jau šiame darbe pasiūlytais ir pagrįstais metodais (parametru atstatymo, kreivės su stabilizacija modeliu ir kt.), visi reikalingi parametrai buvo nustatyti: $c_T = 2.0$, $c_\alpha = 0.32$, $c_{xc} = 1000$, $c_{Te} = 0.3$.




4.7 pav. Proceso skaidymo į 4 dalis pavyzdys

Buvo išbandyti keli skirtingi surinkimo būdai, t. y. sudėtingas gaminyš buvo renkamas neskaidytas, po to atitinkamai suskaidytas į kelias dalis ir kiekvienu atveju buvo atliekami gamybiniai matavimai. Skaidymo principas pateiktas 4.7 paveiksle.

Taigi, šiam pasirinktam gaminiui, greta gamybos eksperimentų, skaidant procesą į 1, 2, 3, 5 ir 10 dalių, buvo suskaičiuotas surinkimo laikas pagal pasiūlytą modelį iki 20 dalių (vieno kintamojo optimizavimas). Gamintas užsakymo dydis – 50 vnt. Skaičiavimo ir matavimo rezultatai pateikti 4.8 paveiksle.

Kadangi gamybos eksperimente naudotas 50 vnt. gamybos užsakymas, šie duomenys buvo panaudoti įvertinti ir kitiems užsakymo dydžiams t. y. kai n yra 5, 15 ir 30. Visi rezultatai pateikti 4.8 paveiksle. Vertinant eksperimento

rezultatus, akivaizdu, kad tik vienas iš eksperimentų ($n=15$) atitinka apskaičiuotą minimumą. Kitais atvejais eksperimento duomenys tik apytiksliai sutampa su apskaičiuotu modeliu. Todėl tai, tam tikra prasme, komplikuoja išvadą apie adekvatumo patvirtinimą ir reikalauja papildomų diskusijų ir pagrindimo. Atidžiau žvelgiant į duomenis, matyti, kad didesnės n ir p vertės rodo daug didesnius nesutapimus. Kitaip tariant, daugiau darbo stotelių lemia tai, kad atsiranda daugiau atsitiktinių paklaidų, ypač perduodant pusgaminių iš vienos darbo stotelės į kitą. Taip pat reikia paminėti, kad didesni gamybos kiekiai reiškia, kad surinkimo laikas artėja prie nustatyto standartinio, o mokymosi laikas artėja prie nulio. Todėl visos nenormalios surinkimo situacijos (iškritę komponentas, susipainioję laidai ir pan.) nebegali būti įskaičiuotos į mokymosi laiką ir yra iš karto matomos ir lemia nesutapimą.



4.8 pav. Apskaičiuotas surinkimo laikas ir realūs gamybiniai duomenys. 1 – gamybiniai duomenys. 2 - $T(p,50)$; 3 - $T(p,30)$; 4 - $T(p,15)$; 5 - $T(p,5)$; 6 – apskaičiuoti minimumo taškai

Apibendrinant tyrimo rezultatus galima konstatuoti, kad tyrimo duomenys tik apytiksliai sutampa su realiais gamybiniais duomenimis. Tačiau žinant visas darytas prielaidas, atsitiktines paklaidas ir kitus trukdžius, galima daryti galutinę išvadą, kad pasiūlytas modelis tikrai rodo pakankamai gerus rezultatus ir tokiu būdu patvirtina savo adekvatumą.

5. BENDROSIOS IŠVADOS

1. Darbe visiškai apibrėžti metodai disertacijos uždaviniams atlikti. Šiame darbe, kaip tipinis rankinio surinkimo atvejis, pasirinktas laidų pynių surinkimas bei išsamiai pristatyti jo aspektai. Taip pat išsamiai aptartos laidų pynių surinkimo technologijos. Nustatyta, kad pagrindinė problema yra tinkamas proceso skaidymo dalių pasirinkimas. Be to, darbe sudarytas matematinis, operacijas ir standartinį surinkimo laiką tiesiogiai siejantis modelis. Šis modelis leidžia modeliuoti surinkimo procesą, paskirstyti operacijas tolygiai tarp proceso dalių. Jis yra naudojamas kaip standartinio laiko skaičiavimo metodas. Standartinis laikas yra vienas iš pagrindinių, laidų pynių surinkimo parametrų, reikalingų modeliavimui. Remiantis šiuo standartiniu laiku bei OEE metodu, suformuluotas našumo optimizavimo uždavinys ir šiame uždavinyje mokymosi laikas yra įtrauktas taip, kad jo sumažinimas lemia našumo didėjimą. Taip pat pasiūlytos kelios metodikos gamybinių duomenų surinkimui, kurios bus naudojamos modelių adekvatumui įvertinti.

2. Šiame darbe sukurta keletas naujų MK modelių, kurie tiksliau aprašo surinkimo laiko kitimą. Pirmiausia darbe pasiūlytas adekvatus, matematiškai pagrįstas mokymosi kreivės su stabilizacija modelis. Visos, modelį pagrindžiančios prielaidos ir jų korektiškumas yra pagrįstos. Taigi, turint tikrai vieną išmatuotą duomenų tašką ir stabilizacijos laiką, MK gali būti vienareikšmiškai nustatytas. Tai leidžia numatyti surinkimo laiko stabilizaciją ateityje. Taip pat, pasiūlytas modelis leidžia prognozuoti surinkimo laiko kitimą turint tikrai standartinį gaminio surinkimo laiką ir numatomus MK parametrus. Tam reikia kombinuoti šį modelį su parametru nustatymo metodais (kurie taip pat pasiūlyti šioje disertacijoje). Kitas, naujas modelis, yra pasiūlytas „beveik mokymosi kreivės“ (BMK) modelis. Pasiūlytas BMK modelis yra paremtas specialios (su perturbacijos parametru) diferencialinės lygties sprendiniu. Papildomas kintamasis (perturbacijos parametras) atveria daug didesnių universalumo ir taikymo galimybių. BMK modelis turi visas KMK modelio savybes. Be to, toks MK nagrinėjimas (per diferencialinę lygtį), atveria visiškai naujas MK taikymo galimybes. Tokiu pat pagrindu yra išvestas kitas, naujas modelis: „mokymosi-nuovargio“ modelis. Kaip ir BMK atveju, modelis yra gautas naudojantis diferencialine lygtimi ir perturbacijos parametru. Tik šiuo atveju, perturbacijos parametras apibrėžia vibracijų ir pasikartojančių judesių įtaką tiek žmogaus sveikatai, tiek jo darbo spartai. Be to, pasiūlytas modelis leidžia numatyti operatoriaus darbingumo praradimą ir atveria galimybes rotacijai, kai darbuotojas atliko tam tikrų, rizikingų operacijų skaičių. Dar vienas naujas, pasiūlytas MK modelis – pasikartojančio mokymosi modelis, panaudotas planavimo įtakai įvertinti. Esant prastam planavimui, sudėtingi gaminiai yra perkėlinėjami iš vieno gamybinio padalinio į kitą – atsiranda pasikartojantis mokymasis. Taikant analitinį įrankį iš anksto paskaičiuojama perkėlimo

perkėlimo įtaka surinkimo laikui. Kita svarbi išvada yra tai, kad techniškai gerai paruoštas ir sutvarkytas procesas gali būti „sugadintas“ prasto planavimo.

3. Šiame darbe yra pasiūlyti deterministiniai MK parametrų nustatymo metodai. Taip pat apibrėžtos aiškios taikymo sąlygos tiek statistinių, tiek deterministinių parametrų atstatymo metodų taikymui. Kitų autorių darbuose šių sąlygų apibrėžimas būdavo praleidžiamas, o statistiniai metodai būdavo taikomi nekorektiškai. Darbe pasiūlytų metodų taikymas yra paprastas, todėl jie gali būti nesunkiai taikomi realiose situacijose. Kadangi taikoma MK gali skirtis skirtingiems operatoriams, toks paprastumas taikant modelius gali būti sėkmingai naudojamas tokiems skirtumams efektyviai nustatyti.

4. Rankinio surinkimo proceso našumo optimizavimo uždavinys suformuluotas ir išspręstas naudojant proceso skaidymo modelį. Modelis yra paremtas mokymosi kreive su stabilizacija, kuri taip pat yra pasiūlyta šioje disertacijoje. Analitiniais tyrimais patvirtinta, kad egzistuoja tam tikras proceso dalių skaičius, kuriam esant, surinkimo laikas bus minimalus. Iš kelių, darbe suformuluotų apibendrintų optimizavimo uždavinių, du turi reikšmingas taikymo praktikoje galimybes. Pirmasis yra vieno kintamojo optimizavimo uždavinys optimaliam proceso dalių skaičiui p surasti. Matematiškai buvo įrodyta, kad šis optimizavimo uždavinys turi globalinį minimumą. Antrasis, svarbus dviejų kintamųjų optimizavimo uždavinys su normuota laiko funkcija, yra skirtas nustatyti ir optimalų skaidymo dalių skaičių p ir optimalų partijos dydį n . Matematinė analizė parodė, kad tikslo funkcija yra monotoninė, o globalusis minimumas neegzistuoja. Tačiau, mažiausia funkcijos vertė, kuri patenka į leistiną sritį G , vis tiek gali būti apskaičiuota. Tai atveria svarbią galimybę kombinuoti šį modelį su kitais, surinkimo linijų sinchronizavimo metodais. Tai ir sudaro pagrindą tolimesnėms studijoms.

5. Šiame tyrime pasiūlytų metodų adekvatumui patikrinti, buvo atliktas proceso laikų stebėjimas, laidų pynių surinkimą atliekančioje įmonėje. Rezultatai pagrindžia prielaidą apie surinkimo laiko stabilizacijos fenomeno egzistavimą, t. y., surinkimo laikas mažėja iki tam tikros ribos T_C . Lyginant gamybinius duomenis su pasiūlytu metodu, matyti, kad modelis pakankamai tiksliai juos aprašo, santykinės paklaidos yra gana mažos (ne didesnės kaip 5 %). Tai patvirtina modelio adekvatumą. Pasiūlytas BMK modelis buvo išbandytas su įvairiais gamybiniais duomenimis. Ištirtos trys skirtingos situacijos: pasikartojantys užsakymai, pasikartojantys per pakankamai ilgą laiką, prototipų užsakymai bei dideliu kiekiu gaminami užsakymai. Taikymo gamyboje rezultatai patvirtina tiek pasiūlyto modelio adekvatumą (paklaidos ne didesnės kaip 5 %), tiek universalumą – BMK modelis geriau aprašo realius gamybinius duomenis negu standartinis KMK modelis. Be to, taikymo gamyboje rezultatai rodo, kad pasiūlytas „mokymosi-nuovargio“ modelis aprašo realius gamybinius duomenis gana tiksliai. Santykinė paklaida ne didesnė kaip 5 %. Deterministinių parametrų nustatymo metodų taikymo gamyboje rezultatai

parodė, kad ir tokiu atveju parametrai gali būti pakankamai tiksliai nustatomi naudojant ne statistinius, matematiškai pagrįstus metodus. Pateikti pavyzdžiai atskleidžia, kaip deterministiniai metodai rodo gana adekvačius rezultatus tiek vienietiniams, tiek kaupiamojo vidurkio duomenims tik iš vieno duomenų rinkinio (paklaidos ne didesnės kaip 5 %). Modelių palyginimas rodo, kad kaupiamuoju vidurkiu paremti atstatymo metodai yra tikslesni, nes kaupiamasis vidurkis, dar prieš parametų atstatymą, tam tikru laipsniu suglodina gamybinius duomenis. Naudojantis pasiūlytais metodais, parametrai buvo apskaičiuoti daugybei skirtingų automobilinių pynių. Buvo nustatyta, kad parametrai (mokymosi koeficientas ir pirmojo gaminio surinkimo laikas) yra labai skirtingi: kuo gaminiai sudėtingesni (daugiau komponentų), tuo parametrai didesni. Vieno kintamojo optimizavimo uždavinys buvo išbandytas realioje gamybinėje situacijoje. Išanalizavus rezultatus išaiškėjo, kad pasiūlytas modelis tik apytiksliai aprašo matuotus gamybinius duomenis. Kita vertus, vertinant visas prielaidas, didžiulį rankinio darbo kiekį, atsitiktines paklaidas, konstatuojama, kad modelio taikymo rezultatai yra pakankamai geri. Todėl galima teigti, kad neskaidomas didelių, sudėtingų gaminių surinkimas yra neefektyvus dėl pernelyg didelio mokymosi laiko, o surinkimo skaidymas netgi į nedidelį dalių skaičių sumažina galutinį surinkimo laiką; kitavertus per didelis proceso dalių skaičius šį laiką vėl imtų didinti – taigi, egzistuoja optimumas. Visi disertacijoje iškelti uždaviniai atlikti, todėl galima teigti, kad disertacijos tikslas pasiektas.

LITERATŪRA

1. ABDULLAH, T. A., POPPLEWELL, K. and PAGE C. J. A review of the support tools for the process of assembly method selection and assembly planning. *International Journal of Production Research*, 2003, 41(11), 2391–2410.
2. BEVIS, F. V., FINNIEAR, C., TOWILL, D. R. Prediction of Operator Performance During Learning of Repetitive Tasks. *International Journal of Production Research*. 1970, 8(4), 293-305.
3. BOOTHROYD, G. and DEWHURST, P. *Product design for manufacture and assembly*. New York: CRC Press, Taylor & Francis Group, 2002.
4. FOGLIATTO, F. S. and ANZANELLO, M. J. Learning Curves: The State of the Art and Research Directions. In M.Y Jaber (Ed.), *Learning Curves: Theory and models, and applications*. FL, Boca Raton: CRC Press, Taylor and Francis Group, 2011. pp. 3-23
5. GABEL, T. and RIEDMILLER, M. Distributed policy search reinforcement learning for job-shop scheduling tasks. *International Journal of production research*. 2012, 50(1), 41-61.

6. GLOCK C.H., JABER M.Y. and ZOLFAGHARI, S. Production planning for a ramp-up process with learning in production and growth in demand. *International Journal of Production Research*. 2012, 50(20), 5707-5718.

7. HEIZER and RENDER. *Operations Management*. Pearson: Prentice Hall, 2006.

8. KUMAR, R. S. and GOSWAMI A. EPQ model with learning consideration, imperfect production and partial backlogging in fuzzy random environment. *International Journal of Systems Science*. 2015, 46(8), 1486–1497.

9. WRIGHT, T. P., Factors affecting the cost of airplanes. *Journal of the Aeronautical Sciences*. 1936, 3(4), 122-128.

AUTORIAUS PUBLIKACIJOS DISERTACIJOS TEMA

Mokslinės informacijos instituto duomenų bazės „ISI Web of Science“ leidiniuose, turinčiuose citavimo indeksą

1. Kleiza, Vytautas; Tilindis, Justinas. Log-linear learning model for predicting a steady-state manual assembly time // Nonlinear analysis: modelling and control / Lithuanian Association of Nonlinear Analysis (LANA), Lithuanian Academy of Sciences. Vilnius: Institute of Mathematics and Informatics. ISSN 1392-5113. 2014, Vol. 19, no. 4, p. 592-601. DOI: 10.15388/NA.2014.4.5. [Science Citation Index Expanded (Web of Science); Index Copernicus; Inspec; Zentralblatt MATH]. [0,500]. [IF (E): 1,099 (2014)]
2. Tilindis, Justinas; Kleiza, Vytautas. Impact of vibrations to the human fatigue and manual assembly performance // Journal of vibroengineering / Vibromechanika, Lithuanian Academy of Sciences, Kaunas University of Technology, Vilnius Gediminas Technical University. Kaunas: Vibroengineering. ISSN 1392-8716. 2015, vol. 17, iss. 7, p. 3919-3927. [Science Citation Index Expanded (Web of Science); Inspec; Academic Search Complete; Central & Eastern European Academic Source (CEEAS); Computers & Applied Sciences Complete; Current Abstracts; TOC Premier]. [0,707]. [IF (E): 0,617 (2014)]

Kitų tarptautinių duomenų bazių leidiniuose

1. Kleiza, Vytautas; Tilindis, Justinas. Application of LEAN production system tools for manual assembly process improvement // Mechanika 2012: proceedings of the 17th international conference, 12, 13 April 2012, Kaunas University of Technology, Lithuania / Kaunas University of Technology, Lithuanian Academy of Science, IFTOMM National Committee of Lithuania, Baltic Association of Mechanical Engineering.

- Kaunas: Technologija. ISSN 1822-2951. 2012, p. 130-133. [Conference Proceedings Citation Index]. [0,500]
2. Kleiza, Vytautas; Tilindis, Justinas. Problems of new technology and systems introduction into production: LEAN case // Intelligent technologies in logistics and mechatronics systems, ITELMS'2012: proceedings of the 7th international conference, May 03-04, 2012, Panevėžys, Lithuania / Kaunas University of Technology Panevezys Institute, Panevezys Technology and Science Park, Intelligent Transport Systems, Poland, Tallin University of Technology, Riga Technical University. Kaunas: Technologija, 2012. ISBN 9786090205716. p. 105-109. [Conference Proceedings Citation Index]. [0,500]
 3. Tilindis, Justinas; Kleiza, Vytautas. The effect of learning factors due to low volume order fluctuations in the automotive wiring harness production // Procedia CIRP : Robust manufacturing conference (RoMaC 2014). Amsterdam: Elsevier Science. ISSN 2212-8271. 2014, Vol. 19, 129-134. DOI: 10.1016/j.procir.2014.05.019. [Conference Proceedings Citation Index; Science Direct]. [0,500]
 4. Tilindis, Justinas; Kleiza, Vytautas. Mathematical modeling of production operations and processes for product design and manufacturing // Applied Mechanics and Materials: Materials Engineering for Advanced Technologies (ICMEAT 2013). Stafa-Zurich: Trans Tech Publications Ltd. ISSN 1660-9336. 2014, Vol. 510, p. 243-247. DOI: 10.4028/www.scientific.net/AMM.510.243. [Conference Proceedings Citation Index]. [0,500]

Kituose recenzuojamuose mokslo leidiniuose paskelbti straipsniai

1. Kleiza, Vytautas; Tilindis, Justinas. The optimization of the overall learning dependent manual assembly efficiency // Intelligent technologies in logistics and mechatronics systems, ITELMS'2014 : proceedings of the 9th international conference, May 22-23, 2014, Panevėžys, Lithuania / Kaunas University of Technology. KTU Panevezys Faculty of Technologies and Business, Military University of Technology, Tallin University of Technology, Riga Technical University. Kaunas: Technologija. ISSN 2345-0088. 2014, p. 159-161. [0,500].
2. Tilindis, Justinas. Optimization of the total production efficiency by manual assembly processes modeling // Intelligent technologies in logistics and mechatronics systems, ITELMS'2015 : proceedings of the 10th international conference, May 21-22, 2015, Panevezys, Lithuania / Edited by Z. Bazaras, V. Kleiza. Kaunas: Technologija. ISSN 2345-0088. 2015, p. 270-272. [1,000].

INFORMACIJA APIE AUTORIŲ

Justinas Tilindis gimė 1986 metais Panevėžyje.

2005 metais baigė Panevėžio Kazimiero Paltaroko vidurinę mokyklą.

2009 metais su pagyrimu baigė mechanikos inžinerijos bakalauro studijas Kauno technologijos universitete, Technologijų fakultete.

2011 metais su pagyrimu baigė mechanikos inžinerijos magistro studijas Kauno technologijos universitete, Technologijų fakultete.

2011–2015 metais studijavo doktorantūros studijose Kauno technologijos universitete, Mechanikos ir dizaino fakultete (Technologijos mokslai, mechanikos inžinerija, 09T)

Elektroninis paštas: jtilt@yahoo.com

ABSTRACT

The manual assembly as a manufacturing technology is being widely replaced by robotic and automated equipment; however there are still many production fields where mechanical human work is inevitable due to a variety of reasons. These reasons include, but are not limited to, labor cost, production volumes, cost of equipment, task complexity, dangerous working environments and etc. Since human work is involved, the assembly time is highly affected by cognitive human factors, i.e. the learning phenomenon. This phenomenon defines operating time decrement as the human operator becomes more familiar with the task. The time improvement is defined by a learning curve. Learning curve models have been known for several decades. Initially, they were based on a study of the processing time decrement, as manufacturing continues to forecast time (or cost) decrements achieved by large production volumes. It is very important to emphasize that a long time trend in the manufacturing industry clearly shows the fall of mass production and spread of mass customization. Therefore, manufacturing companies are forced to reduce order quantities, increase product variety and shorten production lead times. In manual assembly, when the order quantities are small, intermittent and even occasional, there is no possibility of completing the learning phase, so production is always at the start-up (learning) phase i.e. at the beginning of the learning curve. As a result, the processing time is not stable, also fluctuating and much higher than the calculated standard production time. This is one of the major events why interest in the learning effect increased and re-emerged among production researchers recently. To sum up, this topic is very important in manufacturing engineering.

In this research, the manual assembly process as the manufacturing technology with small production lots is studied and the major technological process parameter (assembly time) is addressed. As the operating time in such a manufacturing technology is highly affected by learning, the analysis, modelling and development of the learning curve is the main topic of the dissertation.

The goal of the work is to optimize (increase) manual assembly process efficiency by modelling process parameters. In order to achieve the goal, the following **tasks** were established:

1. Define the appropriate research methodology in the context of manufacturing engineering.
2. Develop and apply new mathematical learning models that adequately approximate the operating time development (reduction) of the manufacturing process.
3. Create methodology to estimate parameters of the learning curve from limited production data.
4. Define, state and solve the manual assembly process efficiency optimization problem by employing appropriate LC models proposed in this dissertation.
5. Perform production data monitoring to test, evaluate and prove the adequacy of the proposed models.

The dissertation consists of an Introduction, 4 sections, general conclusions, list of references, list of the author's publications and conferences in the topic of the dissertation. The first section is dedicated to the review of the manual assembly process modelling for both operations and process level. In the beginning of the section, the general trends in manufacturing systems were addressed to understand recent developments. Operational improvements are also considered as well as process modelling. However, the major part is dedicated to the review of the learning curve: current models, complexity implications and manufacturing applications. A completed review of previous research confirms the tasks of the dissertation and also points out clear gaps in current literature, since most of the currently known learning curve models are dedicated for mass production and also learning itself is perceived as a factor to be calculated rather than eliminated.

In the second section, a full methodology to complete both analytical and experimental research is presented. Firstly, the automotive wiring harness is fully defined, regarding terminology, components, assembly technology and process design. Another important part of the section is dedicated to the assembly time calculation. Moreover, the optimization problem to increase efficiency by reducing learning time is stated and learning time is posed as waste in this way. Some insights and directions for appropriate model selection for development, production data monitoring methodology and adequacy evaluation methodology are presented in this section as well.

The third section is dedicated to the most important part of the dissertation, analytical research, with two major topics covered: development of new models and the development of deterministic methods of learning curve parameter recovery. Regarding parameter recovery methods, several of them were

developed to estimate parameters from the limited production data. Regarding new model developments, the following models were created: Plateau learning model with stabilization, Almost Learning Curve (ALC) model, learning-fatigue model, reoccurring learning model and the process splitting model, which is actually the goal of the work. All models were mathematically proved and grounded.

The fourth section is dedicated to experimental research. To perform the experiments, a case study in a certain manufacturing company was conducted. The goal of the case study was to evaluate the adequacy of the proposed analytical models (for new learning curve models, parameter recovery methods and process splitting). Comparison between calculations and real life data confirmed the adequacy with only small relative error values for all the models and methods proposed.

UDK 621.717 + 658.515]:519.87(043.3)

SL344. 2016-04-26, 2,5 leidyb. apsk. l. Tiražas 50 egz. Užsakymas 179.

Išleido Kauno technologijos universitetas, K. Donelaičio g. 73, 44249 Kaunas
Spausdino leidyklos „Technologija“ spaustuvė, Studentų g. 54, 51424 Kaunas