



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Elektronikos gaminių gamybos procesų trukmės nustatymo sistemos kūrimas ir tyrimas

Baigiamasis magistro projektas


Marius Galbuogis

Projekto autorius

lekt. dr. Vygandas Vaitkus

Vadovas

Kaunas, 2022



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Elektronikos gaminių gamybos procesų trukmės nustatymo sistemos kūrimas ir tyrimas

Baigiamasis magistro projektas

Valdymo technologijos (6211EX014)

Marius Galbuogis

Projekto autorius

lekt. dr. Vygandas Vaitkus

Vadovas

lekt. dr. Kęstas Rimkus

Recenzentas

Kaunas, 2022



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Marius Galbuogis

Elektronikos gaminių gamybos procesų trukmės nustatymo sistemos kūrimas ir tyrimas

Akademinio sąžiningumo deklaracija

Patvirtinu, kad:

1. baigiamąjį projektą parengiau savarankiškai ir sąžiningai, nepažeisdama(s) kitų asmenų autoriaus ar kitų teisių, laikydamasi(s) Lietuvos Respublikos autorių teisių ir gretutinių teisių įstatymo nuostatų, Kauno technologijos universiteto (toliau – Universitetas) intelektinės nuosavybės valdymo ir perdavimo nuostatų bei Universiteto akademinės etikos kodekse nustatytų etikos reikalavimų;
2. baigiamajame projekte visi pateikti duomenys ir tyrimų rezultatai yra teisingi ir gauti teisėtai, nei viena šio projekto dalis nėra plagijuota nuo jokių spausdintinių ar elektroninių šaltinių, visos baigiamojo projekto tekste pateiktos citatos ir nuorodos yra nurodytos literatūros sąrašė;
3. įstatymų nenumatytų piniginių sumų už baigiamąjį projektą ar jo dalis niekam nesu mokėjęs (-usi);
4. suprantu, kad išaiškėjus nesąžiningumo ar kitų asmenų teisių pažeidimo faktui, man bus taikomos akademinės nuobaudos pagal Universitete galiojančią tvarką ir būsiu pašalinta(s) iš Universiteto, o baigiamasis projektas gali būti pateiktas Akademinės etikos ir procedūrų kontrolieriaus tarnybai nagrinėjant galimą akademinės etikos pažeidimą.

Marius Galbuogis

Patvirtinta elektroniniu būdu

Galbuogis, Marius. Elektronikos gaminių gamybos procesų trukmės nustatymo sistemos kūrimas ir tyrimas. Magistro baigiamasis projektas / vadovas lekt. dr. Vygandas Vaitkus; Kauno technologijos universitetas, Elektros ir elektronikos fakultetas.

Studijų kryptis ir sritis (studijų krypčių grupė): elektronikos inžinerija, inžinerijos mokslai

Reikšminiai žodžiai: klasifikavimas, prognozavimas, gamyba.

Kaunas, 2022. 47 p.

Santrauka

Modernėjant elektroninėms sistemoms ir gilėjant įrangos integracijai į pramonės įmonių duomenų bazes fiksuojamas ir kaupiamas vis didesnis duomenų kiekis. Šie duomenys dažnu atveju naudojami kaip rezultatai arba medžiaga praeities atvejų tyrimams, kitaip tariant jie yra naudojami *reaktyviems* veiksams. Baigiamojo projekto tikslas yra įmonių kaupiamus istorinius gamybos rezultatų duomenis naudoti ne tik praeities rezultatų fiksavimui ar analizei, bet juos paversti į *išteklį*, kuriuo remiantis būtų galima nustatyti naujų gaminių gamybos trukmę elektronikos surinkimo pramonėje.

Pasirinkta analizuoti kaip dabar vertinama gamybos trukmė elektronikos gamybos įmonėje Kitron. Pristatomas gamybos procesas, darbuotojų laiko raportavimas, įmonės procese vertinamos gaminių charakteristikos ir svarbiausių gamybinių operacijų atrinkimas. Supažindinama su duomenų struktūra ir pristatomas galimas sprendimas kaip patobulinti trukmės vertinimo procesą, įvedant trukmės nustatymo sistemą, paremtą istorinių duomenų klasifikavimu.

Tyrimo objektu pasirinkta paviršinių komponentų montavimo operacija, kaip turinti didžiausią įtaką įmonės finansiniams rezultatams. Taip pat, įmonės duomenų bazėje yra kaupiama daugiausia su šiuo procesu susijusių duomenų, kuriuos galima išnaudoti klasifikavimo metodų apmokymui. Tyrimui reikalingi duomenys buvo paimti iš įmonės Kitron duomenų bazės. Vertinti gaminiai, kurių gamyba vyko 2021 metais. Viso tyrime naudota informacija apie virš 5000 gamybos partijų ir virš 500 unikalių gaminių. Duomenų rinkimo ir apdorojimo metu buvo traukiama informacija iš įvairių informacinės sistemos raportų, teikiančių informaciją apie gaminių sudedamąsias dalis, jų gamybinius rezultatus ir kitas charakteristikas, kurios turi įtakos gamybos trukmei. Įvertintas trukmių netolygumas gaminant tą patį gaminį skirtingose partijose, ir greta aritmetinio trukmių vidurkio, panaudota trukmių mediana bei trukmės vidurkis pritaikius 1 Sigma taisyklę. Agreguotiems duomenims priskirtos klasės, paremtos trukmių ruožais. Vertinti trys trukmių ruožai – 30 s, 10 s ir 5 s. Klasių trukmių ruožai parinkti atsižvelgiant į sistemos tikslą – trukmės prognozavimą. Taip pat siekta, kad klasės būtų suprantamos galutiniams naudotojams. Rezultate sudaryti devyni atskiri duomenų rinkiniai.

Naudojant MATLAB programinį paketą išbandyta virš 20 klasifikavimo metodų su devyniais duomenų rinkiniais. Kiekvienam duomenų rinkiniui pristatyti rezultatai su geriausiai veikiančiu klasifikavimo metodu. Taip pat ištirti svarbiausi trukmei įtaką darantys kintamieji.

Trukmės nustatymo sistemos įvertinimui panaudoti gaminiai nepatekė į klasifikavimo metodų apmokymų duomenų rinkinius. Pristatytas palyginimas tarp įmonės skaičiuoklės pateikto laiko, kurtos sistemos siūlytos klasės – laiko ruožo ir faktinių gamybos rezultatų. Pastebėta, kad geriausiai veikia *Linear SVM* klasifikavimo metodas su 30 s laiko intervalu - klase.

Galbuogis, Marius. Development and Investigation of a System for Determining the Duration of Electronic Manufacturing Processes. Master's Final Degree Project / supervisor lect. dr. Vygandas Vaitkus; Faculty of Electrical and Electronics Engineering, Kaunas University of Technology.

Study field and area (study field group): electronics engineering, engineering science;

Keywords: classification, forecasting, manufacturing

Kaunas, 2022. 47 p.

Summary

Developments in electronic systems and advances of industrial equipment integration into enterprise databases means constantly increasing amount of accumulated data. Currently this data is often used to represent results, meaning they are used in reactive actions. The goal of this Final Degree Project is to use the historical data not only for representation or analysis of past results but turn them into a resource that could be used to determine production time of new products in the electronics manufacturing industry.

The field of electronics manufacturing is chosen for analysis in this Final Degree Project, primarily in the company Kitron. A short presentation of manufacturing processes, employee time registration and current method for evaluating production time is given. Also noted is the method of determining the most financially important manufacturing processes. Examples of how production data and structure is given. Finally, a classification-based production time determining system is proposed as an improvement to the current company process of determining production time.

Surface component mounting process is chosen as an object for classification because it has the greatest impact on the company's financial results. In addition, the company database has the biggest amount of data on this process when compared to others. This data allows to develop and train classification methods. Because of various data reports, formatting etc., data aggregation and preprocessing had to be performed, compiling information on each production batch together with related data on products, actual production times, product structures and other characteristics that might have impacted production time. The unevenness of durations in the production of the same product in different batches was observed. Median value of the duration and filtering of the production batches using 1 sigma rule were introduced in addition to the average of the durations. Classes were assigned to aggregated data based on duration segments. Three stretches of duration at 30 s, 10 s and 5 s were evaluated. The durations of the classes are selected according to the purpose of the system - duration prediction as well as simple interpretation by the end user.

Classification methods with nine data sets were tested using the MATLAB software package. The results with the best-performing classification method are presented for each data set. Most important features were evaluated.

The products used to evaluate the duration determination system were not included in the training datasets of the classification methods. A comparison between the time provided by the company's calculator, the class proposed by the developed system and the actual production results is presented. The best performing classification method was Linear SVM, while using the 30 s time class.

Turinys

Lentelių sąrašas	8
Paveikslų sąrašas	9
Terminų ir santrumpų žodynas	10
Įvadas	11
1. Literatūros analizė	12
1.1. Sprendimų paramos sistemos	12
1.2. Atvejais pagrįsti sprendimai	13
1.3. Prognozavimas	14
1.3.1. Prognozavimo etapai	14
1.3.2. Gamybos trukmės prognozavimas	14
1.4. Duomenų klasifikavimas	15
1.4.1. Klasifikavimas	15
1.4.2. Klasifikavimo naudojimas gamybos duomenims.....	17
1.4.3. Klasifikavimo metodai	17
1.4.4. Klasifikavimo trūkumai.....	18
1.5. Nuspėjamoji analizė	19
2. Atvejo analizė	20
2.1. Įmonės gamybos proceso apžvalga	20
2.1.1. Gaminių ir gamybos proceso pavyzdys.....	20
2.1.2. Laiko raportavimas ir trukmės skaičiavimas	21
2.2. Elektronikos gaminių gamybos trukmės nustatymas	21
2.2.1. Dabartinio įmonės proceso vertinamos charakteristikos.....	21
2.2.2. Gamybos procesų trukmės vertinimas ir skaičiavimas.....	22
2.2.3. Vertinimo klaidų vertė.....	22
2.2.4. Gamybinių operacijų atrinkimas	23
2.2.5. Gaminių charakteristikų atrinkimas.....	24
2.2.6. Analizuojami duomenys	25
2.3. Siūlomas sprendimas	25
2.3.1. Trukmės nustatymo sistema	25
2.3.2. Sprendimų paramos sistemos veikimo principas.....	25
2.3.3. Sprendimų paramos sistemos panaudojimas ir panaudos atvejų diagrama.....	26
2.3.4. Sprendimų paramos sistemos apribojimai	28
2.3.5. Tyrime naudojamų duomenų struktūra	28
2.3.6. Siekiami rezultatai	29
3. Tyrimas	30
3.1. Tyrimo eiga	30
3.1.1. Naudota programinė įranga	30
3.2. Gamybos operacijų atrinkimas trukmės nustatymui	30
3.3. Duomenų surinkimas ir apdorojimas.....	31
3.3.1. Duomenų šaltiniai.....	32
3.3.2. Ekspertinių žinių pritaikymas agreguojamiems duomenims.....	33
3.3.3. Gamybos operacijų agregavimas	33
3.3.4. Gaminių struktūrų agregavimas.....	33
3.3.5. Gaminių charakteristikų atrinkimas.....	34

3.3.6. Vertinami kintamieji.....	34
3.3.7. Trukmės vidurkis, mediana ir standartinio nuokrypio pritaikymas.....	35
3.3.8. Duomenų apribojimai.....	35
3.4. Klasių priskyrimas.....	35
3.4.1. Statistinių duomenų klasifikavimas.....	35
3.4.2. Klasių tikslumas.....	36
3.5. Tinkamiausio klasifikavimo metodo parinkimas.....	36
3.6. Tyrimo rezultatai.....	36
3.6.1. Klasifikatoriaus tikslumas naudojant skirtingus duomenų apdorojimo metodus.....	36
3.6.2. Tiksliausių metodų atrinkimas.....	41
3.6.3. Svarbiausių kintamųjų nustatymas.....	41
3.7. Testavimas.....	42
3.8. Rekomendacijos praktiniam taikymui.....	43
Išvados ir rezultatai.....	44
Literatūros sąrašas.....	45
Priedai.....	48

Lentelių sąrašas

1 lentelė. SPS matrica	12
2 lentelė Skirtingų operacijų įkainiai	23
3 lentelė Gaminų charakteristikų įtaka gamybos trukmei.....	24
4 lentelė Gaminio charakteristikų parinkimas.....	24
5 lentelė Planuojamų naudoti duomenų pavyzdys	26
6 lentelė. ERP raporto rodančio vienos gamybos partijos statistiką pavyzdys	29
7 lentelė. Agreguotų duomenų rinkinio ištrauka.....	32
8 lentelė Skaičiuoklėje naudojamų trumpinių paaiškinimas.....	32
9 lentelė. Kintamųjų įtaka gamybos trukmei	34
10 lentelė. Sudaryti duomenų rinkiniai	36
11 lentelė Skirtingų klasifikavimo metodų tikslumo palyginimas.....	41
12 lentelė. Kintamųjų svarbumas pagal skirtingus metodus.....	42
13 lentelė. Klasifikavimo metodų palyginimas su įmonės skaičiuokle ir realia trukme.....	42

Paveikslų sąrašas

1 pav. Klasifikavimo metodo schema	16
2 pav. Sprendimų medžio pavyzdys	17
3 pav. Surinktos spausdintinės plokštės pavyzdys	20
4 pav. Standartinių gamybos procesų eigos schema.....	20
5 pav. Metiniai skirtingų gamybos operacijų nuostoliai esant 10 s klaidai vertinime	22
6 pav. Išteklių valdymo sistemoje esančių įkainių tipų iškarpa	23
7 pav. Gaminio gamybinių operacijų trukmės raportas.....	25
8 pav. Sprendimų paramos sistemos panaudojimo ir veikimo schema	26
9 pav. Gamybos efektyvumo analizės procesas	27
10 pav. Gamybos konkurso procesas su siūlomu patobulinimu.....	27
11 pav. Sprendimų paramos sistemos panaudos atvejų diagrama.....	28
12 pav. Skirtingų proceso trukmės vertinimo metodų palyginimo pavyzdys	29
13 pav. Paviršinių komponentų montavimo gamybos linija	31
14 pav. Komponentų tipo priskyrimas įmonės skaičiuoklėje.....	32
15 pav. Klasifikavimo tikslumas naudojant 30 s žingsnį ir <i>Linear SVM</i> metodą.....	37
16 pav. Klasifikavimo tikslumas naudojant 10 s žingsnį ir <i>Cubic SVM</i> metodą.....	37
17 pav. Klasifikavimo tikslumas naudojant 5 s žingsnį ir <i>Boasted Trees</i> metodą	38
18 pav. Klasifikavimo tikslumas naudojant 30 s žingsnį ir <i>Linear SVM</i> metodą.....	38
19 pav. Klasifikavimo tikslumas naudojant 10 s žingsnį ir <i>Linear SVM</i> metodą.....	39
20 pav. Klasifikavimo tikslumas naudojant 5 s žingsnį ir <i>Bagged Trees</i> metodą.....	39
21 pav. Klasifikavimo tikslumas naudojant 30 s žingsnį ir vidutinį Gauss'o SVM metodą.....	40
22 pav. Klasifikavimo tikslumas naudojant 10 s žingsnį ir <i>Bagged Trees</i> metodą.....	40
23 pav. Klasifikavimo tikslumas naudojant 5 s žingsnį ir <i>Narrow Neural Network</i> metodą.....	41

Terminų ir santrumpų žodynas

SPS – Sprendimų paramos sistema

CBR – Atvejais pagrįsti sprendimai (angl. *Case based reasoning*)

ERP – Išteklių valdymo sistema (angl. *Enterprise Resource Planning*)

Ivadas

Šiuolaikinės pramonės įmonės susiduria su konkurencija ne tik nacionaliniu, bet ir tarptautiniu mastu. Siekiant įgyti pranašumą prieš konkurentus vienas iš pagrindinių uždavinių yra gamybos optimizavimas. Ši plati sritis apima viską nuo gamybai reikiamų išteklių (medžiagų ir žmogiškosios jėgos) planavimo, procesų parinkimo, darbo organizavimo ir gamybos vykdymo, iki savalaikio produktų išvežimo klientams.

Labai svarbi optimizavimo grandinės dalis yra duomenų ir inžinierių-ekspertų žinių kaupimas, sistemizavimas bei tinkamas jų išnaudojimas. Pramonei pereinant prie *Industry 4.0* ir išmanios gamybos standartų, gamyboje atsiveria naujos galimybės kaip išnaudoti jau sukauptas inžinerines žinias, kaupiamus gamybinius duomenis ir naujus metodus bei technologijas jų analizei. Sukurta daug skirtingų metodų kaip vertinti gamybos trukmę: ekspertinės žinios, skaitmeninis klonavimas, simuliacijos, statistiniai metodai, dirbtinis intelektas.

Šiuo darbu siekiama ištirti galimybę apjungti istorinius gamybinius duomenis ir inžinierių-ekspertų sukauptas žinias apie gamybinius procesus sukuriant sistemą skirtą gamybos trukmės nustatymui. Tokia sistema naudotų kaupiamus duomenis kaip išteklių ir duomenis panaudotų proaktyviems veiksams ir sprendimams, vietoje duomenų kaip rezultatų atspindžio. Sujungus istorinius duomenis ir inžinierių-ekspertų įgytas žinias norima sukurti įrankį, kurio naudojimas leistų priimti taiklesnius, greitesnius, duomenimis ir patirtimi paremtus sprendimus, kurie leistų pasiekti norimų gamybos pelningumo ir optimizavimo rezultatų.

Darbo tikslas ir uždaviniai

Tiriamąjį darbo tikslas yra sukurti elektronikos gaminių gamybos procesų trukmės nustatymo sistemą ir atlikti jos kokybinį tyrimą.

Tiksliui įgyvendinti numatyti šie uždaviniai:

1. Išanalizuoti ir parinkti labiausiai tinkančius metodus gamybos trukmės nustatymo sistemos kūrimui
2. Pristatyti tyrimo analizės objektą – elektronikos gaminių surinkimo įmonę Kitron. Ištirti kaip įmonėje nustatomos gamybos trukmės, kokios charakteristikos yra vertinamos. Pateikti sprendimą proceso tobulinimui
3. Paruošti tyrimui reikalingus duomenis iš įvairių Kitron šaltinių. Parinkti klasių priskyrimą duomenims
4. Atlikti įvairių klasifikavimo metodų taikymo efektyvumą, ištirti svarbiausius kintamuosius
5. Nustatyti bandomųjų gaminių gamybos trukmę naudojant sukurta sistemą. Palyginti sukurto sistemos prognozuojamą elektronikos gaminio gamybos trukmę su faktine realios gamybos trukme

1. Literatūros analizė

1.1. Sprendimų paramos sistemos

Bet kokioje srityje sprendimų priėmimas yra neišvengiamas. Pramonėje inžinieriai ir specialistai su įvairiomis dilemomis susiduria beveik kasdien. Tačiau kiekvienas sprendimas savyje turi paslėptą spėjimą apie ateitį. Kai yra sprendžiama problema ar siekiamas tikslas, mes vertiname dabartinę situaciją ir tada tikimės, kad jei imsime konkrečių veiksmų, arba veiksmų sekos, bus pasiektas tam tikras norimas rezultatas [1].

Teisingų sprendimų priėmimas labai svarbus pramonėje, kur gamybos įmonės turi toliau kurti ir diegti naujus technologinius sprendimus, kad išliktų konkurencingos [2]. Įdiegus šiuos sprendimus, gamybos sistemos turi veikti nuolat aukštesniu našumo lygiu, kuriam būdingos mažesnės veiklos sąnaudos, aukštesnės kokybės produktai ir geresnis sprendimų priėmimas.

Tūkstančius metų žmonės naudojo skirtingus įrankius ir pagalbines priemones siekdami priimti sprendimus. Pavyzdžiui įvairūs sąrašai, istorinių duomenų saugojimas, fizinių modelių statymas. Skaitmenizuotos sprendimų paramos sistemos ir analizės įrankiai leidžia siekti naujų tikslų. Jie jau yra ir ateityje dar bus sukurti ir pagrįsti skirtingomis technologijomis. Skaitmenizuotų sprendimų paramos sistemų sritis kuo toliau, tuo labiau tobulėja ir darosi įvairesnė [3].

Pagal Power [3], sprendimo paramos sistemos (angl. *Decision support system*) turi turėti tikslią vartotojų grupę ir tikslą. Sprendimo paramos sistema yra technologija, sukurta iš techninės ir programinės įrangos, sujungta naudojantis tinklo galimybėmis ir pasiekama per asmeninio kompiuterio arba išmaniojo telefono sąsają.

Kaip teigia Power [4], „Sprendimų paramos sistema yra interaktyvi, kompiuteriu paremta sistema arba posistemė skirta padėti sprendimų priėmėjams naudoti komunikacijos technologijas, duomenis, dokumentus, žinias ir/ar modelius problemų identifikavimui ir sprendimui, sprendimo proceso uždavinių įvykdymui ir sprendimų priėmimui.“

Pagrindiniai išskiriami sprendimų paramos sistemų tipai:

- Komunikacijos technologijomis paremtos SPS
- Duomenimis paremtos SPS
- Dokumentais paremtos SPS
- Žiniomis paremtos SPS
- Modeliais paremtos SPS

SPS skirstymui Dan Powers remdamasis praeities tyrimais [3] pasiūlė šiuos klausimus:

- Koks yra pagrindinis funkcionalumą teikiančios architektūros komponentas?
- Kas yra tiksliniai SPS naudotojai?
- Koks yra SPS tikslas?
- Kokia technologija paremtas SPS veikimas?

1 lentelė. SPS matrica

SPS tipas	Pagrindinis funkcinis komponentas	Tiksliniai naudotojai	Tikslas	Technologija
	Komunikacijos	Vidinės komandos	Vesti susirinkimus	Skelbimų lenta

Komunikacijos technologijomis paremtos SPS		Tiekimo partneriai	Padėti naudotojams bendradarbiauti	Video konferencijos
Duomenimis paremtos SPS	Duomenų bazė	Vadovai, darbuotojai, tiekėjai		Santykiais pagrįstos duombazės, Multidimensinės duombazės
Dokumentais paremtos SPS	Dokumentų laikykla ir valdymas	Specialistai	Ieškoti internete	Paieškos sistemos, HTML
Žiniomis paremtos SPS	Žinių bazė, dirbtinis intelektas	Vidiniai vartotojai, nauji klientai	Vadovavimo patarimai	Ekspertų sistemos
Modeliais paremtos SPS	Skaitiniai modeliai	Vadovai, darbuotojai, nauji klientai	Planavimas	Tiesinis programavimas, Excel

Sprendimų paramos sistema paremta ekspertų žiniomis ir dirbtiniu intelektu siūloma [5]. Straipsnyje įvedama *Pi-mind* technologijos sąvoka. Ji reiškia žmogaus intelekto ir dirbtinio intelekto sujungimą ir pritaikymą pramonės valdyme ir optimizavime.

Kaip teigia Stungurienė [6], spartus informacinių technologijų diegimas gamybos procesų valdymo srityje atvėrė naujų galimybių taikyti operacijų valdymo metodus, kuriant sprendimų paramos sistemas (SPS). Sprendimų paramos sistemų funkcionavimo dėka modeliuojami galimi vadybiniai sprendimai ir atliekama priimtų sprendimų analizė.

Lee [7] teigia, kad duomenys nėra iš savęs naudingi, nebent jie yra apdorojami taip, kad suteiktų kontekstą ir prasmę juos naudojantiems žmonėms. Tik prijungus jutiklius prie įrangos, ar vieną įrangą prie kitos įrangos, žmonės nepradės priimti geresnių sprendimų.

1.2. Atvejais pagrįsti sprendimai

Atvejais paremti sprendimai (angl. *case based reasoning* - *CBR*) yra problemų sprendimo metodologija. Šios problemos (uždaviniai) gali būti labai įvairios ir iš principo joks problemos tipas nėra išskiriamas kaip neišsprendžiamas naudojant CBR [8]. Tačiau tai nereiškia, kad CBR rekomenduojama naudoti bet kokiai problemai spręsti [9].

CBR trumpinys susideda iš trijų žodžių, kuriuos verta trumpai atskirai aptarti:

Atvejis yra tam tikra patirtis, išmokta pamoka ar įgūdis, atsiradęs išsprendus problemą. Tai galima atvaizduoti daugybe būdų. Atvejų bazė (angl. *case base*) yra tokių atvejų suvestinė. Išsireiškimas „paremta“ (angl. *based*), reiškia, kad samprotavimas (sprendimų priėmimas) yra paremtas atvejais, atvejai yra pirminis samprotavimo šaltinis. Samprotavimas reiškia, kad šis metodas yra naudojamas gauti išvadas naudojant praeities atvejus, kuomet yra sprendžiama problema [9].

Ką vadiname atveju?

Atvejis gali būti ištisa istorija ar pasakojimas kaip buvo išspręstas koks nors uždavinys ar iškilusi problema. CBR naudoja atvejus uždavinių sprendimui, taigi atvejyje turi būti kažkas kas aprašo pačią problemą ir jos sprendimą [10]. Galima teigti, kad CBR atvejį suskaido į:

- Uždavinio ar problemos dalį (arba uždavinio aprašas)
- Sprendimo dalį, kuri aprašo kas buvo padaryta

Dažnai neteisingi uždavinių sprendimai yra pašalinami ar atmetami kaip nereikalingi CBR. Tačiau net ir neteisingas sprendimas yra informacija, kokio sprendimo reikia vengti. [9]

1.3. Prognozavimas

Šiame skyriuje trumpai apžvelgiama siūloma prognozavimo eiga ir gamybos trukmės prognozavimo metodai.

1.3.1. Prognozavimo etapai

Stungurienė [6] nepriklausomai nuo pasirinkto metodo išskiria šiuos prognozavimo proceso etapus

1. Prognozavimo problemos identifikavimas
2. Prognozavimui reikalingų duomenų rinkimas
3. Prognozavimo modelio tinkamumo patikrinimas
4. Prognozavimas
5. Rezultatų pritaikymas

1.3.2. Gamybos trukmės prognozavimas

Lee [7] gamybą pasiūlė apibrėžti kaip 5M sistemą, susidedančią iš medžiagų, mašinų, metodų, matavimų ir modeliavimo. Kuo labiau įmonės procesai integruojami į duomenų sistemą, tuo labiau galima atlikti tikslesnes analizes ir patikimesnę prognozavimą. Šiame skyrelyje apžvelgtas gamybos trukmės prognozavimas naudojant įvairius metodus.

Chung [11] išskyrė keturis pagrindinius gamybos trukmės prognozavimo būdus: proceso simuliaciją, statistinę analizę, analitinį metodą ir hibridinį metodą.

Kallio [12] aprašė elektronikos gaminių paviršinių komponentų surinkimo trukmės simuliaciją paremtą įrangos parametrais. Jo darbo rezultatas buvo sistema, kuri testavimo metu parodė apie 1% procento trukmės nustatymo tikslumą. Sistema paremta išvesta lygtimi

$$CT_i = F + N0 + \sum_{j=1}^T (P_j + I_j + R_j) + \sum_{j=1}^C N_j$$

Kur F – laikas atskaitos taškų paieškai, $N0$ – pirminio paruošimo laikas, P_j – komponento paėmimo laikas, I_j – komponento padėjimo laikas, R_j – video kameros patikros laikas, N_j – antgalio pakeitimo laikas.

Tiesa, viena iš darbo išvadų buvo tai, kad tokios simuliacijos užima daug laiko ir resursų. Taip pat, tyrimo metu buvo simuliuojamas vienos paviršinių komponentų statymo mašinos veikimas, kuomet realiose surinkimo linijose būna viena po kitos statomos kelios surinkimo mašinos. Greta jų dar būna litavimo pečius, automatinės optinės kontrolės įranga ir kitos galutinę trukmę pailginančios įrangos.

Tuo pačiu iš pateiktos lygties matome, kad reikalinga sukaupti daugybę informacijos apie kiekvieną į gaminį įeinantį komponentą. Dažniausiai gaminius sudaro nuo kelių iki šimtų unikalių komponentų, taigi tokios sistemos naudojimas reikalauja didelės duomenų bazės ir intensyvių skaičiavimų.

Vainio [13] aprašo elektronikos gaminių paviršinių komponentų surinkimo trukmės nustatymo būdą naudojant neuroninius tinklus. Neuroninių tinklų modelis lygintas su ankstesniuose tyrimuose Laakso [14] gautu regresijos modeliu:

$$t = 0,115n + 0,163c + 0,000536l - 6,467$$

Kur n – bendras komponentų skaičius, c – unikalių komponentų skaičius, l – spausdintinės plokštės ilgis.

Vainio [13] sukurtas modelis naudojo 12 paslėptų neuronų ir davė ženkliai geresnius rezultatus nei regresijos modelis. Paklaidos apskaičiuotos naudojant neuroninį tinklą buvo iki 20 kartų mažesnės nei regresijos modelis. Taip pat buvo išryškinta, kad bendras komponentų skaičius yra svariausias surinkimo trukmę lemiantis kintamasis.

Hibridinio modelio taikymą pasiūlė Yang [15], tyręs *pilkosios-dėžės* (angl. *grey-box*) sistemą, kuri sudaryta iš dviejų dalių: baltosios dėžės, kuri paremta gamybos žiniomis ir juodosios dėžės, kuri paremta statistiniais modeliais. Toks priėjimas leidžia išnaudoti žmogiškąsias proceso žinias kartu su kaupiamais statistiniais duomenimis. Sukurtas modelis taip pat leido sumažinti prognozavimo paklaidas.

1.4. Duomenų klasifikavimas

Ankstesniuose skyreliuose buvo aprašytas trukmės nustatymas naudojant proceso simuliacijos ir statistinės analizės metodus. Labai plačiai naudojamas statistinės analizės metodas, kuris dar nebuvo paminėtas, yra duomenų klasifikavimas.

1.4.1. Klasifikavimas

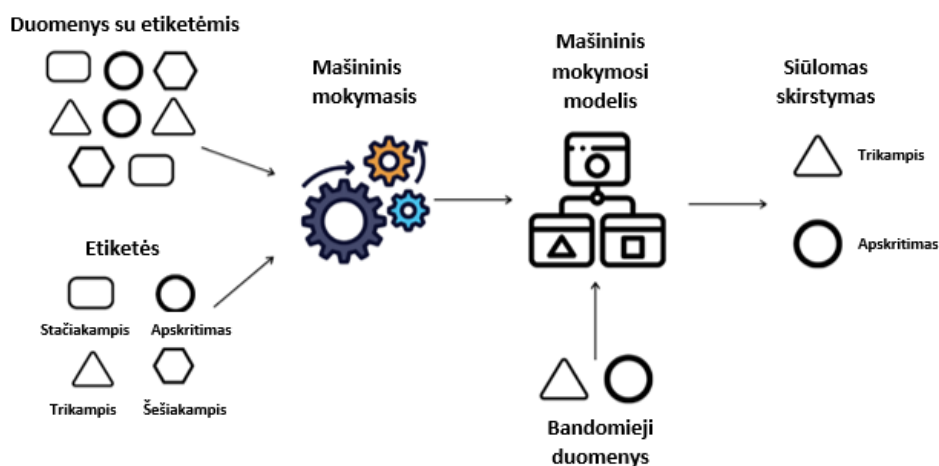
Pagal Henery [16] klasifikacija turi dvi atskiras reikšmes. Galima gauti stebėjimų duomenų rinkinį su tikslu juos sugrupuoti (suklasifikuoti), arba turime jau sugrupuotus duomenis ir tikslas yra nustatyti taisykles, pagal kurias nauji duomenys būtų priskiriami jau egzistuojančioms klasėms. Pirmasis tipas yra vadinamas neprižiūrimu mokymusi (angl. *unsupervised learning*) arba klasterizavimu, o antrasis prižiūrimu mokymusi.

Tai duomenų organizavimas į įvairias kategorijas ar grupes. Duomenų klasifikavimas remiasi jau suskirstytais pavyzdiniais duomenimis, kurie suskirstyti į kategorijas ar klases. Šių kategorijų mokymasis paremtas modeliais arba metodais.

Keturi duomenų klasifikavimo tipai mašiniame mokymesi [17]:

- Dvejetainis (angl. binary) klasifikavimas – kuomet yra dvi duomenų klasių etiketės
- Daugiaklasis (angl. multi-class) klasifikavimas – kuomet yra daugiau nei dvi duomenų klasių etiketės
- Daugiaetietinis (angl. multi-label) klasifikavimas – kuomet yra naudojamos dvi ar daugiau klasių etikečių ir kiekvienam objektui gali būti numatoma daugiau nei viena etiketė
- Išbalansuotas klasifikavimas – kuomet objektų kiekvienoje klasėje skaičius yra nevienodas

Paprastas klasifikavimo metodo atvaizdavimas pateikiamas 1 pav.



1 pav. Klasifikavimo metodo schema

Kas yra klasė

Henery [16] išskiria tris klasių atvejus. Daugumoje duomenų rinkinių atsispindės šių tipų mišiniai.

1. Klasės atspindi skirtingas populiacijas – dėl priklausomybės nekyla klausimų. Priskyrimas klasei vykdomas nepriklausomo stebėtojo, nepriklausomai nuo kažkurių konkrečių atributų ar kintamųjų.
2. Klasės išskylančios iš prognozavimo. Šiuo atveju klasė yra prognozavimo rezultatas ir priklauso tiesiogiai nuo atributų žinojimo.

Klasės yra iš anksto sukuriamos, padalinant pavyzdinius duomenis, t.y. pačius atributus. Galima teigti, kad klasė yra funkcija priklausoma nuo atributų. Tokius atveju užduotis yra sukurti taisyklės, kurios kopijuoja jau egzistuojančios taisyklės veikimą kaip galima tiksliau.

Kam reikia klasifikatorių – klasifikatorių panaudojimas

Duomenų klasifikavimo metodai šiais laikais naudojami daugybėje praktinių pritaikymų:

- Informacijos ar daiktų rūšiavimui. Automatinės klasifikavimo procedūros gali būti žymiai greitesnės – pašto kodų skaitymo įranga gali surūšiuoti daugumą einančių laiškų, sudėtingus atvejus paliekant gyviems darbuotojams.
- Pacientų simptomų klasifikavimas naudojamas sveikatos sutrikimams nustatyti. Medicinoje norima išvengti operacijų arba sudėtingų tyrimų siekiant išsiaiškinti negalavimus, tad norima remtis modeliais kurie gali tiksliai nustatyti negalavimo priežastis remdamasis išoriniais simptomais [18]
- Kredito reitingo priskyrimui. Paskolos suteikimo vertinimo metodai sprendimą pateikia remdamiesi tuo, kas pateikta paskolos paraiškoje. Žmonės atliekantys tą patį darbą gali būti šališki dėl kai kurių atvejų ir priimti įmonei nuostolingus klientus, arba praleisti įmonei pelną galinčius nešti klientus [19].

Kiek kintamųjų naudoti prognozavimui

Kaip nurodoma Matloff [19], nors pilnai neištirtas geriausias santykis kiek reikia prognozavimui naudojamų faktorių lyginant su bendru stebėjimų skaičiumi, tačiau siūloma vadovautis bendra taisykle, kad

$$f < \sqrt{(n)}$$

Kur f – prognozavimui naudojamų faktorių skaičius, o n – bendras stebėjimų skaičius.

Duomenų žymėjimas – klasių priskyrimas

Duomenų žymėjimas arba anotavimas yra procesas, kurio metu duomenims yra priskiriami atributai, tam kad kuriamas modelis žinotų kokius spėjimus jis turi grąžinti [20]. Šis procesas yra viena iš duomenų paruošimo sudedamųjų dalių.

Duomenų žymėjimas užtrunka daug laiko ir naudoja žmogiškųjų išteklių, jei pasitelkiami srities ekspertai

1.4.2. Klasifikavimo naudojimas gamybos duomenims

Klasifikavimo metodai jau seniai naudojami klasifikuojant gamybos duomenis. Kuo sudėtingesnis klasifikuojamas procesas, tuo potencialiai daugiau kintamųjų, darančių įtaką proceso eigai. Tokiu atveju svarbus tampa esminių kintamųjų atrinkimas. Anzanello [21] siūlo atmesti kaip įmanoma daugiau kintamųjų, taip drastiškai supaprastinant klasifikavimo metodų veikimą.

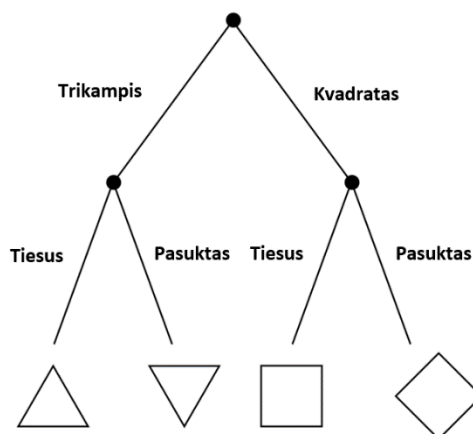
1.4.3. Klasifikavimo metodai

Skirtinguose literatūros šaltiniuose aprašoma daug skirtingų klasifikavimo metodų. Žemiau sąrašė pateikiamos pagrindinės klasifikavimo metodų grupės [22]:

- Klasifikavimo medžiai, paremti sprendimų medžiais
- Diskriminantų analizė
- Bejeso modeliai
- Artimiausių kaimynų metodas
- Atraminių vektorių mašina
- Klasifikavimo ansambliai – skirtingų metodų rinkiniai
- Neuroniniai tinklai

Sprendimų medis ir atsitiktinis miškas

Sprendimų medis (angl. *decision tree*) yra sprendimų paramos įrankis, kuris primena išsišakojantį medį. Tai yra vienas iš klasifikavimo būdų. Medį sudaro sprendimai ir jų galimi rezultatai. Pavyzdys pateikiamas 2 paveiksle.



2 pav. Sprendimų medžio pavyzdys

Paprastai tariant sprendimų medis gali būti apibūdintas kaip mokymosi metodas, kuris yra prižiūrimas ir turi iš anksto nustatytą tikslo kintamąjį (angl. *target variable*), kuris yra naudojamas klasifikavimo uždaviniuose [23].

Atsitiktinis miškas yra sudarytas iš kelių sprendimų medžių, iš kurių kiekvienas yra šiek tiek skirtingas [23]. Norint sugeneruoti šiuos sprendimų medžius reikalingi pradiniai duomenys su žinomomis savybėmis ir rezultatais. Vykdomame tyrime numatytas rezultatas bus gaminio gamybos laikas, kuris priklauso nuo tam tikrų parametrų, pvz. komponentų skaičiaus, komponentų tipo, ruošinio dydžio ir t.t.

Padavus duomenis su parametrais ir rezultatais į atsitiktinio miško metodą, jis juos išanalizuos ir atrinks kuriuos duomenis naudoti geriausio sprendimų medžio kūrime [24].

Svarbu, kad duomenys kurie buvo naudoti sprendimų medžio generavime turėtų tuos pačius parametrus kaip duomenys su kuriais bus naudojamas atsitiktinio miško metodas.

1.4.4. Klasifikavimo trūkumai

Išskylančios problemos

Tikslumas. Dažniausiai klasifikatoriaus tikslumas išreiškiamas teisingų klasifikavimų santykiu, tačiau kai kurios klaidos gali būti žymiai brangesnės nei kitos. Tam gali teikti kontroliuoti kai kurių klasių tikslumą.

Greitis. Tam tikrais atvejais, klasifikatorius veikiantis 90% tikslumu gali būti tinkamesnis nei veikiantis 95% tikslumu, priklausomai nuo to, ar mažesnę tikslumą turintis modelis yra pakankamai greitesnis.

Suprantamumas. Žmonės naudojantys sistemą, turi suprasti ir pasitikėti Sistema, bei jos teikiamais rezultatais. Kitu atveju vėl grįžtama prie žmonių šališkumo ir savarankiško sprendimų priėmimo.

Mokymosi trukmė. Esant greitai besikeičiančioms aplinkybėms, gali būti reikalinga turėti sistemą, kuri greitai prisitaiko prie naujų įvesčių.

Klasių neproporcingumas

Nagrinėjant skirtingus duomenų rinkinius, suskirstytus į daug klasių gali iškilti neproporcingo pasiskirstymo tarp klasių problema, t.y. skirtingoms klasėms priskirtų duomenų kiekiai tarpusavyje neproporcingi. Kaip pastebi Henery [16] tokios problemos gali iškilti nuo paties duomenų rinkimo, kuomet yra renkami specifiniai duomenys, taip iškreipiant jų pasiskirstymą tarp klasių. Šios problemos sprendimas – misklasifikavimo kainų įvedimas ir diferencijavimas tarp skirtingų neteisingų priskyrimų.

Tiesa, kaip pastebi Matloff [19] klasių neproporcingumas nebūtinai yra problema. Jei klasių neproporcingumas atspindi duomenų neproporcingumą, tuomet jis paprasčiausiai parodo, kad tam tikri atvejai yra labai reti arba išskirtiniai.

Klasifikavimo modelio klaidų kaina

Kaip modelio parametras gali būti įvedamas klaidos kainos rodiklis. Pavyzdžiui medicinoje naudojant klasifikavimą pacientų skirstymui į sveikus ir sergančius, sveiko paciento priskyrimas prie sergančių

bus akivaizdi klaida. Tačiau ši klaida gali būti lengvai pastebėta apžiūrint pacientus – sveiki asmenys bus vis tiek atskirti nuo sergančių, tik šis atskyrimas reikalaus resursų apžiūros metu [25].

Kitu atveju, kai įvyksta klasifikavimo klaida ir sergantys pacientai priskiriami sveikiems, susiduriama su žymiai didesne problema – klasifikavimo modeliui pacientą priskyrus prie sveikų grupės, jis gali likti toliau neapžiūrėtas ar neištirtas, o tai gali pasibaigti rimtais sveikatos sutrikimais ar mirtimi.

1.5. Nuspėjamoji analizė

Kaip pastebėta McKinsey Global Institute pramonės ateities apžvalgoje [26], mokslinis grynų duomenų analizavimas su tikslu gauti išvadas ir išvalgas apie tuos duomenis yra esminis išmanios gamybos faktorius. Seung-Jun [27] teigia, kad išmanioje gamyboje duomenų infrastruktūra yra reikalinga siekiant analizuoti didžiulius duomenų kiekius sukuriamus gamybinėje aplinkoje, kurie gali būti nestruktūrizuoti ir įvairių formatų, ir priimti savalaikius sprendimus.

Nuspėjamoji analizė (angl. *predictive analytics*) tiria neapdorotus duomenis, kurie turi būti papildyti siekiant nustatyti sistemų elgseną, įvertinant ir numatant, kas gali nutikti artimiausioje ateityje [28]. Naudojant nesenos praeities duomenis, nuspėjamoji analizė leidžia nuspėti ateities tendencijas, elgesį ir t.t. per duomenų priežastinius ryšius ir koreliaciją.

Dubey [29] prideda, kad nuspėjamoji analizė padeda gamybos organizacijoms pagerinti sudėtingų sprendimų priėmimą ir gaminių kokybę tuo pačiu mažinant palaikymui skirtas išlaidas gerinant defektų sekimą ir gamybos planavimą. Krumeich [30] teigia, kad šiandien įmonės vis dar neatlieka pakankamai analizių ir prognozių, pagrįstų surinktais duomenimis, nors tai gali turėti didžiulį poveikį jų ekonominei ir ekologinei veiklai. Tai skiriasi nuo verslo šakų, tokių kaip draudimas ar bankininkystė, kurios savo verslo modeliuose žymiai giliau įdiegė nuspėjamąją analizę.

Kaip kritiškai pastebėjo Lee [31], tradiciškai gamybos sistemos valdymas labai priklauso nuo patyrusių darbuotojų. Kai šie darbuotojai, pradeda išeiti į pensiją, prarandama daug žinių, praktinių žinių ir supratimo. Todėl reikalinga sumani analitinė sistema, kuri patirtimi pagrįstą praktinę patirtį paverstų įrodymais pagrįstu sprendimų priėmimu siekiant tvarios veiklos.

Apžvelgdamas puslaidininkų gamybos pramonę Moyne [32] pastebi, kad įmonės pasinaudojo didžiųjų duomenų ir analizės pažanga, tobulindamos esamas galimybes, pvz., gedimų aptikimą, ir remdamos naujas galimybes, pvz., nuspėjamąją priežiūrą. Daugeliui šių galimybių duomenų kokybė yra svarbiausias didžiųjų duomenų veiksnys teikiant aukštos kokybės sprendimus. Norint įgyvendinti veiksmingus tiesioginius gamybos sprendimus, dažnai reikia įtraukti dalykinę patirtį į analizę.

2. Atvejo analizė

2.1. Įmonės gamybos proceso apžvalga

Šiame skyriuje apžvelgiama įmonės gamybiniai procesai, gaminių trukmės vertinimo eiga. Skyrius skirtas geriau suprasti kokias problemas spręš kuriama trukmės nustatymo sistema.

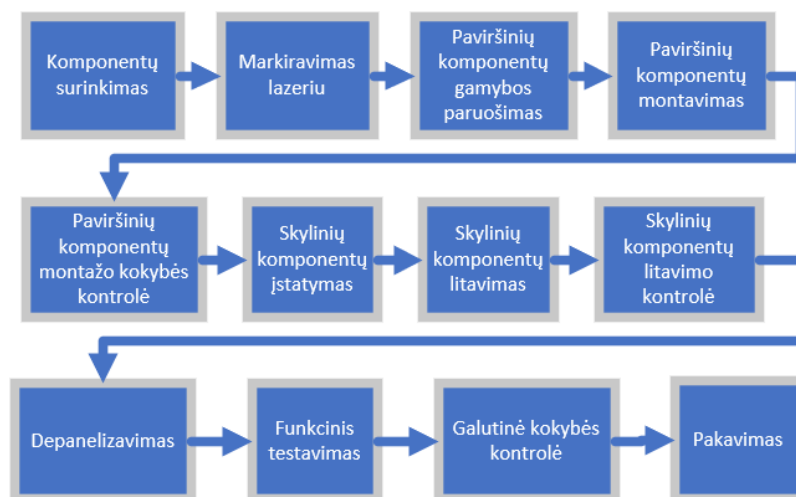
2.1.1. Gaminių ir gamybos proceso pavyzdys

Įmonėje Kitron gaminami elektronikos gaminiai – vykdomas spausdintinių plokščių surinkimas, testavimas, surinkimas į galutinius gaminius. Surinktos spausdintinės plokštės pavyzdys 3 pav.



3 pav. Surinktos spausdintinės plokštės pavyzdys

Norint supažindinti su standartiniu gamybos procesų eiga, sudaryta schema parodyta 4 pav. Ši schema nurodo gamybos kelią, kurį praeina dauguma įmonėje gaminamų gaminių.



4 pav. Standartinių gamybos procesų eigos schema

Kiekvienas iš schemoje esančių gamybos etapų turi būti atskirai vertinamas ir analizuojamas, kai yra vertinama gamybos kaina ir trukmė.

2.1.2. Laiko raportavimas ir trukmės skaičiavimas

Darbo trukmė įmonėje Kitron raportuojama naudojant ERP (angl. *Enterprise Resource Planning*) sistemą IFS 10. Kiekvienas gamybos darbuotojas individualiai raportuoja savo darbo laiką. Laikas atskirai raportuojamas į kiekvieną gamybos partiją. Darbuotojas įsiregistruoja į gamybos partijos operaciją, kurioje pradės dirbti ir tada pradeda pasiruošimą darbui: pasiima pusgaminius, reikalingus įrankius, detales ar komponentus, susipažįsta su gaminio surinkimo instrukcija ir kokybiniais ar kitais reikalavimais. Laikas skirtas pasiruošimui įeina į bendrą raportuojamą laiką ir nėra atskiriamas nuo tiesioginio darbo laiko.

Darbuotojas iš partijos išsiregistruoja baigęs tiesioginį darbą ir sutvarkęs darbo vietą. Laikas tarp įsiregistravimo ir išsiregistravimo laikomas darbo trukme. Ši trukmė yra saugoma ERP sistemoje. Tuo pačiu darbuotojas registruoja savo pagamintų gaminių kiekį. Padalinus trukmę iš kiekio, gauname laiką per vienetą.

Kaip minėta, kadangi darbo pasiruošimas ir tiesioginis darbas nėra registruojamas atskirai, į laiką per vienetą patenka ir laikas tekęs pasiruošti partijos gamybai. Tęsiant šią mintį, dažniausiai yra naudingiau gaminti didesnes partijas, kadangi tas pats pasiruošimo laikas tenka didesniai kiekiui gaminių – padalinus visa trukmę iš gaminių kiekio, pasiruošimui tekusio laiko dedamoji mažėja.

Visa statistika, įskaitant įsiregistravimo, išsiregistravimo laikus, sistemos apskaičiuotas trukmes ir suraportuotus gaminių kiekius yra saugoma ERP sistemoje. Laikas per vienetą yra išvestinis šių duomenų rodiklis, kurį dažniausiai nagrinėja inžinieriai.

2.2. Elektronikos gaminių gamybos trukmės nustatymas

Šiame skyriuje aprašoma nagrinėjamos realios elektronikos gamybos įmonės naujų gaminių gamybinių procesų vertinimo eiga ir kylantys iššūkiai. Pateikiami potencialūs finansiniai nuostoliai esant mažai vertinimo paklaidai ir įmonėje kaupiamų duomenų pavyzdžiai.

2.2.1. Dabartinio įmonės proceso vertinamos charakteristikos

Kadangi vienas iš pagrindinių atskaitos matavimų bus sukurtos trukmės nustatymo lyginimas su įmonės dabar naudojama skaičiuokle, svarbu yra išanalizuoti dabartinį skaičiavimo procesą. Jis yra paremtas rankiniu gaminio charakteristikų įvedimu. Įvesti duomenys toliau yra apdorojami įmonės naudojamos skaičiuoklės.

Įmonėje naudojamos skaičiuoklės vertinamos charakteristikos:

- Komponento tipas. Egzistuoja 12 skirtingų tipų, priklausomai nuo to ar komponentas yra paviršinio montažo ar atvadinis, jo dydžio, statymo tipo ir pan.
- Skirtingų komponentų (skirtingų nominalų) skaičius
- Maskavimo taškų skaičius
- Gaminio paviršiaus plotas
- Gamybos partijos dydis
- Spausdintinės plokštės storis
- Spausdintinių plokščių ruošinio multiplikacija
- Kitos

2.2.2. Gamybos procesų trukmės vertinimas ir skaičiavimas

Nagrinėjamu atveju įmonė remiasi įmonėje sukurta skaičiavimo forma, kuri vertindama gamybinių procesų trukmę, vadovaujasi gaminių sudarančių komponentų skaičiumi, jų tipu, dydžiu, lituojamų atvadų skaičiumi ir kitais parametrais.

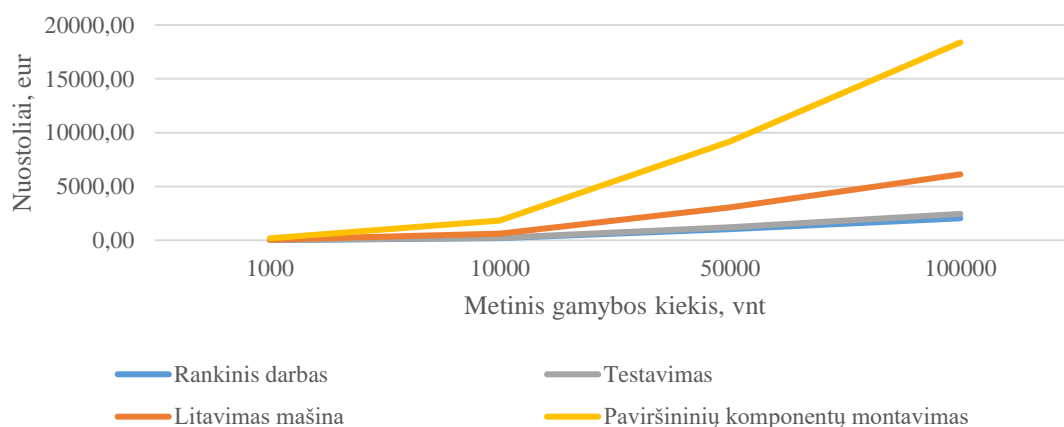
Naujo gaminio vertinimo metu iš užsakovų dažniausiai gaunama ši informacija:

- Gaminio brėžiniai
- Gaminio komponentų sąrašas
- Surinkimo instrukcija

Į naudojamą skaičiavimo formą suvedus iš užsakovo gautą gaminio informaciją yra gaunami preliminarūs rezultatai. Jie peržiūrimi ir koreguojami specialistų-inžinierių, kurie vadovaujasi savo sukaupta patirtimi ir konsultacijomis su bendradarbiais. Taip pat ieškoma panašių jau gaminamų gaminių, su kuriais būtų galima palyginti skaičiavimo formos pateiktas gamybinių procesų trukmes. Tačiau verta pastebėti, kad tai yra subjektyvi, nesisteminė paieška. Galima teigti, jog intuityviai naudojama tam tikra CBR sistema, tačiau ji nėra formalizuota ir automatizuota.

2.2.3. Vertinimo klaidų vertė

Pristatomas vertinimo pavyzdys. Gaminio vertinimo metu nustatant gamybinio proceso trukmę, padarius klaidą kuri lemia 10 s neatitikimą tarp užsakovams parduoto darbo laiko ir faktinio darbo laiko. Tokio iš pažiūros mažo neatitikimo finansinės pasekmės matomos 5 pav.



5 pav. Metiniai skirtingų gamybos operacijų nuostoliai esant 10 s klaidai vertinime

Kaip matosi pateiktame grafike, net ir 10 s klaida vertinant gamybinio proceso trukmę, gali reikšti dešimtis tūkstančių eurų nuostolių per metus. Pateiktame pavyzdyje rodoma apie vieno gaminio gamybos trukmės per mažą įvertinimą. Jei gamybos įmonė gamina 5, 10, 100, 1000 ar daugiau skirtingų gaminių, lengva suprasti, kokio masto galimi nuostoliai jei nustatoma sistemingai per maža surinkimo trukmė.

Nuostolių skaičiavimui panaudota viešai prieinama atlyginimų informacija apie elektronikos gamybos įmones Kauno mieste ir Kauno rajone. 25% kvantilio mėnesinis atlygis buvo naudotas kaip atskaitos taškas rankinio darbo valandinio įkainio skaičiavime. Kitų operacijų įkainiai paremti pramonėje priimtais koeficientais.

2.2.4. Gamybinių operacijų atrinkimas

Siekiant sukurti funkcionalią ir realia verte teikiančią trukmės nustatymo sistemą, svarbu atsirinkti prioritetus, į kuriuos sistema koncentruosis.

Vieno gaminio gamybinių operacijų pavyzdys pateiktas 7 pav. parodo, kad gamybos eiga susidaro iš septyniolikos gamybinių operacijų. Natūralu, kad visos gamybinės operacijos netolygiai prisideda prie gaminio gamybos kaštų.

Galima teigti, kad inžinieriui, atsakingam už gamybos efektyvumą, svarbiausia yra koncentruotis į tas operacijas, kurios generuoja daugiausia kaštų įmonei. Šiuos kaštus galima įvertinti pagal paprastą lygybę

$$\text{Kaštai} = \text{Operacijos įkainis} \times \text{Operacijos trukmė}$$

Norint pasinaudoti šia lygybe, reikia papildyti 7 paveiksle pateiktos lentelės duomenis operacijų įkainiais.

Žemiau 2 lentelėje, šalia operacijų yra įvedamas įkainio tipas, t.y. rankinis darbas, testavimas, skylinių komponentų litavimas, paviršinių komponentų montavimas, ir t.t. ir jo vertė

2 lentelė Skirtingų operacijų įkainiai

Operacija	Įkainio tipas	Įkainis
Komponentų montavimas	Rankinis darbas	...
Rankinis litavimas	Rankinis darbas	...
Testavimas	Testas	...
...

Šie duomenys yra integruoti į įmonės išteklių valdymo sistemą. Išteklių valdymo sistemoje esančių gamybinių operacijų įkainio tipų pavyzdys parodytas 10 paveiksle.

Operation Description	Labor Class Description
LLP - Label printing	Manual work PBA
Laser marking	Manual work SMD
Kitting THT Preforming	Warehouse
Kitting HLA Preforming	Warehouse
LPC3 - Preforming components	Preforming compon...
SMT Kitting	Rigging
SMT Rigging	Rigging
Mounting SMT line5 + AOI BOTT...	SMD lines operators
Mounting SMT line5 + AOI TOP	SMD lines operators

6 pav. Išteklių valdymo sistemoje esančių įkainių tipų iškarpa

Apjungus duomenis galima vertinti operacijų svarbą, svarstant į kurias operacijas verta atkreipti dėmesį kuriant trukmės nustatymo sistemą. Kuo operacijos kaštai didesni, tuo svarbesnė yra operacija ir tuo svarbesnis yra jos laiko įvertinimas.

2.2.5. Gaminų charakteristikų atrinkimas

Atrinkus gaminų gamybos operacijas kurias reikia vertinti sistema, galima pereiti prie konkretaus gaminio charakteristikų.

Žemiau esančioje 3 lentelė pateiktos charakteristikos ir jų galima įtaka operacijos trukmei

3 lentelė Gaminų charakteristikų įtaka gamybos trukmei

Charakteristika	Daroma įtaka	Operacija (-os)
Komponentų kiekis	Kuo daugiau komponentų, tuo ilgiau trunka komponentų rinkimas sandėlyje ir tiekimas gamybai	Komponentų rinkimas
Paviršinių komponentų kiekis	Kuo daugiau paviršinio montažo komponentų, tuo ilgiau trunka gamybos linijos paruošimas ir tuo ilgiau truks komponentų pastatymas	Paviršinio montažo komponentų paruošimas, Paviršinio montažo gamyba
Paviršinių komponentų kiekis	Kuo daugiau paviršinių komponentų, tuo ilgiau trunka tikrinimas po montažo	Paviršinio montažo komponentų kontrolė
Skylinių komponentų kiekis	Kuo daugiau skylinių komponentų, tuo ilgiau trunka jų surinkimas prieš litavimą ir tuo ilgiau truks litavimas	Komponentų montavimas, komponentų litavimas
Skylinių komponentų kiekis	Kuo daugiau skylinių komponentų, tuo ilgiau truks jų atvadų patikra po litavimo	Rankinis litavimas, kontrolė
Gaminio paviršiaus plotas	Labai maži gaminiai ilgina laiką, kuris yra praleidžiamas tik judinant gaminį ir jam nesuteikiant pridėtinės vertės Dideli išmatavai reiškia, kad kiekvieną gaminį reikia ilgai tikrinti	Visos
Gaminio montavimo pusė	Priklausomai ar gaminys vienpusis ar dvipusis, skirsis laikas, reikalingas jo gamybai	Visos

Iš 3 lentelė aptartų gaminio charakteristikų, galima sudaryti gaminų sąrašą, kur kiekviena kiekybinė charakteristika yra pateikta kaip stulpelis, pavyzdys pateikiamas 4 lentelė. Ši lentelė bus naudojama tolimesnei gamybos operacijų trukmės priklausomybių analizei ir prognozavimui.


4 lentelė Gaminio charakteristikų parinkimas

Gaminio kodas	Gamybinė operacija	Komponentų skaičius, vnt	Paviršinių komponentų skaičius, vnt	Skylinių komponentų skaičius, vnt	Gaminio paviršiaus plotas, cm ²	Operacijos trukmė, s
123	Litavimas	185	180	5	77	
...

4 lentelė pateikti duomenys bus vienas iš duomenų bazės pagrindų. Pagal šiuos duomenis, bus atrenkami panašiausi gaminiai, lyginant duomenų bazėje esančius įmonės gaminamus gaminius ir naujai įvedamo gaminio charakteristikas.

2.2.6. Analizuojami duomenys

Norint sukurti funkcionalią ir vertę nešančią sprendimų priėmimo sistemą, reikės sukurti duomenų bazę, kuri bus naudojama sistemos veikime. Ši duomenų bazė bus sukurta iš įmonės jau kaupiamų duomenų. Įmonės raportų pavyzdys pateikiamas 7 pav.



Part No	Operation Description	Time per unit
1452470LF	LLP - Label printing	0,00
1452470LF	Laser marking	0,01
1452470LF	Kitting THT Preforming	0,00
1452470LF	Kitting HLA Preforming	0,00
1452470LF	LPC3 - Preforming components	0,01
1452470LF	SMT Kitting	0,01
1452470LF	SMT Rigging	0,01
1452470LF	Mounting SMT line5 + AOI BOTTOM	0,04
1452470LF	Mounting SMT line5 + AOI TOP	0,05
1452470LF	SMT Unrigging	0,00
1452470LF	Manual SMT Inspection	0,03
1452470LF	SMT UnKitting	0,01
1452470LF	Kitting THT Selective Wave	0,02
1452470LF	Kitting HLA Selective Wave	0,00
1452470LF	LMT3-Manual assembling, Inline5	0,14
1452470LF	Selective soldering Inline5	0,02
1452470LF	TH AOI inspection	0,08
1452470LF	Depaneling	0,01
1452470LF	LM88 - PBA modification	0,16
1452470LF	LTIG - Incircuit test Genrad	0,11
1452470LF	LQA - Quality inspection	0,03

7 pav. Gaminio gamybinių operacijų trukmės raportas

2.3. Siūlomas sprendimas

Šiame skyriuje aprašomi numatomos gamybos trukmės nustatymo sistemos veikimo ir panaudojimo principai. Pateikiami pavyzdžiai kaip sistemą siūloma integruoti į dabartinius įmonės veiklos procesus. Sekant verslo praktika, šiame skyriuje kuriame trukmės nustatymo sistema vadinama ir sprendimų priėmimo sistema (SPS). SPS principai aprašyti 1.1 skyrelyje.

2.3.1. Trukmės nustatymo sistema

Aprašytam atvejui spręsti yra siūloma sukurti inžinieriams skirtą sprendimų paramos sistemą, kuri remiantis kaupiamais gamybos duomenimis ir naujų vertinamų gaminių charakteristikomis pasiūlyti naujų gaminių gamybos procesų trukmę. Tai turi būti vykdoma mažiausiai taip pat gerai kaip dabartinėje situacijoje. Komerciniu požiūriu tai reiškia, kad būtų galima mažinti žmogiškųjų išteklių – inžinierių kiekį, išlaikant ne mažesnę priimamų sprendimų kokybę.

2.3.2. Sprendimų paramos sistemos veikimo principas


Kiekvieno gaminio kiekviena operacija laikoma kaip atskiras „atvejis“ SPS duomenų bazėje. Kuriam SPS remsis jau gaunamų ir kaupiamų gamybinių duomenų lyginimu su naujai vertinamo gaminio duomenimis. Kaupiamus duomenis sudaro gaminami gaminiai, gamybinių operacijų

trukmių statistika ir pačių gaminių charakteristikos. Apjungtų gamybinių duomenų pavyzdys pateiktas 4 lentelėje.

5 lentelė Planuojamų naudoti duomenų pavyzdys

Gaminio kodas	Gamybinė operacija	Bendras skaičius, vnt	Paviršinių komponentų skaičius, vnt	Skylinių komponentų skaičius, vnt	Gaminio paviršiaus plotas, cm ²	...	Operacijos trukmė, s
123	Litavimas	185	180	5	77	...	120
321	Kokybės kontrolė	240	237	3	109	...	87
231	Komponentų montavimas	563	543	20	231	...	300
122	Pakavimas	217	217	0	82	...	30

Kaupiami gamybiniai duomenys sudaro trukmės nustatymo sistemos pagrindą. Duomenyse esančios gaminių operacijos (kaip pavieniai atvejai) bus klasifikuojami pagal savo trukmę. Naujai įvedamo gaminio charakteristikos bus lyginamos su duomenų bazėje pagal trukmę suklasifikuotais gaminiiais-atvejais. Remiantis panašiausiais pagal charakteristikas gaminiiais, bus siūlomos naujai vertinamo gaminio gamybinių operacijų trukmės. Ši seka pavaizduota 8 pav.



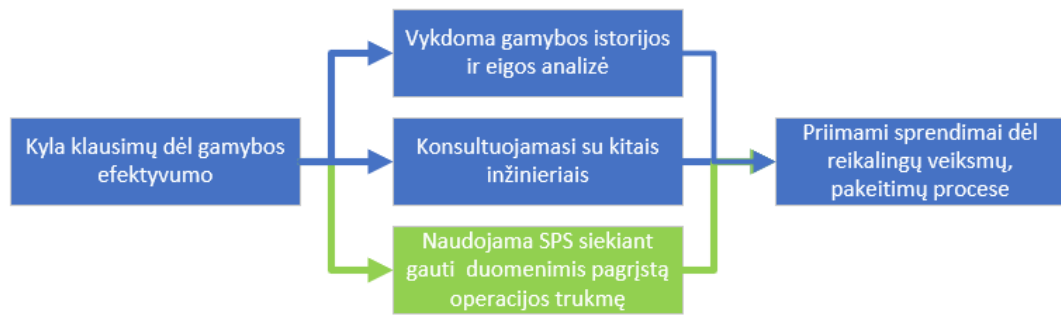
8 pav. Sprendimų paramos sistemos panaudojimo ir veikimo schema

Iš 8 pav. pateiktos schemos, galima teigti, kad sprendimų paramos sistema veikia kaip skaitmeninis asistentas inžinieriams. Ieškant informacijos arba galimų sprendimų, inžinieriui reikia kreiptis į SPS ir paduoti kertinius duomenis apie gaminį, kurį norima analizuoti. Sprendimų paramos sistema pateikia labiausiai tikėtinas gamybos trukmes, remiantis savo duomenų bazėje sukauptomis gamybos rezultatų žiniomis.

2.3.3. Sprendimų paramos sistemos panaudojimas ir panaudos atvejų diagrama

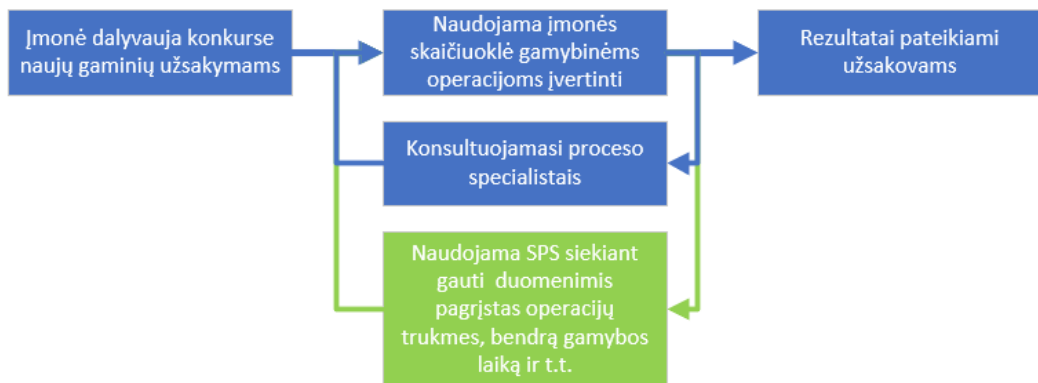
Sprendimų paramos sistema padės inžinieriams patikrinti kiek laiko trunka panašių gaminių gamybinės operacijos. Tai leis:

- Nagrinėjant gamybos efektyvumą, patikrinti kiek trunka analogiškų gaminių gamybos procesai. Tarkime, inžinierius nagrinėja gaminio X rankinio litavimo laiką. Dabartiniame procese, jis galėtų remtis gan siauru gaminių skaičiumi – tiek kiek gaminių „pažįsta“ pats ir kiek informacijos gali gauti iš savo kolegų. Įgalinus įmonės jau kaupiamus duomenis, sprendimų paramos sistema pradeda veikti kaip skaitmeninis ekspertas, kuris duomenų bazėje atranda panašiausius gaminius ir pasiūlo tikėtiną gamybinės operacijos trukmę. Šis procesas iliustruotas 9 paveiksle, siūlomas proceso papildymas paryškintas žalia spalva



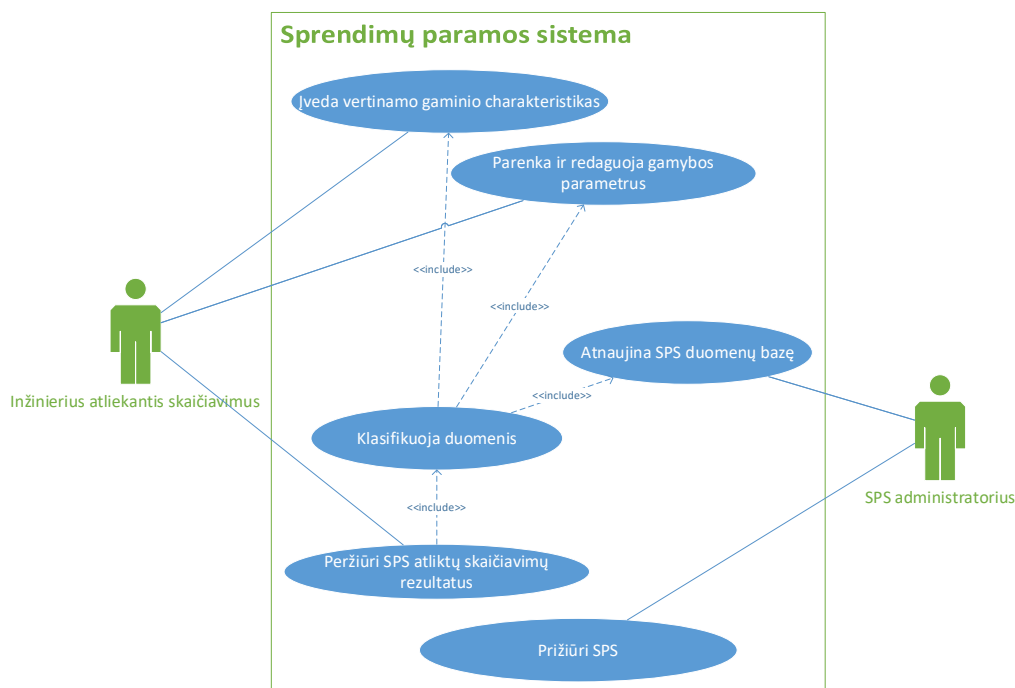
9 pav. Gamybos efektyvumo analizės procesas

- b) Siekiant laimėti naujų gaminių gamybos konkursus ir užtikrinti laimėtų konkursų pelningumą, svarbu teisingai įvertinti gamybos procesą, gamybinių operacijų trukmes. Dabartiniame procese yra naudojamos patyrusių inžinierių žinios, vykdant konsultacijas ir įmonės naudojama skaičiuoklė, kuri vertina įvairias vertinamų gaminių charakteristikas. Darbuotojų kaita ir taip prarandamos specifinės žinios, galimas neatidumas ar tiesiog žmogiškos klaidos faktorius gali lemti netinkamus vertinimus, kurie reikš finansinius nuostolius įmonei. Siūloma dabartinį įmonės gaminių vertinimo procesą papildyti naujai kuriamą sprendimų paramos sistema, kuri naudotų duomenų bazę, kurioje būtų sukaupti ir susisteminti istoriniai gamybos duomenys. Siūlomas procesas išdėstytas 10 paveiksle, žalia spalva pažymėtas siūlomas proceso papildymas



10 pav. Gamybos konkurso procesas su siūlomu patobulinimu

Siekiant vizualiai pristatyti kuriamos sprendimų paramos sistemos veikimo principą, sukurta panaudos atvejų diagrama, parodyta 11 paveiksle. Reikia pastebėti, kad diagramoje pavaizduoti tik tiesiogiai su SPS veikimu susiję faktoriai ir nėra parodomas pirminis duomenų šaltinis, įmonės gamybiniai procesai ir t.t.



11 pav. Sprendimų paramos sistemos panaudos atvejų diagrama

Aukščiau esančioje diagramoje pavaizduoti pagrindiniai SPS sistemos aktoriai ir panaudos atvejai. Pažymėtos panaudos atvejų priklausomybės, diagramoje žymimos punktyrine linija. Šios priklausomybės parodo kurios užduotys (panaudos atvejai) yra priklausomos nuo kitų užduočių. Aktoriai, diagramoje pažymėti žaliai, simbolizuoja žmones tiesiogiai dirbančius su sistema. Šiuo atveju, tai yra tiesioginis naudotojas – inžinierius ir sistemos administratorius. Aktoriai sujungti su jų atliekamomis užduotimis ir veiksmais. Panaudos atvejai (kitaip vadinami užduotimis), esantys Sprendimų paramos sistemos bloko viduje, pažymėti mėlynais ovalais. Šiame kontekste, užduotis – tai su SPS veikimų susiję veiksmai, atliekami arba nurodytų aktorių, arba pačios sistemos.

2.3.4. Sprendimų paramos sistemos apribojimai

Trukmės nustatymo sistemos veikimas paremtas realiais statistiniais duomenimis kurie yra prieinami inžinieriams gaminių įvedimo į gamybą metu. Kaip ir kiekviena sistema, ši taip pat turi ribotumą ir faktorius kurių ji negali įvertinti. Versle yra tam tikros priežastys, kurios daro didelę tiesioginę įtaką operacijos atlikimo laikui, bet negali būti įvertintos remiantis vien gaminio charakteristikomis. Tokių priežasčių pavyzdžiai:

- Specialūs užsakovo reikalavimai – kiekybiškai neįvertinamas faktorius, pavyzdžiui jei klientas reikalauja specifinių veiksmų ar švarumo reikalavimų
- Nenumatyti iššūkiai gaminio surinkimo eigoje, pavyzdžiui mažos kiaurymių tolerancijos, dėl kurių sunkėja skylinių komponentų atvadų įstatymas

Šiems faktoriams įvertinti gali būti reikalingas eksperto įsikišimas, tam kad įvertinti ne kiekybinius, o kokybinius parametrus.

2.3.5. Tyrime naudojamų duomenų struktūra

Visi gamybos rezultatai yra kaupiami įmonės išteklių planavimo sistemoje. Čia galima pamatyti kiek valandų buvo įregistruota kiekvieno gaminio, kiekvienos gamybos partijos, kiekvienai gamybos operacijai, šių duomenų pavyzdys pateikiamas 6 lentelėje.

6 lentelė. ERP raporto rodančio vienos gamybos partijos statistiką pavyzdys

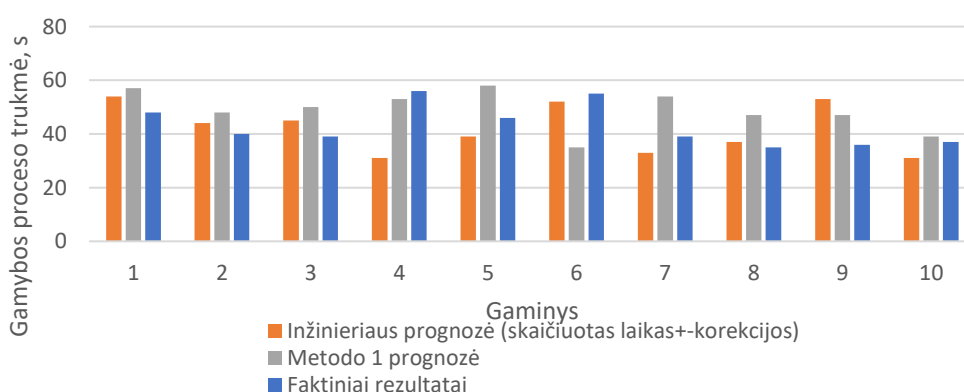
Part No	Order No	Op No	Operation Description	Op Status	Planned Labor Run Time	Actual Labor Run Time
145247OLF	309753	12	Laser marking	Closed	1	0.12
145247OLF	309753	24	SMT Kitting	Closed	2.38	2.82
145247OLF	309753	25	SMT Rigging	Closed	4.22	6.12
145247OLF	309753	30	Mounting SMT TOP	Closed	10	16.87
145247OLF	309753	31	Mounting SMT BOTTOM	Closed	6	8.73
145247OLF	309753	33	SMT Unrigging	Closed	1.74	1.35
145247OLF	309753	55	Manual SMT Inspection	Closed	8	12.55
145247OLF	309753	56	SMT UnKitting	Closed	2.62	3.77
145247OLF	309753	57	Kitting THT Selective Wave	Closed	1.02	2.1
145247OLF	309753	58	Kitting HLA Selective Wave	Closed	0.07	0.6
145247OLF	309753	60	LMT3-Manual assembling	Closed	32	37.05
145247OLF	309753	70	Selective soldering Inline5	Closed	0	0
145247OLF	309753	80	TH AOI inspection	Closed	18	22.7
145247OLF	309753	90	Depaneling	Closed	2.5	3.2
145247OLF	309753	110	LTIG - Incircuit test Genrad	Closed	12	11.07
145247OLF	309753	118	LQA - Quality inspection	Closed	7.2	8.87
145247OLF	309753	160	LWA2 - Packing	Closed	2.33	3.8

2.3.6. Siekiami rezultatai

Šio tyrimo planuojamas rezultatas yra trukmės nustatymo sistemos sukūrimas, kuris leistų prognozuoti naujų į elektronikos gamybos įmonę priimamų gaminių gamybinių procesų trukmę. Siekiant įsitikinti sukurtos sistemos patikimumu, reikalingas palyginimas tarp įvairių gaunamų įvertinimų ir galimų gamybinių procesų trukmės gavimo būdų, t.y.:

- Įmonėje naudojamos skaičiuoklės rezultatai (naudojama kaip įmonės dabartinio proceso atskaita) ir inžinierių darytos prielaidos (individualios žinios ir patirtis)
- Realūs (faktiniai) gamybiniai duomenys
- Gamybiniais duomenimis pagrįstos sistemos pasiūlymas

Norint įvertinti sprendimų paramos sistemos veikimą, palygintos dabartinio metodo apskaičiuojamos, faktinės ir sukurto sprendimo (skirtingais metodais) siūlomos gamybos procesų trukmės



12 pav. Skirtingų proceso trukmės vertinimo metodų palyginimo pavyzdys

Aukščiau esančiame grafike matosi, kad skirtingi proceso trukmės prognozavimo metodai siūlo skirtingą trukmę. Taip pat matomas skirtumas nuo standartinio įmonės proceso

3. Tyrimas

3.1. Tyrimo eiga

Tyrimas pradėtas norint sukurti sistemą, kuri naudodama klasifikavimo metodus leistų prognozuoti gamybos trukmę. Norima naujų gaminių gamybos trukmės nustatymą paremti istorinių duomenų klasifikavimu. Vykdyto tyrimo eiga suskirstyta į šiuos etapus

1. Gamybinių operacijų atrinkimas
2. Įmonės duomenų agregavimas
3. Duomenų apdorojimas, paruošimas ir filtravimas
4. Klasifikatoriaus tyrimas
5. Klasifikatoriaus bandymas

Tyrimui naudoti realūs elektronikos gaminių surinkimo įmonės Kitron duomenys. Buvo naudota statistika iš 2021 kalendorinių metų.

3.1.1. Naudota programinė įranga

Tyrimui vykdyti naudotos pagrindinės programos:

- IFS AB – IFS 10 – įmonėje Kitron naudojama ERP sistema, iš kurios buvo parsisiunčiami tyrimui naudoti duomenys.
- Microsoft Excel – programinė įranga naudota duomenų agregavimui, apdorojimui ir filtravimui. Buvo pasirinkta ją naudoti nes būtent Excel formatu buvo eksportuojami duomenys iš IFS 10 programos.
- Mathworks – MATLAB – programinė įranga naudota klasifikavimo modelių kūrimui, bandymui.

3.2. Gamybos operacijų atrinkimas trukmės nustatymui

Ankstesniuose skyriuose aprašyta kokios gamybinės operacijos yra tipinės, t.y. dažniausiai reikiamos norint surinkti elektronikos gaminį. Atsižvelgiant į šių operacijų subtilybes, galima jas suskirstyti į prognozuotinas ir neprognozuotinas, remiantis statistiniais duomenimis. Pavyzdžiui - nors tarp naudojamų statistinių duomenų yra daug testavimo, rankinio litavimo arba mechaninio surinkimo rezultatų, tačiau šiose operacijose egzistuoja daug specifinių niuansų, kurie neatsispindi nei rezultatų duomenyse, nei kituose įmonės duomenyse.

Dauguma gaminamų gaminių yra testuojami elektriškai arba funkciškai, siekiant arba patenkinti užsakovo reikalavimus arba užtikrinti kad brokuoti gaminiai nebūtų išvežti užsakovams. Tačiau skirtingiems gaminiams yra naudojama skirtinga įranga, testavimo principas, testavimo eiga. Tarp gaminių skiriasi ir testo aprėptis, t.y. kiek procentiškai komponentų dengia konkretus elektrinis testas konkrečiam gaminiui. Ši aprėptis nėra saugomas kaip gaminio charakteristika, taigi nepapuola prie agreguotų duomenų.

Dabartiniame įmonės vertinimo procese testo trukmės vertinimas paliekamas atvejo analizei. Kiekvienas gaminys vertinamas pagal užsakovo reikalavimus ir pateiktus poreikius. Kai kuriais atvejais, įranga yra pateikiama iš trečios šalies su jau nustatyta testavimo eiga ir trukme.


Kodėl sunku prognozuoti rankines operacijas

Gamybines operacijas, kurios paremtos rankiniu žmonių darbu yra sudėtinga prognozuoti, nes jose yra gausybė kintamųjų, kurie neatsispindi istoriniuose duomenyse ar gaminio informacijoje. Pavyzdžiui: lituojamų atvadų kiekis, lituojamų atvadų tankis, komponento įstatymo sudėtingumas, reikiamas litavimo tikslumas ir kiti.

Kodėl atrinkta paviršinių komponentų montavimo operacija

Vertinant operacijų įkainius, lengva pamatyti, kad brangiausiai įmonei kainuoja mašininės operacijos, t.y. gamybos veiksmai, kuriuose naudojama sudėtinga įranga, reikalaujanti didelių pradinių investicijų, naudojimo ir palaikymo kaštų. Tuo pačiu, tai yra operacijos, apie kurias yra sukaupta daugiausia statistinės informacijos ir kuri „leidžiasi“ būti klasifikuojama.

Įmonėje Kitron pagrindinės „mašininės“ operacijos yra paviršinių komponentų montavimas bei litavimas ir skylinių komponentų litavimas, kuomet naudojamas litavimas banga arba selektyvinio litavimo įranga. Paviršinių komponentų montavimo gamybos linija pavaizduota 13 pav.paveiksle. Prie šios linijos dirba nuo vieno iki keleto darbuotojų.



13 pav. Paviršinių komponentų montavimo gamybos linija

Tuo pačiu, greta „mašininė“ operacijų galima išskirti jas palaikančias operacijas, t.y. operacijas, kurių metu žmonės surenka reikiamus komponentus iš sandėlio, transportuoja juos į gamybos vietą. Tiek „mašininės“ tiek jas palaikančios „rankinės“ operacijos priklauso nuo kai kurių vienodų faktorių, pavyzdžiui skirtingų unikalių komponentų skaičiaus, bendro jų kiekio. Taigi surinkus ir agregavus duomenis reikalingus „mašininėms“ operacijoms, galima tuos pačius duomenis panaudoti ir palaikančių operacijų klasifikavimui.

Kodėl nesirinkti kiti prognozavimo metodai

Regresija – puikus metodas prognozuoti laiką esant pastoviems procesams. Pavyzdžiui esant tolydiniams procesams arba periodiniams matavimams. Iš kelių bandymų su agreguotais duomenimis pamatyta, kad regresijos modeliai pasižymi didele prognozių sklaida.

3.3. Duomenų surinkimas ir apdorojimas

Ankstesniuose skyriuose aprašyti norimi naudoti įmonės duomenys. Siekiant juos panaudoti klasifikavimo modelių apmokymui, reikėjo juos apjungti į vieną duomenų rinkinį.

3.3.1. Duomenų šaltiniai

Reikalingiems duomenims pasiekti naudoti keturi įmonės ERP sistemos raportai (duomenų rinkiniai), eksportuoti MS Excel formatu. Tai yra:

Manufacturing Structures – gaminių struktūrų raportas, t.y. gaminamų gaminių sudedamųjų dalių (komponentų) sąrašas. Šiame raporte esantys esminiai duomenys – Gaminys, komponento kodas, komponento aprašas, komponento kiekis per gaminį ir kuriai gaminio gamybinei operacijai priskirtas šis komponentas.

Routing Operations – gaminių gamybinių operacijų raportas, t.y. sąrašas operacijų, kurios yra naudojamos kiekvieno gaminio gaminimui. Šiame raporte esantys esminiai duomenys – Gaminys, gamybinės operacijos eilės numeris, operacijos pavadinimas.

Operation Statistics – Istorinių gamybos rezultatų raportas, parodantis kiekvieno gaminio, kiekvienos gamybos partijos, kiekvienos operacijos faktinę trukmę ir suraportuotą kiekį.

Inventory Part Planning Details – raportas rodantis įvairias su gamybos planavimu susijusias detales

Naudojantis šiais trimis raportais, buvo konstruojamas duomenų rinkinys, kurio iškarpa pateikta 7 lentelė lentelėje. Klasifikavimui naudotų duomenų rinkinio fragmentas pateiktas priede nr.1.

7 lentelė. Agreguotų duomenų rinkinio ištrauka

Product	Average machine time	SMT sides	Count of Unique	Total components	Simple SMT	Complex SMT	SMT line	Panel	Batches	LF	IPC	N2	Laser	Class
2247872LF	0,002842	1	8	9	7	1	1	30	2	1	2	0	0	3
2249168LF	0,002892	1	23	43	38	2	2	10	15	1	2	0	1	3
2247218LF	0,003055	2	4	4	1	3	3	56	12	1	3	0	1	3
2248241LF	0,003088	1	20	28	25	2	5	45	2	1	2	0	1	3
2248387LF	0,003115	2	12	18	16	1	3	20	4	1	2	1	1	3
1452829LF	0,003317	2	20	27	21	3	1	20	20	1	3	0	0	3

Duomenų agregavimo metu, siekiant replikuoti duomenis, kurie būtų naudojami kaip įvestis įmonės naudojamoje skaičiuoklėje, reikėjo komponentus išskaidyti pagal kaip jie traktuojami dabartinėje skaičiuoklėje. Komponentų skirstymas iškarpa iš įmonės skaičiuoklės pateikta 14 pav., o platesnis skirstymo aprašas pateiktas 8 lentelėje.

14 pav. Komponentų tipo priskyrimas įmonės skaičiuoklėje

8 lentelė Skaičiuoklėje naudojamų trumpinių paaiškinimas

Komponento tipas	Galimas skirstymas	Paaškinimas
------------------	--------------------	-------------

PCB	PCB	PCB – spausdintinė plokštė ant kurios montuojami komponentai
THT	THDBM/ THDBD THDRM/ THDRD	THDBM / THDBD - maži/dideli komponentai, lituojami banga arba selektyvu THDRM / THDRD - maži / didelis komponentai, lituojami ranka
SMT	L V	L – lazeriu paremtas komponentų statymas – paprasti komponentai V – vaizdo atpažinimu paremtas komponentų statymas – sudėtingi komponentai
Lipdukas	Label	

Tyrimo tikslams buvo sukurtas metodas kaip iš komponento aprašo ERP sistemoje, jį priskirti paprastų arba sudėtingų paviršinių komponentų grupėms. Po konsultacijų su proceso specialistais, buvo sutartos taisyklės, pagal kurias remiantis apraše esančia informacija, komponentai buvo padalinti į minėtus du tipus.

3.3.2. Ekspertinių žinių pritaikymas agreguojamiems duomenims

Siekiant duomenis apdoroti prieš juos pradėdant naudoti klasifikavimo modelio kūrimui, buvo surinktos žinios iš įmonės Kitron proceso inžinierių komandos.

Gaminio ruošinys (galintis susidėti iš n individualių gaminių, kur $1 < n < 60$) iš paviršinių komponentų pečiaus neišeis greičiau nei per 30 s. Tai yra apatinė trukmės riba, kurią sąlygoja litavimo pastos tepimo įrangos veikimo ciklas. Ši taisyklė reiškia, kad visi atvejai kuomet duomenyse galioja nelygė $t \times n < 30s$, kur t yra gamybos laikas per vieneta, o n gaminių kiekis ruošinyje yra klaidingi. Klaida gali būti lemta neteisingo laiko raportavimo, kurį atliko darbuotojai arba neteisingu laiko nustatymų įrangoje.

Pagal įmonės proceso specialistus paviršinių komponentų montavimo trukmei svarbiausi parametrai yra:

- Bendras komponentų skaičius
- Individualių komponentų skaičius
- Paprastų komponentų skaičius
- Sudėtingų komponentų skaičius
- Gaminių kiekis ruošinyje
- Partijos dydis

3.3.3. Gamybos operacijų agregavimas

Pirmiausia nuspręsta atrinkti visas gamybos partijas, gamintas 2021 metais ir remiantis šiais duomenimis, atrinkti tuos gaminius kurie turėjo paviršinių komponentų montavimo operaciją – taip buvo sudarytas pirminis tiriamų gaminių sąrašas. Tuomet buvo atrinkti gaminiai, kurie sąraše turėjo du vienos partijos atvejus, kitaip tariant buvo surinkinėjami iš dviejų pusių. Vienpusių ir dvipusių gaminių atskyrimui buvo išvestas naujas kintamasis kurio vertės 1 arba 2. Taip pat buvo suskaičiuotas kiekvieno gaminio gamintų partijų kiekis – nuo gamybos dažnumo priklauso darbuotojų įgūdžiai.

Atrinkus gaminius, kurie buvo gaminti 2021 metais ir kuriems buvo atliekama paviršinių komponentų statymo operaciją, buvo sudarytas atskiras jų sąrašas.

3.3.4. Gaminių struktūrų agregavimas

Kitron ERP sistemos IFS 10 raporte *Product Structures* laikomi visų gaminių sudedamųjų dalių sąrašai, dar kitaip vadinami BOM (angl. *Bill of Material*). Šiame raporte atskirose eilutėse saugomi

skirtingi komponentai. Kiekvienas komponentas, be kitos informacijos, turi savo kodą, ir aprašymą. Komponento kodas – septynių skaitmenų unikalus kodas. Komponento aprašymas – tekstinė informacija, kurioje nurodami svarbiausi komponento parametrai.

Siekiant ištraukti naudingą informaciją, buvo sudaryti du komponentų atpažinimo pagal jų aprašą metodai. Šie metodai skirti atskirti paprastus ir sudėtingus paviršinio montavimo komponentus pagal tai kokia informacija pateikta jų aprašymuose.

Komponentų sudėtingumo išskyrimui naudotos tokios pačios sąlygos kaip ir dabartinėje Kitron skaičiuoklėje. Šių duomenų išskyrimas leidžia kaupiamą atvejų bazę papildyti informacija apie bendrą komponentų kiekį, unikalų komponentų kiekį, paprastų ir sudėtingų komponentų kiekį.

3.3.5. Gaminų charakteristikų atrinkimas

Norint surinkti kuo daugiau potencialiai surinkimo trukmei įtaką turinčių faktorių, iš ERP sistemos buvo paimtos šios charakteristikos: gaminio tipas (švininis ar bešvinis), gaminio IPC klasė (elektronikos pramonėje paplitęs standartas apibrėžiantis kokybinius reikalavimus), ar gamybos metu buvo naudotos azoto dujos. Atrinkti faktoriai privesti prie bendro gaminų-atvejų sąrašo, taip sudarant beveik galutinį atvejų bazės formatą.

3.3.6. Vertinami kintamieji

Tyrime vertinami kintamieji ir jų reikšmė gamybos procesui pateikiama **9 lentelėje**.

9 lentelė. Kintamųjų įtaka gamybos trukmei

Kintamasis	Galimos vertės	Įtaka proceso trukmei
SMT sides	1;2	Parodo kiek kartų gaminys praeina montavimo liniją
Count of Unique	1-1000	Parodo kiek skirtingų tipų komponentų reikia pakrauti į surinkimo mašinas
Total components	1-2000	Kuo didesnis bendras komponentų kiekis, tuo ilgiau truks jų montavimas
Simple SMT	1-1000	Paprasti komponentai dedami sparčiau
Complex SMT	1-300	Sudėtingų komponentų statymas trunka greičiau
SMT line	1;2;3;4;5;6	Naudojama surinkimo linija. Skirtingos linijos pasižymi skirtingais greičiais.
Panel	1-60	Kuo daugiau ruošinyje gaminių, tuo mažesnis darbo laikas per vienetą.
Batches	2-30	Partijų kiekis 2021 m. Kuo dažniau gaminama, tuo didėja darbuotojų įgūdžiai.
LF	0;1	Švininiai/bešviniai gaminiai. Pereinant tarp jų, reikia papildomo pasiruošimo.
IPC	2;3	Elektronikos pramonės standartas, apibrėžiantis reikalaujamą kokybės lygį
N2	0;1	Azotas litavimo aplinkoje. Įsodrinimas azotu trunka papildomą laiką
Laser	0;1	Gaminio žymėjimas lazeriu pagreitina surinkimą, nes nekljuojami lipdukai.

Šie kintamieji buvo parinkti, nes jie yra prieinami įmonės ERP sistemoje. Po konsultacijų su proceso specialistais, buvo identifikuota, kad dalis didelę įtaką trukmei turinčių parametrų nėra saugoma įmonės duomenų bazėje. Vienas iš tokių kintamųjų yra komponentų pakuotės tipas ir dydis. Jis gali kisti kiekvienos gamybos partijos metu. Nuo šio kintamojo priklauso kiek dažnai darbuotojams teks keisti pakuotes prijungtas prie komponentų statymo įrangos.

3.3.7. Trukmės vidurkis, mediana ir standartinio nuokrypio pritaikymas

Ankstesniuose skyriuose aptartas dabartinis įmonės procesas gamybinių operacijų trukmių vertinimui. Darbinėje praktikoje inžinieriai dažniausiai naudoja trukmių vidurkį, kaip įrankį vertinti gamybos trukmę ilgesnėje perspektyvoje. Tačiau atsižvelgiant į duomenų pasiskirstymą, galima pamatyti, kad kiekvienas individualus gaminys dažnai turi skirtingą gamybos trukmę, skirtingose gamybos partijose. Susiduriama su situacija, kuomet turint tas pačias kintamųjų vertes, gauname skirtingus rezultatus. Jei šie skirtumai tarp partijų gamybos trukmių būtų maži, būtų galima teigti, jog teisinga yra naudoti trukmių vidurkį, o menki trukmių svyravimai yra lemiami žmonių darbo netolygumo.

Tačiau kai svyravimai tarp trukmių skirtingose gamybos partijose tampa pakankamai dideli reikia imtis kitų sprendimų, kurie atsižvelgtų į duomenų pasiskirstymą. Vieni iš paprasčiausių sprendimų – mediana ir vienos sigmos taisyklė. Mediana leidžia pamatyti aplink kokią vertę išsidėstę visi duomenys. Vienos sigmos taisyklė teigia, kad duomenis galima atfiltruoti paliekant tik tuos atvejus kurie patenka į režį vidurkis \pm vienas standartinis nuokrypis.

Tolimesnei tyrimo eigai buvo sudaryti trys pirminiai duomenų rinkiniai, kuriuose prie atskirų gaminių buvo privestas jų 2021 metų gamybos trukmės vidurkis, trukmės mediana ir vidurkis, išskaičiuotas pritaikius 1 sigma taisyklę.

3.3.8. Duomenų apribojimai

Tyrimo eigoje analizuota kas turi įtakos gamybos laikui, bet ko nėra įmonės ERP sistemoje ar kitose naudojamose duomenų bazėse.

Nors skaičiuojant gamybos trukmę, į skaičiuoklę įvedamos tokios charakteristikos kaip spausdintinės plokštės dydis, jos storis, išpjaustymo iš ruošinio metodas, tikslūs komponentų tipai (įskaitant lituojamų atvadų skaičių) ir t.t., tačiau ši informacija nesaugoma ERP sistemoje.

Turimi duomenys detaliam aprašyti 3.3.1 skyrelyje.

Atlikus prieinamos informacijos analizę, prieita išvados, kad daugiausia duomenų yra saugoma apie paviršinių komponentų montavimo procesą.

3.4. Klasių priskyrimas

3.4.1. Statistinių duomenų klasifikavimas

Norint naudoti klasifikavimo modelius, visų pirma reikia suklasifikuoti duomenis, kurie bus naudojami šių modelių apmokymui.

Pradedant sistemos kūrimą, buvo išbandyta į klasifikatoriaus apmokymo programą paduoti skirtingų gaminių, skirtingų operacijų duomenis. Pamačius pirminius rezultatus buvo greitai nuspręsta, kad klasifikatoriui trukdo skirtingos trukmės, priklausančios nuo skirtingų faktorių.

Klasifikavimo tikslinimas ir duomenų siaurinimas

Viso buvo surinkti duomenys apie >700 2021 metais gamintus gaminius. Skaičiuojant ir atskiras gamybos partijas, viso buvo virš 5000 atvejų. Po pirminių klasifikatorių kūrimo, kurio rezultatai pateikti, buvo pamatyta, kad paviršinių komponentų montavimo ir litavimo trukmės yra

pasiskirsčiusios labai plačiame ruože, t.y. nuo <1s iki >10min. Reikia pastebėti, kad tokios vertės gautos paėmus 2021 metų trukmių vidurkius. Atskirų gamybos partijų trukmės papuola į dar platesnį spektrą.

Nagrinėjant šį pasiskirstymą ir siekiant gauti trukmių spektrą analizei, buvo vykdytos konsultacijos su įmonės proceso specialistais ir prieita išvados, kad retai (<2 kartų per metus) gaminamų gaminių trukmė gali būti ilgesnė dėl žmogiškojo faktoriaus. Kuo rečiau darbuotojai kažką dirba, tuo mažiau prisimena apie gaminio specifiką. Tuo pačiu, jei problema yra pastebima vienos gamybos partijos metu, neretai detalesnė analizė, proceso stebėjimas ir pakeitimų įvedimas vykdomas tik sekančios gamybos partijos metu. Tai reiškia, kad gaminiai, kurie gaminami tik vieną kartą per metus, galimai iškreipia bendrą statistiką.

3.4.2. Klasių tikslumas

Kadangi tyrime klasės priskiriamos trukmei, svarbiu tampa klasės „žingsnis“, t.y. kokią trukmių amplitudę apima konkreti klasė. Čia susiduriama su keliomis problemomis, susijusiomis su klasifikatoriaus teikiama nauda galutiniam naudotojui:

- Klasės žingsnis turi būti suprantamo žmogui intervalo
- Klasės žingsnis turi būti pakankamai siauras, tam kad turėtų prasmę trukmės prognozavime

Tam, kad spręsti šias problemas, duomenys suskirstyti klasėmis, kurių žingsniai: 30 s, 10 s, 5 s.

Klasių dydis ir kiekis

Norint turėti pakankamai duomenų kiekvienoje klasėje klasifikavimo metodo apmokymui ir remtis tik tikrais duomenimis, buvo priimtas sprendimas naudoti tik tas klases, kuriose yra daugiau nei 10 atvejų.

3.5. Tinkamiausio klasifikavimo metodo parinkimas

Numatyta geriausiai tinkantį klasifikavimo metodą atrinkti naudojant *Matlab Classification Learner App* aplikaciją. Ši aplikacija leidžia vienu metu apmokyti virš 20 klasifikavimo metodų ir greitai pamatyti geriausiai veikiančius. Tinkamiausiu klasifikavimo metodu nuspręsta laikyti tą, kuris rodys didžiausią tikslumą (angl. *accuracy*).

3.6. Tyrimo rezultatai

Viso buvo sudaryti 9 atskiri duomenų rinkiniai, pateikti 10 lentelėje.

10 lentelė. Sudaryti duomenų rinkiniai

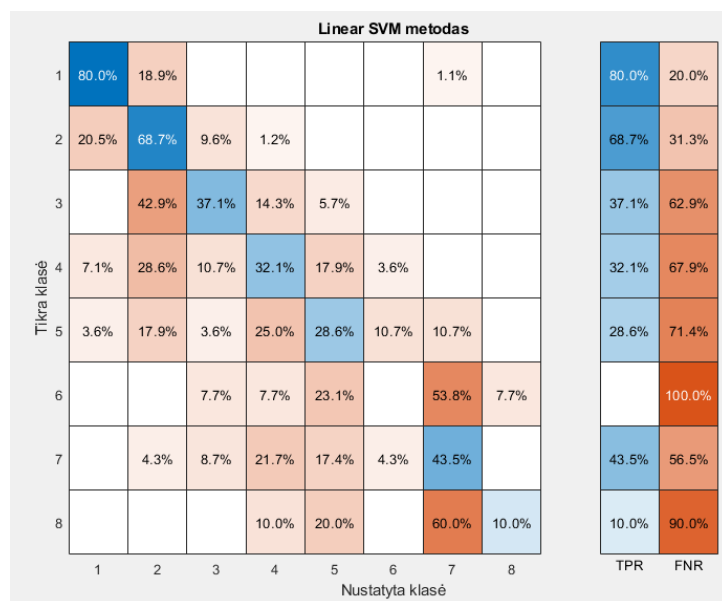
Trukmės apdorojimo metodas	5 s klasės žingsnis	10 s klasės žingsnis	30 s klasės žingsnis
Vidurkis	1 rinkinys	2 rinkinys	3 rinkinys
Mediana	4 rinkinys	5 rinkinys	6 rinkinys
1 Sigma taisyklė	7 rinkinys	8 rinkinys	9 rinkinys

3.6.1. Klasifikatoriaus tikslumas naudojant skirtingus duomenų apdorojimo metodus

Trukmių vidurkis taikant 1 Sigma taisyklę


Pirmiausia tirti duomenų rinkiniai sudaryti iš gaminių, kurių gamybos trukmė buvo apskaičiuota kaip visų gamintų partijų trukmės vidurkis, pritaikius 1 Sigma taisyklę.

30 s klasės žingsniu pasiekiami geriausi rezultatai, prognozavimo tikslumas iki 80%. Šis rezultatas pasiektas su *Linear SVM* metodu.



15 pav. Klasifikavimo tikslumas naudojant 30 s žingsnį ir *Linear SVM* metodą


Naudojant duomenų rinkinį, kuriame naudotas 10 sekundžių klasės žingsnis, geriausius rezultatus parodė *Cubic SVM* klasifikavimo metodas.



16 pav. Klasifikavimo tikslumas naudojant 10 s žingsnį ir *Cubic SVM* metodą

Šiuo metodu pasiekiamas iki 54% klasifikavimo tikslumas. Taip pat pirmos keturios klasės buvo prognozuojamos pakankamai tolygiu tikslumu. Tai gali būti paaiškinama didesniu atvejų skaičiumi, kuris buvo prieinamas modelio apmokymui.

Geriausias klasifikatoriaus tikslumas naudojant 1 Sigma taisyklę ir 5 sekundžių klasės žingsnį pasiektas su *Boosted Trees* klasifikavimo metodu – 28% tikslumas.




17 pav. Klasifikavimo tikslumas naudojant 5 s žingsnį ir *Boosted Trees* metodą

Matome, kad tik 4 klasė prognozuota daugiau nei 50% tikslumu.

Mediana

Toliau buvo atlikti bandymai su gamybos trukmėmis, kurios gautos apskaičiavus visų gaminių gamybos partijų trukmių medianą.


Kuomet naudotas 30 s klasės žingsnis, geriausiai veikia *Linear SVM* klasifikavimo metodas, kuris bendrai turi 47,8% tikslumą, o atskiras klases prognozuoja iki 80% tikslumu.



18 pav. Klasifikavimo tikslumas naudojant 30 s žingsnį ir *Linear SVM* metodą

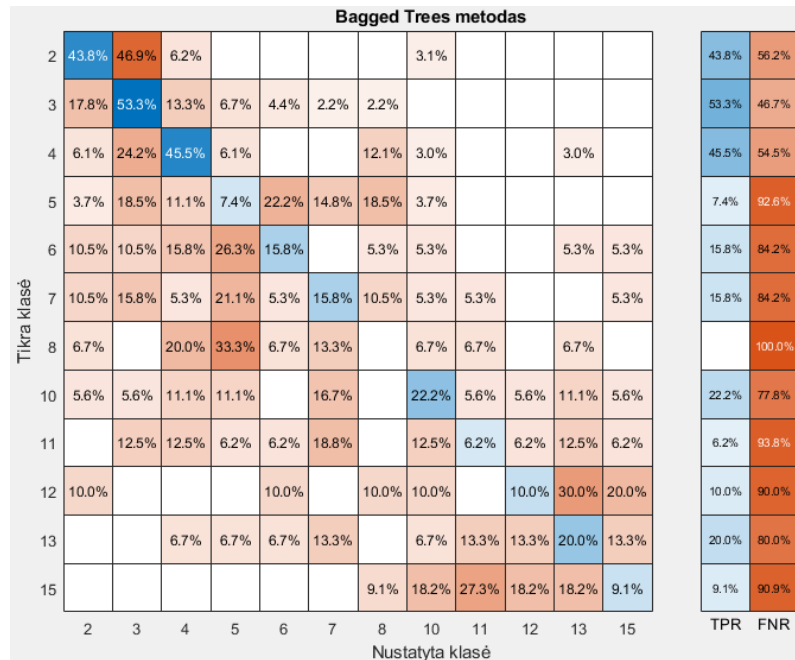
Pritaikius 10 s žingsnį, geriausias modelis buvo *Linear SVM* ir rodė vidutiniškai 33,8% tikslumą. Atskiros klasės buvo klasifikuojamos iki 60% tikslumu.

pastebėti, jog šiame duomenų rinkinyje į 1 ir 2 klases patenka gerokai daugiau atvejų, nei į kitas klases



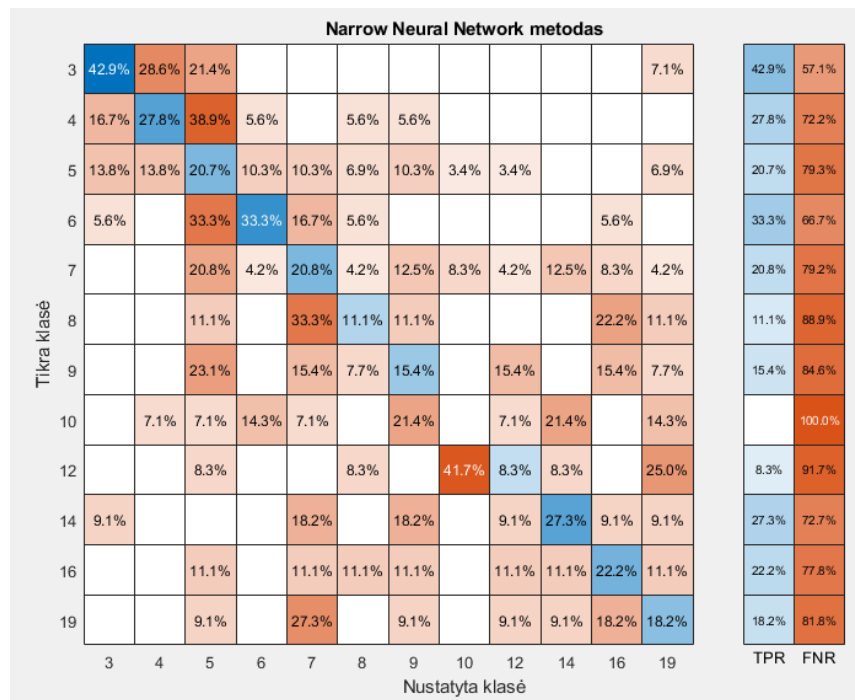
21 pav. Klasifikavimo tikslumas naudojant 30 s žingsnį ir vidutinį Gauss'o SVM metodą

Prie 10 s klasės žingsnio buvo pasiektas bendras 27,3% tikslumas, atskirų klasių tikslumas yra iki 54%. Geriausiai pasirodęs metodas buvo *Bagged Trees*.



22 pav. Klasifikavimo tikslumas naudojant 10 s žingsnį ir *Bagged Trees* metodą

Galiausiai perėjus prie smulkiausio klasės žingsnio – 5 s trukmės, bendras tikslumas siekė 21,4%, o atskirų klasių tikslumas iki 43%. Geriausių tikslumą parodė *Narrow Neural Network* metodas



23 pav. Klasifikavimo tikslumas naudojant 5 s žingsnį ir *Narrow Neural Network* metodą

3.6.2. Tiksliausių metodų atrinkimas

Visi aukščiau aprašyti metodai ir jų rezultatai pateikti palyginimui 11 lentelėje.

Lentelėje pateiktas bendras geriausio metodo tikslumas, skliausteliuose nurodytas geriausias pavienės klasės tikslumas. Šalia parašytas metodo pavadinimas. Didžiausiu tikslumu pasižymėję rezultatai paryškinti.

11 lentelė Skirtingų klasifikavimo metodų tikslumo palyginimas

Klasės žingsnis	1 Sigma	Mediana	Vidurkis
30 s	54,8% (80%) Linear SVM	47,8% (80,4%) Linear SVM	39,8% (75%) Medium Gaussian SVM
10 s	39,4% (53,5%) Cubic SVM	33,8% (59,5%) Linear SVM	27,3% (53,3%) Bagged Trees
5 s	28,1% (56,5%) Boosted Trees	32% (46,7%) Bagged Trees	21,4% (42,9%) Narrow Neural Network

Tiksliausi metodai, veikę prie 30 s ir 10 s žingsnių buvo SVM (angl. *Support Vector Machine*) tipo. Šie metodai paremti klasių atskyrimu išdėsčius jų atvejus erdvėje.

Tiksliausias metodas prie 5 s žingsnio buvo *Bagged Trees*. Šis metodas paremtas daugelio sprendimų medžių prognozių naudojimu, kaip rezultatą naudojant prognozių vidurkį.

3.6.3. Svarbiausių kintamųjų nustatymas

Naudojant MATLAB *Classification Learner* aplikacijoje prieinamą prognozavimui naudojamų kintamųjų analizę, buvo pasirinkta ištirti geriausiai veikusią klasifikatorių savybes. Nagrinėjant klasifikavimo metodus ir duomenis, labai svarbus yra svarbiausių kintamųjų vertinimas. Išbandyti

MATLAB siūlomi kintamųjų svarbumo rikiavimo metodai, kuomet naudojamas didžiausią tikslumą parodęs Linear SVM metodas, su 30 s klasės žingsniu ir 1 sigma taisyklės duomenų apdorojimu.

12 lentelė. Kintamųjų svarbumas pagal skirtingus metodus

Eilės Nr	MRMR	Įvertis	Chi2	Įvertis	ANOVA	Įvertis	Kruskal Wallis	Įvertis
1	Average Batch	0,27	Average Batch	50,88	Total Components	72,78	Average Batch	61,45
2	Count of Unique	0,23	Panelization	50,34	Simple SMT	66,41	Panelization	59,70
3	LF	0,12	Total Components	43,08	Count of Unique	46,76	Total Components	58,08
4	SMT line	0,09	Simple SMT	41,59	Complex SMT	38,90	Simple SMT	54,32
5	Panelization	0,09	Complex SMT	26,33	Average Batch	33,20	Complex SMT	47,88
6	N2	0,07	Count of Unique	24,71	Panelization	32,36	Count of Unique	37,59
7	Count of batches	0,04	SMT line	11,04	LF	11,00	LF	10,42
8	Total Components	0,04	LF	10,47	SMT line	5,82	SMT line	5,38
9	IPC Class	0,03	SMT sides	5,33	SMT sides	5,45	SMT sides	5,30
10	Complex SMT	0,02	Laser	2,68	Laser	2,69	Laser	2,66
11	Laser	0,02	IPC Class	2,32	IPC Class	2,33	IPC Class	2,31
12	Simple SMT	0,01	Count of batches	1,92	Count of batches	1,11	N2	0,60
13	SMT sides	0,01	N2	0,6	N2	0,59	Count of batches	0,31

12 lentelėje matoma, kad skirtingi svarbumo rikiavimo metodai skirtingai rikiuoja kintamuosius. Panašiausias kintamųjų rikiavimas matomas *Chi2*, *ANOVA* ir *Kruskal Wallis* metodų rikiavime. Reikia pastebėti, kad visi minėtų trijų metodų atrinkti penki kintamieji sutampa su įmonės proceso specialistų išvardintais kintamaisiais, kurie aprašyti 3.3.2 skyrelyje. Tai reiškia, kad inžinierių ekspertinės žinios sutampa su išvadomis, kurias prieina kintamųjų svarbumo rikiavimo metodai, remdamiesi tik statistiniais gamybos duomenimis.

3.7. Testavimas

Siekiant įvertinti kaip kuriama sistema vertina visiškai naujus gaminius, sudarytas palyginimas kaip gaminius vertina dabartinė įmonės skaičiuoklė, koks buvo realus gamybos laikas ir kokią klasę gaminiui priskiria sukurta trukmės nustatymo sistema. Paimti trys gaminiai, kurie pradėti gaminti 2022 metais, klasifikavimo metodai parinkti pagal 11 lentelėje paryškintus geriausiai veikusius metodus. Palyginimo rezultatai pateikti 13 lentelėje.

13 lentelė. Klasifikavimo metodų palyginimas su įmonės skaičiuokle ir realia trukme

Gaminys	Įmonės skaičiuoklės vertinta trukmė, h	30 s klasės žingsnis, Linear SVM, h	10 s klasės žingsnis, Cubic SVM, h	5 s klasės žingsnis, Bagged Trees, h	Realioji trukmė, h
2247955LF	0,0044	0,0005-0,0083	0,0027-0,0055	0,0069-0,0083	0,0056

2248070LF	0,0174	0,0083-0,0166	0,0111-0,0139	0,0111-0,0125	0,0142
1452233LF	0,0065	0,0005-0,0083	0,0027-0,0055	0,0042-0,0055	0,0089

Klasifikavimo metodai, kurių klasių intervalai sutampa su realia gamybos trukme pažymėti paryškintu šriftu. Galima pastebėti, kad intervalai atitiko tik naudojant 30 s klasės žingsnį. 10 s ir 5 s klasės žingsnį naudoję metodai neatitiko realios trukmės, tačiau reikia pastebėti, kad jų prognozuotos trukmės yra iš gretimų klasių, taigi metodai prognozuoja teisinga linkme.

Įmonės skaičiuoklės vertės neatitinka realios gamybos trukmės, tačiau bandyme naudoti gaminiai tik pradėjo serijinę gamybą. Pirmos gamybos partijos dažnai pasižymi techniniais nesklendumais, o tai ištempia bendrą gamybos trukmę. Su laiku, praėjus kelioms serijinės gamybos partijoms, tikėtina, kad trukmė normalizuosis ir priartės prie skaičiuoklės vertinamos trukmės.

Vertinant iš praktinio panaudojimo ir vertės pusės, 30 s intervalai yra nepakankamai tikslūs, kad būtų užtektini trukmės vertinimui. Nors mažesnių intervalų klasės rodo rezultatus esančius arti realių trukmių, tačiau toks tikslumas yra nepakankamas praktiniam panaudojimui. Atmetus pačių metodų veikimą, rekomenduotina grįžti prie įmonės duomenų ir proceso lemiančių kintamųjų paieškos.

3.8. Rekomendacijos praktiniam taikymui

Siekiant sukurtą įrankį panaudoti kitose gamybinėse įmonėse, nepaisant jų veiklos srities, turi būti išpildytos šios sąlygos:

- Turi egzistuoti ir būti prieinami pakankamai istorinių duomenų klasifikavimo modelių apmokymui
- Duomenys turi būti struktūrizuoti, arba turi būti galimybė manipuliuoti duomenų struktūra, apjungiant iš skirtingų šaltinių gaunamą informaciją. Tai reiškia, kad skirtinguose duomenų šaltiniuose turi egzistuoti bendrų „vardiklių“, kurie leistų apjungti turimus duomenis. Apibendrintai galima teigti, kad turi būti galimybė duomenis agreguoti ir paruošti tolimesniam naudojimui
- Reikalingos ekspertinės proceso žinios, siekiant parinkti teisingas charakteristikas ir duomenų priklausomybes

Vartotojo sąsaja

Siekiant, kad sukurta sistema būtų paprastai ir intuityviai naudojama galutinio naudotojo – inžinieriaus, reikalinga vartotojo sąsaja. Ji būtų skirta vertinamo gaminio charakteristikų įvedimui, sistemos parametrų parinkimui ir rezultatų vizualizavimui.

Išvados ir rezultatai

1. Išanalizuoti skirtingi metodai trukmės nustatymui, įskaitant gamyklos skaitmeninį klonavimą, inžinieriaus-eksperto klonavimą, proceso simuliaciją ir duomenų klasifikavimą. Tolimesniam sistemos vystymui parinktas duomenų klasifikavimo metodas, kuriuo remiantis būtų sudaroma klasifikavimo sistema, nustatanti naujai įvedamo gaminio gamybos trukmę remiantis jau sukauptais atvejais.
2. Pateikus dabartinio įmonės gaminių gamybos trukmės nustatymo procesą išvardinti jo trūkumai veikimo principu ir panaudojime. Dabartinis procesas paremtas iš užsakovų gaunamų duomenų vedimu į inžinierių naudojamą skaičiuoklę, kur kiekviena dedamoji dalis turi savo fiksuotą laiko vertę. Atnaujinimai rengiami tik pastebėjus klaidas, nėra atsižvelgiama į jau sukauptus duomenis. Pasiūlyta sukurti sistemą, kuri gaminių gamybos trukmės vertinimui panaudotų kaupiamus duomenis. Sistemą suplanuota paremti klasifikavimo metodais. Sukurta sistema galėtų būti naudojama tiek kaip savarankiškas įrankis, tiek greta dabartinės skaičiuoklės ar atliekant efektyvumo tyrimus.
3. Remiantis įmonės ERP sistemoje saugomais duomenimis, iš skirtingų raportų buvo surinkti tyrimui reikalingi duomenys apie gamybos trukmes, gaminių charakteristikas. Naudoti 2021 metų duomenys, viso vertinta >5000 gamybos partijų ir >700 unikalių gaminių. Trukmės nustatymui parinkta paviršinių komponentų montavimo operacija. Apjungus duomenis, buvo įvestos trys taisyklės trukmių apdorojimui – aritmetinis vidurkis, mediana ir vidurkis naudojant 1 Sigma taisyklę. Gaminiai buvo klasifikuoti pagal jų gamybos trukmę, pritaikius tris laiko intervalus – klasės žingsnius: 30 s, 10 s ir 5 s. Šie intervalai parinkti dėl jų aiškumo žmogui, ir tinkamumo vertinamam procesui. Viso sukurti devyni duomenų rinkiniai
4. Sukurti 9 duomenų rinkiniai panaudoti apmokant klasifikavimo modelius. Remiantis kiekvienu rinkiniu buvo apmokyti 20 klasifikavimo modelių ir lygintas jų tikslumas. Geriausiai savo laiko klasėse pasirodę klasifikavimo modeliai buvo *Linear SVM* (54,8%), *Cubic SVM* (39,4%) ir *Bagged Trees* (32%). Tiriant svarbiausius klasifikavime naudotus kintamuosius pastebėta, kad *Chi2*, *ANOVA* ir *Kruskal Wallis* metodais nustatyti svarbiausi kintamieji, sutampa su įmonės specialistų nurodytais kintamaisiais.
5. Siekiant ištirti sukurto sistemos praktinį naudingumą, parinkti trys 2022 m. pradėti gaminti gaminiai. Bandyta jų trukmę nustatyti naudojant tris geriausiai pasirodžiusius klasifikavimo modelius. Tiksliausiai trukmę nustatė 30 s klasės intervalą taikęs *Linear SVM* metodas. Naudojant mažesnio intervalo klasės žingsnius, trukmė nustatyta neteisingai. Tai lemama nepakankamo duomenų ir kintamųjų kiekio, kurie neleidžia tiksliai apmokyti mažesnio intervalo klasifikavimo metodų

Literatūros sąrašas

1. *Handbook on Decision Support Systems 1: Basic Themes*. . BURSTEIN, Frada; and HOLSAPPLE, Clyde eds., Berlin Heidelberg: Springer-Verlag, 2008 [tikrinta May 7, 2021]. Prieiga per <<https://www.springer.com/gp/book/9783540487128>>. ISBN 9783540487128.
2. LEE, Y. T., et al. A Classification Scheme for Smart Manufacturing Systems' Performance Metrics. *Smart and Sustainable Manufacturing Systems*. 2016/12/12 ed., 2017, vol. 1, no. 1. pp. 52-74. Prieiga per <<https://pubmed.ncbi.nlm.nih.gov/28785744>
<<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5544019/>> PubMed. ISSN 2572-3928.
3. *Real-World Decision Support Systems: Case Studies*. . PAPATHANASIOU, Jason; PLOSKAS, Nikolaos and LINDEN, Isabelle eds., Springer International Publishing, 2016 [tikrinta May 7, 2021]. Prieiga per <<https://www.springer.com/gp/book/9783319439150>>. ISBN 9783319439150.
4. POWER, Dan. *Decision Support Systems Resources*. Prieiga per:<<http://dssresources.com/>>.
5. TERZIYAN, Vagan; GRYSHKO, Svitlana and GOLOVIANKO, Mariia. Patented Intelligence: Cloning Human Decision Models for Industry 4.0. *Journal of Manufacturing Systems*, 2018, vol. 48. pp. 204-217. Prieiga per <<https://www.sciencedirect.com/science/article/pii/S0278612518300608>>. ISSN 0278-6125.
6. STUNGURIENĖ, Stanislava. *Operacijų Valdymas: Vadovėlis*. Vilnius: TEV, 2010. ISBN 9786094330131.
7. LEE, Jay, et al. Recent Advances and Trends in Predictive Manufacturing Systems in Big Data Environment. *Manufacturing Letters*, 2013, vol. 1, no. 1. pp. 38-41. Prieiga per <<https://www.sciencedirect.com/science/article/pii/S2213846313000114>>. ISSN 2213-8463.
8. YAN, Aijun; YU, Hang and WANG, Dianhui. Case-Based Reasoning Classifier Based on Learning Pseudo Metric Retrieval. *Expert Systems with Applications*, Dec 15, 2017, vol. 89. pp. 91-98. Prieiga per <<http://dx.doi.org/10.1016/j.eswa.2017.07.022>> CrossRef. ISSN 0957-4174.
9. RICHTER, Michael M.; and WEBER, Rosina. *Case-Based Reasoning: A Textbook*. Berlin Heidelberg: Springer-Verlag, 2013 [tikrinta May 24, 2021]. Prieiga per <<https://www.springer.com/gp/book/9783642401664>>. ISBN 9783642401664.
10. FINNIE, Gavin; and SUN, Zhaohao. R5 Model for Case-Based Reasoning. *Knowledge-Based Systems*, January 1, 2003, vol. 16, no. 1 [tikrinta Jun 12, 2021]. pp. 59-65. Prieiga per <<https://www.sciencedirect.com/science/article/pii/S0950705102000539>>. ISSN 0950-7051.
11. CHUNG, SHU-HSING; and HUANG, HUNG-WEN. Cycle Time Estimation for Wafer Fab with Engineering Lots. *Null*, 2002, vol. 34, no. 2. pp. 105-118. Prieiga per <<https://doi.org/10.1080/07408170208928854>>. ISSN 0740-817X.
12. KALLIO, Kai; JOHANSSON, Mika and NEVALAINEN, Olli. Estimating the Operation Time of Flexible Surface Mount Placement Machines. *Production Engineering*, 2010, vol. 6.
13. VAINIO, Frans, et al. Estimating the Production Time of a PCB Assembly Job without Solving the Optimised Machine Control. *Null*, 2015, vol. 28, no. 8. pp. 823-835. Prieiga per <<https://doi.org/10.1080/0951192X.2014.902104>>. ISSN 0951-192X.

14. LAAKSO, Tero, et al. Estimating the Production Times in PCB Assembly. *Journal of Electronics Manufacturing*, 2002, vol. 11. pp. 161-170.
15. YANG, Zhuo, et al. *Investigating Grey-Box Modeling for Predictive Analytics in Smart Manufacturing*. , 2017 [tikrinta 5/24/2022]. Prieiga per <<https://doi.org/10.1115/DETC2017-67794>>. ISBN 9780-791858134.
16. MICHIE, D.; SPIEGELHALTER, D. and TAYLOR, Charles. Machine Learning, Neural and Statistical Classification. *Technometrics*, January 1, 1999, vol. 37 [tikrinta May 13, 2022].
17. BROUGHTON, Vanda; and BROUGHTON, Vanda. *Essential Classification*. London, UNKNOWN, Facet Publishing, 2017. ISBN 9781783300310.
18. GIBELIN, P. An Evaluation of Symptom Classification Systems used for the Assessment of Patients with Heart Failure in France. *European Journal of Heart Failure*, 2001, vol. 3, no. 6. pp. 739-746. Prieiga per <[https://doi.org/10.1016/S1388-9842\(01\)00206-9](https://doi.org/10.1016/S1388-9842(01)00206-9)>. ISSN 1388-9842.
19. MATLOFF, N. *Statistical Regression and Classification: From Linear Models to Machine Learning*. CRC Press, 2017. Prieiga per <<https://books.google.lt/books?id=IHs2DwAAQBAJ>>. ISBN 9781351645898.
20. *How to Organize Data Labeling for Machine Learning: Approaches and Tools*. Nov 26, 2021 [tikrinta May 7, 2022] Prieiga per: <<https://www.altexsoft.com/blog/datascience/how-to-organize-data-labeling-for-machine-learning-approaches-and-tools/>>.
21. ANZANELLO, Michel J.; ALBIN, Susan L. and CHAOVALITWONGSE, Wanpracha A. Selecting the Best Variables for Classifying Production Batches into Two Quality Levels. *Chemometrics and Intelligent Laboratory Systems*, 2009, vol. 97, no. 2. pp. 111-117. Prieiga per <<https://www.sciencedirect.com/science/article/pii/S0169743909000410>>. ISSN 0169-7439.
22. AGGARWAL, C. C. *Data Classification: Algorithms and Applications*. Taylor & Francis, 2014. Prieiga per <<https://books.google.lt/books?id=gJhBBAAAQBAJ>>. ISBN 9781466586741.
23. YIU, Tony. *Understanding Random Forest*. -08-14T04:06:49.957Z, 2019 [tikrinta Jun 12, 2021] Prieiga per: <<https://towardsdatascience.com/understanding-random-forest-58381e0602d2>>.
24. HE, Zhenglei, et al. A Deep Reinforcement Learning Based Multi-Criteria Decision Support System for Optimizing Textile Chemical Process. *Computers in Industry*, Feb, 2021, vol. 125. pp. 103373. Prieiga per <<http://dx.doi.org/10.1016/j.compind.2020.103373>> CrossRef. ISSN 0166-3615.
25. MCHUGH, Leo C.; SNYDER, Kevin and YAGER, Thomas D. The Effect of Uncertainty in Patient Classification on Diagnostic Performance Estimations. *Plos One*, 2019, vol. 14, no. 5. pp. e0217146. Prieiga per <<https://doi.org/10.1371/journal.pone.0217146>>.
26. MANYIKA, James; SICLAIR, Jeff and DOBBS, Richard. *Manufacturing the Future: The Next Era of Global Growth and Innovation*. , 2012.
27. SHIN, Seung-Jun; WOO, Jungyub and RACHURI, Sudarsan. Predictive Analytics Model for Power Consumption in Manufacturing. *Procedia CIRP*, 2014, vol. 15. pp. 153-158. Prieiga per <<https://www.sciencedirect.com/science/article/pii/S2212827114004594>>. ISSN 2212-8271.

28. MENEZES, Brenno C., et al. Predictive, Prescriptive and Detective Analytics for Smart Manufacturing in the Information Age. *IFAC-PapersOnLine*, 2019, vol. 52, no. 1. pp. 568-573. Prieiga per <<https://www.sciencedirect.com/science/article/pii/S2405896319302095>>. ISSN 2405-8963.
29. DUBEY, Rameshwar, et al. Big Data and Predictive Analytics and Manufacturing Performance: Integrating Institutional Theory, Resource-Based View and Big Data Culture. *British Journal of Management*, 2019, vol. 30, no. 2. pp. 341-361. Prieiga per <<https://doi.org/10.1111/1467-8551.12355>>. ISSN 1045-3172.
30. J. Krumeich, et al. *Big Data Analytics for Predictive Manufacturing Control - A Case Study from Process Industry*. , 2014. ISBN 2379-7703.
31. LEE, Jay; BAGHERI, Behradand JIN, Chao. Introduction to Cyber Manufacturing. *Manufacturing Letters*, 2016, vol. 8. pp. 11-15. Prieiga per <<https://www.sciencedirect.com/science/article/pii/S2213846316300049>>. ISSN 2213-8463.
32. MOYNE, James; and ISKANDAR, Jimmy. *Big Data Analytics for Smart Manufacturing: Case Studies in Semiconductor Manufacturing*. , 2017. ISBN 2227-9717.

Priedai

1 Priedas. Klasifikavimui naudotų duomenų rinkinio fragmentas

Product	Average machine time	Class	SMT sides	Count of Unique components	Total components	Simple SMT	Complex SMT	SMT line	Panelization	Count of batches	LF	IPC Class	N2	Laser
1453155LF	0,000855	1	1	5	6	5	0	4	20	18	1	IPC Class 2	0	1
2247479LF	0,000876	1	1	4	5	4	1	5	40	29	1	IPC Class 2	0	1
2248245LF	0,00133	1	1	5	5	3	1	5	60	11	1	IPC Class 2	0	1
2248647LF	0,001644	1	1	21	34	31	2	5	20	34	1	IPC Class 2	0	1
1451702LF	0,001778	1	1	34	71	67	2	4	30	27	1	IPC Class 2	0	1
2248240LF	0,002143	1	1	20	29	26	1	5	45	14	1	IPC Class 2	0	1
1452364LF	0,002287	1	1	5	5	3	0	3	10	6	1	IPC Class 2	0	1
2247448LF	0,002679	1	1	2	3	0	2	3	4	11	1	IPC Class 2	0	0
2247872LF	0,002842	1	1	8	9	7	1	1	30	2	1	IPC Class 2	0	0
2249168LF	0,002892	1	1	23	43	38	2	2	10	15	1	IPC Class 2	0	1
2247218LF	0,003055	1	2	4	4	1	3	3	56	12	1	IPC Class 3	0	1
2248241LF	0,003088	1	1	20	28	25	2	5	45	2	1	IPC Class 2	0	1
2248387LF	0,003115	1	2	12	18	16	1	3	20	4	1	IPC Class 2	1	1
1452829LF	0,003317	1	2	20	27	21	3	1	20	20	1	IPC Class 3	0	0

2247396LF	0,003331	1	1	8	12	10	1	5	12	3	1	IPC Class 2	0	1
1452832LF	0,003459	1	2	3	3	0	2	4	20	20	1	IPC Class 3	0	0
1452473LF	0,003572	1	1	16	20	16	3	5	16	5	1	IPC Class 2	1	1
2247756LF	0,003602	1	1	3	4	3	0	5	5	8	1	IPC Class 2	0	0
2247782LF	0,003634	1	1	2	5	4	0	5	10	7	1	IPC Class 2	0	0
2247787LF	0,003641	1	1	3	4	3	0	5	5	19	1	IPC Class 2	0	0
2248126LF	0,003722	1	1	1	1	0	1	3	10	16	1	IPC Class 2	0	1
2248315LF	0,003932	1	1	10	12	10	1	4	20	7	1	IPC Class 2	0	0
2247543LF	0,00416	1	1	47	114	107	7	4	16	23	1	IPC Class 2	0	1
1450722LF	0,004171	1	2	13	24	19	4	1	20	30	1	IPC Class 2	0	1
2247754LF	0,004294	1	1	3	6	4	1	5	8	5	1	IPC Class 2	0	0
2249294LF	0,004344	1	1	44	94	87	2	1	10	21	1	IPC Class 2	0	1
2247579LF	0,00461	1	2	26	55	41	10	4	10	22	1	IPC Class 3	0	0
2247429LF	0,004773	1	1	3	5	4	0	1	30	3	1	IPC Class 2	0	0