Poboljšanje procesa upravljanja podacima u proizvodnji

Pavičić, Morana

Master's thesis / Diplomski rad

2021

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Mechanical Engineering and Naval Architecture / Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:235:562742

Rights / Prava: Attribution 4.0 International/Imenovanje 4.0 međunarodna

Download date / Datum preuzimanja: **2024-03-28**

Repository / Repozitorij:

Repository of Faculty of Mechanical Engineering and Naval Architecture University of Zagreb







SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Morana Pavičić

Zagreb, 2021.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Mentor:

Doc. dr. sc. Miro Hegedić, dipl. ing.

Studentica:

Morana Pavičić

Zagreb, 2021.

Izjavljujem da sam ovaj rad izradila samostalno koristeći znanja stečena tijekom studija i navedenu literaturu.

Zahvaljujem mentoru, doc. dr. sc. Miri Hegediću, na pruženoj podršci i pomoći tijekom izrade diplomskog rada, ali i realizacije ostalih projekata u okviru Udruge studenata Industrijskog inženjerstva i menadžmenta te Katedre za industrijsko inženjerstvo.

Također, zahvaljujem svim zaposlenicima tvrtke HAIX obuća d.o.o. koji su na mojih *1000 zašto* strpljivo ponudili *1000 zato*.

Posebno zahvaljujem svojoj majci Korneliji na neizmjernoj cjeloživotnoj podršci.

Morana Pavičić



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE
Središnje povjerenstvo za završne i diplomske ispite
Povjerenstvo za diplomske radove studija strojarstva za smjerove:
proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment,
inženjerstvo materijala te mehatronika i robotika

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum:	Prilog:
Klasa: 602 - 04 / 21 - 6 / 1	
Ur. broj: 15 - 1703 - 21 -	

DIPLOMSKI ZADATAK

Student: **MORANA PAVIČIĆ** Mat. br.: 0035200575

Naslov rada na hrvatskom jeziku: **Poboljšanje procesa upravljanja podacima u proizvodnji**

Naslov rada na engleskom jeziku: **Improvement of data management process in manufacturing**

Opis zadatka:

Podaci koji se prikupljaju i obrađuju kroz svakodnevne aktivnosti transformiraju način na koji ljudi obavljaju iste. U proizvodnji se također prikupljaju velike količine podataka s različitih strojeva, uređaja i radnih stanica. Velike količine podataka osim dobrobiti stvaraju i poteškoće s obzirom da nije lako odrediti koji podaci predstavljaju dodanu vrijednost, a koji bi trebali biti eliminirani jer predstavljaju gubitke u proizvodnom procesu. Također, iako poduzeća prikupljaju velike količine podataka, ponekad im cjelokupna slika njihovog procesa prikupljanja podataka nije dostupna pa nisu sigurni donose li odluke na temelju svih relevantnih podataka.

U radu je potrebno:

1. Napraviti pregled literature iz područja prikupljanja podataka u proizvodnji.
2. Objasniti pristupe mapiranju procesa i podataka u proizvodnji.
3. Definirati pristup analizi postojećeg stanja prikupljanja podataka u proizvodnom poduzeću.
4. Za proizvoljno odabrano poduzeće analizirati trenutni sustav upravljanja podacima.
5. Na temelju analize predložiti poboljšanja.

U radu je potrebno navesti korištenu literaturu i eventualno dobivenu pomoć.

Zadatak zadan:	Rok predaje rada:	Predviđeni datum obrane:
21. siječnja 2021.	25. ožujka 2021.	29. ožujka do 2. travnja 2021.

Zadatak zadao: Predsjednica Povjerenstva:

doc. dr. sc. Miro Hegedić prof. dr. sc. Biserka Runje

SADRŽAJ

1. Uvod ... 1
1.1. Podatkovna domena u proizvodnji ... 2
2. Projektni plan ... 4
2.1. HAIX obuća d.o.o. ... 4
2.2. Svrha i cilj projekta ... 5
2.3. Opseg projekta ... 6
3. Toplinsko mapiranje procesa (engl. *Process Heat Mapping*) ... 7
3.1. Pregled literature ... 7
3.1.1. Mapiranje toka vrijednosti ... 7
3.1.2. Sankeyev dijagram ... 9
3.1.3. Primjena metoda vizualizacije velike količine podataka ... 10
3.1.4. Zaključak pregleda literature ... 10
3.2. Metodologija ... 11
3.2.1. Ljestvica evaluacije toka informacija ... 12
3.2.2. Korišteni simboli ... 13
4. Dijagram toka procesa ... 15
4.1. Metodologija ... 15
4.1.1. Korišteni simboli ... 15
4.2. Dijagrami toka procesa proizvodnje tvrtke HAIX obuća d.o.o. ... 17
4.2.1. Generalni prikaz toka procesa prikupljanja podataka ... 17
4.2.2. Generalni prikaz toka procesa evidencije zastoja strojeva ... 18
4.2.3. Dijagram toka procesa evidencije zastoja i praznih stanica DESMA strojeva ... 20
4.2.4. Dijagram toka procesa testiranja u laboratoriju i kontrole kvalitete ... 23
4.2.5. Dijagram toka procesa šivanja i krojenja ... 26
4.2.6. Dijagram toka procesa pripreme na AGO liniji ... 29
4.2.7. Dijagram toka procesa reparacija na AGO liniji ... 31
4.2.8. Dijagram toka procesa međukontrole na AGO liniji ... 32
4.2.9. Dijagram toka procesa međukontrole i završnih radova na DESMA liniji ... 33
4.2.10. Dijagram toka procesa izrade đonova i cvikanja ... 36
5. Ključni pokazatelji uspješnosti ... 38
5.1. Ključni pokazatelji uspješnosti – HAIX obuća d.o.o. ... 38
5.1.1. Produktivnost ... 39
5.2. Prijedlog implementacije ključnih pokazatelja uspješnosti ... 42
5.2.1. Ukupna učinkovitost opreme ... 43
5.2.2. First Pass Yield ... 44
6. Analiza rezultata ... 51
6.1. Procesi identificirani analizom toplinske mape i dijagrama toka procesa ... 51
6.1.1. Proizvodni pogon H2 ... 52
6.1.2. Proizvodni pogon H3 ... 53
6.1.3. Proizvodni pogon H4 ... 53

7. Zaključak 55
8. Literatura 57
Prilog 1. Toplinska mapa proizvodnog pogona H2 1
Prilog 2. Toplinska mapa proizvodnog pogona H3 2
Prilog 3. Toplinska mapa proizvodnog pogona H4 3

POPIS I OBJAŠNJENJE KRATICA

IDC – *International Data Corporation* (Međunarodno udruženje za podatke), vodeći globalni pružatelj tržišne inteligencije, savjetodavnih usluga i događaja za tržišta informacijske tehnologije, telekomunikacija i potrošačke tehnologije

ZB – *Zettabyte* (zetabajt), mjera kapaciteta pohrane, iznosi 10^{21} bajtova

BI – *Business Intelligence* (poslovna inteligencija), sustavi koji koriste softver i usluge u svrhu pretvaranja podataka u informacije potrebne za donošenje strateški presudnih poslovnih odluka

IoT – *Internet of Things* (internet stvari)

TPS – *Toyota Production System*, integrirani sustav koji je kasnih 1940-ih godina razvila Toyota, a temelji se na *Just-In-Time* proizvodnji te kontinuiranom unaprjeđenju proizvodnih procesa

BDE – *Betriebsdatenerfassung*, interno razvijeni sustav za prikupljanje podataka o zastojima na DESMA strojevima u tvrtki HAIX obuća d.o.o.

ERP – *Entrerprise Resource Planning*, sustav koji objedinjuje sve bitne funkcije za upravljanje tvrtkom (računovodstvo, upravljanje zalihama i narudžbama, ljudske resurse, upravljanje odnosima s kupcima, proizvodnju, lanac opskrbe, usluge, nabavu) u cjelovitom sustavu, sa svrhom pojednostavljenja procesa i protoka informacija cijele organizacije

MRP – *Material Requirements Planning*, sustav planiranja proizvodnje, rasporeda i praćenja zaliha koji se koristi za upravljanje proizvodnim procesima

WMS – *Warehouse Management System*, napredno softversko rješenje koje pomaže u upravljanju zalihama u skladištu, često dio većeg poslovnog softverskog rješenja, poput ERP sustava

KPI – *Key Performance Indicator*, pojam koji industrija koristi za kvantificiranu procjenu ili mjeru izvedbe

CRM – *Customer Relationship Management*, strategija i tehnologija koja se koristi za izgradnju i poboljšanje poslovnih odnosa s kupcima

ILO – *International Labour Organization*, agencija Ujedinjenih naroda čiji je cilj unapređivanje socijalne i ekonomske pravde postavljanjem međunarodnih standarda rada

CNC – *Computer Numerical Control*, proizvodni postupak koji obično koristi računalne kontrole i alatne strojeve za uklanjanje slojeva materijala s obratka i izrađuje proizvod po mjeri

AGV – *Automated Guided Vehicles*, prijenosni roboti koji slijede oznake ili žice na podu, a mogu koristiti i radio valove, kamere, magnete ili lasere za navigaciju

JIT – *Just-In-Time*, metodologija usmjerena na skraćivanje vremena ciklusa unutar proizvodnog sustava, kao i na vrijeme odziva dobavljača i kupaca

FPY – *First Pass Yield*, metrika *dobrih proizvoda iz prvog pokušaja*

MK – međukontrola

TK – testiranje kliještima

ZK – završna kontrola

POPIS SLIKA

Slika 1. Globalna podatkovna domena po regijama [1]
Slika 2. HAIX grupa - prikaz prihoda po godinama [3]
Slika 3. HAIX grupa - broj zaposlenih po godinama [3]
Slika 4. Primjer Senkeyevog dijagrama [izrada autorice]
Slika 5. Oznake vezane za produktivnost (lijevo), odnosno kontrolu kvalitete (desno) [izrada autorice]
Slika 6. Simboli korišteni pri izradi dijagrama toka procesa [izrada autorice]
Slika 7. Referentne oznake – veza između toplinskog mapiranja i dijagrama toka procesa [izrada autorice]
Slika 8. Tri moguće vrste nedostataka u procesu prikupljanja podataka [izrada autorice]
Slika 9. Generalni prikaz toka procesa prikupljanja podataka [izrada autorice]
Slika 10. Generalni prikaz toka procesa evidencije zastoja strojeva [izrada autorice]
Slika 11. Dijagram toka procesa evidencije zastoja i praznih stanica DESMA strojeva [izrada autorice]
Slika 12. Dijagram toka procesa testiranja u laboratoriju i kontrole kvalitete [izrada autorice]
Slika 13. Dijagram toka procesa šivanja i krojenja [izrada autorice]
Slika 14. Dijagram toka procesa pripreme na AGO liniji [izrada autorice]
Slika 15. Dijagram toka procesa reparacija na AGO liniji [izrada autorice]
Slika 16. Dijagram toka procesa međukontrole na AGO liniji [izrada autorice]
Slika 17. Dijagram toka procesa međukontrole i završnih radova na DESMA liniji [izrada autorice]
Slika 18. Dijagram toka procesa izrade đonova i cvikanja [izrada autorice]
Slika 19. Nadzorna ploča tvrtke HAIX obuća d.o.o.
Slika 20. Shematski prikaz izračuna FPY-ja za DESMA proizvodni proces [izrada autorice]
Slika 21. Hodogram za izradu Pareto dijagrama [izrada autorice]
Slika 22. Pareto dijagram [izrada autorice]

POPIS TABLICA

Tablica 1. Raspored aktivnosti po tjednima [izrada autorice]
Tablica 2. Pregled simbola korištenih prilikom mapiranja toka vrijednosti [5]
Tablica 3. Ljestvica evaluacije toka informacija [2]
Tablica 4. Pareto tablica [izrada autorice]

SAŽETAK

Potencijal velikih količina podataka koje se svakodnevno prikupljaju u proizvodnji često je u velikoj mjeri neiskorišten. Jedan od glavnih ciljeva projekta provedenog u svrhu izrade diplomskog rada jest utvrđivanje metoda koje omogućuju da se protok podataka i informacija u proizvodnim procesima vizualizira i analizira na sistematizirani i efikasan način.

U uvodnom dijelu prikazana je važnost podatkovne domene u proizvodnji te njen utjecaj na industriju, s naglaskom na proizvodni sektor. Nadalje, dan je prikaz projektnog plana te kratki opis tvrtke HAIX obuća d.o.o. u kojoj je praktični dio rada proveden. U trećem poglavlju slijedi opis metoda korištenih za realizaciju projekta, uz pregled literature te najčešće korištenih alata koji se koriste u svrhu vizualizacije protoka informacija kroz proizvodne procese. Naglasak je na metodi toplinskog mapiranja procesa (engl. *Process Heat Mapping*). Razlog tome je postojanje najčešće korištenih metoda koje se prvenstveno usredotočuju na protok materijala, a svrha ovog rada je prikazati važnost *podataka* te posljedično i informacija na temelju kojih se donose strateški značajne odluke za organizaciju. Nadalje, dijagramima toka procesa dan je sekvencijalni prikaz koraka od kojih se pojedini proizvodni procesi sastoje, sa svrhom razumijevanja izvršavanja procesa te identifikacije onih dijelova u kojima postoji prostor za unaprjeđenje. Na kraju je provedena analiza ključnih pokazatelja uspješnosti koji se trenutno koriste u organizaciji te je dan prijedlog onih pokazatelja koji bi trebali biti implementirani u svrhu unaprjeđenja procesa na svim razinama organizacije. Slijedi analiza dobivenih rezultata te zaključak projekta provedenog korištenjem predstavljenih metoda.

Implementacija predloženih unaprjeđenja većim dijelom uključuje sustave, znanja i vještine koji su već prisutni u tvrtki HAIX obuća d.o.o., a iskorištavanje njihovog potencijala rezultira stvaranjem dodane vrijednosti za organizaciju. Idući korak u unaprjeđenju procesa organizacije podrazumijeva i razmatranje novih sustava ili nadogradnju postojećih, s ciljem razvoja Industrije 4.0 te izgradnje pametne tvornice.

Ključne riječi: *toplinsko mapiranje procesa, dijagram toka procesa, pametna tvornica, Industrija 4.0*

SUMMARY

The potential of Big Data in production is often largely unutilized. One of the main goals of the conducted project presented in this thesis is to establish methods that allow data and information flow in production processes to be visualized and analyzed systematically and efficiently.

The introductory part presents the importance of the data domain in production and its impact on the industry, with an emphasis on the manufacturing sector. Furthermore, the project plan was presented, followed by a brief description of the company HAIX obuća d.o.o. in which the practical part of the work was carried out. The third chapter describes the methods used for project implementation, with a review of the literature and the most common tools used to visualize the flow of information through production processes. The emphasis is on Process Heat Mapping. The reason for this is the existence of the most commonly used methods that primarily focus on the flow of materials, and the purpose of this paper is to show the importance of data and consequently information which result in strategically important decisions for the organization. Furthermore, process flow diagrams provide a sequential overview of each production process, in order to understand the execution of the process and identify those parts which need to be improved. Finally, an analysis of currently used Key Performance Indicators was conducted and a proposal was given for those indicators that should be implemented to improve the process at all levels of the organization. Lastly, an analysis of results obtained using presented methods was carried out, followed by the conclusion of the project.

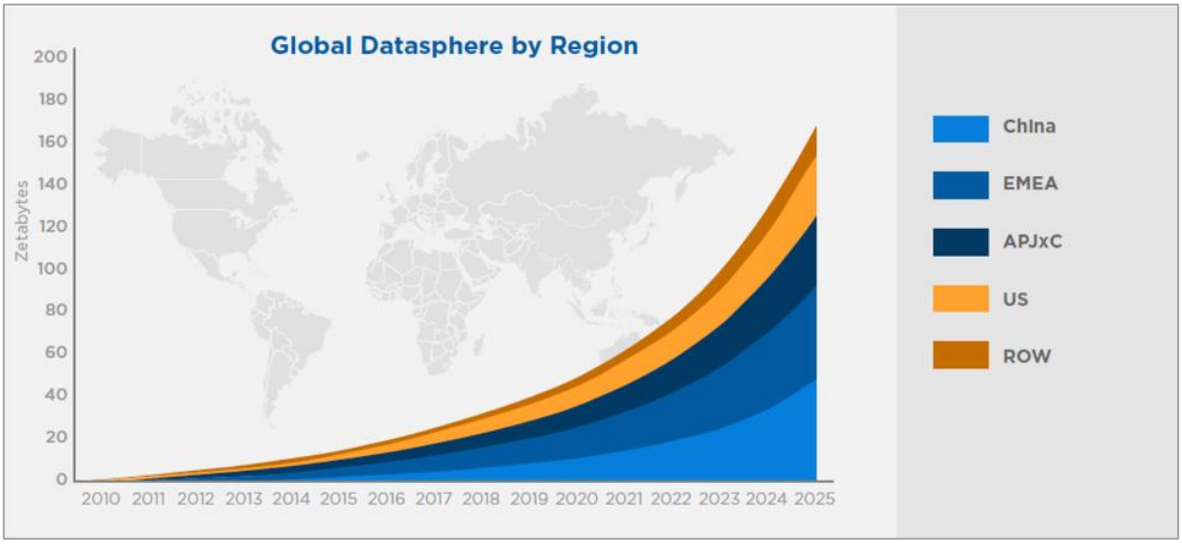
The implementation of the improvements proposed in this project largely includes the systems, knowledge, and skills that are already present in the company HAIX obuća d.o.o. Utilization of their potential results in the creation of added value for the organization. The next step in improving the organization's processes involves considering new systems or upgrading existing ones, intending to develop Industry 4.0 and build a Smart Factory.

Keywords: *Process Heat Mapping, Process Flow Diagram, Smart Factory, Industry 4.0*

1. Uvod

Korištenje prikupljenih podataka transformira način na koji ljudi danas obavljaju svakodnevne aktivnosti. Industrije diljem svijeta koriste se podacima kako bi transformirale svoj način poslovanja, postale agilnije, poboljšale korisničko iskustvo, uvele nove poslovne modele i razvile nove izvore konkurentske prednosti. Ekonomija i gospodarstvo oslanjaju se na podatke, što će u budućnosti napredovati i rasti u sve većoj mjeri. Tvrtke prikupljaju, sistematiziraju te posredno unovčuju podatke u svakom koraku opskrbnog lanca. Također, koriste se podacima o kupcima kako bi im pružile određenu razinu personalizacije proizvoda i usluga, a kupci istovremeno integriraju te podatke u svoje svakodnevice i time sve više samostalno oblikuju proizvod u skladu s vlastitim zahtjevima. Time se postiže zadovoljstvo svih onih koji sudjeluju u opskrbom lancu – tvrtke imaju točnu informaciju o tome kakav proizvod ili uslugu kupac traži, a istovremeno kupac dobiva točno ono što je u skladu s njegovim očekivanjima.

Posljedica sve većeg oslanjanja na podatke bit će enormni rast globalne podatkovne domene. *International Data Corporation*, IDC, vodeći globalni pružatelj sustava poslovne inteligencije, savjetodavnih usluga, telekomunikacijske i potrošačke tehnologije, predviđa da će količina generiranih digitalnih podataka porasti s 33 ZB u 2018. na 175 ZB do 2025. godine, kao što je prikazano na slici 1.



Slika 1. Globalna podatkovna domena po regijama [1]

Sustavna računalna analiza podataka dobivenih iz proizvodnje rezultira valjanim i utemeljenim odlukama, što utječe na povećanje učinkovitosti. Tokovi informacija temelje se na podacima i dokumentaciji te su ključni za ostvarivanje kvalitetne komunikacije između proizvodnje i rukovodstva. Postoje razni alati vizualizacije podataka koji se primjenjuju na velike količine podataka (engl. *Big Data*), no samo je nekoliko onih koji služe za prikaz proizvodnih ili logističkih procesa. Većina uobičajenih alata koji se koriste za vizualizaciju pojedinih procesa usredotočuje se na tok materijala.

Ako se zaprimljena informacija u procesu prijenosa pretvara u drugi oblik, primjerice iz elektroničkog u ručni zapis, velika je vjerojatnost da će doći do problema u komunikaciji. Spomenuta promjena medija rezultira aktivnostima koje ne dodaju vrijednost te je poželjno iste eliminirati. U praksi je vrlo zahtjevno identificirati promjene medija zbog nedovoljne transparentnosti toka informacija u organizaciji i nedostatka potrebnih metoda prikupljanja podataka [2].

Kao što će u ovom radu biti predstavljeno, metode toplinskog mapiranja procesa i izrada dijagrama toka procesa usredotočuju se upravo na tok podataka, a posljedično i informacija.

1.1. Podatkovna domena u proizvodnji

Budući da podatkovna domena eksponencijalno raste, očekivano je da i proizvodnja doživljava radikalan utjecaj tog rasta. Proizvodne tvrtke koje su već usvojile informatizaciju i implementirale informacijske sustave unutar organizacije teže pretvorbi u pametne organizacije vođene podacima, a ne pretpostavkama ili iskustvenim navikama. Razlog tome je kontinuirano traženje i uvođenje metoda za povećanje učinkovitosti, produktivnosti i profitabilnosti, uz istovremeno smanjenje troškova. Podaci predstavljaju ključni alat za utvrđivanje gdje i kako se to može učiniti u bilo kojem proizvodnom procesu ili njegovom segmentu. Za sve odjele organizacije ključno je poznavanje cijelog poslovanja i onih dijelova koji se mogu unaprijediti i poboljšati, bilo da je riječ o proizvodnji, zalihama, logistici ili distribuciji.

Informatizacija i automatizacija proizvodnje u velikoj mjeri povećavaju količinu podataka koje tvrtke prikupljaju. Moderne tvornice posjeduju brojne strojeve, senzore i uređaje koji generiraju podatke te prate zadane parametre. Razne metode poput pohrane podataka u oblaku ili skladištima podataka omogućuju tvrtkama pohranu velikih količina podataka koje prikupljaju. Međutim, to je korisno samo ako se isti podaci mogu precizno analizirati, pri čemu se dobiva točna informacija i uvid u područja gdje je moguće unaprjeđenje procesa, a time i cjelokupnog

poslovanja. Za proizvodni sektor, veliki je izazov spomenute podatke prikupiti u stvarnom vremenu i učinkovito ih koristiti. Kako bi se to postiglo, potrebna je implementacija sustava poslovne inteligencije (engl. *Business Intelligence*) te analitika koja može transformirati podatke u oblik koji daje uvid u poslovanje organizacije.

Značajan dio podataka može se prikupljati i obrađivati u stvarnom vremenu ugrađivanjem sustava izravno u proizvodnu opremu. Na tome se temelje Industrija 4.0, Internet stvari (engl. *Internet of Things*), digitalizacija i koncept pametnih tvornica. Kao rezultat toga, uvid u trenutno stanje može se dobiti u stvarnom vremenu te upravo na onom mjestu na kojemu su podaci generirani. Time se eliminira potreba da IT, kao i drugi odjeli u organizaciji prikupljaju, analiziraju i generiraju izvještaje, što oduzima mnogo vremena i iskorištava resurse koji bi se mogli primijeniti u bolje svrhe.

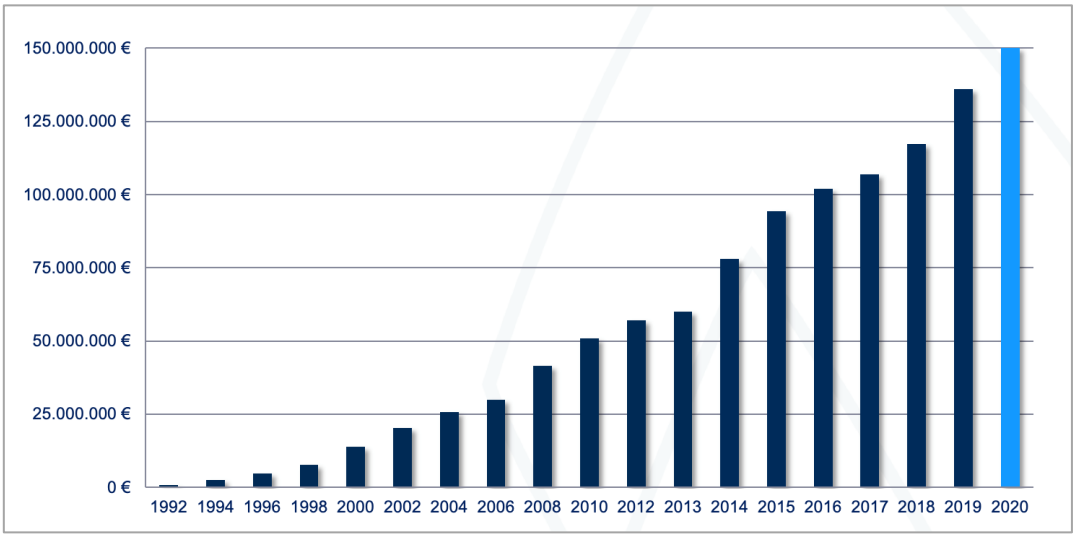
2. Projektni plan

Praktični dio projekta odrađen je u tvrtki HAIX obuća d.o.o., gdje se velika količina podataka svakodnevno prikuplja s različitih strojeva, uređaja i radnih stanica. To uzrokuje poteškoće pri razumijevanju koji podaci predstavljaju dodanu vrijednost, a koji bi trebali biti eliminirani jer predstavljaju gubitke u procesu njihovog prikupljanja, odnosno proizvodnom procesu.

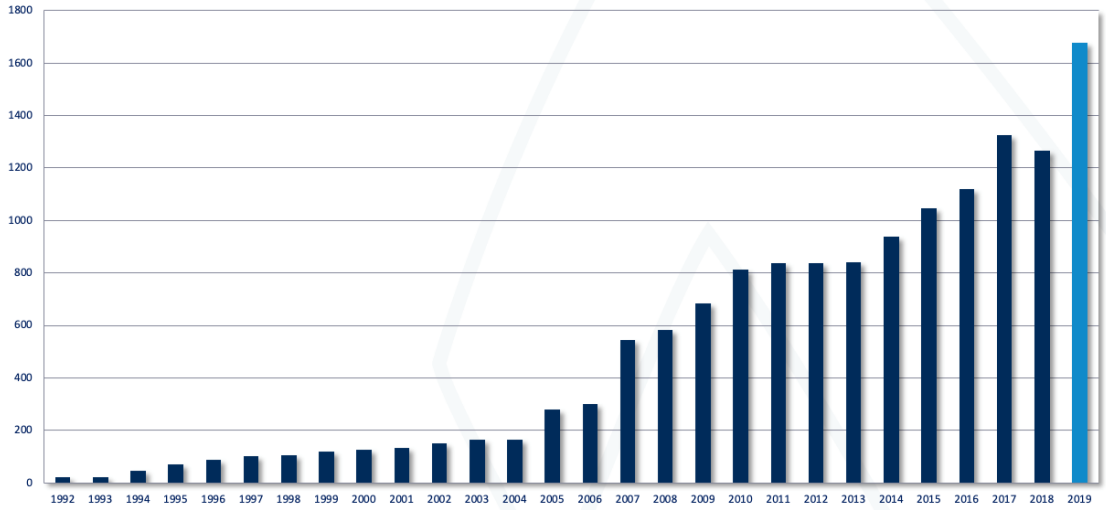
2.1. HAIX obuća d.o.o.

HAIX grupa osnovana je 1948. godine u njemačkom gradu Mainburgu s ciljem proizvodnje planinarskih čizama, a 1992. godine u tvrtki su razvijene prve kožne vatrogasne čizme. Zaštitni znak organizacije su istraživanja temeljena na praksi i kreativni razvoj novih proizvoda. HAIX grupa redefinira cipele za profesionalnu upotrebu koristeći tehnička znanja i visokotehnološke proizvodne postupke.

U Hrvatskoj su prve aktivnosti započele 1999. godine ugovornom proizvodnjom s tvrtkom Jelen u Čakovcu. Tvrtka HAIX obuća d.o.o. osnovana je 2005. godine, a iste je godine započela s vlastitom proizvodnjom. 2009. godine tvrtka je pokrenula proizvodnju u vlastitim proizvodnim pogonima u Maloj Subotici. Razlog odabira Hrvatske kao strateški dobre lokacije jest dostupnost stručnog osoblja i infrastrukture namijenjene obućarskoj industriji te blizina Bavarskoj, odnosno sjedištu u gradu Mainburgu. HAIX obuća d.o.o. zapošljava oko 1,300 zaposlenika te je najveća tvornica obuće u jugoistočnoj Europi.



Slika 2. HAIX grupa - prikaz prihoda po godinama [3]



Slika 3. HAIX grupa - broj zaposlenih po godinama [3]

2.2. Svrha i cilj projekta

Projekt se sastoji od tri dijela:

1. Analiza trenutnog stanja
   - Identifikacija podataka koji se svakodnevno prikupljaju te njihovih izvora – strojeva, radnih stanica, softvera i ostalih
   - Izrada vizualnog prikaza – toplinsko mapiranje procesa (engl. *Process Heat Mapping*)
   - Identifikacija načina prikupljanja podataka – isticanje onih proizvodnih jedinica koje prikupljaju podatke ručno te onih koje to čine automatski
   - Identifikacija zaposlenika koji zaprimaju i koriste, ili ne koriste, prikupljane podatke
   - Analiza utjecaja prikupljanih podataka na svakodnevne operacije i proces odlučivanja u organizaciji
2. Analiza jaza
   - Identifikacija nedostajućih podataka koji bi mogli utjecati na proces kontinuiranog poboljšanja
   - Identifikacija nedostajućih pokazatelja potencijalno ključnih za organizaciju
3. Prijedlog budućih poboljšanja
   - Identificirati podatke koji bi se trebali koristiti pri upravljanju proizvodnjom te u daljnjem procesu kontinuiranog poboljšanja

- Identificirati nove metode prikupljanja podataka koje bi se mogle implementirati

2.3. Opseg projekta

Projekt se sastoji od identifikacije, praćenja, kategorizacije te analize podataka prikupljanih sa svih izvora u proizvodnom procesu tvrtke HAIX obuća d.o.o. Izvori u proizvodnom procesu podrazumijevaju sve strojeve, uređaje, radne stanice i ljude koji na bilo koji način sudjeluju u procesu prikupljanja podataka. Naglasak je na razumijevanju informacija koje se mogu dobiti na temelju prikupljanih podataka te odlukama koje se mogu donijeti na temelju istih. Osim spomenutog, u obzir su uzete i odluke koje bi se mogle donositi kada bi proces transformacije podataka u informacije bio drugačiji.

Posljedica identifikacije, praćenja, kategorizacije te analize podataka jest povećana transparentnost, sljedivost i učinkovitost, što izravno utječe na proces kontinuiranog poboljšanja.

Za postizanje ciljeva projekta korišteni su alati i vještine stečene tijekom studija te prethodnim iskustvom. Praktični dio projekta odrađen je kroz pet radnih tjedana u tvrtki HAIX obuća d.o.o., prema unaprijed definiranom rasporedu prikazanom u tablici 1.

Tablica 1. Raspored aktivnosti po tjednima [izrada autorice]

Tjedan	Aktivnost
1	Identifikacija podataka te pripadajućih izvora Mapiranje postojećih izvora podataka
2	Analiza postojećih metoda prikupljanja podataka Analiza utjecaja dostupnih podataka na aktivnosti u kojima se isti koriste (sastanci, donošenje odluka, dnevne operacije)
3	Identifikacija nedostajućih podataka važnih za proces kontinuiranog poboljšanja Identifikacija nedostajućih pokazatelja važnih za organizaciju
4	Identifikacija nedostajućih metoda važnih za proces kontinuiranog poboljšanja
5	Prijedlog rješenja za daljnje poboljšanje proizvodnog procesa

3. Toplinsko mapiranje procesa (engl. *Process Heat Mapping*)

Toplinsko mapiranje procesa je alat pomoću kojeg se kategorizira i vizualizira protok podataka, odnosno informacija. Za razliku od uobičajenih alata korištenih u metodologijama poput *Lean Six Sigma* metodologije, primjerice mapiranje toka vrijednosti, prvi je korak pri izradi toplinske karte analiza vrijednosti toka podataka. Nadalje, spomenuti tok podataka vizualizira se u ovisnosti o dodijeljenoj vrijednosti koristeći tlocrt proizvodnog pogona. Rezultat korištenja ovog alata je povećana transparentnost, čime se neposredno dobiva uvid u područja koja treba unaprijediti. Također, mogu se identificirati i prekidi tokova podataka, čime se ističu procesi koji dodaju vrijednost, ali i mogući izvori gubitaka [2].

Neadekvatna interna komunikacija, kao i nepouzdani prijenos informacija predstavljaju gubitke koji ne dodaju vrijednost proizvodnom procesu. Aktivnosti se općenito, prema *Lean Six Sigma* metodologiji, dijele na one koje dodaju vrijednost te na one koji ne dodaju vrijednost. Aktivnost koja ne dodaje vrijednost podrazumijeva svako ulaganje napora i resursa koje kupac nije spreman platiti. Gubitke koji dodaju vrijednost neophodno je optimizirati, a one koji ne dodaju vrijednost smanjiti ili eliminirati. Hoće li gubici koji ne dodaju vrijednost biti smanjeni ili eliminirani ovisi o tome je su li potrebni ili suvišni u pojedinom (proizvodnom) procesu.

3.1. Pregled literature

3.1.1. Mapiranje toka vrijednosti

Mapiranje toka vrijednosti (engl. *Value Stream Mapping*) je metoda kojom se primjenjuju načela *Lean* metodologije pri ispitivanju proizvodnih procesa. Može se definirati kao metoda kojom inženjeri nastoje razumjeti razvojne procese u organizaciji te poboljšati iste. Naglasak je na one aktivnosti koje dodaju vrijednost konačnom proizvodu ili usluzi. Te su aktivnosti međusobno povezane i tvore tok vrijednosti [4].

Način na koji se spomenute aktivnosti nadziru jest identifikacija i eliminacija gubitaka u proizvodnom procesu. Izvorno je metoda razvijena 1990. godine te se povezuje s Toyotinim proizvodnim sustavom (TPS). Danas je mapiranje toka vrijednosti široko rasprostranjeni alat koji se koristi u mnogim industrijama u svrhu unaprjeđenja procesa. Rezultat korištenja ovog alata je prikaz protoka resursa od početka do kraja lanca opskrbe, odnosno od nabave materijala do isporuke gotovog proizvoda ili usluge kupcu [2].

Prilikom vizualizacije toka vrijednosti mapiranjem, obično se koriste unaprijed definirani simboli za protok resursa i informacija. Tablica 2 prikazuje neke od najčešće korištenih simbola prilikom mapiranja toka vrijednosti [5].

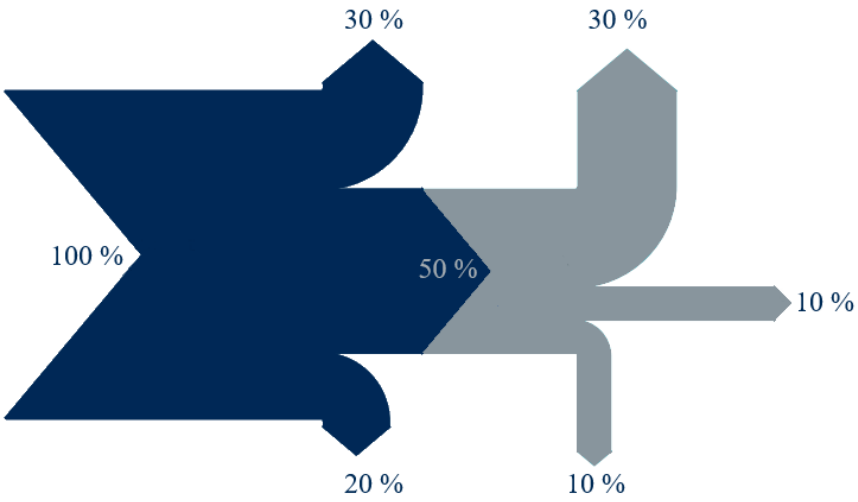
Tablica 2. Pregled simbola korištenih prilikom mapiranja toka vrijednosti [5]

	Kupac / Dobavljač
	Odjel, operacija ili oprema s fiksnim i neprekinutim internim tokom materijala
	Odjel, operacija ili oprema koja dijeli proces s drugim tokom vrijednosti
	Podatkovni okvir, mjesta u procesu koja zahtijevaju analizu podataka
	Više integriranih procesa unutar jedne radne stanice
	Zalihe
	Isporuka
	Prijenos materijala iz jednog procesa u drugi
	Fizičko dohvaćanje zaliha iz skladišta
	*First-In-First-Out* sustav koji sprječava stvaranje prekomjernih zaliha
	Dostava
	Ručni prijenos informacija
	Elektronički prijenos informacija
	MRP ili ERP sustav
	Prikupljanje informacija i donošenje odluka promatranjem određenog procesa
	Kaizen blitz, simbol za naglašavanje kritičnih područja i identifikaciju mjesta za unaprjeđenje
	Broj potrebnih zaposlenika za izvršavanje određene operacije
	Transport
	Skladište

Q	Problem vezan za kvalitetu
	Rješenje / prijedlog poboljšanja

3.1.2. Sankeyev dijagram

Sankeyev dijagram koristi se za vizualizaciju protoka energije, materijala ili drugih resursa u različitim primjenama. Izvorno, ovaj je dijagram korišten za prikaz protoka energije u parnim strojevima, odnosno za termodinamičke sustave. U novije se vrijeme sve više počeo primjenjivati u sustavima poput elektrana te za generalni prikaz upotrebe energije. Sankeyev dijagram se, dakle, koristi u svrhu prikaza protoka resursa u određenom procesu, ovisno o industriji [6]. Slika 4 prikazuje jednostavan primjer Sankeyevog dijagrama.



Slika 4. Primjer Senkeyevog dijagrama [izrada autorice]

Glavna komponenta Sankeyevog dijagrama su strelice koje povezuju pojedinačne korake i smjer toka procesa. Debljina strelica kvantificira promatrani čimbenik koji se javlja u toku procesa, odnosno predstavlja njegovu količinu. Sankeyev dijagram može se povezati i s tlocrtom proizvodnog pogona. Izrada ovog dijagrama uvijek započinje bilježenjem protoka praćenog parametra koji se javlja unutar analiziranog podsustava. Rezultat je jednostavan dijagram analiziranih koraka procesa i protoka materijala koji omogućuje procjenu promatranog sustava.

Na ovaj je način moguće prikazati križanja tokova materijala u proizvodnom pogonu koja uzrokuju uska grla ili zastoje u transportu. Kao rezultat toga, moguće je objasniti vremena čekanja u proizvodnji [2].

3.1.3. Primjena metoda vizualizacije velike količine podataka

Pojam *Big Data* podrazumijeva enormno velike skupove podataka koji se analiziraju u svrhu otkrivanja obrazaca, trendova ili odstupanja. S obzirom na jako brzi razvoj tehnologije i sve veću količinu podataka koja se svakodnevno prikuplja, vizualizacija postaje ključni alat za razumijevanje nepreglednih redaka podataka.

Učinkovita vizualizacija podrazumijeva uspostavljanje ravnoteže između funkcije i oblika. To znači da je vrlo bitno znati prepoznati i predstaviti određenu informaciju na pravi način. Naime, često se događa da određene, iznimno bitne informacije, ne rezultiraju donošenjem pravih odluka ili čak dovode do pogrešnih zaključaka. Razlog tome je prezentacija podataka koja nije u skladu s njihovim značenjem ili utjecajem na određeni proces. Primjerice, graf može biti previše jednoličan i repetitivan da bi privukao pažnju na informaciju koja je od iznimne važnosti za donošenje određene odluke. S druge strane, suvišno dotjerivanje dijagrama i pretjerana količina nebitnih informacija također dovode do neutemeljenog donošenja odluka, ili čak do donošenja odluka koje negativno utječu na organizaciju te ju mogu ugroziti [7].

3.1.4. Zaključak pregleda literature

Mapiranje toka vrijednosti i Senkeyev dijagram primjeri su alata čija je svrha vizualizacija protoka resursa kroz određeni proces. Pritom se mapiranje toka vrijednosti usredotočuje na one aktivnosti proizvodnog procesa koje dodaju, odnosno ne dodaju vrijednost konačnom proizvodu ili usluzi. Senkeyev se dijagram usredotočuje na fizički protok resursa, a širina strelica proporcionalna je protoku.

Vizualizacija velike količine podataka (engl. *Big Data*) se, s druge strane, usredotočuje na razumijevanje i prezentaciju podataka kako bi se naglasile ključne brojke te donijele strateški bitne odluke na temelju istih.

Međutim, ni jedna od ovih metoda vizualizacije procesa ne usredotočuje se na protok podataka određenog procesa. To ne znači da su spomenute metode od manje važnosti za proizvodnu industriju ili organizaciju, već da je neophodno uspostaviti njihovu sinergiju u svrhu ostvarivanja ciljeva i postizanja rezultata.

Napredak tehnologije često je brži od njene uspješne implementacije u proizvodne pogone i organizacije. Prema tome, neophodno je reagirati prediktivno i preskriptivno, a ne korektivno. Prediktivna reakcija podrazumijeva implementaciju sustava koji pružaju odgovore na pitanje što će se dogoditi te kolika je vjerojatnost pojave anomalije u procesu. Preskriptivno djelovanje odnosi se na prikupljanje podataka iz deskriptivnih, korektivnih i prediktivnih izvora u svrhu njihovog povezivanja i razmatranja posljedica odluka te njihovog utjecaja na budućnost. Sve to sprječava nepotrebne gubitke vremena i resursa koji se naknadno troše na ispravljanje napravljenih pogrešaka zbog previđenih propusta pri donošenju odluka.

S obzirom na sve ranije spomenuto i uzevši u obzir to da sve više organizacija implementira razne sustave poput ERP-a, MRP-a ili WMS-a za pohranu i manipulaciju podacima, naglasak je sve više na aktivnostima vezanim za njihovo bolje razumijevanje. Iz toga potječe motivacija za izradom ovog rada i inovacijom postojećih metoda vizualizacije – da bi se podatke moglo u potpunosti razumjeti, krucijalno je znati kako se oni kreću kroz određeni proces te stvaraju li i u kojoj mjeri dodanu vrijednost za proizvod ili uslugu koju pruža organizacija. Sustavi za obradu i pohranu podataka beskorisni su ako ne postoji potpuno razumijevanje podataka, njihove vrijednosti te putanje u procesu, bilo da je riječ o proizvodnji, prodaji, računovodstvu ili ljudskim resursima.

3.2. Metodologija

Toplinsko mapiranje procesa je inovativni alat za vizualizaciju koji se zasniva na razini dodane vrijednosti čimbenika vezanih za proizvodni proces, a razvili su ga doktori znanosti Dagmar Piotr Tomanek i Jürgen Schröder, inspirirani postojećom metodom termovizije.

Metoda toplinskog mapiranja procesa već se koristi u svrhu vizualizacije iskorištavanja prostora u proizvodnji jer svaki prostor nema istu vrijednost – može biti maksimalne, ograničene ili nepostojeće dodane vrijednosti.

Primjerice, prostor koji se izravno koristi za stvaranje dodane vrijednosti, poput proizvodnih strojeva, smatra se maksimalnom dodanom vrijednošću. No, u proizvodnji je često moguće identificirati i ona mjesta koja nisu izravno povezana sa stvaranjem dodane vrijednosti. To su prostori neophodni za proizvodni proces, primjerice priprema materijala koji čeka na daljnju obradu ili poluproizvodi koji se kreću od jedne radne operacije do druge. Takva su mjesta kategorizirana ograničenom dodanom vrijednošću, dok se podrazumijeva da ona mjesta koja ne

doprinose istoj trebaju biti eliminirana jer ne doprinose stvaranju dodane vrijednosti ni na koji način.

Prilikom toplinskog mapiranja procesa, svaki se dio pogona evaluira u ovisnosti o razini dodane vrijednosti koju stvara. To ima veliki utjecaj na optimizaciju rasporeda proizvodnje. Općenito, ova metoda služi kako bi se vizualizirali čimbenici koji utječu na proizvodnju koristeći mjerilo u bojama, ovisno o razini dodane vrijednosti te je krajnji rezultat toplinska mapa, odakle potječe naziv toplinsko mapiranje procesa [2].

3.2.1. Ljestvica evaluacije toka informacija

U okviru projekta izrađena je ljestvica evaluacije toka informacija, preuzeta od Tomaneka i Schrödera [2] te prilagođena potrebama ovog rada.

Vrlo je bitno razumjeti kako informacije različito doprinose dodanoj vrijednosti koju stvaraju, odnosno ne stvaraju. Tok informacija klasificiran je prema razini dodane vrijednosti, a podijeljen je u pet kategorija (tablica 3). Razina dodane vrijednosti pada povećanjem napora uloženog u stvaranje određene informacije u proizvodnom procesu.

Tablica 3. Ljestvica evaluacije toka informacija [2]

Kategorizacija	**Razina dodane vrijednosti**	**Opis**	**Praktični primjer**
Nepostojeća dodana vrijednost		Nepotpuna, netočna ili nepotrebna razmjena podataka / informacija	Postojanje dva ili više nekompatibilna sustava za praćenje podataka, što rezultira nepouzdanim ili netočnim informacijama (DESMA stroj – tri metode prikupljanja podataka: BDE, ERP sustav Inpos i fizički dokumenti)
Ograničena dodana vrijednost		Pismena razmjena podataka / informacija (dokumenti na papiru, e-mail i sl.)	Ručna evidencija radnika odgovornih za pojedine proizvodne operacije (Proizvodni proces *Zwickerei* – ručni zapis informacije na papir koji prolazi kroz proizvodni proces)
		Elektronička razmjena podataka / informacija koja nije u stvarnom vremenu	Sustavi neizravno povezani s ERP sustavom Inpos (*Takt-Maschine*, *Andon*), lokalizirani podaci koji ostaju u proizvodnom pogonu (proizvodni nalozi u fizičkom obliku u proizvodnom pogonu H3, popratni listići u proizvodnom procesu *Zwickerei*)

		Elektronička razmjena podataka / informacija u stvarnom vremenu	Skeniranje barkodova, izravni unos podataka u ERP sustav Inpos (završna kontrola)
Maksimalna dodana vrijednost		Digitalna razmjena podataka / informacija u stvarnom vremenu (Internet stvari, Internet usluga i sl.)	Automatska komunikacija između ERP sustava, rukovodstva i proizvodnje koja omogućuje izvještavanje u stvarnom vremenu ili čak prediktivno reagiranje na temelju prikupljenih podataka (primjerice obavijest o potencijalnom popravku stroja uslijed sve češćeg čišćenja ili zamjene materijala)

Svaka nepotpuna, netočna ili nepotrebna razmjena podataka i informacija zahtijeva određenu razinu uloženog truda, a ne dodaje vrijednost proizvodu ili proizvodnom procesu. Takav je tok informacija označen plavom bojom i odgovara nultoj razini dodane vrijednosti, što znači da je isti poželjno eliminirati.

Pismena razmjena podataka i informacija, poput raznih dokumenata razmijenjenih putem elektroničke pošte ili u fizičkom obliku, stvara ograničenu dodanu vrijednost. Istovremeno, takva razmjena podataka i informacija ima veliki potencijal za unaprjeđenje te je označena zelenom bojom i klasificirana kao prva razina dodane vrijednosti.

Viša razina klasifikacije podrazumijeva elektroničku razmjenu podataka i informacija – druga, odnosno treća razina dodane vrijednosti. Pritom je neophodno usredotočiti se na one tokove koji nisu u stvarnom vremenu (žuta boja u ljestvici evaluacije toka podataka) i one kod kojih je informacija zaprimljena u stvarnom vremenu (narančasta boja). Primjerice, korištenje Excel izvještaja generiranih iz ERP sustava predstavlja zakašnjeli prikaz podataka. Nadalje, manipulacija podacima iz takvih izvještaja zahtijeva mnogo vremena za razliku od, primjerice, implementirane sistemske aplikacije.

Najviša razina dodane vrijednosti klasificirana je kao peta i posljednja, a podrazumijeva digitalizaciju te implementaciju Interneta stvari i usluga, odnosno glavnih koncepata na kojima se temelji Industrija 4.0. Implementacija sustava koji podržavaju takav način prijenosa podataka i informacija omogućuje da sve razine organizacije komuniciraju u stvarnom vremenu, od proizvodnje koja uključuje sve strojeve, uređaje i radnike do rukovodstva koje donosi ključne, strateški važne odluke.

3.2.2. Korišteni simboli

Osim ljestvice evaluacije toka informacija, pri izradi toplinske mape procesa korišteni su i simboli sa slike 5.



Slika 5. Oznake vezane za produktivnost (lijevo), odnosno kontrolu kvalitete (desno) [izrada autorice]

Riječ je o oznakama koje naglašavaju je li pojedini tok podataka, odnosno informacija vezan prvenstveno za Odjel kontrole kvalitete ili Odjel planiranja i izračun produktivnosti. S obzirom na to da se HAIX obuća d.o.o. pri analizi i praćenju rezultata usredotočuje na dva glavna izvještaja, Izvještaj kvalitete te Izvještaj produktivnosti, ovim se simbolima naglašava kojem su odjelu prikupljani podaci od veće važnosti te gdje se isti koriste. Osim prikaza toka podataka kroz proizvodne pogone, na ovaj se način nastoji prikazati i koji se od podataka u procesu koriste za donošenje odluka u organizaciji.

4. Dijagram toka procesa

Dijagram toka procesa sekvencijalno prikazuje korake od kojih se sastoji određeni proces. Metoda se odabire kada je potrebno razviti razumijevanje o tome kako se proces izvršava, identificirati dijelove koje je potrebno unaprijediti, prezentirati drugima na koji način se proces izvršava, pojasniti komunikaciju među ljudima koji sudjeluju u procesu, dokumentirati proces te planirati određeni projekt. Osim spomenutog, pomoću dijagrama toka procesa moguće je naznačiti i koji točno odjeli ili odgovorne osobe sudjeluju u njegovom pojedinom dijelu te na koji su način međusobno povezane.

U okviru ovog projekta izrađeni su dijagrami toka svih procesa u kojima je identificiran prostor za unaprjeđenje. Sve informacije prikupljene tijekom izvedbe praktičnog dijela rada temelje se na intervjuima sa zaposlenicima iz svih odjela tvrtke HAIX obuća d.o.o. te na podacima iz ERP sustava pod nazivom Inpos.

4.1. Metodologija

Metoda raščlambe procesa na njegove dijelove jedan je od najvažnijih alata korištenih u *Lean Six Sigma* metodologiji. Ključno je jasno vizualizirati proces kroz sve njegove razine jer se na taj način dobiva uvid u raspodjelu resursa te jasni prikaz toka kroz sve razine organizacije koje isti obuhvaća. Osim spomenutog, ovakvim je prikazom moguće naglasiti one dijelove procesa koje je neophodno poboljšati, unaprijediti ili eliminirati.

4.1.1. Korišteni simboli

Pri izradi dijagrama toka procesa korištena su tri simbola (slika 6). Svaki simbol označava vrstu koraka pojedinog procesa – žuti pravokutnik ukazuje na to da je riječ o aktivnosti, plavi trokut na to da je riječ o kontroli, a narančasti romb da je u pitanju donošenje odluke.



Slika 6. Simboli korišteni pri izradi dijagrama toka procesa [izrada autorice]

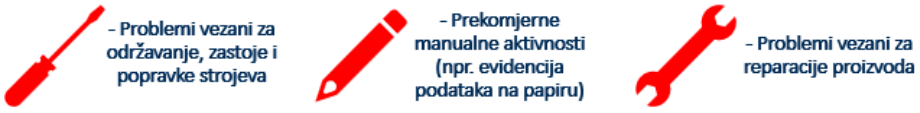
Osim simbola sa slike 6, pri izradi dijagrama toka procesa korištene su i dodatne oznake. Crveni okvir ukazuje na mjesta potencijalnih poboljšanja, a oznake sa slike 7 povezuju toplinsku mapu procesa iz poglavlja 3 s dijagramima toka procesa iz poglavlja 4. Ovisno o boji oznake moguće je zaključiti koju razinu dodane vrijednosti pojedini korak procesa ostvaruje prema prethodno definiranoj ljestvici (tablica 3) te istu oznaku povezati s točno određenim korakom naznačenim u dijagramu toka procesa.



Slika 7. Referentne oznake – veza između toplinskog mapiranja i dijagrama toka procesa [izrada autorice]

Prilikom izrade dijagrama toka procesa tvrtke HAIX obuća d.o.o., naglasak je bio prvenstveno na podacima, odnosno na metodama njihovog prikupljanja kroz proizvodni proces. Dijagramima toka procesa se vizualizira proces prikupljanja podataka unutar proizvodnog procesa pomoću ranije spomenutih simbola (slike 6 i 7). Glavni je cilj identifikacija područja koja zahtijevaju unaprjeđenje. Osim spomenutog, kroz praktični rad identificirane su tri moguće vrste nedostataka prilikom prikupljanja podataka u proizvodnom procesu (slika 8) te je za svaki pojedini dijagram toka procesa naznačeno o kakvom je nedostatku riječ:

1. Nedostaci vezani za zastoje, a posljedično i održavanje
2. Ručna evidencija podataka – dokumenti na papiru, ručni unos podataka u Excel, slanje dokumenata mailom i sl.
3. Nedostaci vezani za reparature u proizvodnom procesu

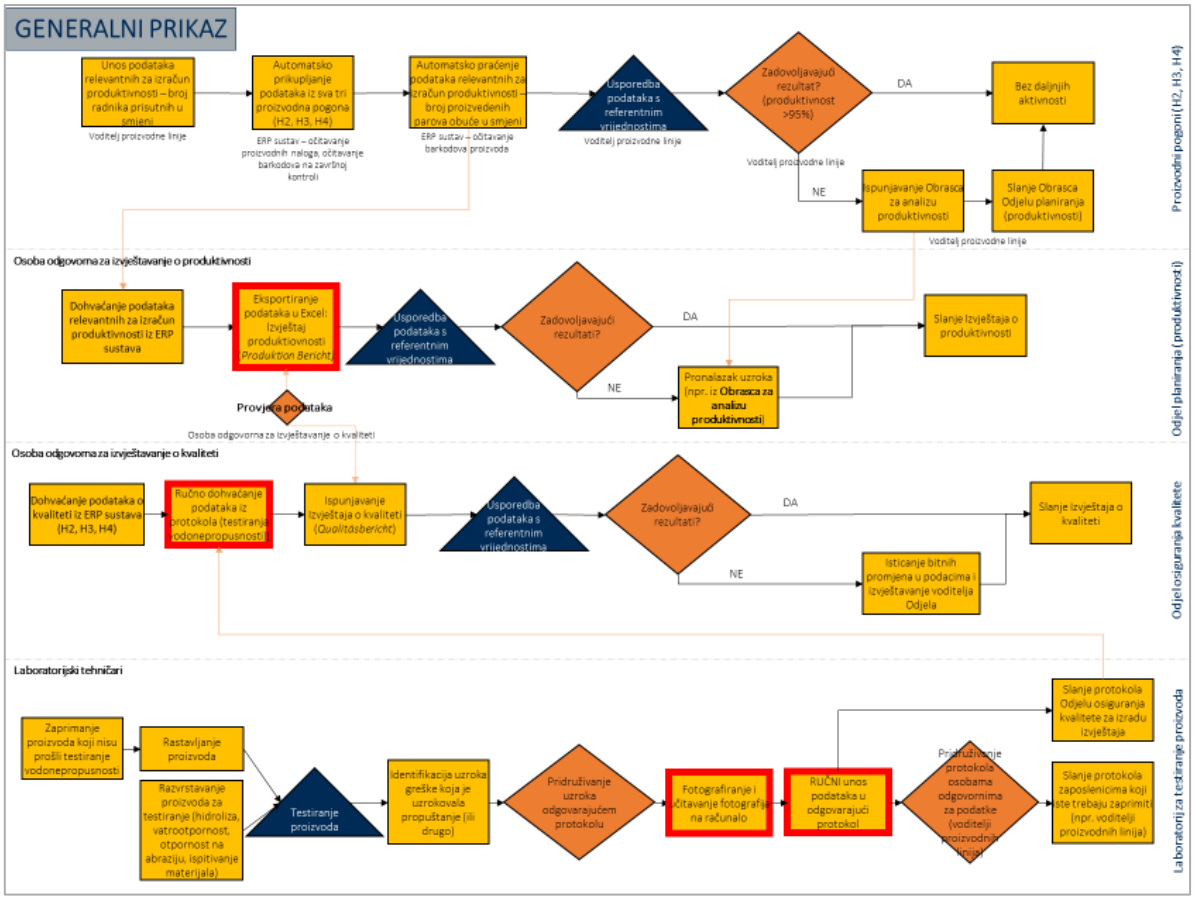


Slika 8. Tri moguće vrste nedostataka u procesu prikupljanja podataka [izrada autorice]

4.2. Dijagrami toka procesa proizvodnje tvrtke HAIX obuća d.o.o.

4.2.1. Generalni prikaz toka procesa prikupljanja podataka

Generalni prikaz toka procesa prikupljanja podataka tvrtke HAIX obuća d.o.o. daje pregled procesa prikupljanja podataka u sva tri proizvodna pogona, iz najšire perspektive (slika 9). Ovaj dijagram predstavlja uvid u cjelokupnu proizvodnju tvrtke te način na koji podaci, odnosno informacije putuju između svih proizvodnih pogona te najvažnijih odjela – Odjel planiranja koji je zadužen za praćenje i izradu Izvještaja produktivnosti (tzv. *Produktion Bericht*), Odjel osiguranja kvalitete te Laboratorij za testiranje proizvoda.



Slika 9. Generalni prikaz toka procesa prikupljanja podataka [izrada autorice]

4.2.1.1. Opis dijagrama

Proces započinje unosom podataka relevantnih za izračun produktivnosti na početku smjene, a to je broj prisutnih zaposlenika. Taj podatak ručno u ERP sustav unosi voditelj smjene. Ostali podaci prikupljaju se automatski pomoću ERP sustava kroz skeniranja proizvodnih naloga na

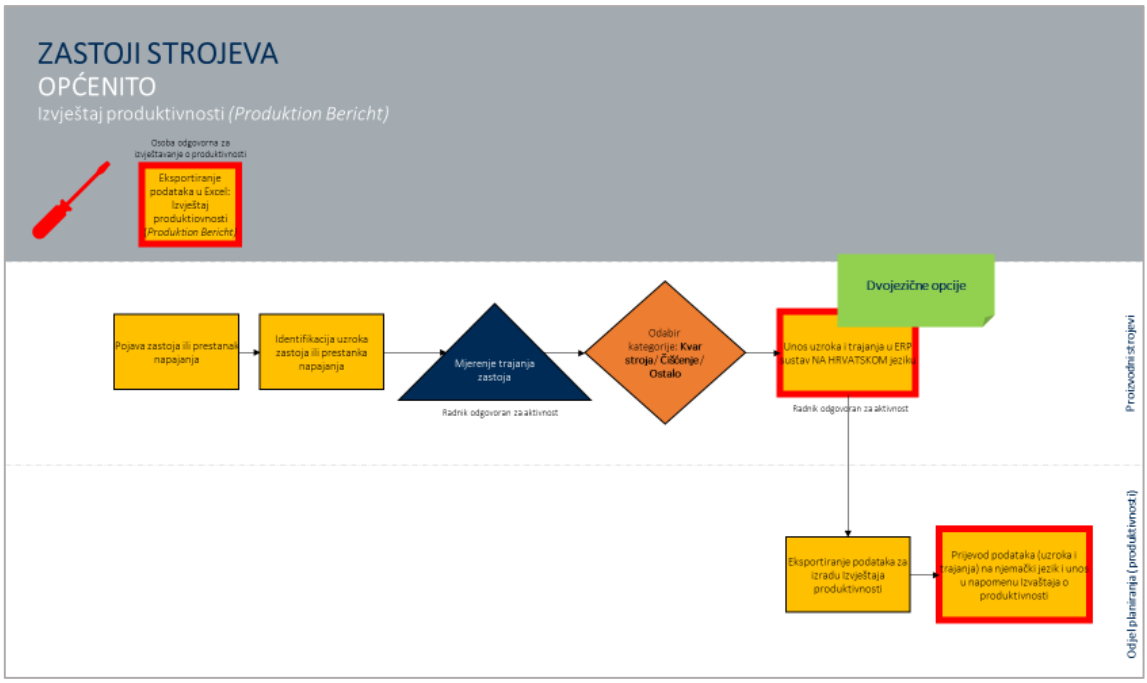
pojedinim radnim operacijama te na kraju i skeniranja broja proizvedenih pari na završnoj kontroli. Ako produktivnost u smjeni ne dosegne 95 %, voditelj smjene dužan je ispuniti Obrazac za analizu produktivnosti koji šalje Odjelu planiranja. Odjel planiranja zatim analizira i evidentira uzrok pada produktivnosti.

Odjel planiranja, odnosno osoba odgovorna za izradu Izvještaja produktivnosti, dohvaća podatke iz ERP sustava i generira Izvještaj produktivnosti. U tom je koraku iz dijagrama toka procesa vidljiv prvi nedostatak – crveni okvir na drugoj razini dijagrama, pobliže objašnjen u sljedećem poglavlju (4.2.2.). Ako su svi podaci iz izvještaja zadovoljavajući, isti se šalje odabranim zaposlenicima. Ako nešto nije u skladu s predefiniranim vrijednostima, traži se uzrok problema, primjerice u ranije spomenutom Obrascu za analizu produktivnosti.

Iduće dvije razine prikazuju korake procesa vezane za Odjel osiguranja kvalitete te za Laboratorij za testiranje proizvoda. Koraci procesa izrade Izvještaja kvalitete (*Qualitätsberichta*) slični su kao i kod izrade Izvještaja produktivnosti. Na ove dvije razine također su vidljivi nedostaci prikazani crvenim okvirom, a koraci su pobliže objašnjeni u poglavlju 4.2.4.

4.2.2. Generalni prikaz toka procesa evidencije zastoja strojeva

Generalni prikaz toka procesa evidencije zastoja strojeva predstavlja detaljnu raščlambu prvog nedostatka koji se pojavljuje u generalnom prikazu toka proizvodnog procesa iz prethodnog poglavlja (slika 10).



Slika 10. Generalni prikaz toka procesa evidencije zastoja strojeva [izrada autorice]

4.2.2.1. Opis dijagrama

Kada na određenom stroju dođe do zastoja, zaposlenik je dužan identificirati njegov uzrok, izmjeriti duljinu trajanja te unijeti uzrok u ERP sustav. Uzroci su u sustavu ponuđeni na hrvatskom jeziku.

Iduća razina dijagrama obuhvaća Odjel planiranja. Osoba odgovorna za izradu Izvještaja produktivnosti dohvaća podatke iz ERP sustava te ih unosi u Izvještaj produktivnosti. S obzirom na to da se izvještaj šalje i zaposlenicima u sjedištu u Njemačkoj, dohvaćene je podatke potrebno prevesti na njemački te u tom obliku pohraniti u izvještaj.

4.2.2.2. Prijedlog poboljšanja

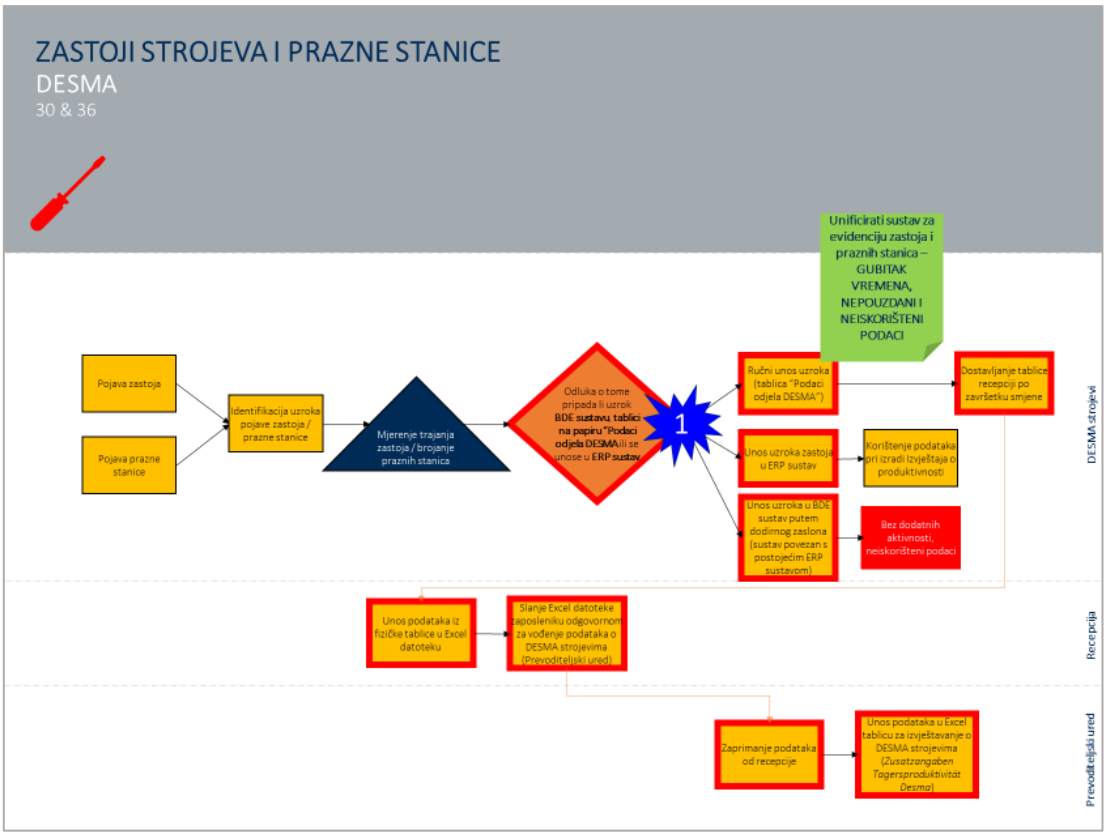
Prijedlog poboljšanja vrlo je jasan iz generalnog prikaza toka procesa evidencije zastoja strojeva. Nedostatak u ovom procesu vezan je za ručnu evidenciju podataka prema simbolima sa slike 8, kao što je vidljivo na slici 11. Potrebno je u ERP sustav unijeti dvojezične podatke, odnosno podatke koje razumije i radnik u proizvodnji koji ne govori njemački jezik, ali i njemački zaposlenici koji ne govore hrvatski jezik. Na taj način izbjeglo bi se nepotrebno prevođenje informacije, što rezultira uštedom vremena te eliminira mogućnost pogreške.

Osim nepotrebnog gubitka vremena, pri aktivnostima poput ove zaposlenici često nalaze načine da si olakšaju i ubrzaju postupak unosa podataka. Primjerice, pri ispunjavanju Excel polja Izvještaja produktivnosti, zaposlenik se može odlučiti kopirati i zalijepiti stari podatak kako bi se izbjeglo nepotrebno pisanje, pri čemu postoji rizik od ostavljanja prijašnje, neispravne informacije u izvještaju (primjerice trajanje zastoja). Osim što to dovodi do prijenosa pogrešne informacije, čak i u slučaju da se greška otkrije na vrijeme, njen uzrok je potrebno identificirati, što dodatno oduzima vrijeme.

4.2.3. Dijagram toka procesa evidencije zastoja i praznih stanica DESMA strojeva

Funkcija DESMA strojeva je brizganje đonova na gornjišta obuće. Trenutno su u tvrtki HAIX obuća d.o.o. u pogonu dva takva stroja, jedan koji sadrži 30, i drugi koji sadrži 36 stanica. To znači da se u jednom ciklusu stroja može brizgati 15, odnosno 18 pari obuće.

Dijagram toka procesa evidencije zastoja i praznih stanica strojeva DESMA 30 i 36 prikazuje hodogram aktivnosti koje se poduzimaju kada dođe do zastoja ili praznih radnih stanica tih strojeva (slika 11). Uobičajeni razlozi su prekid napajanja, zamjena dijelova i čišćenje.



Slika 11. Dijagram toka procesa evidencije zastoja i praznih stanica DESMA strojeva [izrada autorice]

4.2.3.1. Opis dijagrama

Kada dođe do zastoja stroja ili prazne stanice, odgovorna osoba zadužena je za identifikaciju uzroka te mjerenje trajanja zastoja. Nadalje, slijedi donošenje odluke o tome na koji će se od raspoloživih načina uzrok evidentirati:

1. Ručno unošenje uzroka zastoja ili prazne stanice u tablicu na dokumentu pod nazivom *Podaci odjela DESMA* (*Daten von Desma Abteilung*)
2. Ručno unošenje uzroka i trajanja zastoja u ERP sustav Inpos
3. Ručno unošenje uzroka gubitka vremena ili pari obuće putem dodirnog zaslona (BDE sustav)

Ručnim unošenjem uzroka i trajanja zastoja u ERP sustav Inpos pohranjuju se podaci potrebni za izradu Izvještaja produktivnosti. Ti podaci bitni su Odjelu planiranja u svrhu kalkulacije produktivnosti na temelju trajanja zastoja na stroju. Ručnim unošenjem uzroka gubitka vremena

ili pari obuće putem dodirnog zaslona (BDE sustava) tok procesa prestaje te se na temelju istog ne poduzimaju daljnje mjere – korak označen crvenim pravokutnikom na slici 11.

Nakon ručnog unošenja uzroka zastoja ili prazne stanice u tablicu na papiru pod nazivom *Podaci odjela DESMA* (njem. *Daten von Desma Abteilung*), dokument se u fizičkom obliku dostavlja recepciji po završetku smjene. Recepcija zatim prepisuje podatke s dokumenta u Excel tablicu te istu šalje putem elektroničke pošte osobi odgovornoj za evidenciju zastoja i praznih stanica. Odgovorna osoba bilježi dobivene podatke u zaseban Excel dokument (tzv. *Zusatzangaben Tagesproduktivität Desma*). Odjel koji zaprima spomenuti dokument te vodi evidenciju jest Prevoditeljski ured.

4.2.3.2. Prijedlog poboljšanja

U dijagramu toka procesa evidencije zastoja strojeva DESMA 30 i 36 vidljivo je mnogo oznaka mjesta potencijalnih poboljšanja, odnosno crveno uokvirenih koraka procesa. Veliki problem u ovom procesu jest taj što ne postoji unificirani sustav za evidenciju zastoja i praznih stranica stroja, što rezultira nepouzdanim, nepotpunim i netočnim podacima. Situacije poput ove uzrokuju konfuziju među zaposlenicima jer je, između tri dostupna sustava, vrlo teško odabrati onaj ispravni, posebice ako zaposlenicima nisu dane jasne upute na koji se način podaci evidentiraju te nije provedena provjera uspješnosti implementacije.

Tijekom boravka u tvrtki i odrađivanja praktičnog dijela projekta, fizički su dokumenti uspoređivani s podacima prikupljanim pomoću BDE sustava. Sustavi ne sadrže iste podatke te moguće uzroke zastoja ili praznih stranica stroja. Također, BDE sustav drugačije je podijeljen prema kategorijama nastanka zastoja ili pojave prazne stanice na zastoje koji uzrokuju gubitak vremena te one koje uzrokuju gubitak pari obuće. Podaci se međusobno nisu podudarali čak ni u onim podacima koji su isti za oba sustava. Osim toga, u BDE sustavu određeni podaci nedostaju, primjerice evidencija podataka za noćnu smjenu.

Nedostaci identificirani ovim dijagramom toka procesa uzrokuju gubitke vremena. Osim toga, informacije koje se mogu dobiti na temelju tih podataka nisu pouzdane i točne jer je vrlo velika vjerojatnost da se određeni podatak zabilježi u jednom sustavu, dok u drugom isti nije evidentiran, što znači da ni odluke koje se donose na temelju informacija nisu utemeljene na činjenicama.

Prijedlog poboljšanja ovog procesa uključuje stvaranje jedinstvenog sustava koji sadrži relevantne podatke. Potrebno je ustanoviti koji su uzroci zastoja i praznih stanica najčešći te

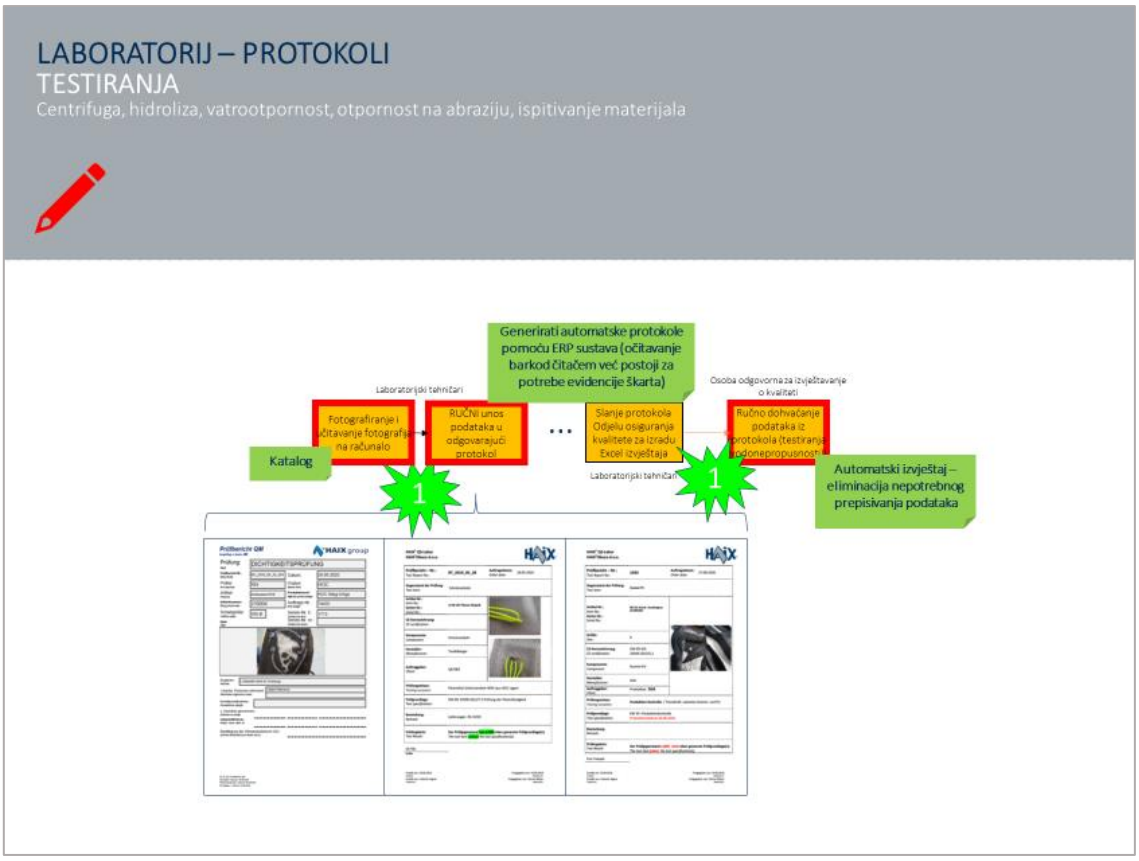
unaprijediti postojeći BDE sustav. Novi sustav treba obuhvaćati sve one ključne podatke iz trenutno dostupnog sustava i fizičke tablice *Podaci odjela DESMA*. Pritom je neophodno napraviti detaljnu analizu podataka koji su tvrtki potrebni i koje tvrtka koristi za donošenje odluka. Tablica u fizičkom obliku uzrokuje velike gubitke vremena jer se podaci upisuju ručno, na papir, te se isti dostavlja recepciji. Nepotrebno kretanje je jedan od sedam vrsta gubitaka prema *Lean Six Sigma* metodologiji i mora biti eliminirano. Osim spomenutog, postoji veliki rizik od prikupljanja pogrešnih informacija. Razlog tome su čak dva koraka u procesu u kojima se podaci prepisuju iz jednog dokumenta u drugi, gdje veliki rizik od unosa krivog podatka predstavlja ljudski faktor.

Što se tiče unošenja uzroka i trajanja zastoja u ERP sustav Inpos, taj je sustav neophodan zbog važnosti podatka za izradu Izvještaja produktivnosti. Trajanje zastoja direktno utječe na produktivnost kao dio formule pomoću koje se ista kalkulira. No, s obzirom na to da je BDE sustav direktno povezan s Inposom, zaposlenicima treba biti omogućen unos trajanja zastoja direktno u Inpos u svrhu izrade Izvještaja putem istog dodirnog zaslona koji prikazuje BDE sustav. Na taj bi način dva sustava bila sjedinjena u jedan te prikazana na jednom dodirnom zaslonu. To bi eliminiralo potencijalne nedoumice vezane za korištenje nekog od sustava jer bi postojao samo jedan, točan način unosa i praćenja podataka.

Praćenje zastoja i praznih stanica od iznimne je važnosti. Analizom tih podataka moguće je primijetiti anomalije u načinu rada stroja te reagirati na vrijeme ako dođe do zastoja ili kvara. Vrlo je važno pratiti rad strojeva statističkim alatima jer se danas proizvodna industrija sve više orijentira preventivnom i prediktivnom održavanju. Korektivno se održavanje sve češće smatra zastarjelom metodom. Dolazi do izrazito velikih gubitaka ako određene mjere nisu poduzete na vrijeme, što može uzrokovati privremeni prestanak rada stroja, kvar ili čak potpunu neupotrebljivost. To ima velike posljedice na proizvodnu industriju. Osim što su troškovi popravaka i opreme iznimno visoki, još veće gubitke predstavlja obustava proizvodnje na određeni period, što negativno utječe na cijeli lanac opskrbe.

4.2.4. Dijagram toka procesa testiranja u laboratoriju i kontrole kvalitete

Slika 12 prikazuje veću razinu detalja procesa iz generalnog prikaza toka proizvodnog procesa (poglavlje 4.2.1.). Naglasak je na zadnje dvije razine sa slike 9, a odnose se na korake procesa koji se odvijaju u Odjelu osiguranja kvalitete te u Laboratoriju za testiranje proizvoda.



Slika 12. Dijagram toka procesa testiranja u laboratoriju i kontrole kvalitete [izrada autorice]

4.2.4.1. Opis dijagrama

Odjel osiguranja kvalitete započinje proces izrade Izvještaja kvalitete (tzv. *Qualitätsberichta*) u Excelu dohvaćanjem podataka iz ERP sustava (slika 9). Nakon toga, osoba odgovorna za izradu Izvještaja kvalitete ručno prepisuje podatke iz protokola u Izvještaj.

Spomenuti protokoli nastaju u Laboratoriju za testiranje proizvoda, a odnose se na hidrolizu, ispitivanje vatrootpornosti, ispitivanje otpornosti na abraziju, ispitivanje materijala, ispitivanje vodonepropusnosti metodom centrifuge i ostala ispitivanja. Naglasak je na vodonepropusnosti obuće te se greške pri proizvodnji koje uzrokuju propuštanje detaljno analiziraju.

Osoba odgovorna za testiranje proizvoda u laboratoriju dužna je fotografirati mjesto greške na proizvodu te učitati fotografiju u Obrazac protokola koji se ručno ispunjava. Osim Odjelu osiguranja kvalitete, protokoli se šalju voditeljima proizvodnje i svima onima koji vrše analizu greške.

4.2.4.2. Prijedlog poboljšanja

Fotografiranje svakog testiranog proizvoda i nestrukturirani prijenos datoteka na računalo oduzima vrijeme. Iako je od velike važnosti analizirati svaki proizvod koji propušta te pronaći uzrok, potrebno je razmotriti mogućnost uvođenja kataloga grešaka, no naprednog u odnosu na postojeći. Nepravilnost na proizvodu važno je označiti vrlo precizno, stoga je jedan od prijedloga raslojeni 3D prikaz proizvoda, pod pretpostavkom da postoje već izrađeni 3D modeli u Odjelu za istraživanje i razvoj. To bi omogućilo preciznije označavanje greške uz istovremenu uštedu vremena.

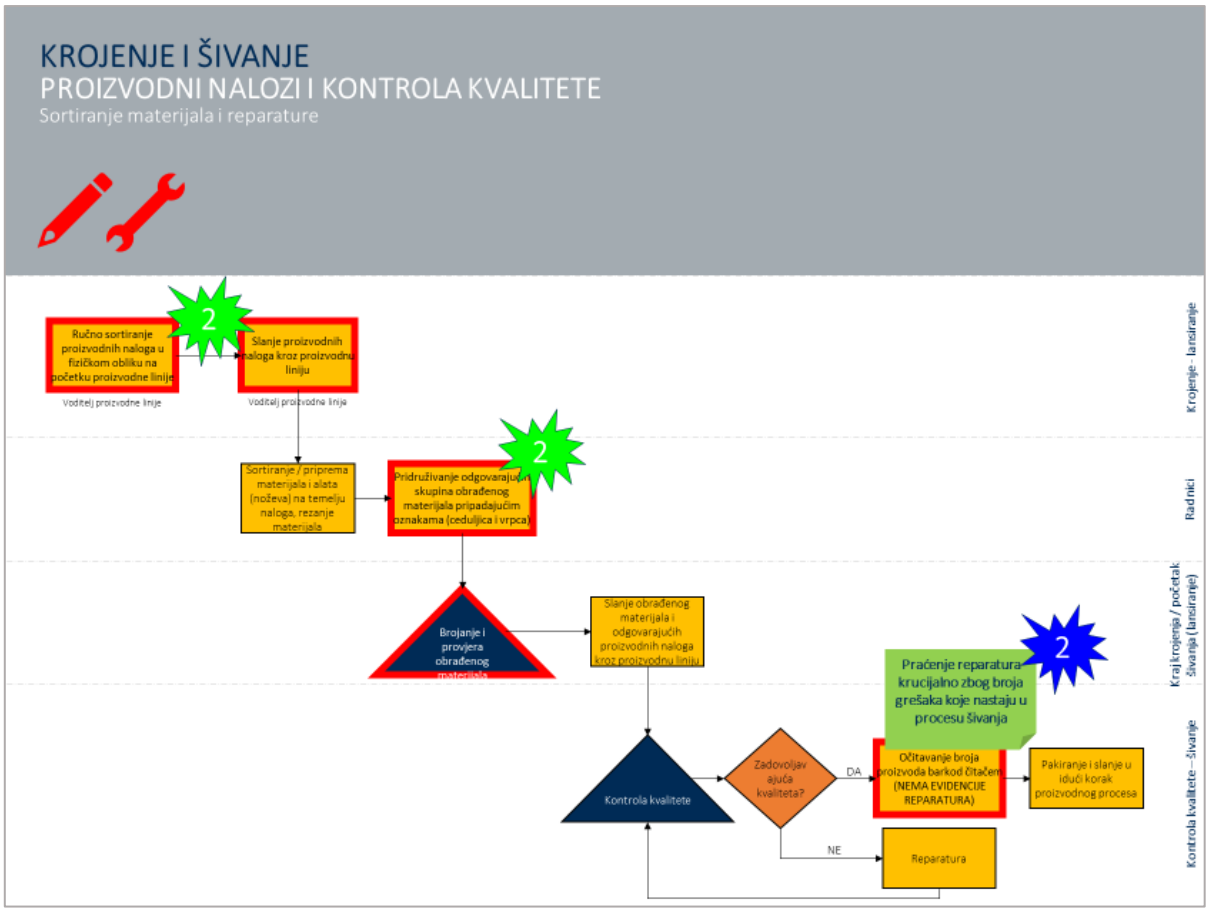
Osim spomenutog, važno je naglasiti prednosti potencijala koji postojeća baza fotografija i podataka posjeduje. Naime, razvoj inteligentnih alata umjetne inteligencije u području računalne znanosti omogućuje maksimalno iskorištavanje dostupnih podataka. Riječ je o sustavu koji bi i dalje koristio fotografije grešaka na proizvodima, no s višim ciljem, a to je učenje neuronskih mreža. Njihovim kontinuiranim razvojem i učenjem, sustav bi u konačnici bio u mogućnosti samostalno prepoznati je li riječ o grešci na proizvodu te o kojoj je vrsti greške riječ. Bitno je napomenuti da je za ovakav sustav obavezna digitalizacija, odnosno neophodno je da se svi prikupljani podaci u obliku slika ili drugog formata automatski unose u već postojeći ERP sustav. Sustavi poput ovog, uz današnji razvoj tehnologije, omogućuju organizacijama da se pravovremeno prilagođavaju novonastalim situacijama na tržištu, uz istovremenu uštedu i realokaciju resursa. Nadogradnja ovakvog sustava dugoročno može uključivati i automatizirane prijedloge rješenja pojedinih problema na temelju dostupnih podataka i ponavljajućih obrazaca ponašanja. Primjerice, ako dođe do velikog odstupanja u podacima koji uobičajeno prate određeni trend, sustav samostalno može izvijestiti o promjeni te se sprječava naknadno rješavanje problema. Cilj je izbjeći korektivne aktivnosti te preusmjeriti postojeće podatke i informacije na razvoj sustava koji probleme rješava prediktivno i preskriptivno, a ne korektivno.

Prednosti spomenutog prijedloga izrazito su velike, no implementacija predloženog sustava zahtijeva ulaganje mnogo truda i vremena te otvara prostor za pokretanje novih projekta koji obuhvaćaju gotovo sve odjele tvrtke, od IT-a, preko Odjela osiguranja kvalitete do Laboratorija za testiranje proizvoda. Međutim, Odjel osiguranja kvalitete i laboratorij od ključne su važnosti za cijelu organizaciju jer je kvaliteta prioritet tvrtke HAIX obuća d.o.o. To je razlog zbog kojeg se isplati uložiti veći dio resursa, prvenstveno znanja i vremena, u projekte poput spomenutog. Rasterećenje Odjela osiguranja i kvalitete i laboratorija znači više vremena za testiranja te kvalitetnu analizu proizvoda, kao i pravovremeno poduzimanje određenih mjera u procesu proizvodnje kako bi se spriječilo ponavljanje grešaka.

Osim fotografiranja grešaka na proizvodima, veliki je nedostatak procesa koji se odvija u laboratoriju taj što se Obrasci protokola ispunjavaju ručno za svaki testirani proizvod. Glavni prijedlog poboljšanja toka procesa testiranja u laboratoriju i kontrole kvalitete jest automatsko generiranje protokola iz ERP sustava Inpos. Riječ je o nekoliko dokumenata koji trenutno postoje u Word ili Excel formatu te se ručno ispunjavaju svaki puta kada je proizvod testiran. Isti se dokumenti zatim šalju Odjelu osiguranja kvalitete koji prepisuje podatke za Izvještaj kvalitete. Naime, laboratorij već posjeduje čitač barkoda koji služi za očitavanje škarta. Ručni unos svakog pojedinog artikla i detalja o testiranju potrebno je zamijeniti automatski generiranim protokolima iz sustava. Polja koja se popunjavaju većinom sadrže ponavljajuće vrijednosti (naziv modela, greške, uzroke propuštanja, uzroke neuspješne hidrolize, je li proizvod uspješno prošao testiranje i sl.), stoga bi se, bez mnogo ulaganja, mogao implementirati sustav koji bi za svaki protokol nudio padajuće izbornike te automatski generirao broj protokola, odgovornu osobu i ostale relevantne podatke. To bi u velikoj mjeri olakšalo i Odjelu osiguranja kvalitete za izradu Izvještaja kvalitete jer bi pristup automatski generiranim protokolima u ERP sustavu zamijenio nepotrebno traženje dokumenata u mapama. Trenutno Odjel osiguranja kvalitete bilježi ručno, na papiru, one datoteke koje su već obrađene i unesene u Izvještaj kvalitete. Mape u koje se pohranjuju protokoli sadrže jako veliku količinu datoteka koje nisu smisleno poredane i traženje potrebnih protokola Odjelu osiguranja kvalitete oduzima mnogo vremena. Ovo unaprjeđenje također bi omogućilo bolje iskorištavanje dostupnog vremena za poboljšanja proizvodnog procesa, kao i kvalitete proizvoda.

4.2.5. Dijagram toka procesa šivanja i krojenja

Proizvodni procesi šivanja i krojenja u tvrtki HAIX obuća d.o.o. specifični su zbog otežanog praćenja kretanja materijala. To je proces u kojem se omogućuje očitavanje barkoda njegovim šivanjem na pojedini artikl, stoga nije iznenađujuće da u ovom procesu ne postoji visoka razina automatizacije prikupljanja podataka. Do trenutka integracije barkoda nije moguće pratiti kretanje materijala trenutno dostupnim sustavima u proizvodnom procesu.



Slika 13. Dijagram toka procesa šivanja i krojenja [izrada autorice]

4.2.5.1. Opis dijagrama

Proizvodni proces započinje ručnim razvrstavanjem i pripremanjem proizvodnih naloga koji su u fizičkom obliku. Sortirani se nalozi zatim s početka proizvodne linije šalju kroz proizvodni proces. Ovi su koraci procesa uokvireni crveno jer se odvijaju ručno i proces nije automatiziran. Nadalje, u procesu krojenja, prilikom rezanja materijala, gotove se skupine proizvoda označavaju odgovarajućom ceduljicom i grupiraju gumicom. Na kraju krojenja, odnosno početku šivanja, grupirani proizvodi ručno se broje i bilježe te se lansiraju u proizvodni proces šivanja.

Kontrola kvalitete na kraju proizvodnog procesa šivanja odvija se na način da se procjenjuje kvaliteta proizvoda te se isti očitavaju barkod čitačem ako je riječ o proizvodima zadovoljavajuće kvalitete. Proizvodi se zatim pakiraju i šalju u preostale dijelove proizvodnog procesa. Ako proizvod treba proći postupak reparature, vraća se u proces te se ponovno ocjenjuje kvaliteta.

4.2.5.2. Prijedlog poboljšanja

Prikupljanje podataka u procesima šivanja i krojenja većim se dijelom odvija ručno. Razlog tome je otežana implementacija sustava za praćenje jer se barkod ugrađuje tijekom tog procesa, a to je jedini način na koji se u proizvodnom procesu tvrtke automatski prikupljaju podaci. U ovom se procesu pojavljuje problem zbog načina na koji se označavaju gotove skupine materijala obrađenih rezanjem, prešanjem i ostalim postupcima krojenja. Naime, gotove skupine poluproizvoda vežu se vrpcom i označavaju ceduljicom te grupiraju u sanduke. Pri transportu sanduka, često se događa da se pripadajuća ceduljica izgubi u proizvodnom procesu, što ima negativni utjecaj na sljedivost. Isti se problem javlja u procesu šivanja, gdje zaposlenici na papir, na mjesto pripadajuće operacije unose svoje ime i prezime, kao i vrijeme trajanja operacije. Na taj se način vodi evidencija zaposlenika odgovornih za radne operacije te se računa produktivnost.

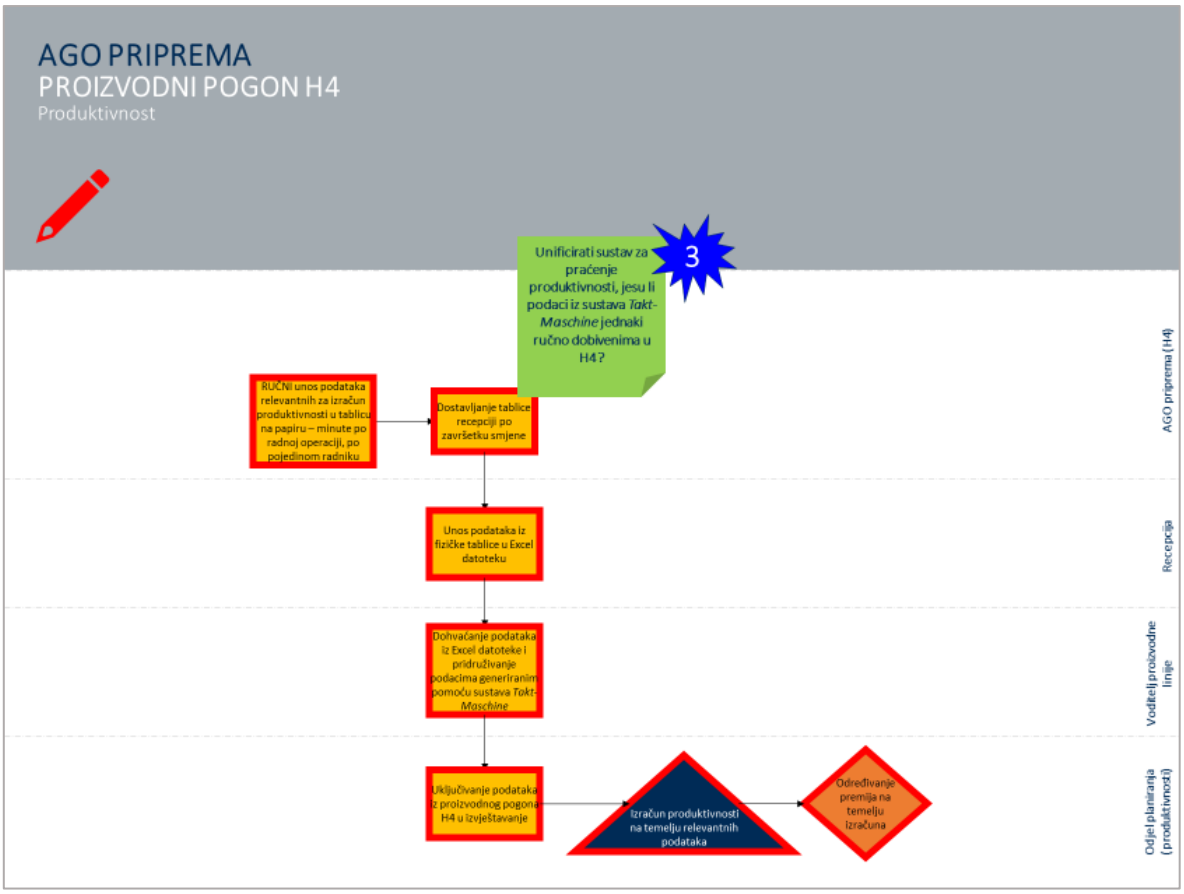
Prijedlog poboljšanja uključuje automatizaciju praćenja radnih operacija implementacijom novog sustava. Sustav bi predstavljao digitaliziranu inačicu trenutno postojećeg, fizičkog dokumenta za evidenciju. Zaposlenici bi se pomoću dodirnog zaslona na početku smjene prijavili u sustav i kroz tijek procesa označavali početak i kraj svake ponuđene radne operacije. Na taj način bi se potpuno eliminiralo ručno unošenje podataka na papiru te bi se dobivala točna informacija o trajanju pojedine operacije, ali i o osobi odgovornoj za istu. Implementacija takvog sustava omogućila bi i da se svaki sanduk, odnosno proizvodni nalog, povezuje s dijelovima od kojih se sastoji i koji se izvršavaju na različitim mjestima u proizvodnom procesu. Također, dobivao bi se točan podatak za izračun produktivnosti, kao i uvid u kritična mjesta koja treba dodatno analizirati. Razlog nastanka kritičnih mjesta koja trebaju posebnu pažnju može biti nedovoljna edukacija zaposlenika ili utjecaj ljudskog faktora, primjerice da zaposlenik zaboravi unijeti trajanje operacije na za to predviđeni listić.

Drugi korak procesa koji je potrebno unaprijediti jest očitavanje barkodova proizvoda pri kontroli kvalitete. Naime, proizvodi se očitavaju ako su zadovoljavajuće kvalitete te se evidentira podatak o broju proizvedenih pari obuće za izračun produktivnosti. Međutim, u proizvodnom pogonu gdje se izvršavaju procesi krojenja i šivanja ne postoji evidencija reparatura. To je od velike važnosti upravo u ovom pogonu jer se u spomenutim proizvodnim postupcima stvara veliki broj grešaka koje se trenutno ne bilježe. To uzrokuje probleme u daljnjim koracima proizvodnje zbog ranije spomenutog nedostatka sljedivosti. Naime, određena greška postane vidljiva tek u kasnijoj fazi proizvodnje te se retrospektivno traži uzrok problema

ili odgovorna osoba, što je često vrlo teško ili nemoguće identificirati zbog načina na koji se prate radne operacije. Prije svega, s obzirom na to da već postoji implementirani sustav za očitavanje barkodova u svrhu brojanja pari obuće, potrebno je nadograditi postojeći sustav koji će imati mogućnost evidentirati reparature. Izrazito je bitno pratiti pokazatelje poput omjera dobrih i loših artikala jer je kvaliteta prioritet tvrtke HAIX obuća d.o.o. Također, nedostatak ovakvog sustava ostavlja mnogo prostora za utjecaj ljudskog faktora jer se neispravni proizvodi mogu poslati u daljnje korake procesa bez da su evidentirani kao loši, što dolazi do izražaja u trenutku kada je to već prekasno i zahtijeva komplicirane reparature, a može rezultirati i škartom.

4.2.6. Dijagram toka procesa pripreme na AGO liniji

Na AGO liniji koja se nalazi u proizvodnom pogonu H2 odvija se proces montaže. Dio poluproizvoda za AGO liniju dolazi iz proizvodnog pogona H4, gdje se proizvode donjišta obuće. Osim kalupljenja đonova u pogonu H4, tamo se odvija i dio procesa pripreme za AGO liniju. Ovaj se dijagram odnosi samo na onaj dio pripreme koji se odvija u proizvodnom pogonu H4.



Slika 14. Dijagram toka procesa pripreme na AGO liniji [izrada autorice]

4.2.6.1. Opis dijagrama

Proces evidencije podataka o produktivnosti kod AGO pripreme započinje ručnim unosom trajanja radnih operacija na za to predviđeni papir. Taj papir se po završetku smjene dostavlja recepciji koja zatim prepisuje te podatke u zasebnu Excel datoteku. Na temelju tih podataka voditelj AGO proizvodnje zatim nadopunjava tablicu za kalkulaciju produktivnosti. Tablica produktivnosti generira se iz podsustava *Takt-Maschine* koji automatski bilježi trajanje radnih operacija na AGO liniji. Dakle, voditelj AGO proizvodnje ručno nadopunjuje automatski generirane podatke za AGO liniju. Nadalje, automatski generirani i ručno uneseni podaci zajedno se koriste za izradu Izvještaja produktivnosti u Odjelu planiranja, a na temelju tih podataka računaju se ostvareni bonusi zaposlenika.

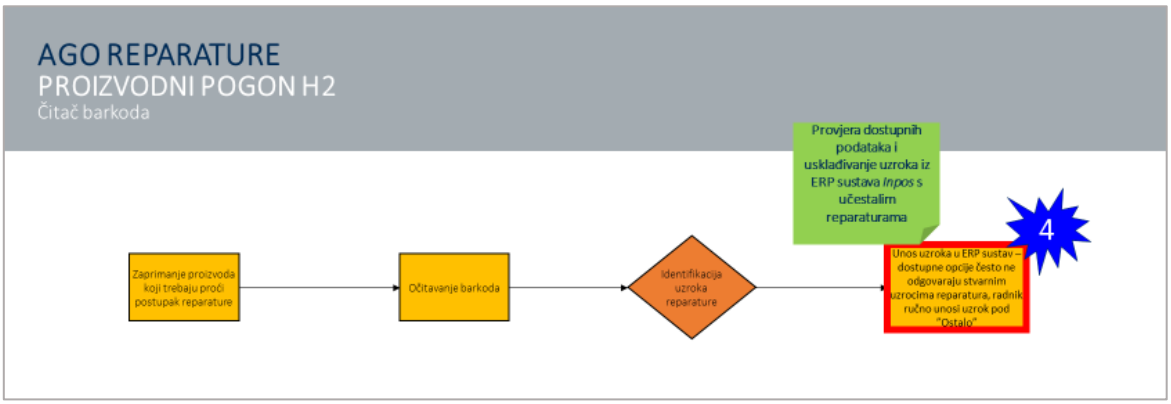
4.2.6.2. Prijedlog poboljšanja

Proces pripreme na AGO liniji koji se odvija u pogonu H4 neophodno je uskladiti s procesom pripreme koji se odvija u pogonu H2, gdje se odvija i AGO montaža. Naime, podaci koji se

prikupljaju u pogonu H4 razlikuju se od onih koji se prikupljaju automatski u pogonu H2, što ne bi trebao biti slučaj. S obzirom na to da se kod pripreme u H4 evidencija trajanja operacija vodi ručno, postoji velika vjerojatnost za stvaranje grešaka zbog utjecaja ljudskog faktora. Prijedlog poboljšanja uključuje unificirani sustav za sve AGO linije pripreme jer, neovisno o tome što je linija u H4 dislocirana, ne bi trebala postojati razlika u načinu na koji se za isti proizvodni postupak prikupljaju relevantni podaci. Prikupljani podaci, odnosno umnožak vremena trajanja pojedine operacije i pripadajuće norme, izravno utječu na mjesečni izračun bonusa. Prema tome, nesukladnost podataka ovih dviju linija i postojanje razlike među njima može značiti i da se donose krive odluke na temelju istih.

4.2.7. Dijagram toka procesa reparacija na AGO liniji

Reparature na AGO liniji izvode se kao zasebna operacija te, osim proizvoda s AGO linije, uključuju i proizvode sa strojeva DESMA koji trebaju proći postupak reparature (slika 15).



Slika 15. Dijagram toka procesa reparacija na AGO liniji [izrada autorice]

4.2.7.1. Opis dijagrama

Radnik zaprima proizvode koji trebaju proći postupak reparature. Proizvodi se skeniraju te se identificira uzrok greške. Nadalje, uzrok se unosi u ERP sustav koji nudi moguće uzroke.

4.2.7.2. Prijedlog poboljšanja

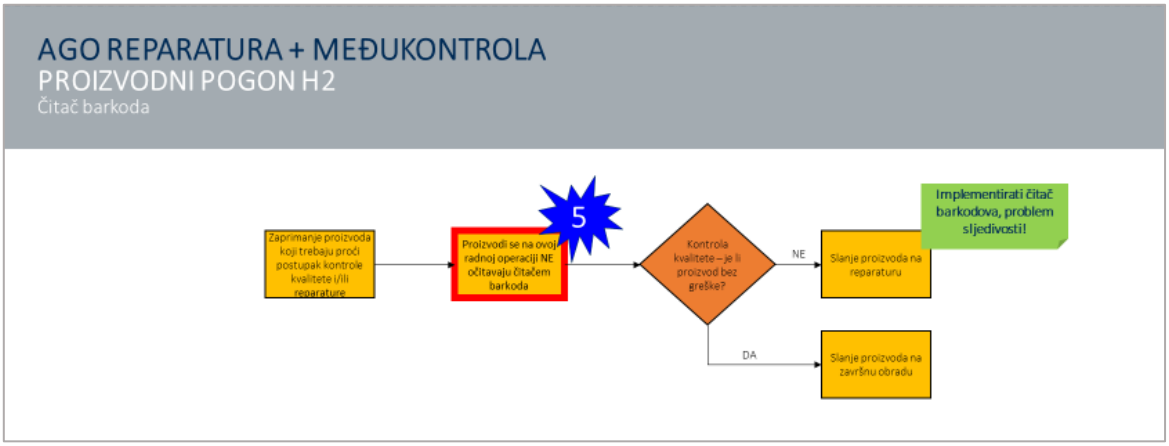
Ovaj dijagram predstavlja mali segment cjelokupne proizvodnje. Međutim, bitno je predložiti poboljšanje jer je implementacija jednostavna. Naime, uzroci ponuđeni u ERP sustavu često ne odgovaraju greškama na proizvodima te radnik odabire opciju *ostalo* te ručno unosi potrebni

podatak. Prijedlog poboljšanja uključuje nadopunu sustava mogućim uzrocima reparatura na liniji kako bi se izbjeglo nepotrebno ručno unošenje podataka. Dakle, treba analizirati koje se greške najčešće pojavljuju i sukladno tome unijeti sve moguće opcije u sustav.

Također, na ovom se radnom mjestu vrše sve reparature, a ne nužno s AGO linije. To znači da veliki broj proizvoda sa DESMA strojeva prolazi postupak reparature, no ne bilježi se točno koliki je udio pripao upravo tom radnom mjestu. ERP sustav razvrstava reparature na one greške identificirane na međukontroli te završnoj kontroli linije DESMA, na završnoj kontroli AGO linije te na sve ostale. Među svim ostalima nalaze se i AGO reparature analizirane dijagramom u ovom poglavlju. Zbog postizanja više razine sljedivosti poželjno je da se u svakom trenutku zna točno gdje je koji proizvod, prvenstveno kada su u pitanju popravci istih.

4.2.8. Dijagram toka procesa međukontrole na AGO liniji

Za razliku od DESMA linije, na AGO liniji ne provodi se postupak očitavanja barkoda u procesu međukontrole. Do nedavno nije postojalo ni očitavanje grešaka na završnoj kontroli, no sustav je uveden u rujnu zbog velike važnosti podataka za analizu kvalitete.



Slika 16. Dijagram toka procesa međukontrole na AGO liniji [izrada autorice]

4.2.8.1. Opis dijagrama

Na AGO međukontroli zaprimaju se proizvodi koji trebaju proći kontrolu kvalitete i manje reparature poput podljepljivanja proizvoda. Proizvodi se ne skeniraju, već se obavlja zadana radna operacija te se po završetku iste šalju na završnu obradu te završnu kontrolu. Ako je riječ o proizvodu s greškom, isti se šalje na reparaturu.

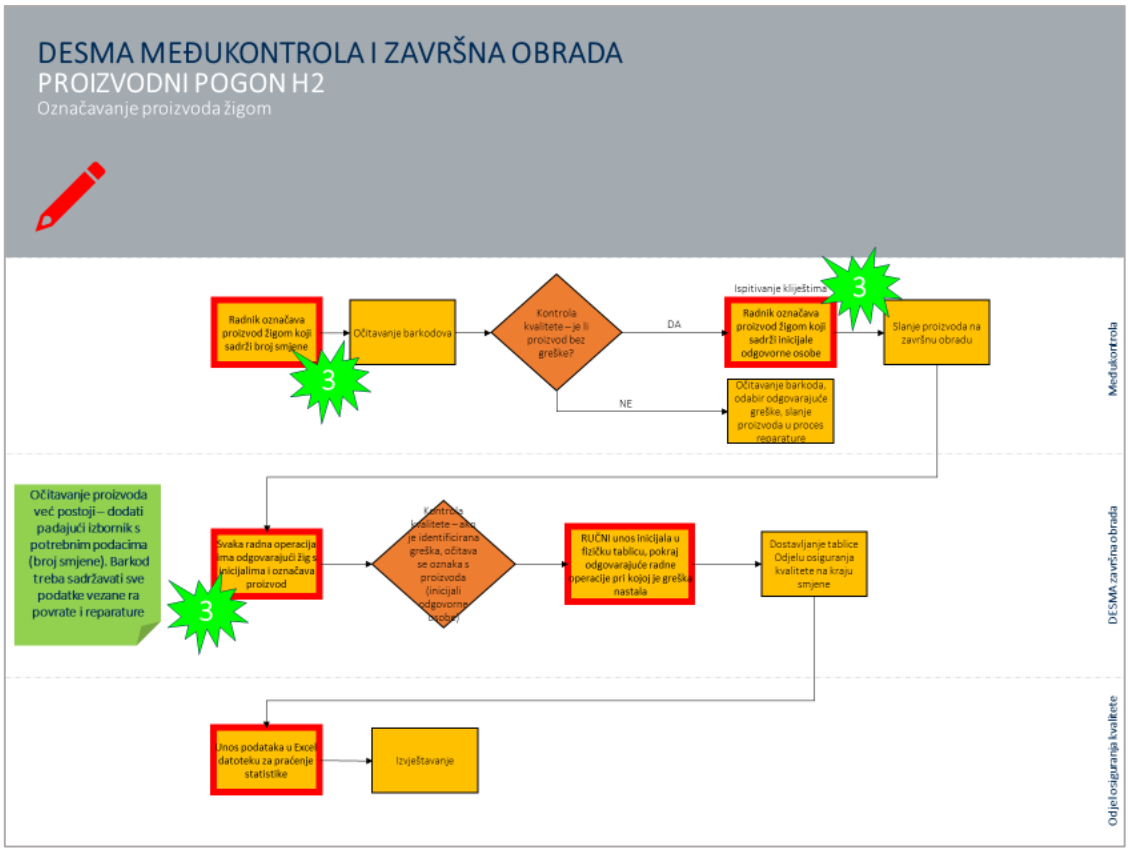
4.2.8.2. Prijedlog poboljšanja

Vrlo je bitno da svaka operacija kontrole posjeduje mogućnost očitavanja proizvoda. AGO međukontrola, za razliku od DESMA međukontrole, nema čitač na toj radnoj stanici. Vrlo je bitno implementirati već postojeći sustav i na ovu radnu stanicu jer se javljaju problemi sa sljedivošću proizvoda. Naime, nakon međukontrole slijede završna obrada i završna kontrola. Ako na završnoj kontroli određeni proizvod ne zadovoljava uvjete, isti se očitava barkod čitačem i vraća u proces na reparaturu, no nije zabilježen kada po drugi put prolazi međukontrolu jer ista nema mogućnost evidencije proizvoda i potencijalne greške.

Također, implementacija spomenutog sustava od velike je važnosti jer se proizvod nakon određene operacije ne šalje uvijek na isto mjesto u proizvodnom procesu. Nakon međukontrole, može se dogoditi da slijedi reparatura, završna obrada ili pak rastavljanje i ponovna montaža. Važno je znati koji točno problemi uzrokuju reparature proizvoda, gdje se isti uočavaju te koji je idući korak u proizvodnom procesu. To omogućuje pravovremeno uočavanje često ponavljajućih grešaka i osoba odgovornih za iste, ali i točne informacije o tome gdje se proizvod nalazi i kada.

4.2.9. Dijagram toka procesa međukontrole i završnih radova na DESMA liniji

DESMA proizvodna linija trenutno ima najveći stupanj automatizacije u tvrtki HAIX d.o.o. Razlog tome su implementirani barkod čitači na svakoj radnoj operaciji gdje je to neophodno. Radne operacije ove linije rezultiraju gotovim proizvodima te je završna kontrola ista onoj na AGO liniji. Razlika je u tome što se pomoću DESMA strojeva gotovi proizvodi dobivaju brizganjem donjišta na gornjišta obuće. Na AGO liniji, za razliku od DESMA-e, više se operacija montaže proizvoda izvršava ručno, a poluproizvodi za montažu dolaze dijelom iz proizvodnog pogona H4, a dijelom od vanjskih dobavljača.



Slika 17. Dijagram toka procesa međukontrole i završnih radova na DESMA liniji [izrada autorice]

4.2.9.1. Opis dijagrama

Nakon brizganja donjišta na strojevima DESMA, proizvodi prolaze kroz određene obradne operacije te dolaze do međukontrole. Na međukontroli radnici označavaju proizvod žigom koji označava smjenu u kojoj je proizvod izrađen. Osim toga, proizvodi se očitavaju barkod čitačem te se evidentiraju sve greške koji moraju proći proces reparature. Nadalje, proizvodi dolaze do mjesta gdje se vrši postupak testiranja kliještima, gdje također postoji barkod čitač kako bi se evidentirali proizvodi koji nisu prošli testiranje kliještima, kao i mjesto na proizvodu gdje materijal nije zadovoljio zahtjeve. Kod radne operacije testiranja kliještima, proizvodi se također označavaju žigom koji sadrži inicijale osobe odgovorne za tu radnu operaciju. Ako je proizvod prošao testiranje kliještima, šalje se kroz proces završne obrade.

Pri završnoj obradi, radnici na svakoj operaciji imaju vlastiti žig s inicijalima kojim označavaju proizvod na određenom mjestu, ovisno o operaciji. Na taj način može se identificirati osoba odgovorna za, primjerice, grešku nastalu pri nanošenju boje. Na završnoj kontroli, ako je uočena

greška, odgovorna osoba očitava inicijale osobe koja je istu načinila te unosi podatak u tablicu na papiru. Tablica sadrži radnu operaciju pri kojoj je greška nastala te inicijale osobe odgovorne za tu operaciju. Ista se tablica u fizičkom obliku dostavlja Odjelu osiguranja kvalitete koji zatim podatke unosi u Excel datoteku u svrhu statističkog praćenja podataka.

4.2.9.2. Prijedlog poboljšanja

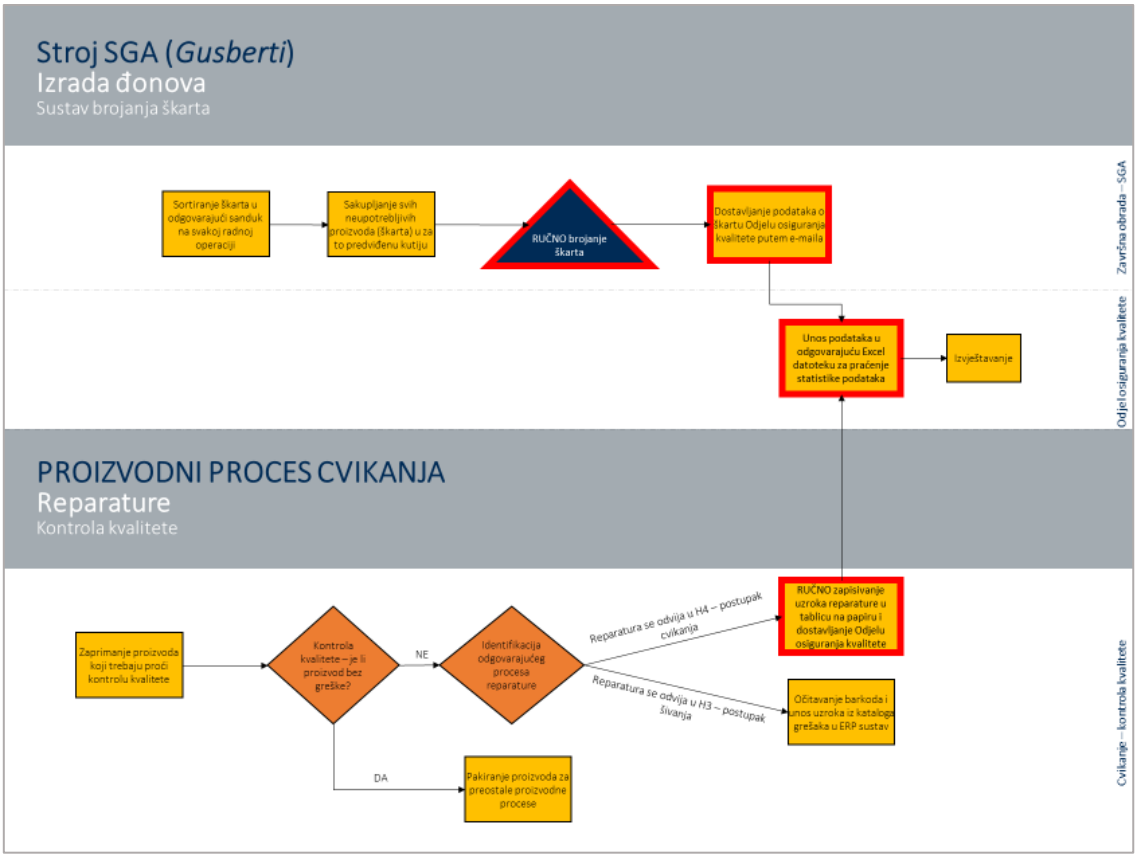
Iz proizvodnih procesa s DESMA linije potrebno je eliminirati ručno označavanje smjene i odgovornih radnika žigom. Odjel osiguranja kvalitete često nije u mogućnosti očitati inicijale iz tablice jer su isti ručno zapisani. Osim toga, čak i ako inicijali jesu jasno navedeni, često je potrebno provjeriti o kojem se zaposleniku točno radi te tko je taj dan bio na određenoj operaciji u odgovarajućoj smjeni. Ovakve su metode praćenja proizvoda i odgovornih osoba prošlost jer oduzimaju mnogo vremena osobama koje koriste te podatke. Osim toga, iz ručno zapisanih podataka često se dobivaju pogrešne informacije jer takvi podaci nisu pouzdani. Ovdje veliki utjecaj ima ljudski faktor te se može dogoditi da osoba krivo pročita inicijale s papira, navede pogrešnu osobu kao odgovornu za nastanak određene greške, što može rezultirati neispravnom statistikom i sankcijama temeljenim na pogrešnoj informaciji. Također, osoba koja unosi podatke u tablicu dužna je unaprijed, na temelju iskustva, znati gdje se koja operacija označava na proizvodu te tražiti žig na, primjerice, ulošku cipele. Ova tehnika ne može se smatrati prikladnom jer oduzima vrijeme, povećava rizik od netočnih podataka te je kompliciranа za provođenje.

Prijedlog poboljšanja uključuje potpunu eliminaciju metode označavanja žigovima kroz proizvodni proces. Umjesto toga, na mjestima gdje već postoji očitavanje proizvoda barkodom, mogao bi se nadograditi sustav za praćenje smjena i osoba odgovornih za pojedinu operaciju. To je moguće realizirati dodavanjem padajućeg izbornika za odabir smjene, odnosno odgovorne osobe, već postojećem dodirnom zaslonu. S obzirom na to da na završnoj obradi nema čitača barkodova i ovaj prijedlog tamo nije primjenjiv, uzima se u obzir mogućnost da se na jednom mjestu unose relevantni podaci za cijelu smjenu i za sve radne operacije. Kod DESMA proizvodne linije, prvo je mjesto očitavanja barkoda međukontrola, a iduće je testiranje kliještima. Na mjestu testiranja kliještima moglo bi se, jednom dnevno, unijeti relevantne podatke za tu smjenu te za sve radne operacije do završne kontrole, te bi barkod svakog proizvoda, osim trenutnih podataka, sadržavao i podatke o osobama odgovornim za pojedine proizvodne procese. Time bi se dokumenti u fizičkom obliku transformirali u digitalni, što

rezultira uštedom vremena i jednostavnijim prijenosom podataka i informacija do Odjela osiguranja kvalitete, koji iste podatke svakodnevno koristi.

4.2.10. Dijagram toka procesa izrade đonova i cvikanja

U proizvodnom pogonu H4 odvijaju se postupci izrade đonova, odnosno kalupljenja te cvikanja. Dijagram prikazuje oba postupka jer dijele korak – dostavljanje podataka Odjelu osiguranja kvalitete koji te podatke koristi za izradu statistike.



Slika 18. Dijagram toka procesa izrade đonova i cvikanja [izrada autorice]

4.2.10.1. Opis dijagrama

Kod procesa izrade đonova, škart se na svakoj proizvodnoj operaciji odvaja u za to predviđene sanduke. Škart se broji i bilježi ručno te se na kraju smjene podaci dostavljaju Odjelu osiguranja kvalitete.

U procesu cvikanja, na završnoj kontroli, postoji implementiran barkod čitač. Međutim, samo se dio proizvoda koji moraju proći proces reparature očitava barkod čitačem. To su oni

proizvodi koji prolaze proces reparature u proizvodnom pogonu H3, odnosno u šivaoni. Sve one reparature koje se izvršavaju na istoj liniji, u procesu cvikanja, bilježe se ručno te se tablica s podacima dostavlja Odjelu osiguranja kvalitete koji te podatke koristi za praćenje statistike u Excelu.

4.2.10.2. Prijedlog poboljšanja

Poželjno je implementirati sustav za automatsko brojanje škarta sa stroja za izradu đonova. Takav sustav zahtijeva mnogo vremena za izradu i implementaciju, pogotovo ako je riječ o automatizaciji procesa brojanja. Uobičajene metode uključuju vage za brojanje komada ili različite senzore koji omogućuju brojanje bez utjecaja ljudskog faktora. Brojanje škarta na kraju svake smjene oduzima mnogo vremena, a i način prijenosa podatka do Odjela osiguranja kvalitete zahtijeva poboljšanje. Naime, slanje elektroničke pošte s informacijama o broju komada usporava proces izrade izvještaja i u Odjelu osiguranja kvalitete. Sustav bi trebao imati mogućnost unosa škarta direktno u ERP sustav, kako bi Odjel osiguranja kvalitete dohvatio te podatke direktno iz sustava, zajedno sa svim drugim podacima koje je moguće dohvatiti iz sustava.

Što se tiče završne kontrole u procesu cvikanja, samo se dio proizvoda s greškom evidentira i ulazi izravno u ERP sustav. S obzirom na to da na tom mjestu već postoji barkod čitač, poželjno je već postojećom metodom evidentirati i one reparature koje ostaju na istoj proizvodnoj liniji, odnosno lokalizirane u proizvodnom pogonu H4. Razlog tome je potencijalno donošenje krivih zaključaka iz dostupnih podataka jer se samo dio reparatura bilježi u ERP sustavu.

Kao što će biti prikazano u idućem poglavlju vezanom za ključne pokazatelje uspješnosti, vrlo je bitno pratiti i elektronički bilježiti sve korake procesa, posebice kada je riječ o reparaturama. Razlog tomu je praćenje kvalitete, koja je prioritet tvrtke HAIX d.o.o. Kako bi se donosile odluke utemeljene na točnim informacijama, te informacije moraju se zasnivati na velikoj količini točnih podataka o broju proizvedenih pari obuće, broju proizvoda koji nisu zadovoljili kvalitetu iz prvog pokušaja te o tome koji su najčešći uzroci nedostataka proizvoda koji ne zadovoljavaju zahtjeve, ali i gdje uzroci nastaju.

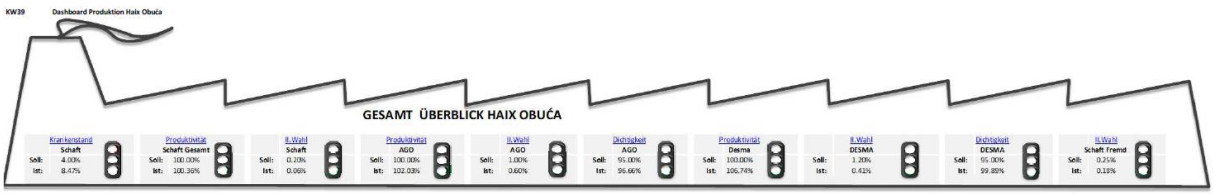
5. Ključni pokazatelji uspješnosti

Pokazatelj uspješnosti ili ključni pokazatelj uspješnosti (KPI) pojam je koji industrija koristi za kvantificiranu procjenu ili mjeru izvedbe. Organizacije uobičajeno koriste KPI-jeve za procjenu cjelokupnog uspjeha ili uspjeha postignutog ulaganjem napora pojedinca.

Iako se definira kao napredak prema očekivanim ciljevima, uspjeh često znači ponavljano postizanje određene razine operativnog cilja. Zaposlenicima postaje sve važnije postavljanje strateških ciljeva te je zbog toga odabir ispravnih KPI-jeva izravno ovisan o razumijevanju onoga što je važno za organizaciju [8].

5.1. Ključni pokazatelji uspješnosti – HAIX obuća d.o.o.

Tvrtka HAIX obuća d.o.o. trenutno koristi nadzorne ploče (engl. *dashboards*) kao glavni alat za praćenje poslovanja (slika 19). Nadzorne se ploče često sastoje od različitih tehnika vizualizacije podataka. Među njima su ključni pokazatelji uspješnosti koji igraju presudnu ulogu u brzom pružanju točnih informacija uspoređujući trenutnu izvedbu s vrijednostima potrebnim za ispunjenje poslovnih ciljeva.



Slika 19. Nadzorna ploča tvrtke HAIX obuća d.o.o.

U tvrtki HAIX obuća d.o.o. ključni pokazatelji uspješnosti koji se svakodnevno prate pomoću nadzornih ploča su sljedeći:

1. Produktivnost [%]
2. Vodonepropusnost [%]
3. Proizvodi druge klase [%]
4. Bolovanje [%]
5. Broj dnevno proizvedenih pari obuće [kom]
6. Škart [%]

Pokazatelji uspješnosti ključni su za mjerenje i poboljšanje izvedbe proizvodnog procesa. Za razvoj strategija poboljšanja izvedbe procesa i ostvarenje definiranih ciljeva neophodno je shvaćanje odnosa između svih KPI-jeva dodijeljenih ciljanom proizvodnom procesu. Međutim, KPI-jevi nisu uvijek jasno definirani i ponekad je teško pronaći odgovarajući KPI koji je moguće povezati sa svakim poslovnim ciljem.

Tvrtke koje usvajaju inovacije, poput HAIX obuće d.o.o., često pretpostavljaju da će ulaganja u inovacije dovesti do poboljšanja produktivnosti ili efikasnosti. Međutim, ulaganje u inovacije ne jamči učinkovitu implementaciju istih. Prethodna istraživanja pokazala su da usvojene inovacije poput uvođenja *Lean* proizvodnje, ERP-a ili CRM-a često ne uspijevaju uspješno završiti fazu implementacije, što ne rezultira očekivanim poboljšanjima. Uloženi napor pri provedbi implementacije određene inovacije neophodno je pratiti i mjeriti. To je od velike važnosti jer omogućava pojedincima i skupinama da procijene stanje vlastite organizacije u odnosu na svoje konkurente. Uz to, procjena učinkovitosti implementiranih inovacija pruža mogućnost pravovremenog prepoznavanja problema i poduzimanja potrebnih mjera. Da bi bile uspješne u današnjem svjetskom konkurentskom okruženju, organizacije moraju biti sposobne zabilježiti objektivnu izvedbu, primjerice jedinični trošak i dobit, ali i subjektivnu izvedbu poput kvalitete i zadovoljstva korisnika [9].

5.1.1. Produktivnost

Međunarodna organizacija rada, ILO, definira produktivnost kao omjer izlaza (engl. *outputa*) dobivenog proizvodnjom i odgovarajućeg uloženog rada (engl. *inputa*). Produktivnost se može izračunati i izraziti kao omjer prosječne proizvodnje u razdoblju i ukupnih troškova nastalih kroz različite resurse – rad, ulazni materijal, potrošni materijal, iskorištenu snagu, kapital, energiju, materijal, osoblje – potrošene u tom razdoblju. U industriji se često događa da organizacije, ovisno o mogućnostima, prilagođavaju jednadžbu za izračun produktivnosti vlastitim potrebama. Razlog tomu su različita mjerila koja industrije imaju te ostali čimbenici koji utječu na izračun produktivnosti [10]:

1. Konstruiranje proizvoda – konstruiranje je vrlo bitan čimbenik za uspjeh organizacije jer u velikoj mjeri utječe na produktivnost radnika. Proizvod mora odgovarati raspoloživim materijalima i biti u skladu s njihovom vrstom, specifikacijama i prirodom, kao i strojevima i ostalom opremom u proizvodnom pogonu.

2. Hodogrami proizvodnih procesa – radnici u proizvodnom pogonu često dobivaju nejasne proizvodne upute. Upute ne sadrže dovoljno detaljan opis procesa, odgovarajuće fotografije ili tehničke crteže, odgovarajuću metodu i potreban alat. Osim spomenutog, na produktivnost često utječu i naizgled trivijalni čimbenici poput šablona ili učvršćenja za pomoć pri radu. Detaljan i pojednostavljen hodogram proizvodnog procesa uvelike olakšava radnicima razumijevanje proizvodnog procesa, što izravno utječe na produktivnost.
3. Dostupni strojevi i ostala oprema – radnici u proizvodnom pogonu često su ograničeni raspoloživim strojevima i opremom. Stanje strojeva i opreme može imati veliki utjecaj na točnost i ostale značajke koje je potrebno zadovoljiti u procesu proizvodnje. Ovisno o tome, postoji mogućnost da strojevi ne rade u skladu s parametrima određenim proizvodnim nalogom, što rezultira proizvodima koji ne zadovoljavaju potrebne specifikacije i otežanom standardizacijom proizvodnog procesa.
4. Planiranje – postupkom planiranja prioritiziraju se poslovi, proizvodni procesi i resursi. Učinkovito planiranje ključno je za osiguravanje dostupnosti prave komponente i u pravo vrijeme pri izvršavanju određenog proizvodnog procesa. Osim spomenutog, planiranjem se osigurava da pravi ljudi izvršavaju ispravni zadatak u pravo vrijeme i na pravom mjestu. Planiranjem se smanjuje prazni hod svih resursa u organizaciji.
5. Ažuriranje tehnologije i automatizacija – nove tehnologije u proizvodnim pogonima podrazumijevaju uvođenje CNC strojeva, automatizirane mjenjače paleta (APC), automatizirane sustave za mjerenje procesa, razne senzorske uređaje, automatski navođena vozila (AGV), razvoj robotike i ostalo.

   Integrirana automatizacija podrazumijeva praćenje i upravljanje cjelokupnim procesom podržano središnjim računalom te upotrebu ERP sustava. Automatizacija smanjuje potrebu za ručnim radom ili ručnim prikupljanjem podataka, uklanja ponavljane zadatke, smanjuje troškove proizvodnje, uz istovremeno povećanje kvalitete proizvoda. Automatizacija također pruža dovoljno podataka o strojevima i ostalim čimbenicima procesa, što omogućava organizaciji da analizira čimbenike koji utječu na produktivnost. No, svaka je industrija jedinstvena i nije uvijek jednostavno implementirati sustav za automatsko praćenje proizvodnog procesa koji je u potpunoj interakciji s ERP sustavom i pomoću kojeg se na jednostavan način mogu pratiti i analizirati čimbenici koji utječu na glavne pokazatelje uspješnosti organizacije.

Osim spomenutih, na produktivnost utječe i mnogo drugih čimbenika. Neki od njih su norme, nedostatak materijala ili potrebnih alata, radno vrijeme te nedostatak podrške i komunikacija s onim, višim hijerarhijskim razinama koje svoje glavne funkcije ne obavljaju u proizvodnom pogonu, već u uredima.

HAIX obuća d.o.o. računa produktivnost prema sljedećoj formuli:

$$\text{Produktivnost [\%]} = \frac{\text{broj proizvedenih pari obuće [kom]} \cdot \text{norma [min]}}{\text{broj prisutnih radnika u smjeni [kom]} \cdot 450\ \text{[min]}} \cdot 100,$$

pri čemu je norma izražena u minutama, kao i radno vrijeme radnika koje iznosi 450 minuta. Radno vrijeme dobiveno je kao razlika trajanje jedne smjene i stanke za odmor u trajanju od 30 minuta:

$$\text{Radno vrijeme [min]} = 8 \cdot 60 - 30 = 480 - 30 = 450.$$

Osim produktivnosti, i u literaturi i u praksi često se spominje pojam efikasnosti, odnosno efektivnosti. U nastavku je objašnjena osnovna razlika između ta tri pojma te važnost svakog od njih za organizacije u proizvodnoj industriji.

5.1.1.1. Razlika između produktivnosti, efektivnosti i efikasnosti

Organizacijska efikasnost definira se kao interni standard izvedbe. U literaturi se često spominje kako efikasnost znači *činiti stvari ispravno* te se odnosi na troškovnu prednost. Dakle, efikasnost se odnosi na izvedbu i funkcioniranje određenog procesa na najbolji mogući način, uz minimalne gubitke i uloženi napor. Za razliku od efikasnosti, efektivnost znaci *činiti prave stvari* te se orijentira prema kupcu. To znači da se efektivnost odnosi na proces koji adekvatno izvršava svoju ulogu te daje planirani, odnosno očekivani rezultat.

Prema tome, poboljšanje efikasnosti može se postići metodologijama poput JIT-a (engl. *Just-In-Time*), dok se efektivnost unaprjeđuje istraživanjem tržišta i uvažavanjem kupčevih zahtjeva [11].

Općenito se produktivnost izražava kao omjer izlaza i ulaza (engl. *outputa* i *inputa*), a razlikuje se od pojma efikasnosti. Efikasnost je uži pojam i odnosi se na izvedbu pojedinog segmenta proizvodnje. Produktivnost se definira u širem smislu, kao mjera efikasnosti proizvodnog sustava [12].

Drugim riječima, produktivnost govori o tome koliko je proces uspješan u davanju rezultata, a efikasnost o tome da se određeni proces obavlja *pametnije*, a ne brže. Primjerice, ako se unaprjeđenjem procesa koji inače traje 40 minuta isti uspije odviti unutar 30, povećala se efikasnost tog procesa. Pritom je neophodno spomenuti i kvalitetu jer, ako smo ubrzali proces i time smanjili kvalitetu, ušteda vremena dugoročno nema smisla, već će se negativno odraziti na organizaciju.

5.2. Prijedlog implementacije ključnih pokazatelja uspješnosti

Kao što je vidljivo sa slika 2 i 3, tvrtka HAIX obuća d.o.o. bilježi iznimno veliki rast prihoda i zaposlenika po godinama. Često se događa da se organizacija vrlo brzo razvija i raste zbog implementiranih inovacija, no tradicionalna mjerenja ne uspijevaju ispravno zabilježiti taj rast zbog nekompatibilnosti s tehnološki naprednijim (proizvodnim) sustavima. U tvrtki HAIX obuća d.o.o. glavni pokazatelji koji se svakodnevno prate su prvenstveno produktivnost i vodonepropusnost, koja je izravno povezana s kvalitetom proizvoda.

Prikupljanjem velikih količina podataka, naglasak se sve više stavlja na kvalitetu. Razlog tomu je njena važnost za poslovanje organizacije jer se kvaliteta više ne svodi samo na identifikaciju onih proizvoda koji ne zadovoljavaju unaprijed definirane standarde. Podaci koji se prikupljaju i analiziraju u različitim odjelima tvrtke potvrđuju da određena razina kvalitete znači konkurentsku prednost za organizaciju. Svrha operativnih uloga organizacije jest prepoznati i izmjeriti vrijeme potrošeno na reparacije proizvoda, povrate, škart i ostale aktivnosti koje ne dodaju vrijednost proizvodu, već predstavljaju gubitke koje je neophodno eliminirati. Ključno je naglasiti da se do rješenja problema s kojima se organizacija susreće dolazi isključivo njihovom suradnjom s ostalim odjelima – od kontrole kvalitete do ljudskih resursa. Uspjeh poslovnih odluka ili projekata, dakle, ovisi i postiže se sinergijom svih odjela, ali i razina organizacije.

HAIX obuća d.o.o. pripada projektnoj organizaciji, odnosno organizaciji koja projektni menadžment definira kao organizacijsku strategiju [13]. To potvrđuje i činjenica da postoji Odjel projektnog menadžmenta koji razvija portfolio različitim vrstama projekata i ima specifične i stalne projektno orijentirane strukture. Dakle, organizacije koje se temelje na projektima su one u kojima je izvršavanje projekata način poslovanja.

U nastavku slijede prijedlozi ključnih pokazatelja uspješnosti na temelju analize vrste, industrije kojoj pripada te podataka koji su prikupljani u tvrtki HAIX obuća d.o.o.

5.2.1. Ukupna učinkovitost opreme

Ukupna učinkovitost opreme (engl. *Overall Equipment Effectiveness*) je kvantitativna metrika proizašla 1980-ih godina iz koncepta totalnog produktivnog održavanja (engl. *Total Productive Maintenance*). Svrha ukupne učinkovitosti opreme je mjerenje produktivnosti opreme u proizvodnom pogonu identifikacijom i mjerenjem gubitaka važnih aspekata proizvodnje – dostupnosti, izvedbe i kvalitete. Koncept ukupne učinkovitosti opreme široko je rasprostranjeni kvantitativni alat za mjerenje produktivnosti [12].

Osnovna jednadžba za izračun ukupne učinkovitosti opreme jest:

$$\text{ukupna učinkovitost opreme [\%]} = \text{dostupnost} \cdot \text{izvedba} \cdot \text{kvaliteta}$$

Pojmovi dostupnosti, izvedbe i kvalitete pobliže su objašnjeni u nastavku.

5.2.1.1. Dostupnost

Dostupnost podrazumijeva sve događaje koji zaustavljaju planiranu proizvodnju dovoljno dugo da ima utjecaja na proizvodnju te je potrebno zabilježiti razlog zastoja. Uobičajeno je to nekoliko minuta.

$$\text{dostupnost} = \frac{\text{operativno vrijeme [min]}}{\text{planirano vrijeme proizvodnje [min]}}$$

Operativno vrijeme podrazumijeva planirano vrijeme proizvodnje umanjeno za trajanje zastoja. Planirano vrijeme proizvodnje podrazumijeva vrijeme trajanja smjene umanjeno za unaprijed definirane stanke.

$$\text{operativno vrijeme [min]} = \text{planirano vrijeme proizvodnje [min]} - \text{vrijeme stajanja [min]}$$

5.2.1.2. Izvedba

Izvedba podrazumijeva sve ono što uzrokuje da se proizvodni postupak izvodi na manjoj od najveće moguće brzine, uključujući i spore cikluse i kraća zaustavljanja.

$$\text{izvedba} = \frac{\text{idealni proizvodni ciklus } \left[\frac{\text{min}}{\text{kom}}\right] \cdot \text{ukupni broj proizvedenih proizvoda [kom]}}{\text{operativno vrijeme [min]}} \cdot 100\ \%$$

5.2.1.3. Kvaliteta

Kvaliteta podrazumijeva sve proizvedene komade umanjene za broj komada koji ne udovoljavaju standardima kvalitete, uključujući i one dijelove koji trebaju proći postupak reparature.

$$\text{kvaliteta} = \frac{\text{broj proizvoda koji zadovoljavaju standarde kvalitete [kom]}}{\text{ukupni broj proizvedenih proizvoda [kom]}} \cdot 100\ \%$$

5.2.2. First Pass Yield

Metrika *dobrih proizvoda iz prvog pokušaja,* engl. *First Pass Yield*, iznimno je važan pokazatelj kvalitete te izvedbe određenog proizvodnog procesa. FPY se dobiva dijeljenjem onih proizvoda koji zadovoljavaju standarde kvalitete u prvom prolazu kroz proizvodni proces s ukupnim brojem proizvedenih jedinica:

$$\text{FPY} = \frac{\text{proizvodi koji zadovoljavaju standarde kvalitete u prvom prolazu kroz proces [kom]}}{\text{ukupni broj proizvedenih proizvoda [kom]}} \cdot 100\ \%$$

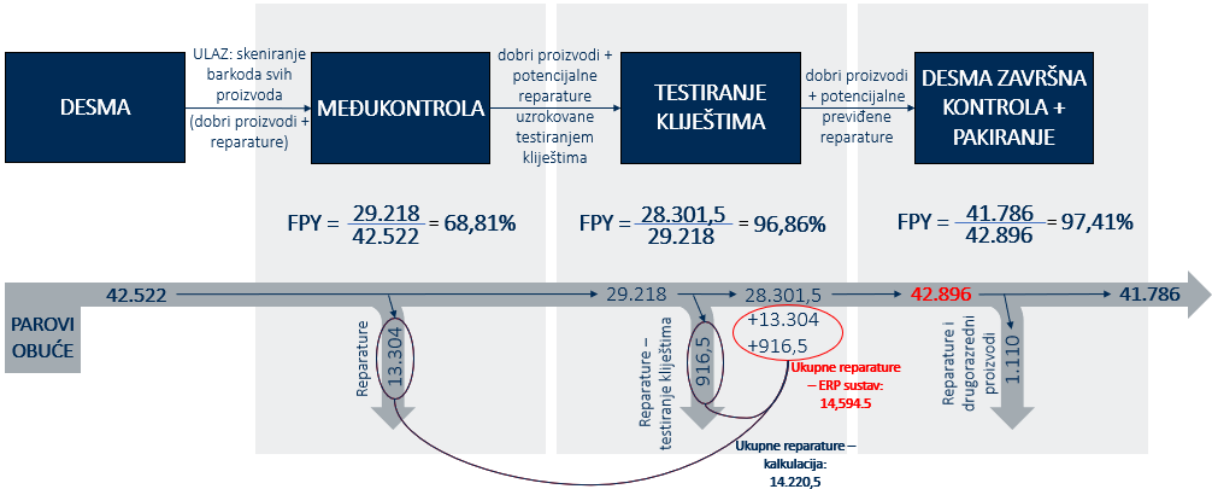
U praksi se FPY najčešće mjeri za pojedinu aktivnost u proizvodnom pogonu. Ukupni FPY računa se množenjem pojedinačnih vrijednosti, što može pokazivati zabrinjavajuće rezultate. Zbog toga je prije implementacije određenog pokazatelja uspješnosti neophodno u potpunosti razumjeti njegovo značenje te način izračuna. Primjerice, komponenta koja prolazi postupak obrade koji se sastoji od deset operacija može pokazivati ukupni FPY od 73 %, dok istovremeno pojedinačni FPY-jevi iznose 98 %, 95 %, 99 %, 98 %, 96 %, 94 %, 99 %, 99 %, 97 % i 94 %. Prema tome, više od četvrtine proizvoda koji prolaze spomenutu obradu predstavlja otpad ili prolazi kroz postupak reparature [14].

5.2.2.1. Primjer izračuna FPY-ja u tvrtki HAIX obuća d.o.o.

Prilikom boravka u tvrtki HAIX obuća d.o.o., provedena je detaljna analiza svih proizvodnih procesa koji se odvijaju u proizvodnim pogonima. Pritom je odabran jedan od procesa za izračun jednog od predloženih ključnih pokazatelja uspješnosti – *First Pass Yield*.

Riječ je o proizvodnom procesu koji započinje brizganjem đonova na gornjišta obuće na DESMA strojevima. Slika 20 prikazuje shematski prikaz izračuna FPY-ja za spomenuti proizvodni proces. Po završetku ove operacije, svi proizvodi prolaze postupak međukontrole, gdje se očitavaju barkodovi. To podrazumijeva sve one proizvode koji zadovoljavaju standarde

kvalitete, ali i one koji trebaju proći postupak reparature zbog određenih grešaka nastalih brizganjem ili nekom drugom operacijom u proizvodnom procesu.



Slika 20. Shematski prikaz izračuna FPY-ja za DESMA proizvodni proces [izrada autorice]

Iz ERP sustava dobiven je broj svih spomenutih proizvoda koji predstavljaju ulaz u postupak međukontrole – 42.522 para obuće. Od 42.522 para, na 13.304 para identificirana je greška te su ti proizvodi preusmjereni na postupak reparature (slika 20).

Uzevši to u obzir, izračunat je FPY za operaciju međukontrole na temelju sheme sa slike 20 te jednadžbe iz poglavlja 5.2.2.:

$$\text{dobri proizvodi}_{\text{MK}}\,[\text{kom}] = \text{ukupan broj proizvoda} - \text{reparature}$$

$$\text{dobri proizvodi}_{\text{MK}} = 42.522 - 13.304 = 29.218$$

$$\text{FPY}_{\text{MK}} = \frac{29.218}{42.522} = 68{,}81\ \%$$

S obzirom na to da je dio proizvoda preusmjeren na postupak reparature, može se zaključiti da samo dobri proizvodi (29.218) nastavljaju svoje kretanje kroz glavni proizvodni proces do iduće operacije – testiranja kliještima. Međutim, oni proizvodi koji se smatraju dobrima u procesu međukontrole nisu nužno dobri i iz aspekta operacije testiranja kliještima. Razlog tome je taj što se pri izvođenju testiranja kliještima identificira nova vrsta greške koja postaje vidljiva tek nakon što se provede testiranje. Dakle, ulaz u ovu operaciju su svi dobri proizvodi koji predstavljaju izlaz iz međukontrole, no kao ulaz u operaciju testiranja kliještima obuhvaćaju

dobre proizvode te one s potencijalnom greškom koji neće proći testiranje. Iz ERP sustava dobiven je broj pari obuće koji nisu uspješno prošli postupak testiranja kliještima, a na temelju istog izračunat je i broj dobrih proizvoda koji predstavljaju izlaz iz operacije testiranja kliještima. Analogno postupku međukontrole, izračunat je FPY za operaciju testiranja kliještima, prema jednadžbi iz poglavlja 5.2.2.:

$$\text{dobri proizvodi}_{\text{TK}}\ [\text{kom}] = \text{izlaz}_{\text{MK}} - \text{proizvodi koji nisu prošli testiranje kliještima}$$

$$\text{dobri proizvodi}_{\text{TK}} = 29.218 - 916.5 = 28.301{,}5$$

$$\text{FPY}_{\text{TK}} = \frac{28.301{,}5}{29.218} = 96{,}86\ \%$$

Preostalo je još izračunati FPY za konačnu operaciju, odnosno završnu kontrolu i pakiranje proizvoda. Treba napomenuti kako se pri ovoj operaciji ponovno skeniraju svi proizvodi: ukupan broj dobrih proizvoda spremnih za pakiranje i isporuku, oni koji i dalje posjeduju određenu grešku previđenu u ranijim koracima procesa te svi oni identificirani postupcima međukontrole i testiranja kliještima koji su prošli postupak reparature te se vratili u glavni proizvodni proces.

Analogno ranijim izračunima, prema formuli iz poglavlja 5.5.2. izračunat je FPY za postupak završne kontrole i pakiranja proizvoda:

$$\text{dobri proizvodi}_{\text{ZK}}\ [\text{kom}] = \text{izlaz}^{*}_{\text{TK}} - (\text{reparature} + \text{drugorazredni proizvodi})$$

$\text{izlaz}^{*}_{\text{TK}}$ - zbroj svih dobrih komada koji su izašli iz procesa testiranja kliještima i obavljenih reparatura vraćenih u proces, odnosno reparatura s prijašnjih operacija međukontrole te testiranja kliještima

$$\text{dobri proizvodi}_{\text{ZK}} = 42.896 - 1.110 = 41.786$$

$$\text{FPY}_{\text{ZK}} = \frac{41.786}{42.896} = 97{,}41\ \%$$

Na temelju dobivenih rezultata, može se izračunati ukupni *First Pass Yield* cijelog proizvodnog procesa. Kako je ranije spomenuto, ukupni se FPY cjelokupnog procesa dobiva množenjem zasebnih vrijednosti za svaku od operacija od kojih se proces sastoji:

$$\text{FPY}_{\text{UK}} = \text{FPY}_{\text{MK}} \cdot \text{FPY}_{\text{TK}} \cdot \text{FPY}_{\text{ZK}}$$

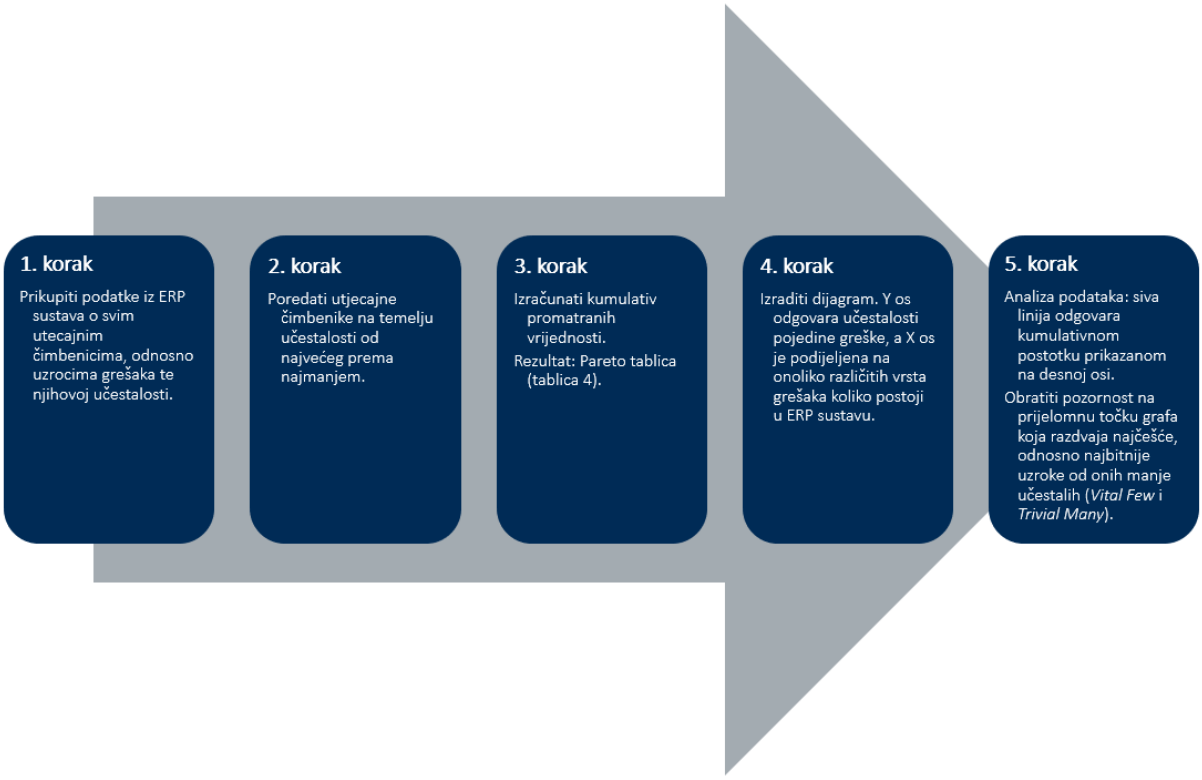
$$\mathrm{FPY_{UK}} = 68{,}81 \cdot 96{,}86 \cdot 97{,}41 = 64{,}92\ \%,$$

pri čemu je MK međukontrola, TK testiranje kliještima, a ZK završna kontrola.

5.2.2.2. Pareto dijagram

Pareto dijagram je stupčasti dijagram čiji stupci, odnosno njihove duljine, najčešće predstavljaju troškove, vrijeme, greške, gubitke ili povratne informacije kupaca. S obzirom na to da je riječ o analizi i prikazu podataka, za uspješno korištenje Pareto dijagrama neophodno je koristiti činjenice, a ne pretpostavke osoba uključenih u analizu. Pretpostavke mogu djelovati kontraproduktivno, što dovodi do dijagrama koji u konačnici daje nepouzdane i netočne rezultate. Također, neophodno je koristiti iste mjere i održavati konzistenciju za sve čimbenike koji utječu na promatrani proces jer je Pareto dijagram tehnika usporedbe podataka. Zbog toga se na jednom Pareto dijagramu prikazuju isključivo podaci vezani za jedan proces te njegove pripadajuće vrijednosti koje se analiziraju u okviru promatranog problema [15].

Pareto dijagram izrađen je prema hodogramu sa slike 21.

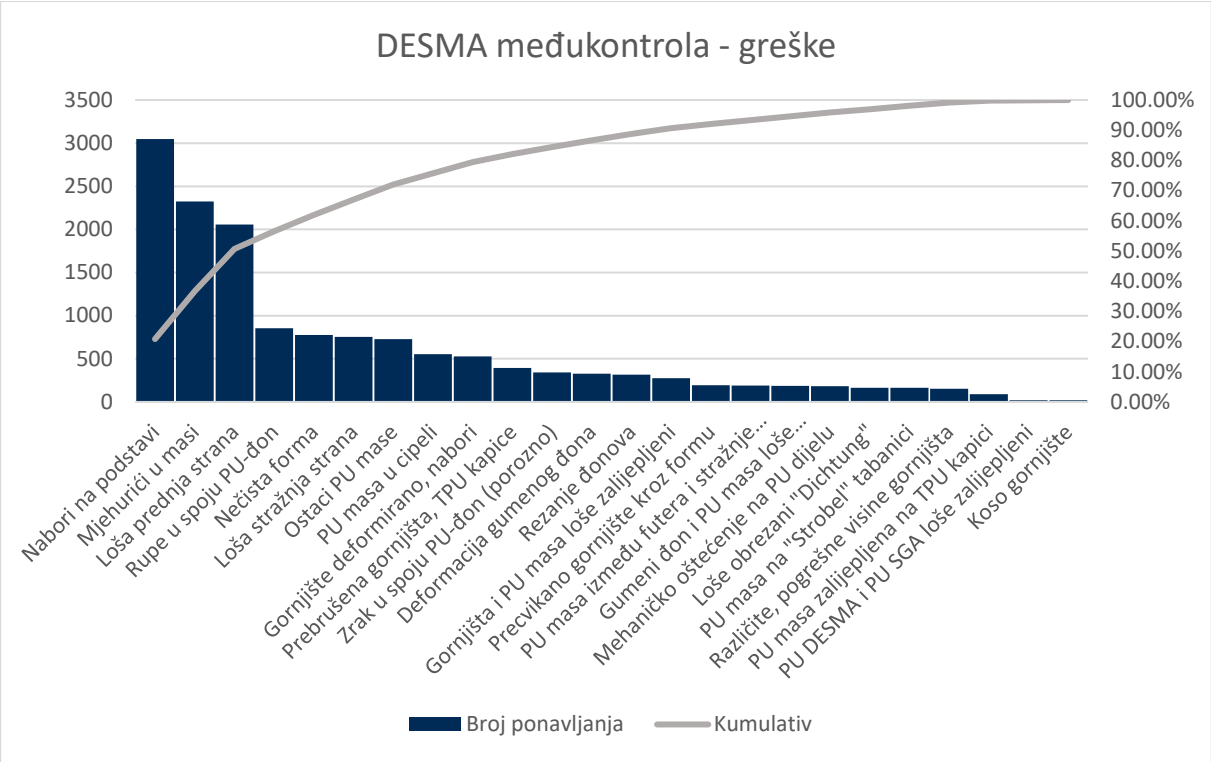


Slika 21. Hodogram za izradu Pareto dijagrama [izrada autorice]

Tablica 4. Pareto tablica [izrada autorice]

Greška	Broj ponavljanja	Kumulativ
Nabori na podstavi	3049	20.83 %
Mjehurići u masi	2324	36.71 %
Loša prednja strana	2055	50.75 %
Rupe u spoju PU-đon	853	56.58 %
Nečista forma	778	61.89 %
Loša stražnja strana	753	67.04 %
Ostaci PU mase	728	72.01 %
PU masa u cipeli	552	75.78 %
Gornjište deformirano, nabori	528	79.39 %
Prebrušena gornjišta, TPU kapice	395	82.09 %
Zrak u spoju PU-đon (porozno)	343	84.43 %
Deformacija gumenog đona	327	86.66 %
Rezanje đonova	315	88.82 %
Gornjišta i PU masa loše zalijepljeni	276	90.70 %
Precvikano gornjište kroz formu	193	92.02 %
PU masa između futera i stražnje kapice	189	93.31 %
Gumeni đon i PU masa loše zalijepljeni	186	94.58 %
Mehaničko oštećenje na PU dijelu	182	95.83 %
Loše obrezani *Dichtung*	165	96.95 %
PU masa na *Strobel* tabanici	165	98.08 %
Različite, pogrešne visine gornjišta	154	99.13 %
PU masa zalijepljena na TPU kapici	90	99.75 %
PU DESMA i PU SGA loše zalijepljeni	19	99.88 %
Koso gornjište	18	100.00 %

Svrha izrade Pareto dijagrama u okviru ovog rada jest prikazati najčešće greške proizvoda koji se izrađuju na DESMA liniji čiji je pripadajući ključni pokazatelj uspješnosti izračunat u prethodnom poglavlju. S obzirom na ukupni *First Pass Yield* od 64,2 %, neophodno je razmotriti najčešće uzroke reparatura na spomenutoj proizvodnoj liniji. Također, s obzirom na to da je FPY najniži za prvu promatranu operaciju, odnosno postupak međukontrole, Pareto dijagramom moguće je potvrditi da većina grešaka identificiranih postupkom međukontrole uistinu nastaje u prvom koraku procesa – brizganjem đonova obuće na gornjišta.



Slika 22. Pareto dijagram [izrada autorice]

Kao što je ranije spomenuto, Pareto dijagramom potvrđeno je da najveći broj grešaka nastaje prvom operacijom na DESMA liniji, odnosno brizganjem donjišta na gornjišta obuće. Razlog tome su čimbenici koji utječu na proizvodnu operaciju, a ne uključuju ljudski faktor. Prema podacima dohvaćenim iz ERP sustava, najčešća greška koja se javlja su nabori na parima obuće. Razlog tome je operacija brizganja pri kojoj se obuća stavlja na kalupe, pri čemu se materijal zagrijava, što negativno utječe na konačni proizvod. Nadalje, druga po redu najčešća greška su mjehurići u masi koja se brizga na gornjišta. To je također rezultat proizvodnog procesa, odnosno materijala koji se koristi pri brizganju. Treća najčešća greška je neispravna prednja strana, što nastaje u prethodnim fazama proizvodnog procesa, a postaje vidljiva tek kada se donjište brizga na gornjište.

Pareto dijagramom opravdan je FPY operacije međukontrole izračunat u prethodnom poglavlju, a iznosi 64,2 %. Nakon operacije brizganja slijedi prvo prikupljanje podataka u DESMA proizvodnom procesu te je očekivano da će se upravo na tom mjestu identificirati najviše grešaka na proizvodima. Većina grešaka koje se pojavljuju ne nastaju utjecajem ljudskog faktora, već proizvodnim procesom čiji parametri mogu imati negativan utjecaj na konačni proizvod. Također, u kompleksnim proizvodnim procesima poput ovog, većina je procesnih

operacija međuovisna te se često tek u kasnijim fazama procesa mogu identificirati greške nastale u ranijim koracima. To je veliki problem jer se rasipaju dostupni resursi, prvenstveno vrijeme, na izradu proizvoda koji se tek naknadno pokažu neispravnima. Rješenje ovog problema jest intenzivnija kontrola kvalitete proizvoda u svim koracima proizvodnog procesa te davanje dodatnih uputa zaposlenicima kako bi se unaprijed spriječile potencijalne greške. Također, potrebno je razmotriti jesu li svi parametri proizvodnog procesa postavljeni u skladu sa zahtjevima jer se može dogoditi da se s vremenom isti promijene, a uz neadekvatno i nedovoljno često održavanje, taj je čimbenik često zanemaren.

6. Analiza rezultata

Prilozi 1, 2 i 3 detaljno prikazuju rezultat dobiven primjenom metodologije toplinskog mapiranja procesa na proizvodni proces tvrtke HAIX obuća d.o.o. Za izradu toplinske mape korišten je AutoCAD softver za računalno potpomognuto oblikovanje i konstruiranje.

Izradom toplinske mape procesa potvrđeno je kako je vizualizacija procesa prikupljanja podataka ključna za razumijevanje njihovog toka. Riječ je o jednom od najjasnijih načina prijenosa informacija na zaposlenike svih razina organizacijske hijerarhije. To je od velike važnosti jer se u razvijenim organizacijskim strukturama koje bilježe brzi rast, poput HAIX obuće d.o.o., često gube informacije u njihovom prijenosu te je vertikalna komunikacija često nepotpuna, netočna ili nejasna.

Prateći unaprijed definiranu ljestvicu evaluacije toka informacija (tablica 3), jasno je kojim je tokovima podataka u pojedinom proizvodnom pogonu potrebno posvetiti pažnju, što je i glavna svrha ovog prikaza. U svrhu što preciznije analize rezultata, ključno je naglasiti da se neophodno koristiti svim smjernicama iz poglavlja 3.2., odnosno 4.1. Dakle, neophodno je u potpunosti razumjeti obje metodologije jer bi u suprotnom dobiveni zaključci bili utemeljeni na nepotpunim podacima, što može dovesti do donošenja krivih odluka potencijalno štetnih za organizaciju.

Bitno je naglasiti da svrha ovog rada nije uobičajena primjena metoda za optimizaciju i unaprjeđenje određenog proizvodnog procesa, već pružanje alata koji pomažu identificirati procese koji zahtijevaju unaprjeđenje. Precizna evaluacija problema i njihovog značaja u ranim fazama projekata poput *Lean Six Sigma* ili kontinuiranog poboljšanja ključna je kako bi se izbjegao trošak resursa na problem koji nije prioritet u određenom trenutku.

S obzirom na to da je HAIX obuća d.o.o. projektno orijentirana organizacija, alati spomenuti u ovom radu imaju veliki značaj za prioritizaciju projekata unaprjeđenja proizvodnih procesa jer na jednostavan način predstavljaju procese na koje bi se tvrtka trebala usredotočiti te njihov redoslijed. Također, tvrtka je u velikoj mjeri orijentirana na implementaciju metoda kontinuiranog poboljšanja te *Lean Six Sigma* alata, pri čemu alati poput toplinskog mapiranja procesa te dijagrama toka procesa imaju veliki značaj zbog njihove srodnosti s načinom na koji su spomenuti projekti organizirani.

6.1. Procesi identificirani analizom toplinske mape i dijagrama toka procesa

U svrhu identifikacije procesa koji ne stvaraju dodanu vrijednost ili je ista ograničena, korišteni su alati predstavljeni ovim radom. Ljestvica evaluacije toka podataka (tablica 3) razvijena je kako bi na prvi pogled bilo očito koja područja zahtijevaju posebnu pažnju u odnosu na ostale dijelove proizvodnog pogona. U nastavku slijedi primjena predloženih metodologija na sva tri proizvodna pogona tvrtke HAIX obuća d.o.o.

6.1.1. Proizvodni pogon H2

Proizvodni pogon H2 prikazan je u prilogu 1. Prema ljestvici evaluacije toka informacija (tablica 3), prvi je korak pri analizi procesa identificirati područja označena plavom bojom jer ti dijelovi proizvodnog procesa ne stvaraju dodanu vrijednost. To podrazumijeva nepotpunu, netočnu ili nepotrebnu razmjenu podataka, a posljedično i informacija. Iz priloga 1 vidljiva su četiri takva područja. Nadalje, moguće je uočiti da svako od četiri spomenutih područja sadrži i referentnu oznaku (slika 6) s odgovarajućim brojem. To znači da postoji detaljno objašnjenje prikazano dijagramom toka procesa koje istaknuti problem razlaže na korake procesa. Pripadajući dijagram toka procesa za referentne oznake pod brojem 1 nalazi se u poglavlju 4.2.3., a prikazuje ga slika 10. Preostale referentne oznake u plavoj boji su pod brojevima 4 i 5, a njihovi pripadajući dijagrami toka procesa nalaze se u poglavljima 4.2.7. (slika 14) i 4.2.8. (slika 15).

Nadalje, u prilogu 1 vidljive su i referentne oznake u zelenoj boji, pod brojevima 1 i 3. Pripadajući dijagrami tih referentnih oznaka nalaze se u poglavljima 4.2.4. i 4.2.7.

Osim spomenutog, vidljive su i linije u bojama iz ljestvice evaluacije toka informacija. Te linije prate tok proizvodnog procesa te također naglašavaju potencijalna mjesta poboljšanja procesa. Zelene linije odnose se na tok procesa koji u određenoj mjeri ovisi o podacima koji se evidentiraju ručno, bilo da je riječ o zapisivanju podataka na papir ili slanju putem elektroničke pošte. Kao što je vidljivo iz priloga, na određenim proizvodnim linijama, uz zelenu, prevladava i žuta boja. Razlog tomu je implementirani podsustav za evidenciju podataka na tzv. AGO linijama proizvodnog pogona H2. Riječ je o elektroničkom načinu prikupljanja podataka i njihovoj razmjeni koja nije u stvarnom vremenu. Kada bi razmjena podataka bila u stvarnom vremenu, ne bi bilo potrebe za takvim podsustavom ili ljudskom intervencijom između izvršavanja proizvodne operacije te elektroničkog bilježenja relevantnog podatka. Primjer elektroničkog bilježenja podataka u stvarnom vremenu su sva mjesta u proizvodnim pogonima HAIX obuće d.o.o. gdje se izvršava očitavanje barkodova proizvoda. Ti se podaci učitavaju u

sustav te se mogu dohvatiti u bilo kojem trenutku, ne postoji posrednik između operacije očitavanja i unosa podatka u bazu podataka za daljnju analizu.

6.1.2. Proizvodni pogon H3

Proizvodni pogon H3 prikazan je u prilogu 2. Analogno poglavlju 6.1.1., redom se identificiraju područja potencijalnog unaprjeđenja prema ljestvici evaluacije toka informacija (tablica 3).

Riječ je o proizvodnom pogonu u kojem se obavljaju glavne operacije krojenja i šivanja. Ova toplinska mapa prikazuje četiri područja u plavoj boji te pripadajuće referentne oznake pod brojem 2. Dijagram toka procesa koji odgovara referentnim oznakama u plavoj boji iz priloga 2 prikazan je u poglavlju 4.2.5. te pobliže opisuje proizvodnu operaciju koja se na označenom mjestu izvršava bez dodavanja vrijednosti proizvodu.

Osim spomenutog, toplinska mapa prikazuje i referentnu oznaku u zelenoj boji. Odgovarajući je dijagram toka procesa opisan u poglavlju 4.2.5., na slici 11., a odnosi se na ručno prikupljanje te prijenos podataka i informacija.

Preostala je narančasta boja koja se nalazi na nekoliko mjesta toplinske mape proizvodnog pogona H3, a odnosi se na očitavanje barkodova proizvoda na mjestima završne kontrole. Kao što je ranije spomenuto, to su mjesta elektroničkog prikupljanja podataka u stvarnom vremenu. Organizacija treba težiti sustavima i inovacijama koje će omogućiti da takav način prikupljanja podataka prevladava u proizvodnom procesu.

6.1.3. Proizvodni pogon H4

Proizvodni pogon H4 prikazan je u prilogu 3. Metoda analize toplinske mape analogna je poglavljima 6.1.1. i 6.1.2. Prema ljestvici evaluacije toka informacije (tablica 3), prioritet je identifikacija plave boje na toplinskoj mapi, ako ista postoji. U prilogu 3 vidljiva je referentna oznaka plave boje pod brojem 3, a detaljno objašnjenje dano je u poglavlju 4.2.6. Objašnjenje je povezano s pripremom namijenjenom AGO liniji iz pogona H2.

Iz priloga je također vidljivo da prevladava zelena boja, što znači da je u velikoj mjeri prisutna pismena razmjena podataka i informacija putem dokumenata na papiru ili elektroničke pošte. Prisutna je i žuta boja, odnosno elektronička razmjena podataka i informacija koja nije u stvarnom vremenu. Razlog tomu je prisutnost čitača QR kodova na pojedinim radnim nalozima koji se kreću kroz proizvodni proces.

Poglavlje 4.2.10. također se odnosi na proizvodni pogon H4 te naglašava probleme prisutne u procesu prikupljanja podataka kroz proizvodni proces koji se odvija u spomenutom proizvodnom pogonu. Kao i kod ostalih procesa završne kontrole i pakiranja, proizvodi se očitavaju barkod čitačem te se podaci u stvarnom vremenu učitavaju u ERP sustav, što je prikazano narančastom bojom.

7. Zaključak

Uobičajene metode vizualizacije prikazane pregledom literature u ovom radu (poglavlje 3.1.) vrlo su korisne kada je riječ o prikazu protoka resursa u proizvodnom procesu. Međutim, njihovim korištenjem nije moguće eksplicitno prikazati protok podataka i informacija. Primjenom toplinskog mapiranja procesa te dijagrama toka procesa dokazano je da nedostajući, nepotpun ili neprikladan protok informacija ima veliki utjecaj na stvaranje gubitaka u proizvodnim procesima tvrtke HAIX obuća d.o.o. To posljedično produžuje i vrijeme proizvodnog ciklusa, s obzirom na to da se dostupni resursi ne iskorištavaju sukladno potrebama organizacije te se isti nepotrebno rasipaju.

Predstavljena metoda toplinskog mapiranja procesa prikazuje kako je moguće na sistematizirani, efikasan način vizualizirati i analizirati protok podataka i informacija u proizvodnom procesu. Kao i kod ostalih alata za unaprjeđenje i optimizaciju proizvodnih procesa, nastoji se pojednostaviti način njegovog korištenja kako bi isti bio jednoznačan i jasan svim razinama organizacije.

S obzirom na enormne količine podataka koji se svakodnevno prikupljaju, često se u organizacijama događa da se njihov potencijal ne iskorištava u dovoljnoj mjeri, što je utvrđeno i provedbom projekta prikazanog ovim radom. Tvrtka HAIX obuća d.o.o. ima implementiran ERP sustav čiji se podaci prvenstveno koriste za izradu dva glavna izvještaja – Izvještaj kvalitete te Izvještaj produktivnosti. No, s obzirom na potencijal koji ERP, MRP, WMS i ostali sustavi imaju za poslovanje organizacija općenito, dokazano je da se isti ne iskorištavaju adekvatno. To je dugoročno štetno za organizaciju te se na istu odražava u obliku raznih gubitaka za poslovanje, poput nepotrebnih gubitaka vremena, produljenja proizvodnog ciklusa, suvišnog kretanja, neiskorištavanja ljudskog potencijala, a u konačni i prekomjernih troškova.

Bitno je naglasiti kako toplinske mape procesa svakog od tri proizvodna pogona prikazane u prilozima 1, 2 i 3 ne sadrže crvenu boju prema ljestvici evaluacije toka informacija (tablica 3). To znači da je postojeći sustav prikupljanja podataka ograničen na stvaranje dodane vrijednosti elektroničkom razmjenom podataka i informacija u stvarnom vremenu. To podrazumijeva očitavanje barkodova te njihov izravni unos u ERP sustav na mjestima završne kontrole te pakiranja gotovih proizvoda.

Da bi sustav stvarao maksimalnu dodanu vrijednost označenu crvenom bojom prema ljestvici evaluacije toka informacija, trebao bi biti u mogućnosti digitalnim putem prikupljati podatke

koji nastaju u procesu proizvodnje. Za razliku od dijelova toplinskih mapa označenih narančastom bojom, crvena boja odnosi se na sustave vezane za Internet stvari, Internet usluga i razne uređaje poput senzora i odašiljača koji omogućuju automatsku komunikaciju između ERP sustava i svih ostalih sustava i uređaja unutar organizacije. Takvi su sustavi predviđeni za automatizirano izvještavanje bez potrebe za ljudskom intervencijom, ili čak prediktivno i preskriptivno reagiranje na pojavu anomalija u uobičajenom uzorku. Tvrtke u današnje vrijeme i eksponencijalni razvoj tehnologije trebaju težiti implementaciji pametnih sustava kako bi ostvarile konkurentsku prednost na tržištu. Međutim, sustavi se trebaju implementirati i nadograđivati s oprezom kako bi se iskorištavali na najbolji mogući način te kako bi proizvodni procesi bili u skladu s korištenom tehnologijom.

U slučaju tvrtke HAIX obuća d.o.o., prvenstveno se treba usredotočiti da se potencijal trenutno dostupnih implementiranih sustava maksimalno iskoristi. Kao što je prikazano, trenutno u organizaciji postoji mnogo prostora za unaprjeđenje korištenjem već dostupnih alata. Implementacija unaprjeđenja predloženih ovim radom pozitivno bi se odrazila na poslovanje, a sve korištenjem sustava, znanja i vještina već prisutnih u organizaciji. Idući korak je, zatim, razmatranje novih sustava ili nadogradnja postojećeg s ciljem razvoja Industrije 4.0 te izgradnje pametne tvornice.

8. Literatura

[1] *175 Zettabytes By 2025*, https://www.forbes.com/sites/tomcoughlin/2018/11/27/175-zettabytes-by-2025/?sh=767c44754597, 7.10.2020

[2] Tomanek, D. T., Schröder, J.: *Analysing the Value of Information Flow by Using the Value Added Heat Map*, 2017.

[3] *HAIX profile*, https://www.haix.com/en/company-profile/, 8.10.2020.

[4] Arbulu, R., Tommelein, I., Walsh, K., Hershauer, J.: *Value stream analysis of a re-engineered construction supply chain*, 2010.

[5] *What is Value Stream Mapping*, https://www.lucidchart.com/pages/value-stream-mapping/,05.11.2020.

[6] Lupton, R. C., Allwood, J. M.: *Hybrid Sankey diagrams: Visual analysis of multidimensional data for understanding resource use*, 2017.

[7] *Data visualisation: a definition, examples and learning resources*, https://www.tableau.com/en-gb/learn/articles/data-visualization, 12.11.2020.

[8] Hedvičáková, M., Král, M.: *Benefits of KPIs for Industry Sector Evaluation: The Case Study from the Czech Republic*, 2019.

[9] Sawang, S.: *Key performance indicators for innovation implementation: Perception vs. actual usage*, 2019.

[10] Sreekumar, M. D., Chhabra, M., Yadav, R.: *Productivity in Manufacturing Industries*, 2018.

[11] Borgström, B.: *Exploring efficiency and effectiveness in the supply chain – A conceptual analysis*, 2005.

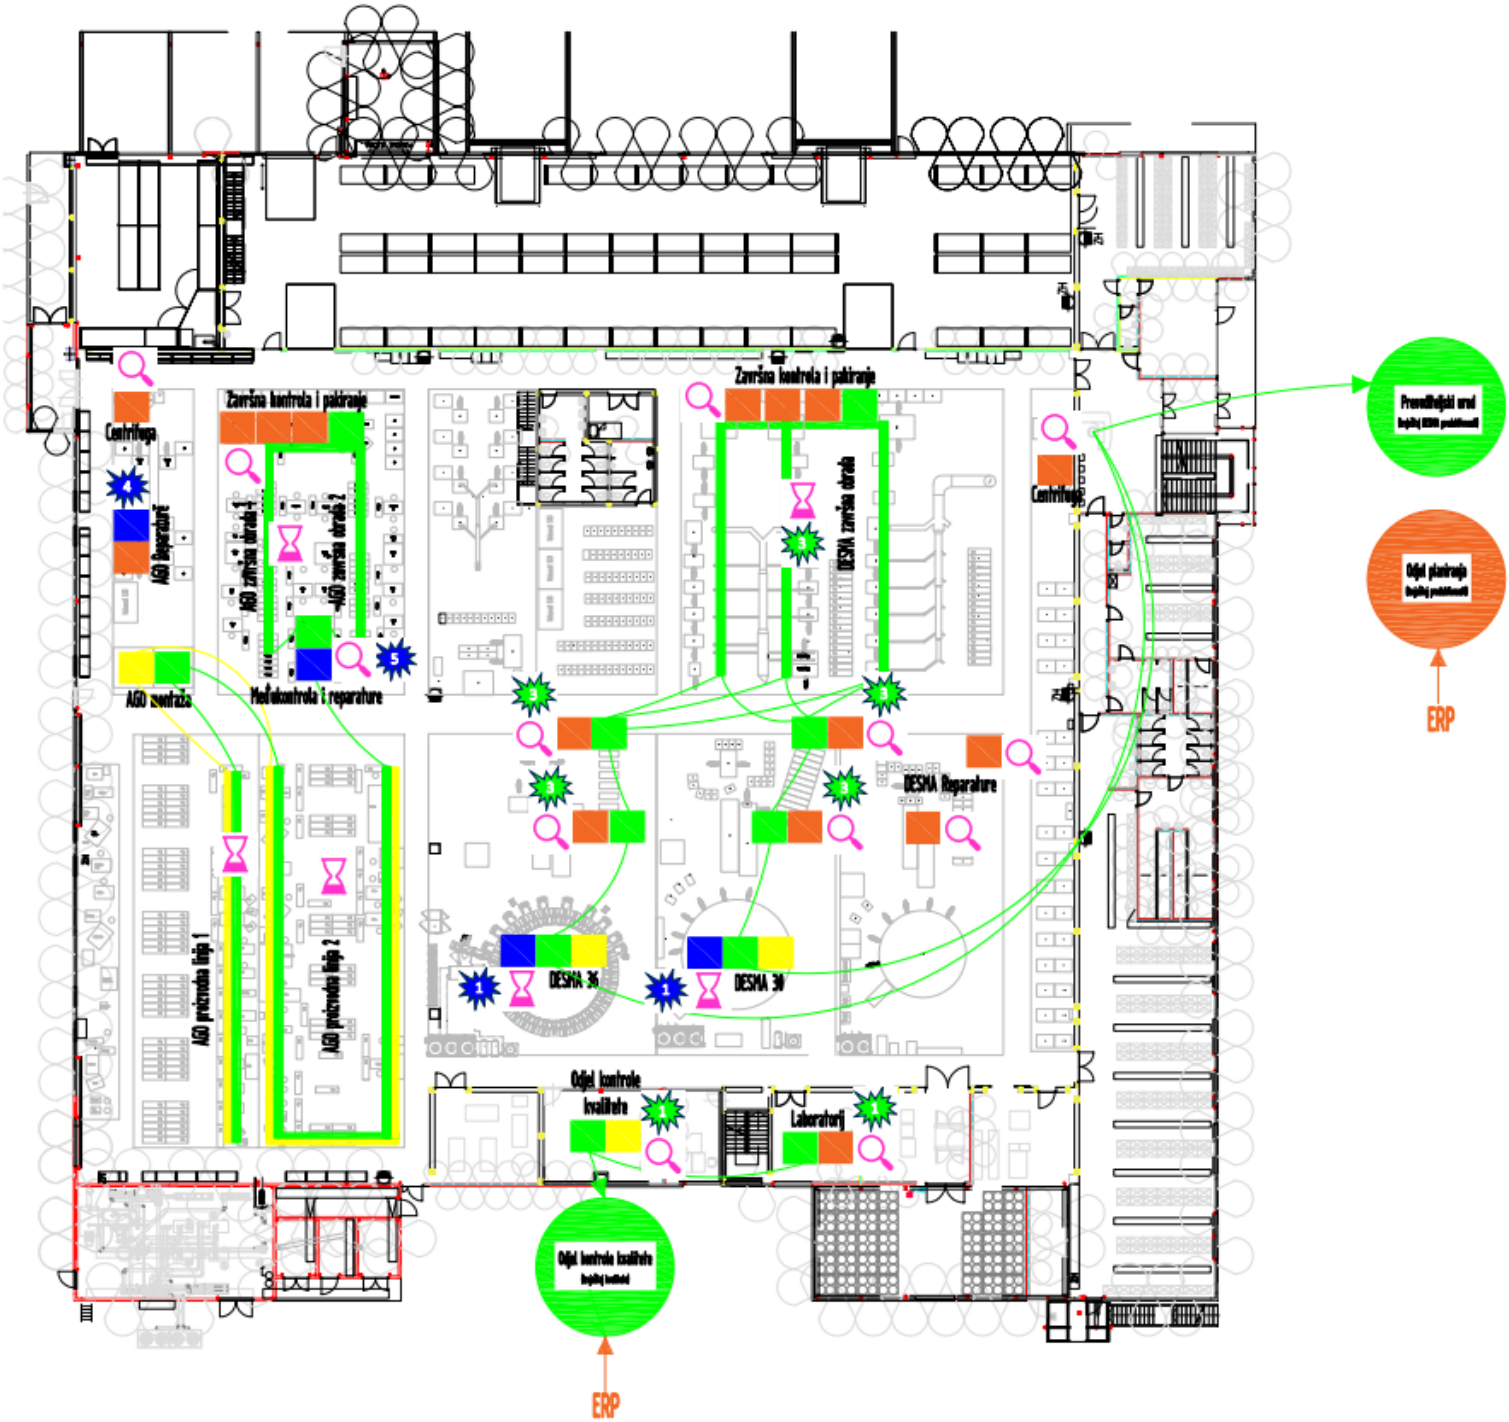
[12] Muchiri, P., Pintelon, L.: *Performance measurement using overall equipment effectiveness (OEE): literature review and practical application discussion*, 2008.

[13] Emblemsvag, J.: *On Quality 4.0 in project-based industries*, 2020.

[14] Nataraj, S., Ismail, M.: *Quality enhancement through first pass yield using statistical process control*, 2017.

[15] *What is a Pareto Chart?* https://asq.org/quality-resources/pareto, 13.11.2020.

Prilog 1. Toplinska mapa proizvodnog pogona H2



Prilog 2. Toplinska mapa proizvodnog pogona H3



Prilog 3. Toplinska mapa proizvodnog pogona H4

