Vizualizacija ključnih pokazatelja uspješnosti u proizvodnom procesu

Filipić, Ines

Master's thesis / Diplomski rad

2022

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:235:932500

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-07-29**

Repository / Repozitorij:

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

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Ines Filipić

Zagreb, 2022.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Mentori:

Doc. dr. sc. Miro Hegedić

Student:

Ines Filipić

Zagreb, 2022.

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

Zahvaljujem mentoru doc. dr. sc. Miri Hegediću na savjetima i pruženoj podršci te povezivanju s tvrtkom Končar D&ST u svrhu izrade diplomskog rada.

Isto tako, zahvaljujem tvrtki Končar Distributivni i Specijalni transformatori na ugodnoj i produktivnoj suradnji te vremenu i resursima koje su mi rado ustupili.

Posebno zahvaljujem svojoj obitelji i dečku na bezuvjetnoj podršci i ljubavi koju mi pružaju.

Ines Filipić

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: 602-14/22-6/1	
Ur. broj: 15-1703-22-	

DIPLOMSKI ZADATAK

Student: **INES FILIPIĆ** Mat. br.: 0035210804

Naslov rada na hrvatskom jeziku: **Vizualizacija ključnih pokazatelja uspješnosti u proizvodnom procesu**

Naslov rada na engleskom jeziku: **Visualization of key performance indicators in the production process**

Opis zadatka:

Proizvodna poduzeća suočena su s konstantnim pritiscima na povećanje kvalitete i fleksibilnosti te smanjenje troškova i vodećeg vremena. Da bi menadžment na svim razinama mogao donositi ispravne odluke vezane uz navedene pokazatelje, važno je da raspolaže s ispravnim informacijama u trenutku kad je potrebno donijeti odluku. Poduzeća u svojim procesima postavljaju ključne pokazatelje uspješnosti (engl. Key performance Indicators (KPIs)) kako bi lakše odredili smjer u kojem se kreću. Jedna od strategija upravljanja pomoću ključnih pokazatelja je i takozvani SQCDP pristup, a koji se temelji na praćenju i prikazivanju pokazatelja vezanih uz proizvodnju direktno u proizvodnom pogonu. Kako bi podatke o pokazateljima dobili u realnom vremenu poduzeća koriste različite digitalne alate.

U radu je potrebno:
1. Objasniti važnost digitalizacije proizvodnje i njezin utjecaj na uspješnost proizvodnih kompanija.
2. Objasniti pojmove poslovne inteligencije, ključnih pokazatelja uspješnosti, vizualizacije podataka u proizvodnji i mapiranja proizvodnih procesa.
3. Istražiti i opisati digitalne alate koji pomažu u prikupljanju i vizualizaciji podataka u proizvodnim procesima.
4. Odabrati jedan proizvodni proces, mapirati ga i prikazati primjenu softvera za vizualizaciju podataka na istom te opisati postignuta poboljšanja.

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

Zadatak zadan: 5. svibnja 2022.

Rok predaje rada: 7. srpnja 2022.

Predviđeni datum obrane: 18. srpnja do 22. srpnja 2022.

Zadatak zadao: doc. dr. sc. Miro Hegedić

Predsjednica Povjerenstva: prof. dr. sc. Biserka Runje

SADRŽAJ

SADRŽAJ I
POPIS SLIKA III
POPIS TABLICA IV
POPIS KRATICA V
SAŽETAK VI
SUMMARY VII
1. UVOD 1
2. POSLOVNA INTELIGENCIJA 3
2.1. Uvod u poslovnu inteligenciju 3
2.2. Važnost informacija i poslovno odlučivanje 4
2.3. Alati poslovne inteligencije 5
2.4. Važnost i primjena poslovne inteligencije 6
2.5. Poslovna inteligencija danas 9
3. KJUČNI POKAZATELJI USPJEŠNOSTI 10
3.1. Što su ključni pokazatelji uspješnosti 10
3.2. Kako odrediti ključne pokazatelje uspješnosti 11
3.3. Karakteristike dobrih ključnih pokazatelja uspješnosti 12
3.4. Primjeri ključnih pokazatelja uspješnosti 14
4. VIZUALIZACIJA 16
4.1. Važnost vizualizacije 16
4.2. Primjeri vizualizacije 16
4.3. Alati za vizualizaciju 22
4.3.1. Značajke alata za vizualizaciju 22
4.3.2. Vrste alata za vizualizaciju 24
4.3.2.1. Tableau 24
4.3.2.2. Qlik 25
4.3.2.3. Plotly 26
4.3.2.4. Excel 26
4.3.2.5. Power BI 27
4.3.3. Usporedba alata za vizualizaciju podataka 28
5. MICROSOFT POWER BI – Primjer korištenja 29
6. MAPIRANJE PROIZVODNOG PROCESA 31
6.1. Proces 31
6.2. *Lean* metodologija 31
6.3. Mapiranje toka vrijednosti i mapiranje procesa 33
7. PLAN PROJEKTA 36
7.1. Svrha i cilj projekta 36
8. IZVEDBA PROJEKTA 38

8.1. SIPOC dijagram 38
8.2. Mapa procesa 39
8.3. Pokazatelji koji se prate 45
8.4. Tlocrt procesa i tok informacija i materijala 46
8.5. Analiza toka informacija 47
8.6. Prijedlog poboljšanja 47
8.6.1. Prijedlog poboljšanja s trenutnim pokazateljima 47
8.6.2. Prijedlog poboljšanja s dodatnim pokazateljima 52
9. ZAKLJUČAK 53
LITERATURA 54

POPIS SLIKA

Slika 1. Industrija 4.0 [1] 1
Slika 2. Zone korištenja podataka [4] 4
Slika 3. Dijagram toka [6] 7
Slika 4. Interaktivni dijagram [6] 8
Slika 5. Postavljene granice razine izvedbe [10] 12
Slika 6. Linijski grafikon [izrada autora] 17
Slika 7. Stupčasti grafikon [izrada autora] 17
Slika 8. Raspršeni grafikon [izrada autora] 18
Slika 9. Tortni grafikon [izrada autora] 18
Slika 10. Vizualni prikaz čvorovima [13] 19
Slika 11. Matrični vizualni prikaz [13] 19
Slika 12. Panel grafikoni [15] 20
Slika 13. Kontrolna ploča SQCDP [17] 21
Slika 14. Kategorije značajki softvera za vizualizaciju [18] 23
Slika 15. Značajke softvera za vizualizaciju [18] 23
Slika 16. Tableau Desktop [20] 25
Slika 17. Kontrolna ploča u alatu Qlik [21] 26
Slika 18. Power BI [26] 27
Slika 19. Kontrolne ploče u Power BI [28] 29
Slika 20. Grafički prikaz procesa [izrada autora] 31
Slika 21. Načela *lean* metodologije [izrada autora] 33
Slika 22. SIPOC dijagram [izrada autora] 38
Slika 23. Mapa procesa, 1. dio [izrada autora] 41
Slika 24. Mapa procesa, 2. dio [izrada autora] 42
Slika 25. Mapa procesa, 3. dio [izrada autora] 43
Slika 26. Mapa procesa, 4. dio [izrada autora] 44
Slika 27. Tlocrt namataone [izrada autora] 46
Slika 28. Kontrolna ploča za operatere [izrada autora] 49
Slika 29. Kontrolna ploča za poslovođu [izrada autora] 49

POPIS TABLICA

Tablica 1. Usporedba alata za vizualizaciju podataka [27] 28
Tablica 2. Razlike između Mapiranja toka vrijednosti i Mapiranja procesa [32] 35
Tablica 3. Plan aktivnosti projekta [izrada autora] 37
Tablica 4. Tablica pokazatelja koji se prate [izrada autora] 45
Tablica 5. Tablica pokazatelja koji se prate uz prijedlog poboljšanja [izrada autora] 51

POPIS KRATICA

Kratica	Opis
BI	*engl. Business Intelligence* – Poslovna inteligencija
CPM	*engl. Corporate Performance Management Software* – programi koji omogućavaju menadžerima poduzeća pregledavanje učinka
DAX	*engl. Data Analysis Expressions* – izrazi za analizu podataka
IDEF0	*engl. Integration Definition for Function Modeling* - metodologija planiranja i razvijanja procesa, za izradu strukturiranih prikaza poslovnih procesa
IoT	*engl. Internet of Things* – internet stvari
ISO	*engl. International organization for standardization* – Međunarodna organizacija za standardizaciju
KPI	*engl. Key Performance Indicator* – Ključni pokazatelji uspješnosti
OLAP	*engl. OnLine Analytical Processing* – Dio poslovne inteligencije za podršku analizi poslovnih procesa
SIPOC	*engl. Suppliers, Inputs, Process, Outputs, Customers* – grafički prikaz na kojem je jednoznačno prikazan poslovni proces s ulazim i izlaznim varijablama
SMART	*engl. Specific, Measurable, Attainable, Realistic / Relevant, Time-based* – Specifičan, Mjerljiv, Održiv, Realan/Značajan, Mjerljiv u vremenu

SAŽETAK

Tema ovog diplomskog rada je vizualizacija ključnih pokazatelja uspješnosti u jednom proizvodnom procesu. Proizvodna poduzeća suočavaju se s izazovima koji se pojavljuju u složenim i dinamičnim proizvodnim sustavima, a za donošenje ispravnih i kvalitetnih poslovnih odluka potrebne su pouzdane informacije dobivene u stvarnom vremenu. Količina podataka eksponencijalno raste, ali njihova analiza i vizualizacija je znatno olakšana uz pomoć digitalnih tehnologija. U radu su objašnjeni pojmovi poslovne inteligencije, digitalizacije, ključnih pokazatelja uspješnosti, vizualizacije podataka te mapiranja proizvodnih procesa. U praktičnom dijelu rada opisan je proces namatanja bakrenih namota za transformatore u tvrtki Končar D&ST. Proces namatanja prikazan je na SIPOC dijagramu te detaljnoj mapi procesa uz tablicu pokazatelja koji se u procesu prate. Predložena su poboljšanja u praćenju i korištenju podataka uz primjenu softvera za vizualizaciju.

Ključne riječi: digitalizacija, vizualizacija podataka, ključni pokazatelji uspješnosti, mapiranje procesa

SUMMARY

The topic of this master's thesis is the visualization of key performance indicators in the manufacturing process. Manufacturing companies are faced with challenges that arise in complex and dynamic production systems, and for making correct and high-quality business decisions, reliable information obtained in real time is needed. The amount of data is growing exponentially, but its analysis and visualization is much easier with the help of digital technologies. The paper explains the concepts of business intelligence, digitization, key performance indicators, data visualization and mapping the production process. In the practical part of the thesis process of winding copper windings for transformers in the manufacturing company Končar D&ST is being explained. Improvements in data tracking and use are suggested with the application of visualization software.

Key words: digitization, data visualization, key performance indicators, process mapping

1. UVOD

U povijesti, industrijske revolucije značajno su promijenile smjer proizvodnje. Nove tehnologije oduvijek su pozitivno utjecale na razvoj industrije: od izuma parnog stroja u 18. stoljeću koji je olakšao posao uvođenjem mehanički potpomognute proizvodnje, masovne proizvodnje koju je omogućila električna energija, razvijanja računalne tehnologije koja je automatizirala proizvodnju 70-ih godina pa sve do danas - četvrte industrijske revolucije u kojoj će internet stvari umrežiti pogone. Područja djelovanja i alati koji se koriste u Industriji 4.0 za transformaciju tvornica u pametne tvornice, usmjerene na produktivnost i efikasnost objedinjene su na Slici 1., a neki od njih su senzori, automatizacija, prikupljanje podataka u realnom vremenu, računalstvo u oblaku i mnogi drugi [1].

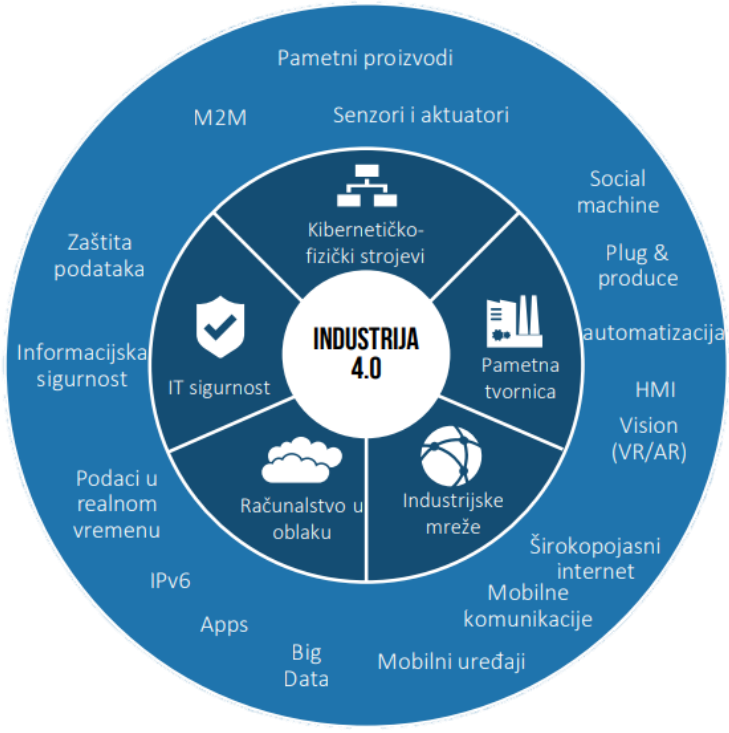

Slika 1. Industrija 4.0 [1]

Umrežavanje pogona od velikog je značaja za tvrtke zato što je trenutna proizvodnja vrlo dinamična te uključuje značajke poput kvalitete proizvoda, agilnosti i produktivnosti koje predstavljaju ključnu ulogu u održivom radu poduzeća. Tvrtke se suočavaju s izazovima koji se pojavljuju u složenim i dinamičnim proizvodnim sustavima, a umrežavanje olakšava rješavanje složenih problema i analizu cjeline. Osim toga, potražnja potrošača za prilagođenim

i inovativnim proizvodima svakodnevno raste. Tvrtkama je zato potrebna izvrsna povezanost i dosljednost procesa u isporuci prilagođenih i pristupačnih proizvoda i usluga. Te izazove tvrtke mogu riješiti učinkovitom konvergencijom, digitalizacijom i tehnologijama Industrije 4.0. Spomenuta uključuje nove tehnologije kojima transformira konvencionalnu industrijsku strukturu. Kontrolne ploče sustava Industrije 4.0 omogućuju održavanje proizvodnog sustava tako da se informacijama iz proizvodnih i logističkih mreža može pristupiti u stvarnom vremenu. Koncept također nudi alternativne načine pojednostavljivanja operativnih sustava i dramatično minimizira resurse i vrijeme isporuke. Uvođenje novih koncepata uvijek je otežano pa se isto događa s Industrijom 4.0 i to desetak godina nakon njezinog predstavljanja. Najčešće je tako zbog ograničene stručnosti i financijskih sredstava, operativnih komplikacija, kibernetičke sigurnosti te tehnološke neodlučnosti pa uvođenje Industrije 4.0 predstavlja izazov za tvrtke. Za rješavanje ovih izazova potreban je sveobuhvatan okvir kojim bi se olakšala integracija novih tehnologija u tvrtkama [2].

2. POSLOVNA INTELIGENCIJA

2.1. Uvod u poslovnu inteligenciju

U modernom društvu koje se bazira na znanju, informacija je od velike vrijednosti za svako poduzeće. Odluke se donose na temelju analize podataka, a točnost i pravodobnost dostavljanja podataka osiguravaju razvijeni sustavi informacijskih tehnologija i poslovne inteligencije. To su sustavi koji uključuju procese, resurse i tehnologiju za transformaciju podataka u informacije i znanje koje pomaže u donošenju poslovnih odluka. Sastoje se od dvije glavne komponente, a to su integracija podataka iz različitih izvora te tehnike analize i vizualizacije informacija na razumljiv način. Sustav poslovne inteligencije je set alata koji se koriste u prikupljanju, analizi, sortiranju, procesiranju i odašiljanju informacija za poslovno inteligentne odluke. Potreba za takvim sustavima svakog dana je sve veća jer digitalizacijom poslovnog okruženja volumen podataka eksponencijalno raste [3].

Glavni tipovi sustava poslovne inteligencije koji pomažu kod donošenja odluka su [3]:

- sustav za obradu podataka (engl. *Transaction processing system*)
- sustav za upravljanje informacijama (engl. *Management Information System*)
- sustav za podršku kod odlučivanja (engl. *Decision Support System*)
- izvršni informacijski sustav (engl. *Executive Support System*).

Trenutno se kao veliki problem ističe sigurnost sustava. Prema izvoru, prijetnje se mogu podijeliti na unutarnje i vanjske. One mogu utjecati na različite komponente sustava: programe, podatke, aplikacije, infrastrukturu i ostale. Do narušavanja sigurnosti sustava može doći slučajno ili namjerno. Slučajno se to događa, primjerice, nenamjernim greškama zaposlenika ili prirodnim katastrofama, a namjerno virusima, računalnim crvima ili softwareima poput Trojanskog konja. Upravo iz tog razloga je uz korištenje digitalnih alata potrebno ozbiljno shvatiti zaštitu podataka i smanjiti rizik od napada. Glavni standardi sigurnosti i upravljanja rizikom su ISO 31000, ISO 31010, ISO 22301 i ISO 27002. Poduzeće bi trebalo neprekidno pratiti i mijenjati okvire upravljanja rizicima kako bi mogli pratiti vanjske i unutarnje promjene rizika i prilagođavati im se [3].

2.2. Važnost informacija i poslovno odlučivanje

Inteligentno poslovanje postiže se dobrim snalaženjem među informacijama i reagiranjem na temelju analize informacija. Smatra se da je vrijednost informacije jednaka kvadratu broja korisnika i broju poslovnih područja koja se koriste tom informacijom.

Postoji pet zona korištenja podataka u poduzeću, a prikazane su na Slici 2 [4].

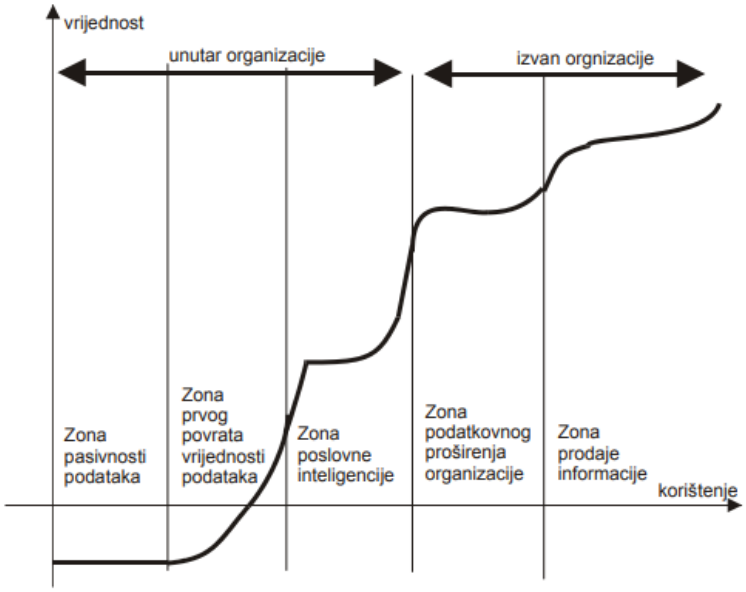

Slika 2. Zone korištenja podataka [4]

U prvoj se zoni podaci rijetko koriste te čak stvaraju troškove održavanja veće od same vrijednosti tih podataka. U drugoj zoni podaci prelaze iz zone pasivnosti u aktivno stanje jer se njima koriste poslovni korisnici. Porastom zaposlenika iz odjela poslovne inteligencije koji u svrhu obavljanja svojih radnih zadataka koriste podatke, raste i vrijednost tih podataka. U trećoj zoni podatke koriste i drugi odjeli pa se poslovna inteligencija primjenjuje na razini cijelog poduzeća. Podacima koji su dostupni izvan poduzeća stvara se nova vrijednost jer, ako su kupci ili dobavljači spremni platiti za njih, mogu se ponuditi uz cijenu i tako donijeti profit. U posljednjoj zoni poduzeće može ponuditi podatke tržištu kao novi proizvod. Primjerice, organizaciji za istraživanje tržišta [4].

U poslovnom svijetu posjedovanje informacija znači veću moć onih koji informacije posjeduju. Kod poduzeća koje je poslovno inteligentno informacije su slobodne, ali upravljane tako da su za njihovo korištenje ovlašteni samo oni koji ih doista trebaju.

Osim praćenja informacija, iste je važno koristiti primjereno jer bez smislene interpretacije prikupljenih podataka praćenje podataka samo za sebe nema svrhu. Poslovne odluke temelje se na analizi podataka, a mogu biti strukturirane, polustrukturirane i nestrukturirane. Kod strukturiranog odlučivanja zaposlenik može biti zamijenjen programom ugrađenim u informacijski sustav jer je odlučivanje rutinsko i može ga se programirati. Polustrukturirano odlučivanje uključuje ljudsko znanje i iskustvo te su potrebni stručnjaci koji se mogu koristiti ekspertnim sustavima koji simuliraju ponašanje u nepoznatim uvjetima. Nestrukturirano odlučivanje ne može imati propisani postupak odlučivanja i odgovornost je isključivo na osobi koja odlučuje, a sustav jedino može pomoći tako da omogući dovoljnu količinu podataka i njihovu analizu [4].

Poslovna inteligencija oslanja se na korištenje informacijskog sustava čije funkcije možemo podijeliti u tri skupine. Operativnom informacijskom podsustavu svrha obrade je izvršavanje poslovnog procesa, a podaci su u njemu tablično strukturirani i nalaze se u bazama podataka. Analitičkom informacijskom podsustavu podaci su dimenzijski strukturirani u skladištu podataka, a funkcija, odnosno svrha obrade, su odlučivanje i upravljanje. Suradničkom informacijskom podsustavu podaci se nalaze u bazama dokumenata u polustrukturiranom ili nestrukturiranom obliku, a funkcija suradničkog podsustava su komunikacija i suradnja sudionika poslovanja. Kad su u informacijskom sustavu uključene sve tri navedene skupine podaci su smisleno povezani i možemo reći da je sustav dobar [4].

2.3. Alati poslovne inteligencije

Alati koji se koriste u poslovnoj inteligenciji su zapravo programi za analizu, sortiranje, procesiranje i prikazivanje podataka. Neki od alata bit će opisani u nastavku [5]:

- Proračunske tablice (engl. *Spreadsheets*) – obično korištene u Microsoft Excelu koji se temelji na tablicama.
- Digitalne kontrolne ploče – jednostavne za tumačenje podataka u realnom vremenu uz grafički prikaz trenutnog stanja.
- Programi za upite i izvješća – programi korišteni za izvješća, upite, sortiranje, filtriranje i prikaz podataka.
- Programi za vizualizaciju podataka – pomažu prikazati analizu podataka u grafičkom prikazu u kratkom vremenskom roku za donošenje bitnih odluka.

- CPM programi (engl. *Corporate Performance Management Software*) – alati koji omogućavaju menadžerima poduzeća pregledavanje učinka u svrhu postizanja zadanih ciljeva.
- OLAP alati - interaktivni alati koji korisnicima daju brze odgovore na višedimenzionalne upite, omogućava modeliranje, proračunavanje, vremensku analizu
- Alati za rudarenje podataka (engl. *Data Mining*) – alati koji uočavanju uzorke u velikoj količini podataka, uključuju metode koje koriste umjetnu inteligenciju, strojno učenje, statistiku i sustave baza podataka
- Skladišta podataka – središnja baza podataka kreirana integracijom podataka s više izvora za buduću analizu

2.4. Važnost i primjena poslovne inteligencije

Kako bi tvrtke stekle konkurentsku prednost i poboljšale svoje proizvodne procese potrebno je ispravno koristiti obrađene pomoću modernih tehnologija iz širokog raspona softvera koje BI nudi. Pomoću BI alata i metoda moguće je transformirati redove podataka u značajne i korisne informacije za donošenje poslovnih odluka. U proučavanom radu autori Kajáti, Mišku i Papcun koristili su stvarne proizvodne podatke i analizirali ih u Excelu s dodatnim proširenjima. Navedeni program je korišten jer su zaposlenici već upoznati s njim, a posljednjih godina nudi složenije dodatke koji su usmjereni na naprednu analizu podataka. U navedenom radu korišten je Power Query, koji se koristi za predprocesiranje podataka, Power Pivot za stvaranje podatkovnog modela, KPI i analiza s DAX izrazima te Power View-om za analizu i vizualizaciju podatka na nove interaktivne načine. Rezultati istraživanja pokazuju da su takvi jednostavni dodaci uspjeli stvoriti složene analize koje su zadovoljile potrebe korisnika u proizvodnoj tvrtki čije su podatke koristili. Slijed koraka kojim se postepeno došlo do vizualiziranih podataka započeo je pripremom dobivenih podataka jer isti nisu bili prilagođeni za analizu. Problemi su bili u različitim nazivima istih podataka, nisu bile definirane veze između podataka, neki podaci su nedostajali i slično. U sljedećem koraku analizirali su se svi zahtjevi tvrtke i struktura podataka. Glavni cilj je bio stvoriti izvješće pomoću BI alata. Neki od zahtjeva su bili odrediti ključni pokazatelj uspješnosti koji pokazuje financijsko upravljanje svakog odjela, predvidjeti financijske izvore za svaki odjel za sljedeću godinu i slični. Na Slici 3. prikazan je dijagram toka koraka koji su se u procesu izrade vizualizacije slijedili [6].

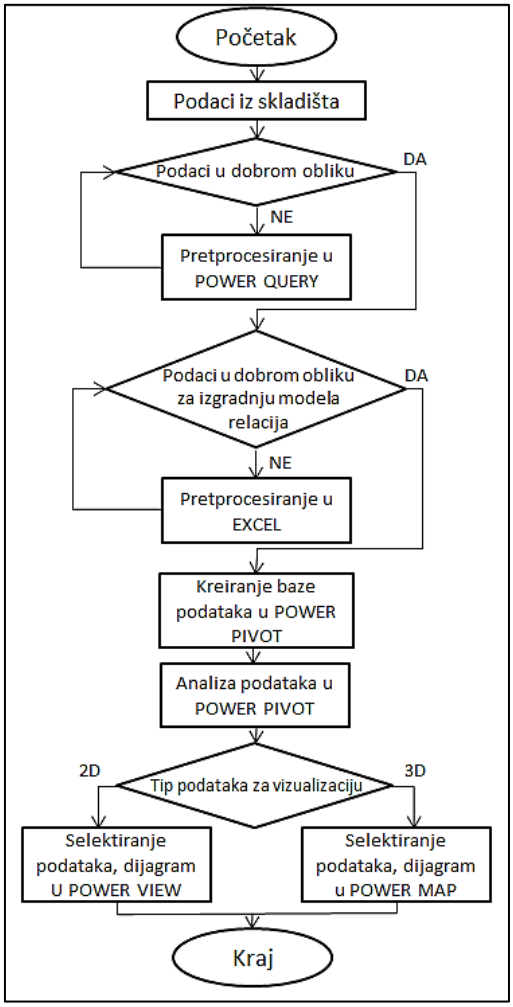

Slika 3. Dijagram toka [6]

Za predprocesiranje podataka korišten je Power Query dodatak. Problemi s oblikom podataka rješavali su se redom. Nakon transformacije, podaci su bili objedinjeni u jednoj tablici i spremni za analizu u Power Pivot-u. Cilj je bio stvoriti kompletan upravljački informacijski sustav koji može odgovarati na različite upite, a za to je bilo potrebno stvoriti model podataka koji se dodatno prilagodio u Excelu. Sada su se modeli mogli analizirati, a prvo je trebalo odgovoriti na pitanje koliko je snažna proizvodnja svakog odjela u tvrtki određujući to na temelju financijskih naknada u postocima prošle godine. Za izradu tog vizuala prvi korak je bio korištenje PivotTable funkcije, kreirala se mjera koja prikazuje podatke u postocima i konačno su se vizualizirali rezultati s tim ključnim pokazateljem uspješnosti. U sljedećoj analizi fokus je bio na planiranju izvora financiranja za svaki odjel u aktualnoj godini. Taj izvor financija bi bio dostupan za kupnju materijala i usluga potrebnih kako bi odjel mogao raditi svoj zadatak. Planiranje je napravljeno prema rezultatima ključnih pokazatelja uspješnosti, no model ne sadrži podatke korisne za analizu. Za dobivanje podataka koji su nam korisni bilo je potrebno

izračunati tražene vrijednosti podataka i povezati varijable. U tome je pomogao jezik formula Data Analysis Expression. DAX je knjižnica funkcija i operatora čijom se kombinacijom mogu stvarati formule i izrazi u Power Pivotu u Excelu ili Power BI Desktop programu. Pomoću formula dolazimo do novih veza između podataka i, u ovom slučaju, podataka koji su ključni pokazatelji. U PivotTable vizualizaciji je prikazan postotak rasta financijskih resursa prema dobivenim podacima za svaki odjel. Izradili su se različiti dijagrami pomoću Power View-a. Svaki od dijagrama prikazivao je informacije o zahtjevima iz svakog odjela pojedniačno. Dijagrami su interaktivno spojeni i kod odabira jedne vrijednosti na dijagramu, svi dijagrami se automatski preračunavaju. Jedan od zahtjeva je da su korisnici upoznati s radom u Excelu kako za rad s podacima ne bi bila potrebna edukacija. Jedan od primjera kontrolne ploče prikazan je na Slici 4. [6].

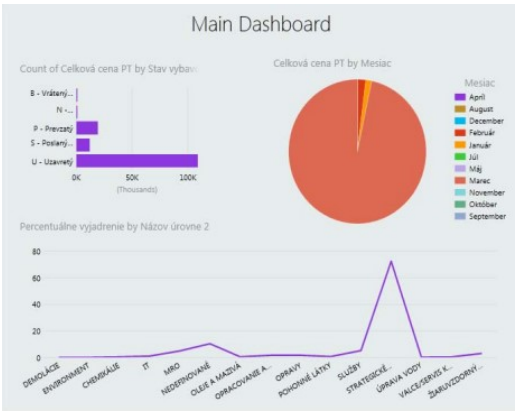

Slika 4. Interaktivni dijagram [6]

Opisani je postupak vizualizacije podataka pomoću programa Excel i dodataka. Odabran je taj program jer je poznat zaposlenicima u tvrtki pa mogu brzo i lako analizirati podatke.

Ako se razmišlja o unapređivanju ovog sustava u budućnosti, kao unapređenje nameće se oblak (*cloud*) jer nudi prednosti poput implementacije strojnog učenja pohranjenog u oblaku, no za sada je veliki problem s oblakom sigurnosni rizik. Mogao bi se koristiti oblak servis gdje analitičar može graditi svoje predikcijske modele, klasificirati, grupirati pa na kraju i objavljivati rezultate.

Industrija 4.0 očekuje da će internet stvari unaprijediti industriju u pogledu sigurnosti i napredovanja povezanosti između tehnologija i biznisa. Poduzeća postižu kompetitivne prednosti i poboljšavaju svoje procese samo ako podatke koriste na pravilan način, a to mogu samo uz korištenje modernih tehnologija zbog velikog broja podataka i veza između njih. U primjeru opisanom u radu, rezultati pokazuju da je nekoliko jednostavnih dodataka Excelu bilo dovoljno za kompleksnu analizu podataka dobivenih od poduzeća [6].

2.5. Poslovna inteligencija danas

Praćenje trendova nužno je da bi poduzeća bila konkurentna. Trendovi se neprestano mijenjanju, a posebice u računalnoj tehnologiji koja je temelj poslovne inteligencije. Trenutno poduzeća prate trendove digitalizacije, sigurnosti, mobilnosti, tehnologije u oblaku i slično.

Istraživanje pod nazivom „Data, BI & Analytics Trend Monitor 2022“ provedeno 2022. godine na uzorku od 2396 stručnjaka iz područja poslovne inteligencije jasnije pokazuje koji su trendovi trenutno vodeći, ali i one koji su manje važni od sveukupno 20 trendova. Trenutno vodeći trendovi su upravljanje glavnim podacima i kvalitetom podataka, predstavljanje kulture temeljene na podacima, upravljanje podacima, vizualizacija podataka, samoposlužna analitika i modernizacija skladišta podataka. Oni manje popularni su IoT podaci i analitika, proširena analitika, mobilni BI i automatizacija odluka [7].

Trend upravljanja glavnim podacima i kvalitetom podataka već se godinama pojavljuje na samom vrhu liste. Ta pozicija pokazuje koliko je poduzećima bitno imati kvalitetne podatke za smislenu analizu i postizanje željenih poslovnih ciljeva. Drugi najvažniji trend je uspostavljanje kulture temeljene na podacima jer stručnjaci smatraju da je svjesnost o važnosti podataka nužna za dostizanje punog potencijala poduzeća [7].

3. KJUČNI POKAZATELJI USPJEŠNOSTI

3.1. Što su ključni pokazatelji uspješnosti

Ključni pokazatelji uspješnosti važni su pokazatelj kreće li se tvrtka svojim djelovanjem prema definiranom cilju. Mogu biti definirani za opremu, podprocese ili cijele odjele. Pomoću ključnih pokazatelja može se kvantificirati i izmjeriti uspješnost različitih dijelova poduzeća, od kontrole kvalitete, održavanja pa do upravljanja resursima, odnosno materijalima i energijom. Izbor KPI-ova ovisi o cilju tvrtke [8].

Dobri KPI-ovi su objektivan dokaz napretka prema željenom rezultatu, oni i mjere što je potrebno u svrhu donošenja boljih poslovnih odluka, uspoređuju stupanj promjene izvedbe tijekom vremena, mogu kvantificirati efikasnost, učinkovitost, kvalitetu, pravodobnost, usklađenost, ponašanje, financije, izvedbu, učinak radnika ili korištenje resursa te balansiraju između vodećih (engl. *leading*) i zaostalih (engl. *lagging*) pokazatelja.

Mogu biti kategorizirani u nekoliko tipova. Ulazni (engl. *inputs*) mjere značajke (količina, tip, kvaliteta) resursa koji ulaze u proces, dok se mjere procesa ili aktivnosti usredotočuju se na to kako je efikasnost, kvaliteta ili dosljednost specifičnih procesa korištena za proizvodnju određenih izlaza iz proizvodnje, a mogu se definirati i za opremu i alate. Izlazni (engl. *outputs*) su mjere koje pokazuju koliko je posla odrađeno i definiraju što je proizvedeno. Ishodi (engl. *outcomes*) se fokusiraju na postignuto (primjerice, svijest kupaca o robnoj marki). Projektne mjere odgovaraju na pitanja o statusu rezultata i napretka vezanih za projekte i inicijative.

Svaka tvrtka trebala bi pratiti strateške i operativne mjere. Strateške mjere prate napredak prema strateškim ciljevima, fokusirajući se na željene rezultate ishoda i zapravo mjere ishod. Operativne mjere usredotočene su na operacije i taktike, određene su da informiraju u svrhu boljeg donošenja odluka o svakodnevnoj isporuci proizvoda ili drugim operativnim funkcijama. U to se ubrajaju ulazne i procesne te izlazne i projektne mjere. Mjere rizika usredotočene su na faktore koji bi mogli biti prijetnja uspjehu, a mjere koje se odnose na zaposlenike fokusirane su na ponašanje ljudi, njihove vještine ili izvedbe. Svaka tvrtka, prema svojim potrebama, koristi neke od ovih mjera iz različitih kategorija kako bi uočila provodi li se strategija učinkovito [9].

3.2. Kako odrediti ključne pokazatelje uspješnosti

Tvrtka bi trebala dizajnirati individualni proces mjerenja učinkovitosti. Prije svega, važno je znati cilj koji se želi postići, a potom razviti strategiju kojom se dolazi do cilja. Potrebno je da je strategija mjerljiva i jednostavna za komunikaciju te odabrati i dizajnirati mjere koje prate proces, a da su značajne i objektivnije od takozvanog *brainstorminga*. Kontrolne ploče morale bi sadržavati razumljiva izvješća iz kojih se jasno vidi u kojem smjeru se kreće proces.

Rad počinje s preciziranjem željenih objektivnih rezultata, nakon toga se razvijaju pokazatelji uspješnosti odnosno odabiru se i definiraju mjere i ciljevi.
Preciziranje željenih rezultata potrebno je jer je cilj u većini slučaja definiran apstraktno. Primjerice, strateški cilj poboljšanja kvalitete proizvoda može zvučati specifično. Međutim, u timu ne podrazumijevaju sve osobe jednako definiciju riječi kvaliteta pa je potrebno jednoznačno definirati željene rezultate kako bi se lakše moglo odrediti što se mjeri.

Razumijevanje alternativnih mjera bitno je jer ponekad nije moguće direktno mjeriti ključni pokazatelj pa treba objediniti više mjera u jednom pokazatelju. U većini slučaja najbolje bi bio odabrati izravnu mjeru, ali kad to nije moguće potrebno je postaviti hipotezu o korelaciji više mjera. Za bolje razumijevanje mjerljivih komponenti prije odabira neizravnih mjera mogu se koristiti alati poput logičkog modela, analize uzroka i posljedica ili analize tijeka procesa [10].

Dobro je izbaciti nepotrebne mjere identificirane u prethodnim koracima i odabrati završne mjere koje nabolje otkrivaju krećemo li se uspješno prema cilju ili ne. Treba odabrati mjere koje imaju značenje i pružaju informacije potrebne za donošenje boljih strateških odluka, validne su i odobrene, potiču zaposlenike na željeno ponašanje i tako izbjeći nepotrebno prikupljanje podataka koje je trošak.

Složeni indeksi definiraju se prema potrebi. Ako individualne mjere daju korisne podatke o različitim komponentama željenog cilja, izrađuje se indeks koji grupira nekoliko mjera pod jednim naslovom i tako pomaže u analizi. Kad pojedina mjera nije sama po sebi korisna potrebni su kompozitni indeksi, obično je to slučaj kad se mjeri nešto nematerijalno poput zadovoljstva i lojalnosti.

Osim definiranih mjera, potrebno je definirati i željenu razinu izvedbe. Izvedba se temelji na ciljevima, željenoj razini izvedbe za određeno razdoblje, te donjoj i gornjoj granici željene izvedbe oko ciljane vrijednosti. Granice utječu na stvaranje točke u kojima se može prikazati zelenom bojom za dobar učinak, žutom bojom za zadovoljavajuće ili crvenom bojom za lošu

izvedbu. Na Slici 5. može se vidjeti primjer označenih granica i željenu razina izvedbe po kvartalima u godini [10].

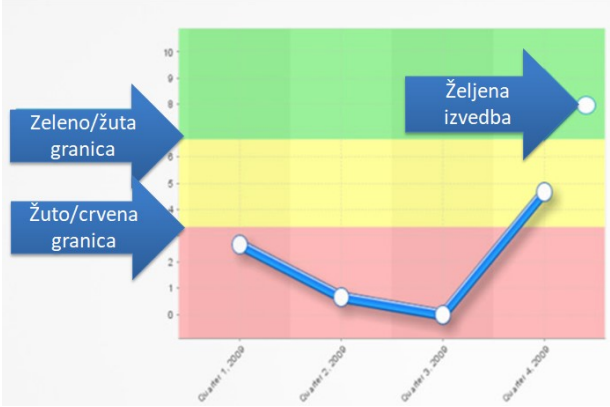

Slika 5. Postavljene granice razine izvedbe [10]

Odabrane mjere potrebno je dokumentirati u tablici koja sadrži definicije pokazatelja uspješnosti. Zabilježene su i bitne informacije svakog od pokazatelja. Dokumentiranje je važan korak za prijelaz s razvoja sustava upravljanja učinkom na stvarno korištenje i implementaciju. Definicija je posebno važna ako se planiraju koristiti izvještaji za donošenje poslovnih odluka ili softveri za upravljanje. Temeljita definicija pomaže kod implementacije softvera, a donesene odluke temeljene na podacima su pouzdanije. Kod ručnog mjerenja, ali i kod računanja pokazatelja uspješnosti važno je dokumentirati i opisati sve pojedinosti mjere tako da se mjera uvijek prikazuje dosljedno i na taj način pridonosi smislenom analiziranju i zaključivanju na temelju podataka. U tablici bi trebali biti jednoznačno i objektivno definirani svi pojmovi [10].

3.3. Karakteristike dobrih ključnih pokazatelja uspješnosti

U literaturi se često nalazi pravilo „**SMART**“ koje definira najpotrebnije karakteristike KPI-eva. To pravilo podrazumijeva [11]:

- S – specifičan – KPI je jasan i ima fokus prema željenom cilju.
- M – mjerljiv – KPI se može iskazati kvantitativno.
- A – održiv – željena izvedba je racionalna i dostižna.
- R – realan i značajan.
- T – mjerljiv u vremenu.

Iako korištenje SMART pravila ima prednosti (pamtljivo je i lako primjenjivo pravilo), zbog velikog broja KPI-eva postoji još karakteristika koje dobro određeni KPI-evo trebaju imati.

12 karakteristika koje kvalitetani KPI-evi moraju imati [11]:

- Usklađeni – KPI je usklađen sa strategijom.
- U posjedu – svaki KPI je „u vlasništvu“ pojedinca ili grupe koja je odgovorna za njegov ishod.
- Djelotvoran – KPI sadrži pravovremene i korisne podatke kako bi korisnici mogli intervenirati i poboljšati izvedbu prije nego li se nepovratno naruši.
- Malobrojni – KPI-evi bi trebali usredotočiti korisnike na nekoliko visokovrijednih zadataka, a ne raspršiti pažnju i energiju.
- Jednostavni – KPI-evi bi trebali biti jednostavni i lako razumljivi, a ne se temeljiti na indeksima na koje korisnici ne znaju izravno utjecati.
- Uravnoteženi i povezani – KPI-evi bi se trebali međusobno uravnotežiti i jačati.
- Pokretači promjena – mjerenje KPI-eva trebao bi pokrenuti lančanu reakciju pozitivnih promjena u organizaciji.
- Standardiziranost – trebali bi se temeljiti na standardnim definicijama, pravilima i izračunima kako bi se mogli integrirati u kontrolne ploče u cijeloj organizaciji.
- Pokrenuti kontekstom – KPI-evi stavljaju izvedbu u kontekst primjenom ciljeva kako bi korisnici mogli procijeniti njihov napredak prema cilju tijekom vremena.
- Ojačani poticajima – poduzeća mogu povećati učinak KPI-eva pomoću poticaja i naknada, međutim samo na pravilno shvaćene i stabilne KPI-eve.
- Relevantni – KPE-evi s vremenom gube svoj utjecaj pa ih je potrebno povremeno pregledavati i osvježavati.

Najvažniji atribut je djelotvornost. Ako je trend nepovoljan, korisnici bi trebali znati što je potrebno poduzeti da se trend ispravi. Isto tako, korisnik mora biti sposoban kontrolirati ishod. Kod slijepog slijeđenja SMART pravila, ova karakteristika nije uključena [11].

3.4. Primjeri ključnih pokazatelja uspješnosti

U ovom poglavlju bit će navedeni najčešći ključni pokazatelji uspješnosti u svrhu shvaćanja što isti predstavljaju i što se sve može pomoću njih pratiti.

Svaki od pokazatelja ima iza sebe cilj koji se želi postići, a mjerenjem specifičnog pokazatelja učinka vidljivo je krećemo li se prema cilju. Na primjer, ukoliko želimo smanjiti broj pogrešaka u isporukama, ključni pokazatelj uspješnosti bio bi iznos pogrešaka, a cilj je 5 ppm (dijelova na milijun).

Ključni pokazatelji uspješnosti podijeljeni su u tri kategorije: proizvodnja, kvaliteta i održavanje [12].

Neki od KPI-eva vezanih uz proizvodnju [12]:

- Dostupnost (A) – postotak vremena u kojem je stroj dostupan
- Učinkovitost dodjele poslova (AE) – korištenje i dostupnost planiranog kapaciteta stroja
- Tehnička učinkovitost (TE) – učinkovitost proizvodnje naspram prekida
- Učinkovitost radnika (WE) – učinkovitost radnika u proizvodnji
- Učinkovitost korištenja (UE) – produktivnost stroja
- Efektivnost (E) – koliko dobro stroj radi tijekom vremena proizvodnje
- Stopa protoka (TR) – pokazatelj učinka procesa u smislu proizvedene količine narudžbe i stvarnog vremena izvršenja
- Vrijeme blokiranja (BLT) – vrijeme mirovanja opreme tijekom proizvodnje kad se čekaju dijelovi

KPI-evi vezani uz kvalitetu [12]:

- Omjer stvarnog i planiranog otpada (SQR) – odnos stvarne količine otpada i planirane količine otpada.
- Omjer otpada (SR) – odnos između količine otpada i proizvedene količine.
- Omjer dorade (RR) – postotak količine prerade među proizvedenom količinom.
- Kvaliteta prvi put (FTQ) – postotak dijelova dobre kvalitete koji prvi put prolaze kroz proizvodni proces.

- Stopa dobre kvalitete za prodaju (QBR) – ukupan postotak dijelova dobre kvalitete nakon dorade.

KPI-evi vezani uz održavanje [12]:

- Srednje vrijeme do kvara (MTTF) ili između otkaza (MTBF).
- Srednje vrijeme za popravak (MTTR).
- Srednje vrijeme kašnjenja (MDET).
- Srednje vrijeme postavljanja (MSET).

Kombinacija KPI-eva je gotovo beskonačna i ovisi o specifičnosti samog procesa proizvodnje [12].

Odabir pravih KPI-eva će omogućiti bolje donošenje odluka, poboljšati izvedbu, pomoći brže definirati područje problema te poboljšati veze između dobavljača, tvrtke i kupaca [11].

4. VIZUALIZACIJA

4.1. Važnost vizualizacije

Istraživanje i povezivanje ključnih pokazatelja uspješnosti vrlo je ozbiljno shvaćeno, a često je sporedna stvar njihov prikaz. Bez dobrog razumijevanja odnosa između KPI-eva, teško je doći do optimalne odluke za poboljšanje procesa. Vizualna analiza pojednostavljuje interakciju ljudi i podataka i odluke čini lakšima. InfoVis (Information vizualization) se najranije pojavljuje 1932. kao kontrolna karta procesa koju je predložio fizičar Walter A. Shewhart kao statističku tehniku za primjećivanje uzoraka u procesu. Digitalizirana postrojenja u proizvodnji prikazuju procesne podatke, a različite boje predstavljaju različita stanja sustava. Takav *lean* alat uvelike poboljšava inženjersku praksu [13].

4.2. Primjeri vizualizacije

Najjednostavniji prikaz je tablični. Podaci su u tablici strukturirani u retke i stupce, a u slučaju kada treba prikazati različite tipove podataka tablica je bolje rješenje od grafikona. Tablica treba biti smisleno strukturirana, pregledna i bez nepotrebnih boja koje će samo odvući pažnju od bitnog – podataka. Baze podataka se temelje na tabličnim unosima podataka, a tablice su zastupljene u računovodstvu, poslovnim evidencijama i analizama jer su pregledne i čitke. Tablični prikaz je najčešće osnova za izradu drugih tipova vizuala [14].

Grafikoni su, za razliku od tablica, vizualno koncipirani. Dobar koncept grafikona prenosi informacije dvostruko brže od tablice, a odgovarajući grafikon može se pronaći u širokoj lepezi tipova. Tip grafikona određuje se prema vrsti podataka. Tablični podaci u stupcima ili redovima prikazuju se jednostavno linijskim grafikonom. Horizontalna os grafikona prikazuje kategorije, a vertikalna vrijednosti. Primjeren je za prikaz trendova. Slika 6. prikazuje linijski grafikon, izrađen u programu Excel [14].

Slika 6. Linijski grafikon [izrada autora]

Stupčasti grafikoni koriste se kod usporedbe vrijednosti. Naziv stupčasti proizlazi iz toga što su vrijednosti u grafikonu prikazane u stupcima, horizontalno ili vertikalno. Jedna os prikazuje vrijednosti, a druga kategorije čije se vrijednosti uspoređuju. Najčešće se koristi vertikalan dvodimenzionalni prikaz zbog jednostavnosti izrade, ali i dobivanja informacija pogledom na isti [14]. Stupčasti grafikon prikazan je na Slici 7.

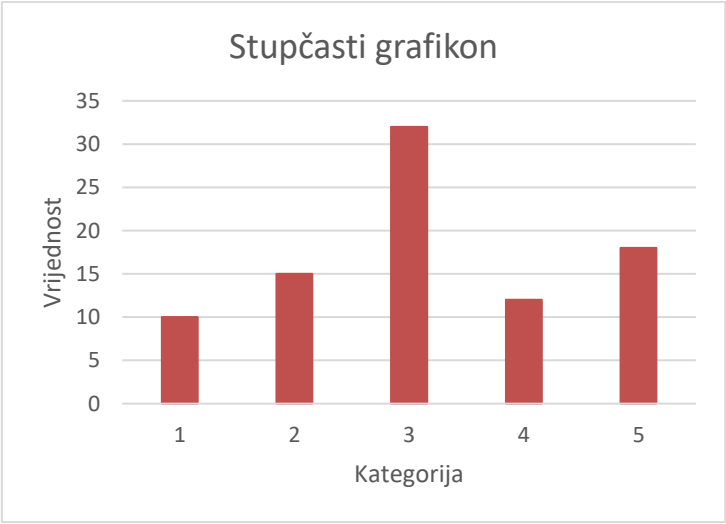

Slika 7. Stupčasti grafikon [izrada autora]

Točkasti/raspršeni grafikon prikazuje korelaciju dviju varijabli, zavisne (promjenjive) i nezavisne (kontrolne) varijable. Raspršene dijagrame ne koristimo za prikazivanje točnih vrijednosti, već za usporedbu velikih skupina podataka. Veći broj podataka znači kvalitetniju usporedbu i bolji grafikon. Slika 8. prikazuje raspršeni grafikon.

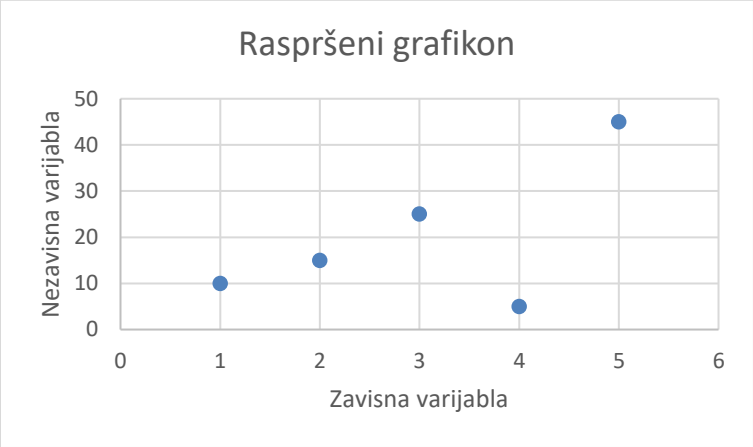

Slika 8. Raspršeni grafikon [izrada autora]

Tortni grafikon je jedan od jednostavnijih i češće korištenih, uz bok stupčastom. Koristi se kad se želi prikazati udio vrijednosti u odnosu na cjelinu. Potrebno je obratiti pažnju na broj kategorija (preporučuje se do sedam kategorija) kako se ne bi izgubila preglednost – najbitnija značajka grafikona. Na Slici 9. prikazan je takav grafikon u kojem je prikazano pet kategorija [14].

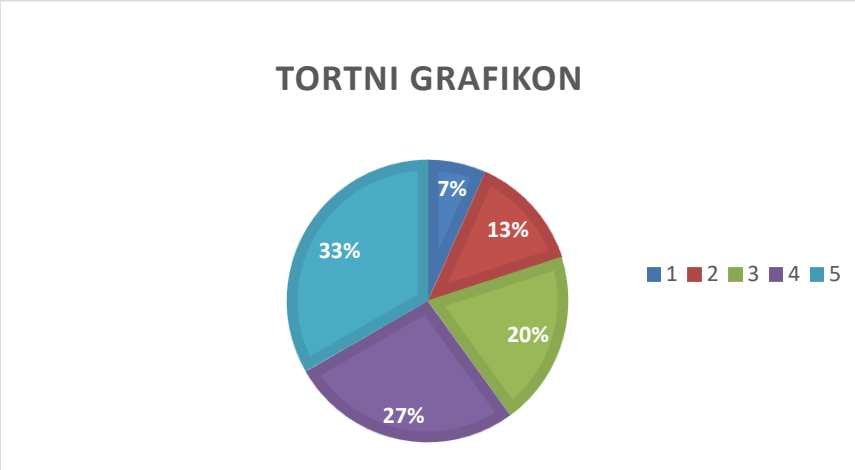

Slika 9. Tortni grafikon [izrada autora]

U nastavku će biti opisani nešto složeniji grafikoni. Grafikoni veze čvorova (*Node-Link*) prikazuju odnose pomoću linija između različitih elemenata predstavljenih čvorištima, odnosno krugovima. Koriste se za prikaz odnosa između KPI-ja i odgovarajućih mjera. Korisni su za općeniti pregled veza mjera i KPI-eva, ali ne prikazuju kako zapravo utječu elementi jedni na druge. Dobro je suziti podatke na one najvažnije jer u suprotnom, ako ima puno veza, lako

izgubiti fokus i prikaz postaje nepregledan. Položaj čvorova određuje dizajner koji ima fleksibilnost vizualizirati čvorove po potrebi [13].

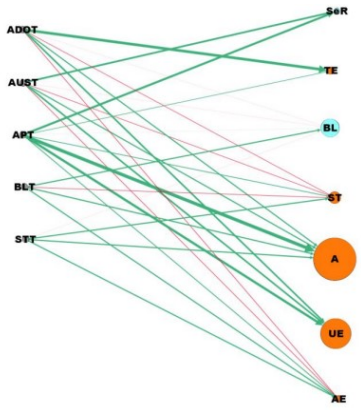

Slika 10. Vizualni prikaz čvorovima [13]

Vizualizacija temeljena na matrici je, za razliku od čvornih, prikladna za guste mreže. Druga prednost je što se njima može ilustrirati napredna analitika. Slika 11. prikazuje iste podatke kao i Slika 10., no ovdje se umjesto povećanja promjera čvora za izražavanje utjecaja na KPI utjecaj označuje bojom (žuta boja – nema utjecaja na KPI, crvena boja – negativan učinak na KPI, zelena boja – pozitivan učinak na KPI) [13].

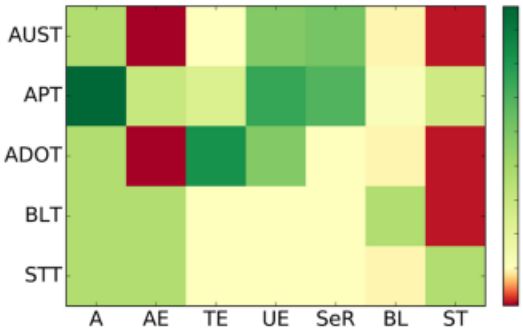

Slika 11. Matrični vizualni prikaz [13]

Vizualizacije pomoću panel grafikona (engl. *Small Multiples)* imaju jednaku os i jednaku skalu za jednostavnu usporedbu, u ovom slučaju, usporedbu utjecaja mjera na KPI-eve. Pregledni su do jedne razine, ali preveliki opseg podataka može ih učiniti vrlo složenima [13]. Primjer je Slika 12., koja prikazuje mjesečnu stopu nezaposlenosti po saveznim državama u SAD-u.

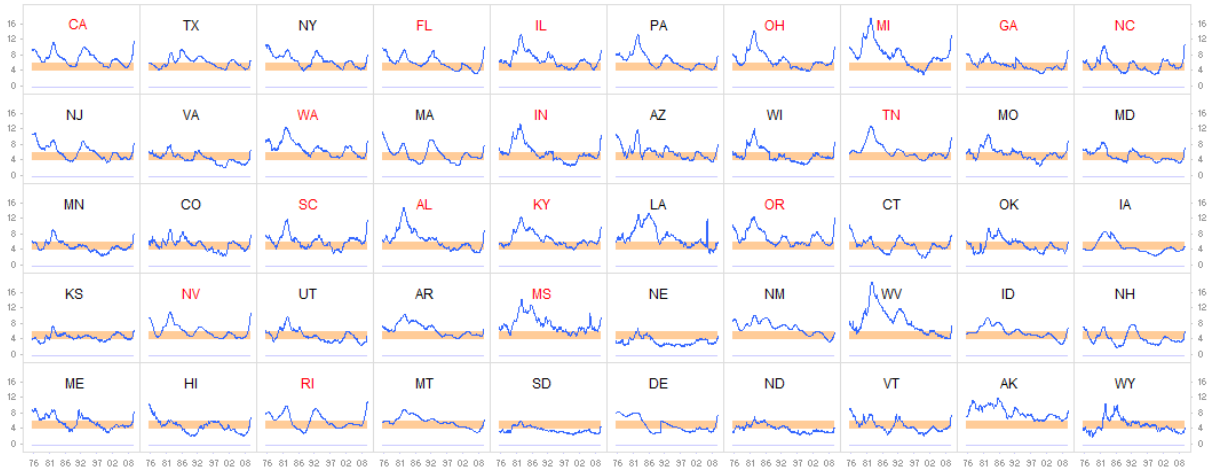

Slika 12. Panel grafikoni [15]

Što se tiče prikaza ključnih pokazatelja uspješnosti, najčešći ključni pokazatelji su objedinjeni na SQCDP ploči. To je vizualni prikaz koji brzo prenosi informacije o izvedbi u određenim ključnim područjima. Specifično, prikazuje Sigurnost (engl. *Safety*), Kvalitetu (engl. *Quality*), Troškove (engl. *Cost*), Isporuku (engl. *Delivery*) i Ljude (engl. *People*). Ploča bi se trebala nalaziti na timu vidljivom mjestu da im pomogne pratiti informacije i reagirati na vrijeme [16]. Primjer jedne takve ploče nalazi se na Slici 13.

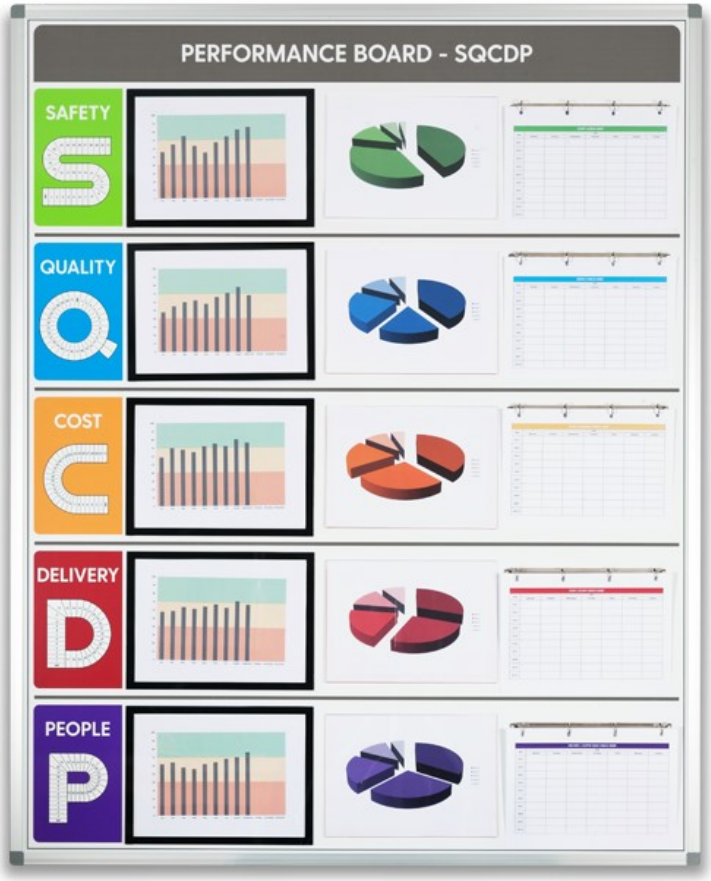

Slika 13. Kontrolna ploča SQCDP [17]

U nekoliko koraka može se izraditi SQCDP ploča. Prvi korak je identifikacija ključnih mjera za svako od navedenih područja. Neki od primjera za sigurnost su dani bez ozljeda, dani bez kršenja mjera zaštite na radu. Za kvalitetu važno je pratiti škart, prinos procesa, kod dostave može se pratiti kad je proizvod došao do kupca i vodeće vrijeme. Za područje troškova može se pratiti kada se pojavljuju nedostaci na završnim provjerama, a u području koje prati zaposlenike mogu se pratiti planirani prekovremeni sati ili matrica kompetentnosti. Sljedeći korak je postaviti ploču na dobro vidljivo mjesto zaposlenicima. Na kraju dana, tim evaluira pokazatelje koji su određeni u prvom koraku. Ako je dan bio uspješan u određenom području označava se zelenom bojom, u suprotnom slučaju crvenom. Posljednji korak je evaluacija trendova. Samim pogledom na ploču može se vidjeti koja su područja uspješna, a na kojima treba poraditi. Ako se promjene naprave, a i dalje je područje u crvenoj boji moraju se poduzeti učinkovitije mjere za poboljšanje. U tom slučaju Pareto dijagram može biti koristan za prepoznavanje problema. Kada se identificira problem, mora se otkriti zašto dolazi do

problema. Svakako bi trebalo slijediti Kaizen filozofiju i kontinuirano, svakodnevno, raditi na unapređenju procesa u tvrtki [16].

4.3. Alati za vizualizaciju

Svako poduzeće odabire alate za vizualizaciju primjerene svojim potrebama. Svaki program ima prednosti i nedostatke za određenu namjenu, a kod odabira se uključuje i faktor cijene.

Kontrolna ploča, odnosno interaktivno sučelje, omogućuje korisniku pregled svih podataka i krajnjem korisniku najbitniji je dio softvera. Jednostavnost, strukturiranost i prilagodljivost najvažnije su značajke kontrolne ploče.

4.3.1. Značajke alata za vizualizaciju

U znanstvenom članku „Karakteristike softvera za vizualizaciju podataka“ prikazano je istraživanje o alatima za vizualizaciju. Podaci su prikupljeni s internetske stranice Capterra koja je korisnicima pomoć u pronalaženju softvera koji najbolje zadovoljava njihove potrebe.
S navedene stranice prikupljeno je 1163 značajki koje su razvrstane u 53 kategorije. Na Slici 14. prikazane su najzastupljenije značajke u alatima za vizualizaciju. Najzastupljenijih pet kategorija su Vizualizacija podataka, Poslovna inteligencija, Izvještaji, Kontrolna ploča i Analitika. Kao što se moglo očekivati, najčešće se pojavljuje kategorija Vizualizacija podataka koja je zastupljena u 84 % alata. Ova kategorija podrazumijeva značajke: Upravljanje sadržajem, Modeli simulacije, Filtrirani pogledi, Relacijski prikaz, OLAP, Vizualno pronalaženje. Po zastupljenosti druga kategorija je Poslovna inteligencija u koju spadaju značajke: Ad hoc izvještaji, Indikatori ključnih performansi, Vrednovanje, Strateško planiranje, Tablice rezultata i Strateško planiranje [18].

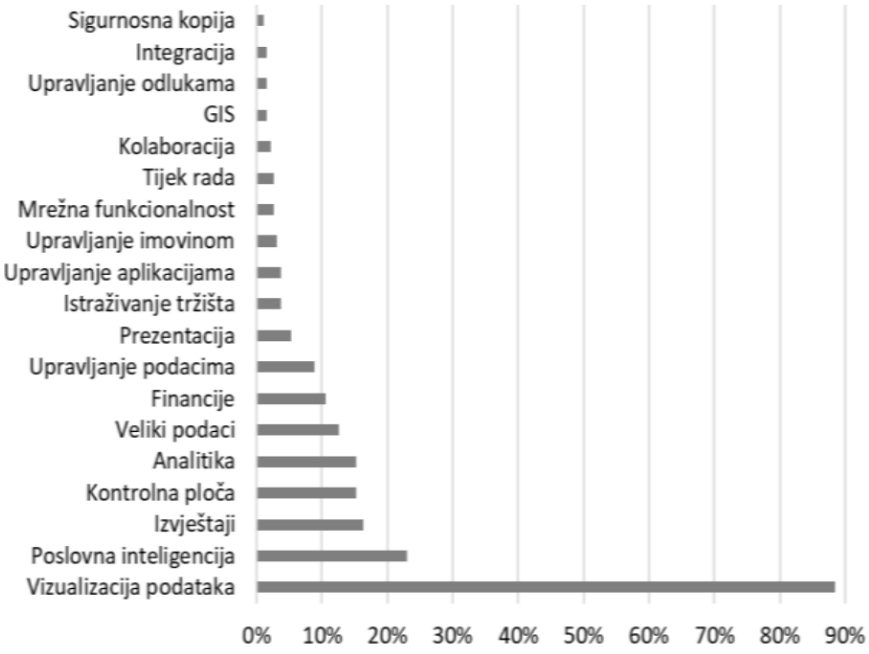

Slika 14. Kategorije značajki softvera za vizualizaciju [18]

Slika 15. prikazuje najzastupljenije značajke alata, bez obzira na kategoriju. Prvih pet značajki su Analitika i izvještavanje, Prilagođene kontrolne ploče, Filtrirani pogledi, Vizualno pronalaženje i Relacijski prikaz [18].

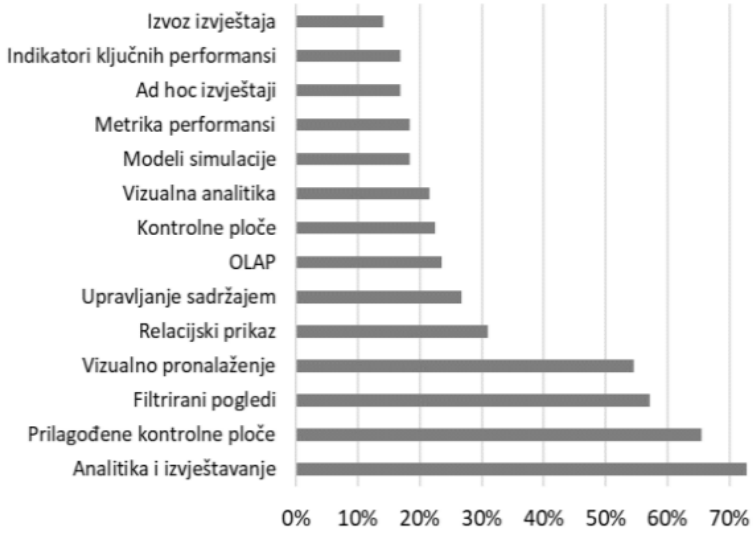

Slika 15. Značajke softvera za vizualizaciju [18]

Istraživanje iz članka potvrdilo je da su najzastupljenije značajke u softverskim alatima za vizualizaciju izvještaji, filtriranje i kontrolne ploče. To su ujedno i najjednostavnije značajke, dok se rad s velikim podacima, prediktivna analitika, otkrivanje uzoraka i automatskih upozorenja često ne spominju. Isto tako izostaju moderne tehnike vizualizacije temeljene na umjetnoj inteligenciji, virtualnoj stvarnosti i analizi u stvarnom vremenu.

4.3.2. Vrste alata za vizualizaciju

4.3.2.1. Tableau

Tableau je softver za vizualizaciju podataka razvijen 2003. godine, a korisnikom mogu postati svi koji trebaju vidjeti i razumjeti podatke. Korišten je u različitim granama: financijske institucije, policija, vojska, medijske kuće, bolnice, izdavačke kuće, edukacijske institucije, osiguravateljske kuće, proizvode i distributivne kompanije [19]. Neke od prepoznatljivih kompanija koje koriste Tableau su Linkedin, Lenovo, Jaguar Land Rover, Specialized, Whole Foods, Nissan… [20]

Softver je vrlo prilagodljiv te omogućava korisniku da sam stvara svoje izvještaje koji su mu relevantni. I manja poduzeća koriste Tableau jer na jeftin način omogućava pretvaranje podataka u korisne informacije [19].

Temeljna tehnologija softvera VizWL vizualno prikazuje podatke transformacijom akcije povlačenja i ispuštanja (engl. *drag-and-drop*) u podatkovne upite kroz interaktivno sučelje. Korištenje softvera je vrlo intuitivno, a podaci za korištenje u analizi mogu biti u bazama podataka, na mreži, u oblaku ili u obliku tablica za izradu interaktivnih kontrolnih ploča. Neki od Tableau proizvoda koji sinergijom omogućavaju obradu i transformaciju podataka, analizu i vizualni prikaz su: Tableau Desktop, Tableau Server (spremanje podataka), Tableau Online, Tableau Vizable (mobilna aplikacija za vizualizaciju podataka), Tableau Mobile i drugi. Tableau nudi i besplatne proizvode, a to su Tableau Public i Reader koji su namjenjeni dijeljenju i pregledavanju vizualizacija. Na Slici 16. prikazano je korisničko sučelje Tableau Desktopa [20].

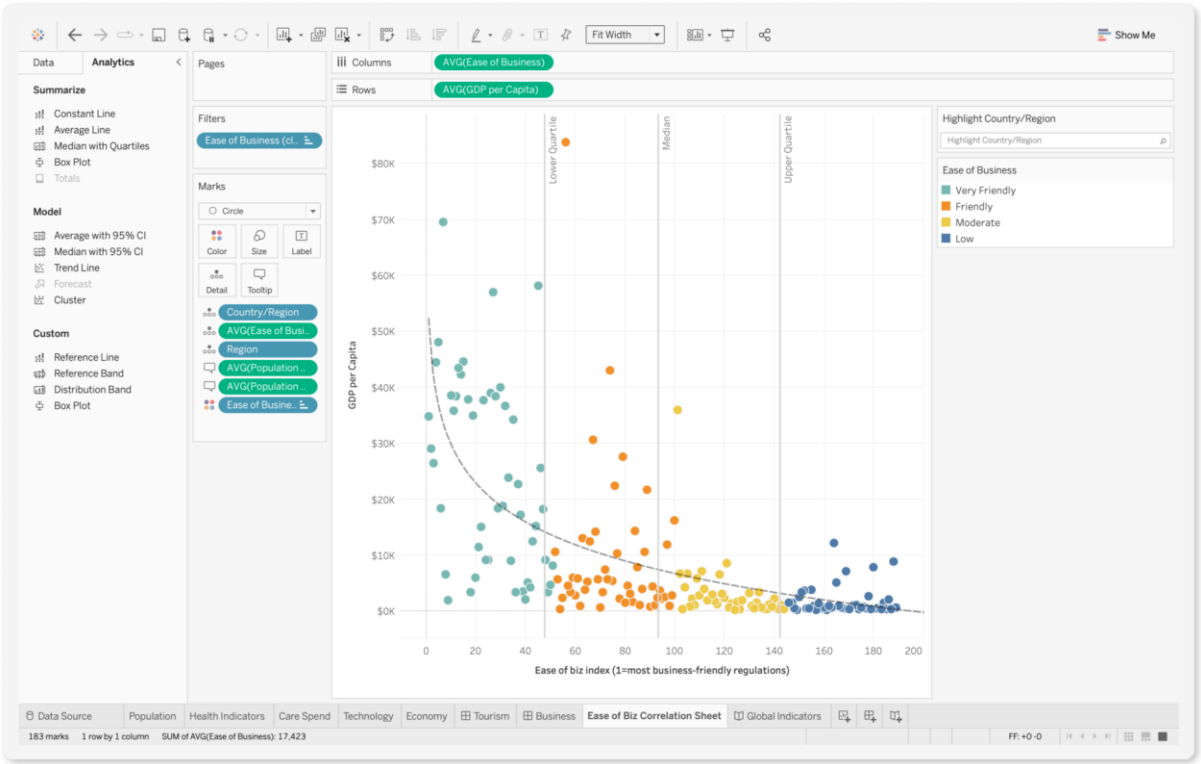

Slika 16. Tableau Desktop [20]

4.3.2.2. Qlik

Drugi utjecajan alat za vizualizaciju je Qlik, odnosno QlikSense. Ovaj softver nudi takozvane „Self-service“ vizualizacije, interaktivne kontrolne ploče, pretraživanja, alarme, izvještaje, naprednu analitiku i personalizaciju, a podaci za analizu se mogu, kao i kod većine sličnih alata, preuzimati s različitih izvora. *Self-service* vizualizacija omogućava jednostavno kombiniranje, učitavanje i vizualiziranje podataka bez obzira na njihovu količinu. Svaki grafikon, tablica i objekt su interaktivni i ažuriraju se trenutno. Interaktivne su i kontrolne ploče, kod kojih je u slučaju abnormalnosti lako uroniti u podatke i istražiti što se događa. Kontrolne ploče s QlikSense-om postaju odskočne daske za donošenje boljih, na podacima temeljenih odluka. Sustav za alarmiranje je koristan kada želimo da reakcija na promjene u praćenim podacima bude trenutna. Tehnologija za alarmiranje je u potpunosti temeljena na podacima, a ne na vizualizacijama kao kod nekih sličnih alata. Na Slici 17. prikazan je primjer kontrolne ploče u sučelju softvera. Korisnici ovog alata su mnoge prepoznatljive kompanije, a neke od njih su Volvo, Sephora, Samsung, Aramark, Honda [21].

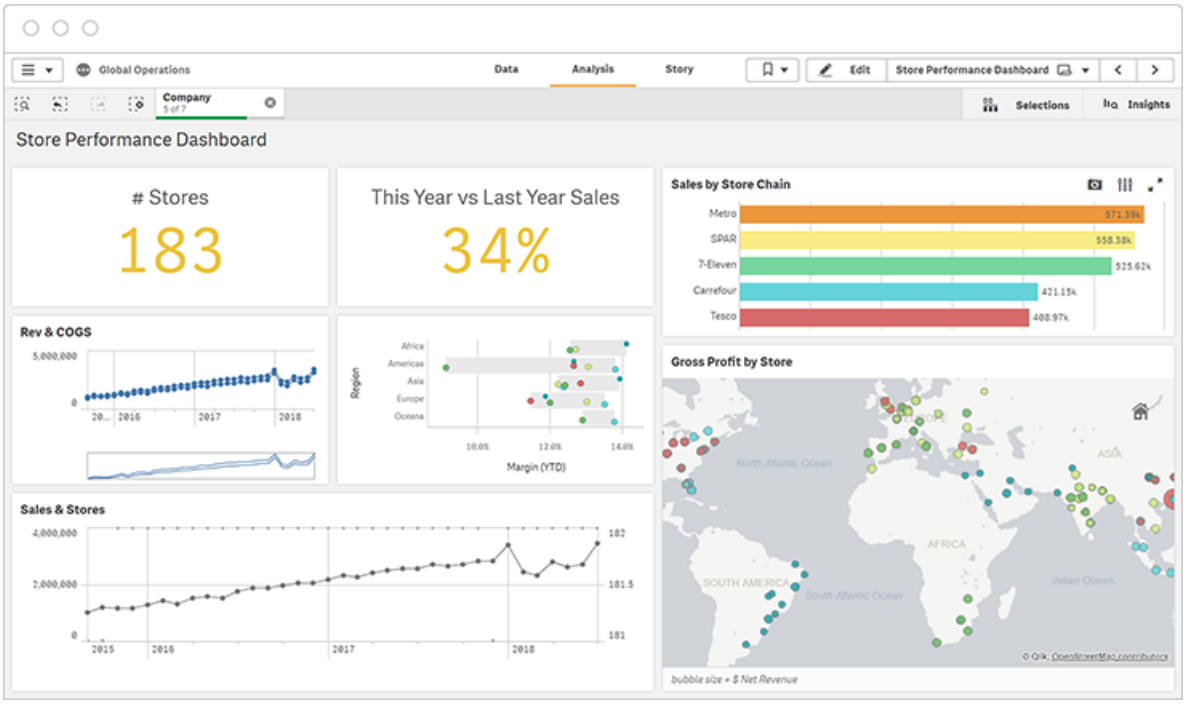

Slika 17. Kontrolna ploča u alatu Qlik [21]

4.3.2.3. Plotly

Plotly je još jedan alat za analizu i vizualizaciju podataka. To je paket za izradu interaktivnih vizualizacija podataka koje će se prikazivati na mreži, a može se koristiti u okviru programskih jezika kao što su Phyton, R, MATLAB… Za takvu vrstu vizualizacije potrebno je poznavanje programskih jezika i njihove sintakse, pa se ne preporuča početnicima [22]. Može se koristiti u području umjetne inteligencije i strojnog učenja, velikih podataka, automobilskoj industriji, farmaciji, energetici, financijama, proizvodnji i slično [23].

4.3.2.4. Excel

Excel je vodeći Microsoft alat, dio Office paketa, specijaliziran za proračunske tablice. Koristi se u svim industrijskim granama, školstvu pa i kućanstvima. Moguće je stvarati proračunske tablice samostalno i izvoditi izračune pomoću vlastitih formula. Iz tablica moguće je stvaranje jednostavnijih grafikona, a čak i predviđanje trendova. Izrada tablica može biti u stvarnom vremenu i s drugim korisnicima, a datotekama se može pristupiti s računala, putem mreže ili s mobilnog uređaja. Nova zanimljiva značajka je dodavanje tablica direktno s fotografije na kojoj se nalazi analogna tablica, a nakon transformacije u digitalno omogućeno je potpuno uređivanje. Tako se korisniku omogućuje brži i lakši način digitalizacije, bez ručnog upisivanja [24].

4.3.2.5. Power BI

Power BI, Microsoft alat, može stvarati interaktivne vizualizacije podataka i izvještaje. Moguće je kombinirati, povezivati i modelirati te na kraju vizualizirati podatke. Omogućeno je i dijeljenje sadržaja s timom objavom sadržaja na web-servisu. Power BI ima više proizvoda: Power BI Desktop, Power BI Service, Power BI Mobile i Power BI Report Server. Koji proizvodi će se koristiti ovisi o paketu kojeg tvrtka želi kupiti, a Power BI Desktop je besplatan. On omogućava transformiranje i kombiniranje podataka iz raznih izvora (Excel tablice, skladište podataka, oblak, s mrežnih stranica…), proširivanje podatkovnih modela uz DAX formule, otkrivanje uzoraka, stvaranje vlastitih dizajna uz jednostavno oblikovanje, stvaranje mobilnih izvještaja [25]…

Na Slici 18. prikazano je korisničko sučelje Power BI Desktopa s već vizualiziranim podacima.

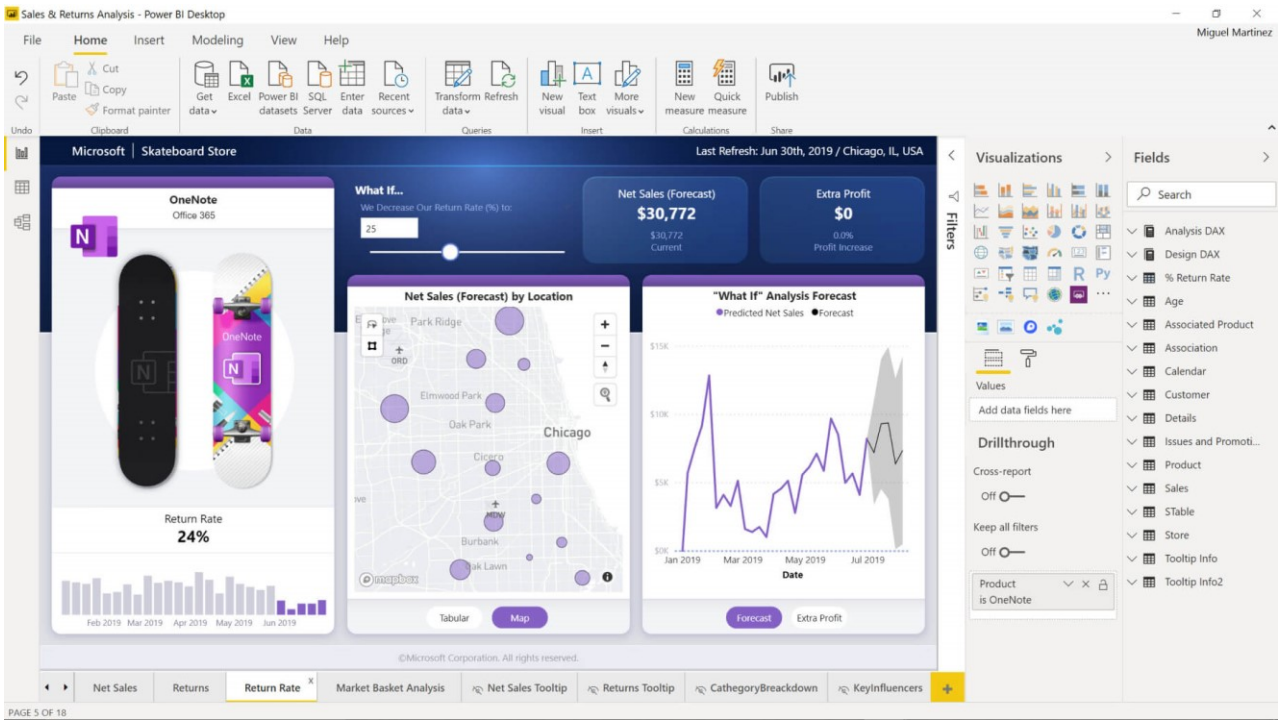

Slika 18. Power BI [26]

4.3.3. Usporedba alata za vizualizaciju podataka

U studiji naziva „Big Data Visualization: Tools and Challenges“ uspoređeni su neki od softvera za vizualizaciju podataka. To su Tableau, Power BI, Plotly, Gephi i Excel 2016. U Tablici 1. su prikazane neke od bitnih karakteristika i podaci o tome koje karakteristike sadrži pojedini program [27].

U tablici su navedene ove karakteristike [27]:

- Open Source – ako alat ima otvoreni izvor ili ne
- kompatibilnost s poznatim izvorima – uključujući MapR Hadoop Hive, Salesforce, Google Analytics, Cloudera Hadoop…
- interaktivne vizualizacije – jesu li vizualizacije interaktivne ili ne
- Desktop, Online, Mobilna aplikacija – gdje se sve može koristiti alat
- dostupni tutorijali – postoje li dostupni tutorijali za učenje korištenja alata
- API – postoji li aplikacijsko programsko sučelje (za međusobnu komunikaciju aplikacija).

Sve aplikacije imale su dostupne tutorijale za učenje korištenja i interaktivne vizualizacije podataka.

Tablica 1. Usporedba alata za vizualizaciju podataka [27]

	Open Source	Kompat. s poznatim izvorima	Interak. vizualizacije	Desktop	Online	Mobilna aplikacija	Dostupni tutorijali	API
Tableau	Ne	Da	Da	Da	Da	Da	Da	Da
Power BI	Ne	Da	Da	Da	Da	Da	Da	Da
Plotly	Da	Ne	Da	Ne	Da	Ne	Da	Da
Gephi	Da	Ne	Da	Da	Ne	Ne	Da	Ne
Excel	Ne	Da	Da	Da	Da	Da	Da	Da

5. MICROSOFT POWER BI – Primjer korištenja

Koristeći kombinaciju IDEF0 i Power BI-ja, studija u Indoneziji 2021. godine je uspješno identificirala, transformirala i dizajnirala integrirani sustav upravljanja učinkom za proučavanu tvrtku. Koristeći Power BI, predložene su integrirane kontrolne ploče (engl. *dashboard*) oko postojećeg tijeka rada i izvješća tvrtke. IDEF0 je korišten kako bi se obuhvatili zahtjevi procesa od početka do kraja, dok se osigurava da sve što se prati jest smisleno i bitno za druge procese. Power BI je korišten zbog jednostavnosti za korisnike, njegove snage u vizualizaciji podataka i mogućnosti zaobilaženja postojećeg Excel radnog lista [28].

Snaga Power BI alata sadržana je u nekoliko značajki: vizualizacija u trenutku s svježim podacima na prilagodljivoj ploči, generiranje sadržajnih izvješća, različitost grafikona, upiti na jednostavnom jeziku, mogućnost korištenja na mobilnom uređaju.

Nakon obrade podataka, izrađene su kontrolne ploče. Prva je za praćenje mjera u odjelu prodaje i marketinga. Izgrađena je upitima koji povezuju detalje narudžbe kupaca s glavnim podacima o kupcu i proizvodu. Na ovoj kontrolnoj ploči predloženo je filtriranje grafikona prema datumu, tvrtki, kategoriji proizvoda, vrsti proizvoda i broju narudžbenice. Vizualizirane su mjere iznosa narudžbe, troška narudžbe i profit.

Sljedeća važna kontrolna ploča je bila kontrolna ploča za proizvodnju, mjere su se mogle interaktivno filtrirati na temelju datuma, proizvoda, radne skupine i stroja. Prikazani KPI-evi su učinkovitost stroja, izvedba s obzirom na kvalitetu (dobro/potrebna prerada/škart), trošak rada te procijenjena potrošnja i trošak električne energije. Prikazi obje kontrolne ploče su na Slici 19. [28].

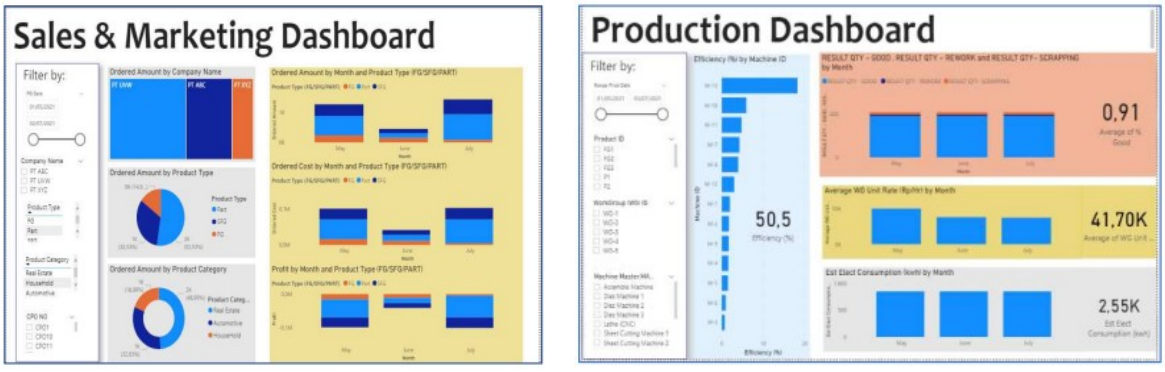

Slika 19. Kontrolne ploče u Power BI [28]

Osim prikazane dvije ploče, izrađene su još tri. PPIC kontrolna ploča koja vizualizira zahtjeve za materijalom i trošak materijala te otpad od proizvodnje. Na ploči se može filtrirati prema datumu, proizvodu i stroju. Sljedeća ploča je kontrolna ploča Nabave i skladišta, a prikazuje iznos kupnje koji se može filtrirati prema datumu, vrsti materijala i dobavljaču. Posljednja ploča je menadžerska kontrolna ploča koja objedinjuje sve četiri ploče i koncentrira se na troškove i učinkovitost [28].

Power BI omogućio je korištenje podataka u svrhu dobivanja informacija za više odjela. Mogao se koristiti i neki drugi alat za vizualizaciju, no besplatno korištenje programa (do neke granice) i intuitivnost korištenja Microsoft alata općenito velike su prednosti zbog kojih je Power BI odabran.

6. MAPIRANJE PROIZVODNOG PROCESA

6.1. Proces

Proizvodni proces definira se kao proces u kome se čimbenici proizvodnje, odnosno ulazi resursa, pretvaraju u korisne izlaze. Na Slici 20. je prikazan grafički. Čimbenici proizvodnje smatraju se kapital, rad, tehnologija, zemlja i drugi resursi koji se koriste za stvaranje proizvoda i usluga. Kapital uključuje iznos uložen u proces proizvodnje. Ulaganje može biti u novčanom smislu ili kao imovina poput strojeva, vozila i slično. Rad se odnosi na ljude te vrijeme i trud koji ulažu u proces. Tehnologija podrazumijeva vrste strojeva i programe te kapacitet strojeva, ali i sve tehničke aspekte koji ne trebaju intervenciju čovjeka. Unutar kategorije zemlje uključeni su i energija i ostali prirodni resursi koji se koriste u procesu. Izlazi su proizvodi ili usluge [29].

Slika 20. Grafički prikaz procesa [izrada autora]

6.2. *Lean* metodologija

Svako poduzeća teži smanjiti gubitke i škart jer se tako direktno smanjuju troškovi. U tu svrhu često se odabire *lean* filozofija, odnosno vitka proizvodnja. Temeljna ideja *lean* proizvodnje je neprestani rad na uklanjaju gubitaka i općenito usmjeravanje na stvaranje visoke vrijednosti proizvoda uz optimizirane proizvodne procese. Potrebno je maksimalno iskoristi resurse, a otpad minimalizirati.

Za uspješno uvođenje *lean*-a potrebno je obuhvatiti što je više moguće metoda i alata, a neki od njih su Mapiranje toka vrijednosti, U-oblik proizvodne linije, kontrola inventara, *Pull* sistem, Kanban i ostali [30].

Pet načela *lean* proizvodnje su [31]:

1. Utvrđivanje vrijednosti - Da bismo bolje razumjeli prvo načelo utvrđivanja vrijednosti, važno je razumjeti što je vrijednost. Vrijednost je ono što je kupac spreman platiti. Najvažnije je otkriti stvarne korisnika i za što žele dati svoj novac. Ponekad kupci možda ne znaju što žele ili nisu u stanju to artikulirati, obično kada su u pitanju novi proizvodi ili tehnologije. U tom slučaju se može raznim tehnikama poput intervjua, ankete i web analitikama otkriti ono što kupci smatraju vrijednim. Korištenjem ovih kvalitativnih i kvantitativnih tehnika može se otkriti što kupci žele, način isporuke i cijenu koju su spremni platiti.
2. Mapiranje toka vrijednosti - Drugo *lean* načelo je identificiranje i mapiranje toka vrijednosti. U ovom koraku cilj je koristiti vrijednost korisnika kao referentnu točku i identificirati sve aktivnosti koje pridonose tim vrijednostima. Aktivnosti koje ne dodaju vrijednost krajnjem kupcu mogu se podijeliti u dvije kategorije: bezvrijedno dodan, ali neophodan (neophodan gubitak) te bezvrijedan i nepotreban (čisti gubitak). Drugi slučaj treba eliminirati, a prvi treba smanjiti što je više moguće. Smanjenjem i eliminacijom nepotrebnih procesa ili koraka mogu se osigurati željeni proizvodi ili usluge kupcu, istovremeno smanjujući troškove proizvodnje tog proizvoda ili usluge.
3. Osigurati tok bez zastoja - Nakon uklanjanja nepotrebnih koraka i akcija iz toka vrijednosti, sljedeća radnja je osigurati da tijek preostalih koraka teče nesmetano bez zastoja ili kašnjenja.
4. Uspostaviti povlačenje (engl. *pull*) - Zalihe se smatraju jednim od najvećih gubitaka u bilo kojem proizvodnom sustavu. Cilj sustava temeljenog na povlačenju je ograničiti zalihe i stavke u procesu rada, a istovremeno osigurati da su potrebni materijali i informacije dostupni za neprekinut tijek rada. Odnosno, sustav koji se temelji na povlačenju omogućuje isporuku i proizvodnju točno na vrijeme gdje se proizvodi stvaraju u vrijeme kada su potrebni i u samo potrebnim količinama. Sustavi temeljeni na povlačenju uvijek se stvaraju prema potrebama krajnjih kupaca.
5. Težiti perfekciji - Gubitak se sprječava postizanjem prva četiri koraka, međutim peti korak u potrazi za perfekcijom najvažniji je među njima. Od želje za perfekcijom

započinje *lean* razmišljanje te bi bilo poželjno da kontinuirano poboljšanje procesa postaje dijelom organizacijske kulture. Svaki zaposlenik treba težiti savršenstvu dok dodaje vrijednost proizvodu, a tvrtka bi trebala neprestano učiti i pronalaziti načine da se svakim danom barem malo poboljša.

Odnosi ovih pet načela prikazani su na Slici 21. na kojoj je vidljivo da su načela međusobno ovisna i povezana te da je to kružni, neprekinuti proces koji se ponavlja u želji za poboljšanjem i perfekcijom.

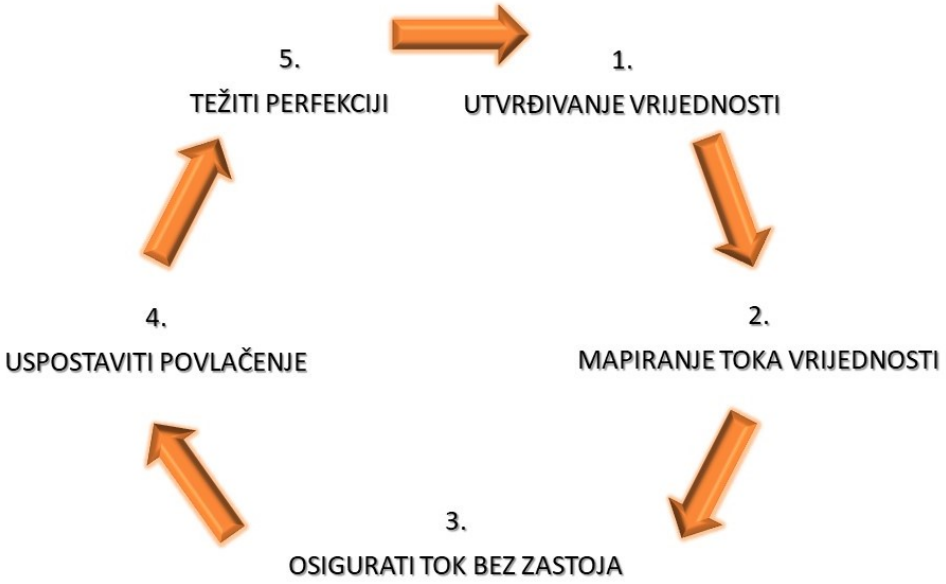

Slika 21. Načela *lean* metodologije [izrada autora]

6.3. Mapiranje toka vrijednosti i mapiranje procesa

Postoje mnogi aspekti koje treba uzeti u obzir kod implementacije *lean*-a, a jedan od temeljnih alata je Mapiranje toka vrijednosti. Mapiranje toka vrijednosti je proces izrađivanja dijagrama svih koraka, materijala i informacija potrebnih za dovođenje proizvoda od narudžbe do isporuke. Alat „Dijagram toka i materijala“ razvila je Toyota te je kritičan dio Toyotinog proizvodnog sustava. Tok vrijednosti su sve radnje (one koje dodaju vrijednost i one koje ne dodaju vrijednost) potrebne da se proizvod isporuči. Prvo je potrebno je stvoriti mapu trenutnog i stvarnog stanja, a potom izraditi buduću mapu koja prikazuje željeni tok materijala i informacija. Ponavljanje ovog postupka je najbolji način za prepoznati vrijednost u procesu.

Prednosti kod ovog alata su to što pruža korisnicima da vide više od gubitaka, odnosno da vide izvore gubitaka u toku vrijednosti. Osim toga, jednoznačno definira proces tako da olakšava razgovor o procesu što čini odluke očiglednima cijelom timu. Ako to ne bi bio slučaj, odluke bi se donosile ovisno o pojedinačnim pretpostavkama članova tima i ne bi svi imali jednak pogled na proces.

Mapiranje toka vrijednosti znači rad na široj slici, a ne individualnom procesu i koristimo ga za poboljšati cjelinu, a ne samo optimiziranje nekih dijelova [32].

Drugi alat, Mapiranje procesa, koristimo kako bismo proces detaljno opisali i koncentrirali se samo na jedan proces i njegovu standardizaciju. Kako se tvrtke polako oporavljaju od pandemije, počele su prilagođavati tradicionalne alate za *lean* upravljanje. Izazov im predstavlja prilagođavanje mapiranja procesa virtualnom okružju. Kako bi se prilagodili na rad od kuće, preporuka je da voditelj koristi kameru fokusiranu na zid ili bijelu ploču koja će prikazivati mapu procesa. Uz korištenje internetske video veze članovi tima prenosili bi korake procesa i druge informacije voditelju koji ih stavlja na ploču pomoću samoljepljivih papirića. Ovdje fokusiranje i pomicanje kamere predstavljaju izazov uz druge moguće tehničke poteškoće. Iz tog razloga vrlo je praktično koristiti računalne programe za izradu virtualnih ploča. U programu je lako označiti vremensku traku, glavne aktivnosti i ostale ključne događaje, ali potrebno je uložiti vremena da svi članovi tima nauče koristiti alat. Kod izrade ovakvih strukturiranih prikaza bitno je uključiti ljude koji su zaista uključeni u proces i dobro ga poznaju, a preporuča se uključiti i dobavljače i kupce. Tek tada svaki sudionik može pisati virtualne bilješke i dodavati na mapu aktivnosti za svoju funkciju u procesu, „šetajući“ kroz proces. Kad su članovi tima zajedno prošli kroz proces, preporuča se da svaki član tima prođe sam kroz mapu procesa prije sljedećeg virtualnog sastanka i uz to detektira gubitke i mogućnosti za poboljšanje procesa. Na sljedećem sastanku izrađuje se mapa budućeg unaprijeđenog stanja i plan provedbe. Ovaj cijeli postupak izrade mape procesa mora se ponavljati uz pitanja „Jesmo li postigli ono što smo mislili postići i što možemo poboljšati?“ [33].

Neke razlike između mapiranja toka vrijednosti i mapiranja procesa prikazane su u Tablici 2..

Tablica 2. Razlike između Mapiranja toka vrijednosti i Mapiranja procesa [32]

	ŠTO	ZAŠTO	KADA
Mapiranje toka vrijednosti	• Alat za širu sliku • Prikazuje sve povezane procese • Prikazuje problem s materijalom I informacijama • Holistički prikaz toka sustava s perspektive kupca	• Poboljšanja na temelju cjelovitih problema nasuprot parcijalnim poboljšanjima • Identificira gdje početi s izradom plana za poboljšanja	• Na početku problema
Mapiranje procesa	• Detaljno opisani koraci za izvršavanje operacije • Rastavlja proces na detalje • Koncentrira se na jedan proces • S perspektive radnika	• Identificira taktična poboljšanja procesa	• Za analizu kritične točke iz mape toka vrijednosti • Za stvaranje standardiziranih operacija

7. PLAN PROJEKTA

Praktični dio diplomskog rada odrađen je na procesu namatanja namota za transformatore u tvrtki Končar – Distributivni i specijalni transformatori, sa sjedištem i pogonom u Zagrebu. Tvrtka nudi distributivne transformatore, specijalne transformatore te srednje energetske transformatore. Transformatori su značajne komponente za distribuciju električne energije koji zadani električni napon pretvaraju u viši ili niži napon. U Končaru se nudi kompletna usluga projektiranja, proizvodnje, transporta, montaže, ispitivanja i puštanja u pogon [34].
Razlog provođenja ovog projekta je mapirati jedan proizvodni proces i prikazati primjenu softvera za vizualizaciju podataka na procesu te predložiti poboljšanja.

7.1. Svrha i cilj projekta

Svrha projekta detektirati trenutno stanje procesa, predložiti poboljšanja te transformirati podatke u upotrebljive informacije. Glavni cilj je vizualizirati pokazatelje koji se prate u procesu. Takva kontrolna ploča bi na jednostavniji način pokazivala napredak i eventualne poteškoće u procesu pa bi traženje uzroka i rješavanje problema bilo brže. Za poboljšanje procesa potrebno je na ispravan način koristiti podatke, a to uvelike olakšavaju BI alati kojima se redovi podataka mogu transformirati u korisne informacije.
Projekt je odrađen prema prethodno definiranom rasporedu, uz neka odstupanja. Aktivnosti su raspoređene po radnim tjednima 2022. godine u planu projekta prikazanom u Tablici 3. na sljedećoj stranici.

Tablica 3. Plan aktivnosti projekta [izrada autora]

RADNI TJEDAN	AKTIVNOST
18 -19	• Mapiranje podataka • Prikupljanje podataka koji nedostaju
20-22	• Prikupljanje podataka • Izrada Excel tablica
23	• Analiza trenutnog stanja prenošenja informacija u tvrtki
24-25	• Predlaganje poboljšanja • Izrada izvještaja

8. IZVEDBA PROJEKTA

8.1. SIPOC dijagram

Za određivanje bitnih elementa u procesu proizvodnje namota, izrađen je SIPOC dijagram (Slika 22.). Na ovome dijagramu prvo se definirao proces, izlazne veličine, kupac (odnosno sljedeći odjel koji preuzima ovaj namot - odjel Montaže), ulazne veličine te dobavljač (skladište, odjel izrade cilindara i izolacije). SIPOC dijagram omogućava fokus na proces sa šireg pogleda, koristi se jednostavni prikaz i definicije koje su jasne svima koji pogledaju dijagram. Takav prikaz dobar je za upoznavanje s procesom i svim njegovim elementima, na način koji nije previše detaljan, nego sadrži osnovne podatke o elementima procesa.

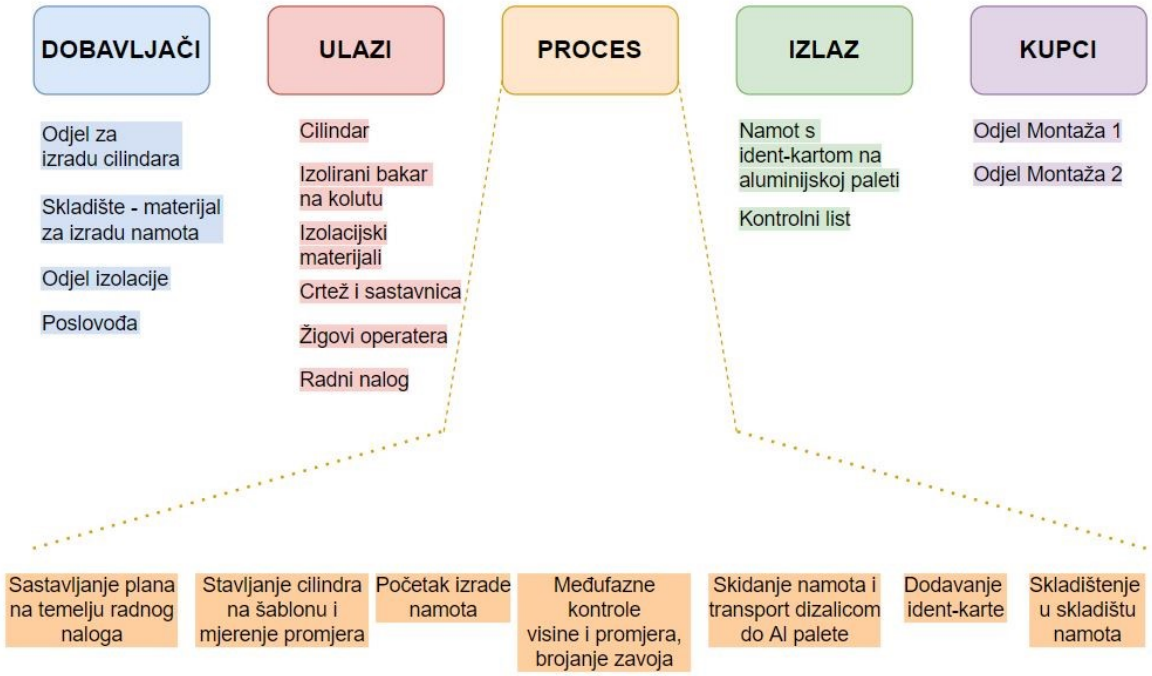

Slika 22. SIPOC dijagram [izrada autora]

SIPOC dijagram opisuje osnovne akcije u procesu izrade namota, izlaze iz procesa, u ovom slučaju to je namot s ident-kartom koji se postavlja na Al paletu te kontrolni list koji poslovođa upisuje u programu Excel. Oba izlaza se prema rasporedu transportiraju u odjele montaže. Ulazi u proces su materijali i dijelovi koji se koriste za izradu namota, potrebna tehnička dokumentacija namota, radni nalog prema kojem se posao organizira, žigovi kojima operateri označavaju zadnji zavoj/svitak koji su izradili u svojoj smjeni (za lakše otkrivanje uzroka problema ukoliko se pojave). Sve materijale i dijelove (osim cilindra) do radne jedinice

skladištar donosi na kolicima ili dizalicom po nalogu poslovođe iz skladišta materijala, a cilindar se isporučuje s odjela za izradu cilindara. Cilindar je unutarnji dio namota, na kojem se izrađuju bakreni zavoji. Izrađuje se od takozvanog *transformerboard* materijala, izolacijskog celuloznog materijala koji se u tvrtku isporučuje u obliku ploča različitih debljina te se u odjelu izrade cilindara oblikuje na potrebne dimenzije i oblik. Vrlo je važan promjer cilindra jer o njemu uvelike ovisi krajnja mjera namota.

Dijagram je izrađen u besplatnom programu na internetu, diagrams.net, koji nudi različite uzorke dijagrama, ali i mogućnost samostalne izrade dijagrama te pohranjivanje na računalo ili oblak u različitim formatima.

8.2. Mapa procesa

Kako bismo vidjeli koji zaposlenik je odgovoran za koji dio posla i kakav je tijek procesa izrađena je mapa procesa. Uključene su sve akcije, mjerenja, kontrole i odluke koje se mogu javiti u procesu. U nastavku postupak će biti tekstualno opisan, a na Slici 24. i na sljedeće tri stranice na Slikama 25., 26. i 27. prikazana je mapa procesa. Mapiranje procesa odrađeno je u online alatu, programu Lucidchart uz korištenje besplatnih opcija. Kako bi se tekst na dijagramu mogao pročitati, dijagram je trebalo rastaviti na više stranica.

Proces započinje planiranjem rada prema radnom nalogu. Poslovođa izrađuje plan rada u Excel tablici za trenutni i naredni tjedan. U planu rada definiraju se operateri, radna jedinica i namoti koji se izrađuju, a plan se postavlja na pano vidljiv operaterima kako bi znali što moraju raditi sljedeće. Skladištar dobiva mail od poslovođe s brojem radnog naloga te prema njemu priprema kolica s izolacijskim materijalom i priključcima, koji dostavlja do radne jedinice. Dizalicom transportira zadani kolut izoliranog bakrenog vodiča i cilindar do mjesta izrade. Osim toga po potrebi dostavlja i tehnološke materijale potrebne za izradu. Poslovođa do radnih jedinica donosi tehničku dokumentaciju namota, crtež i sastavnicu.

Kad su na radnoj jedini svi potrebni materijali i dijelovi, te tehnička dokumentacija operateri počinju s izradom. Prvi korak je postavljanje cilindra na odgovarajuću šablonu na stroju. S obzirom da je promjer cilindra važan, nakon postavljanja na šablonu operateri mjere promjer cilindra te započinju namatanje ako je izmjerena vrijednost unutar tolerancija. Ako vrijednost nije unutar tolerancija, poslovođa rješava problem u odjelu izrade cilindra narudžbom novog cilindra. U tijeku namatanja, operativni tehnolog radi proračun i provjeru dodataka za visinu čije rezultate zapisuje na crtež namota koji operateri imaju kod radne jedinice. U procesu

namatanja operateri trebaju raditi međufazne kontrole mjerenja promjera namota te ako su odstupanja manja naprave korekciju na sljedećem kanalu te nastavljaju namatanje. Ako su odstupanja veća, potreban je sastanak poslovođe s konstruktorom/operativnim tehnologom te provjera proračuna. Ako je namot moguće ugraditi rade se korekcije po uputama koje nastaju iz proračuna, a ako namot nije moguće ugraditi postaje škart. Na zavoju operater ručno zapisuje broj zavoja kako ne bi došlo do greške (previše/premalo zavoja). Brojanje zavoja moguće je i na stroju, no ne koristi se tako često zbog mogućih grešaka (npr. operater ne resetira brojač).

Na kraju svoje smjene operateri postavljaju vlastiti žig na namot (ili potpis) kako bi, ukoliko dođe do problema, znali tko taj dio namota izrađivao. Kad je namot završen (proces traje i do nekoliko dana), operateri rade finalno mjerenje i ručno ispunjavaju zapisnik o mjerama i odrađenom poslu. Ako izmjereni promjer nije unutar tolerancije, a namot nije moguće ugraditi (odluka poslovođe na temelju dodatnih provjera i proračuna s konstruktorima) namot se popravlja ako je moguće ili postaje škart. Ako ga je moguće ugraditi ili ako je izmjereni promjer unutar tolerancija namot se skida sa stroja. Zapisnik koji su operateri ispunili dostavljaju poslovođi, koji dobivene podatke upisuje na kontrolni list u Excel tablici. Nakon skidanja namota, namot se okreće vertikalno i postavlja na aluminijsku paletu. Poslovođa odrađuje vizualnu kontrolu (ako možda nije došlo do oštećivanja izolacije tijekom operacije okretanja), po potrebi namot se popravlja, a ako zadovoljava vizualnu kontrolu poslovođa mu dodaje ident-kartu. Ident-karta sadrži podatke o vrsti namota, broju dijela, crtežu, broju komada, broju naloga, oznaci namota, datum te potpis poslovođe. Završen namot s pripadajućom ident-kartom se na aluminijskoj paleti transportira u skladište gotovih namota gdje čeka transport u odjel montaže.

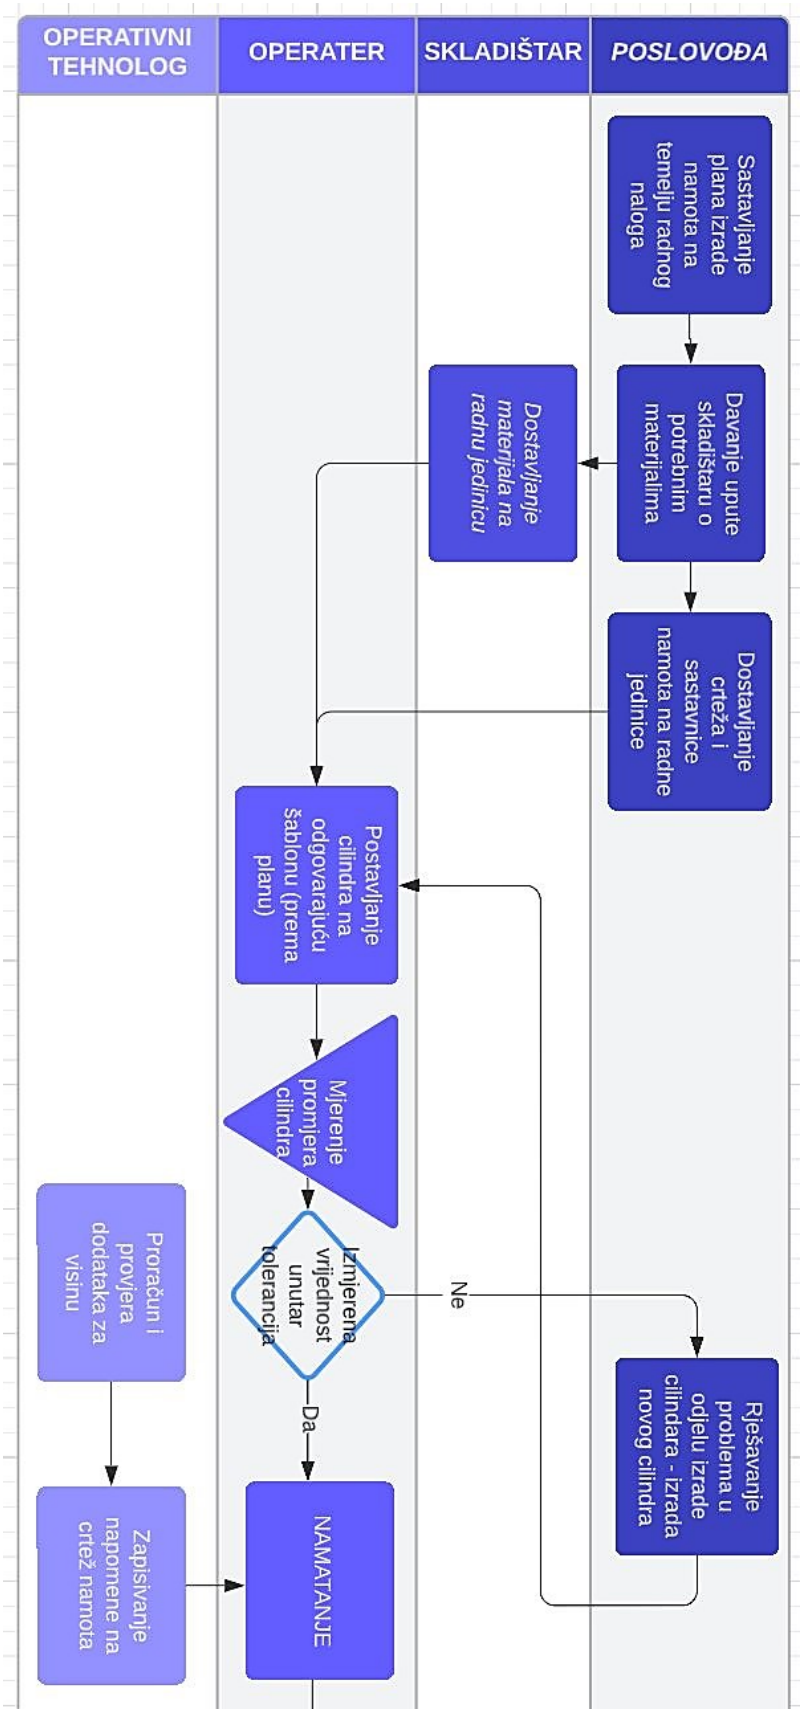

Slika 23. Mapa procesa, 1. dio [izrada autora]

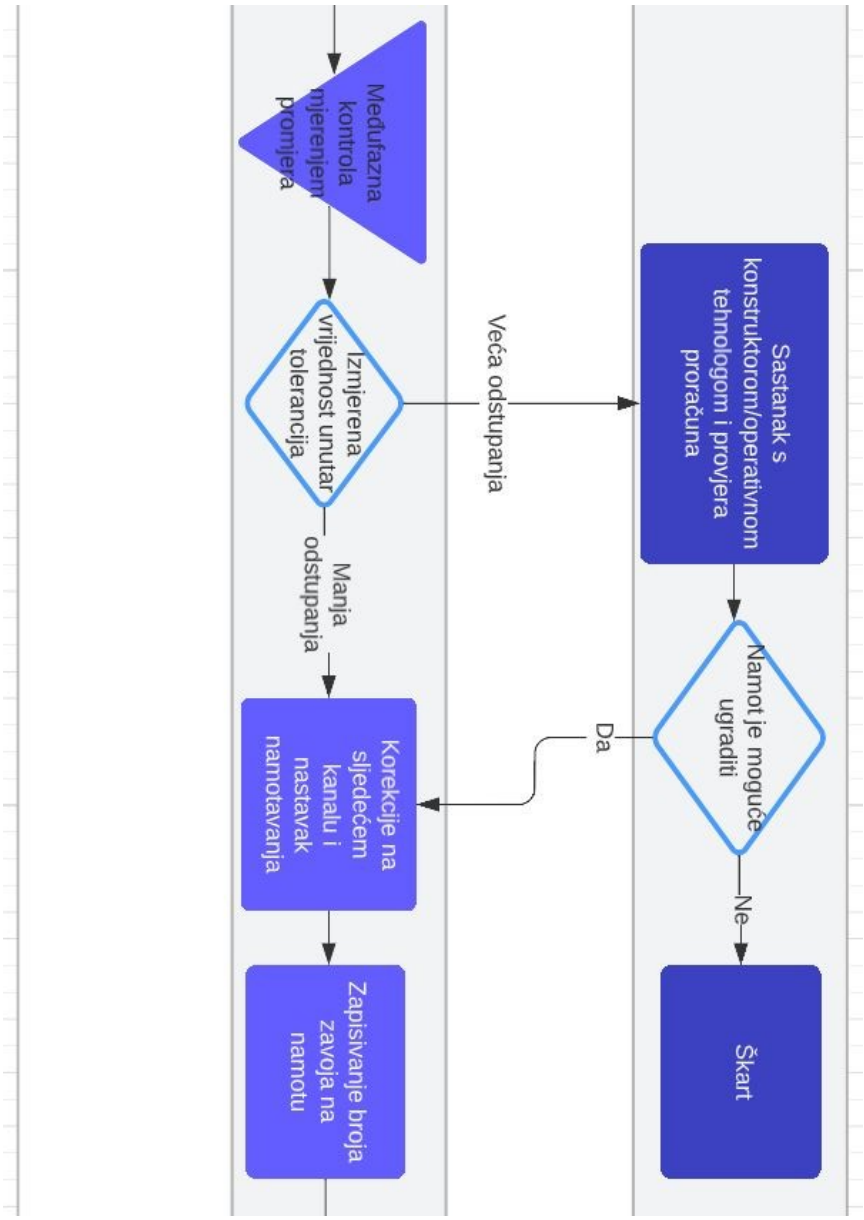

Slika 24. Mapa procesa, 2. dio [izrada autora]

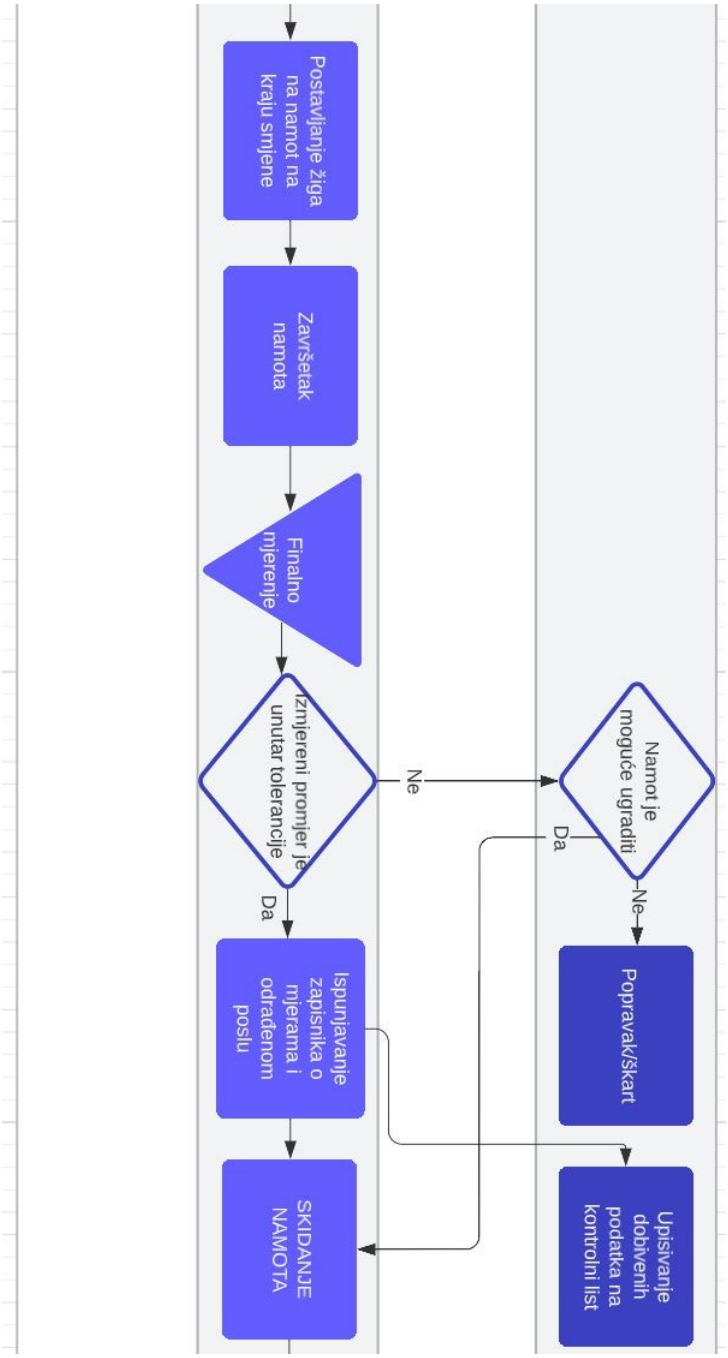

Slika 25. Mapa procesa, 3. dio [izrada autora]

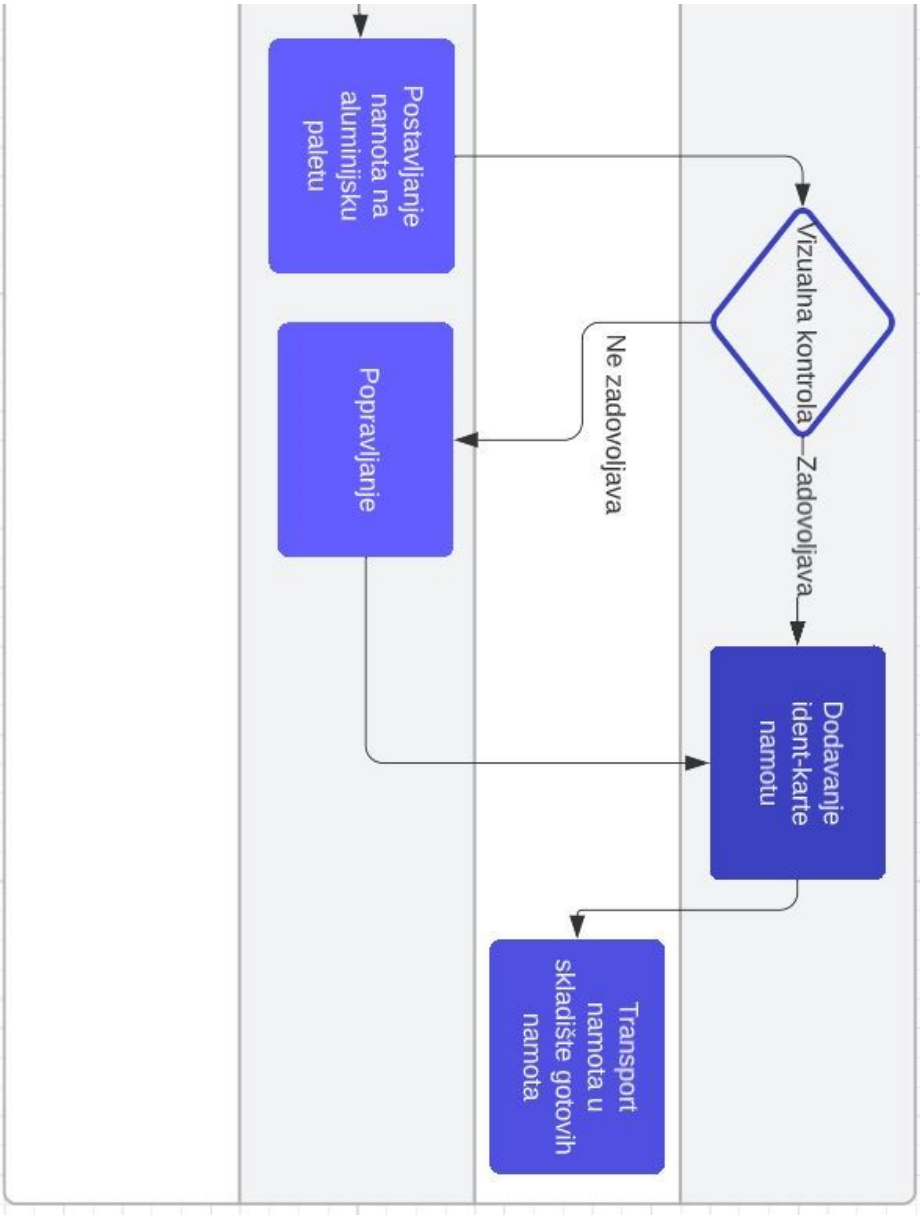

Slika 26. Mapa procesa, 4. dio [izrada autora]

8.3. Pokazatelji koji se prate

Tablica 4. prikazuje pokazatelje koji se prate na neki od načina, digitalno u programu Excel ili ručno na papiru. Točke u bojama označavaju razinu digitalizacije: zelena – digitalizirano, narančasta – djelomično digitalizirano, crvena – u potpunosti ručno, na papiru. Oznaka „*“ označava podatke koji se pojavljuju i upisuju na različita mjesta više puta.

Tablica 4. Tablica pokazatelja koji se prate [izrada autora]

	POKAZATELJI KOJI SE PRATE				
OPERACIJA	**PODACI**	**TKO PRIKUPLJA**	**GDJE SE ZAPISUJE**	**TKO KORISTI**	**NAČIN ZAPISIVANJA**
Namataona	Vanjski promjer namota	Operater	Zapisnik	Poslovođa	Ručno ●
Završna kontrola	*Vanjski promjer namota	Poslovođa	Kontrolni list	Montaža	Digitalno ●
Namataona	Unutarnji promjer cilindra	Operater	Zapisnik	Poslovođa	Ručno ●
Završna kontrola	*Unutarnji promjer cilindra	Poslovođa	Kontrolni list	Montaža	Digitalno ●
Namataona	Broj namatalice	Dodjeljuje poslovođa	Kontrolni list	Operater, Montaža	Usmeno, digitalno ●
Namataona	Vrsta šablone	Dodjeljuje poslovođa	Kontrolni list	Operater, Montaža	Usmeno, digitalno ●
Namataona	Oznaka operatera	Dodjeljuje poslovođa	Kontrolni list	Montaža	Ručno (na namotu), digitalno ●
Završna kontrola	Smjer namatanja i broj zavoja prema crtežu	Poslovođa	Kontrolni list	Montaža	Digitalno ●
Namataona	Radni sati po namotu	Operater	Zapisnik	Tehnolog	Ručno ●
Završna faza	*Radni sati po namotu	Tehnolog	Baza	Prodaja	Digitalno ●
Međufazna kontrola namatanja	Vanjski promjer namota	Operater	Ako nije unutar tolerancije: Protokol	Poslovođa	Ručno ●
Međufazna kontrola namatanja	Visina namota	Operativni tehnolog	Na crtež (zapisuje se potrebna dopuna)	Operater	Ručno ●
Zaštita na radu	Ozljede na radu	Poslovođa	Baza	Zaštita na radu	Digitalno ●

8.4. Tlocrt procesa i tok informacija i materijala

U ovome dijelu prikazat će se *layout* namataone (Slika 27.) kako bi prethodnu tablicu pokazatelja koji se prate i mapu procesa mogli shvatiti u cijelosti.

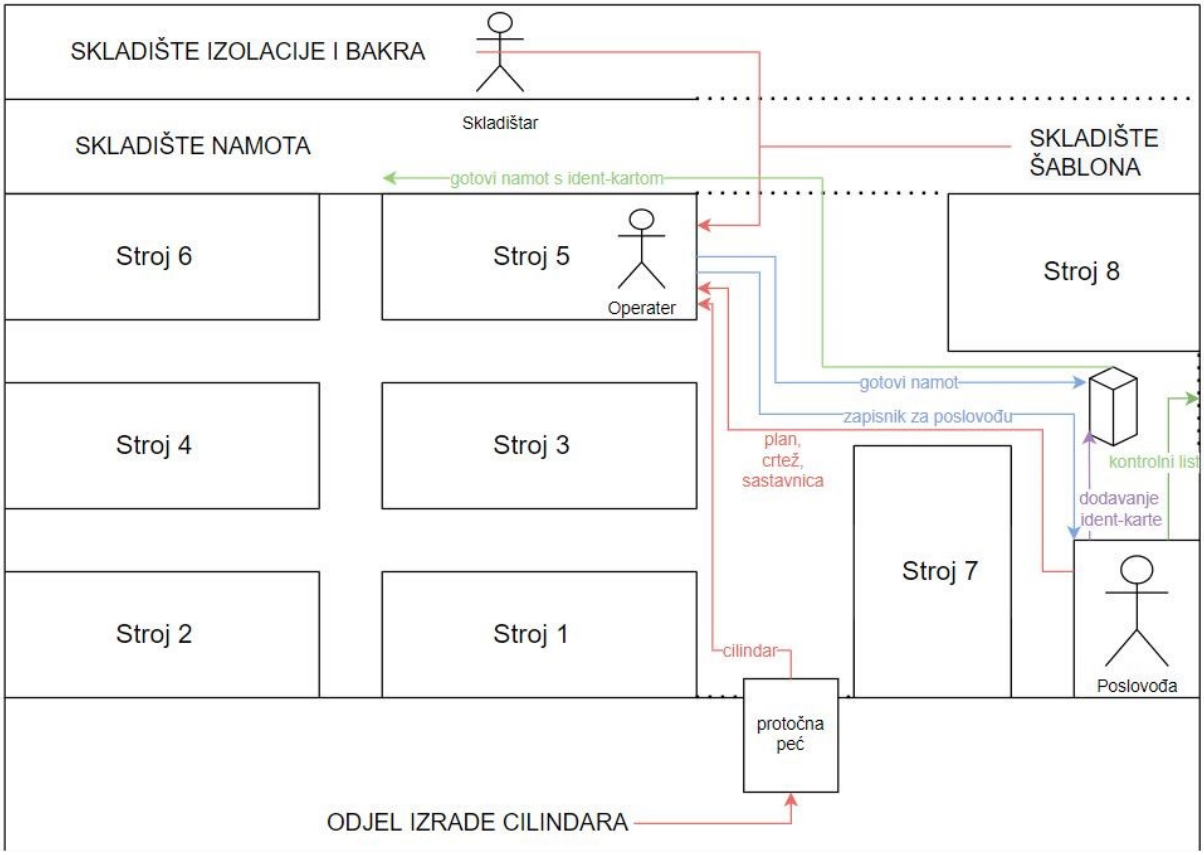

Slika 27. Tlocrt namataone [izrada autora]

Crvenim linijama označeni su ulazi koji dolaze do radne jedinice, odnosno stroja. Plavom linijom označeni su izlazi s radne jedinice, a ljubičastom završni koraci kad je namot već gotov. Zelenom linijom označeni izlazi iz cijelog procesa – gotov namot i kontrolni list.

Zbog preglednosti, prikazani su tokovi prema jednoj radnoj jedinici, no u stvarnosti se ovaj postupak ponavlja na svih osam radnih jedinica.

8.5. Analiza toka informacija

Paralelno uspoređujući tok informacija i materijala na tlocrtu te tablicu pokazatelja koji se prate moguće je primijetiti da se neki podaci upisuju na više mjesta i više puta.

- Podaci koje operateri na kraju namatanja upisuju ručno u zapisnik (vanjski i unutarnji promjer namota) opet se upisuju, ali na računalu, kad ih poslovođa upisuje u kontrolni list.
- Podaci koji se nalaze na planu rada (broj namatalice, vrsta zavoja, oznake operatera) i dodjeljuje ih poslovođa, kasnije se opet moraju upisivati na računalu na kontrolnu listu (koju isto popunjava poslovođa).
- Radne sate operateri upisuju na zapisnik, a kasnije ih tehnolog prepisuje na računalu u bazu.
- Broj zavoja koji operateri pišu direktno na zavoj broje se ručno, a isto tako broji ih i stroj.
- Operativni tehnolog mjeru za dodatke koji su nužni za postizanje potrebne visine namota piše ručno na crtež svakog namota kako bi operateri mogli tako izraditi namot.

8.6. Prijedlog poboljšanja

8.6.1. Prijedlog poboljšanja s trenutnim pokazateljima

Kako bi u procesu bilo što manje ponavljanja radnji (upisivanja istih podataka) u ovom poglavlju bit će opisani prijedlozi za unapređenje prikupljanja podataka te vizualizacije koristeći Microsoft Power BI program. Power BI je odabran jer se lako mogu se povezivati podaci iz različitih izvora te se prikazivati kao napredni interaktivni vizuali, a korisno je što se podaci mogu unositi i prikazivati na više uređaja (tablet, računalo, mobitel). Velika prednost je i što je korištenje vrlo intuitivno i uz malo učenja svi se mogu vrlo jednostavno koristiti ovim programom, a pogotovo kada treba samo upisati podatke. Ako bi se upisivanje podataka koje operateri zapisuju ručno na papiru (zapisnik) digitaliziralo pomoću tableta na svakoj radnoj jedinici, izbjegli bi se problemi s nepouzdanošću informacija koja može nastati jer poslovođa mora čitati različite rukopise te prepisivati brojeve na računalo. Dodaci za visinu bi se mogli prikazivati na istom tabletu kojeg operateri imaju kod radne jedinice pa bi tehnolog umjesto na crtež taj podatak upisivao u tablicu u programu na svojem računalu. Kod ručnih upisivanja te

prepisivanja podataka veliki utjecaj ima ljudski faktor i nenamjerna greška se vrlo lako može dogoditi, a osim toga takav način oduzima puno vremena.

Prijedlog poboljšanja odnosio bi se na eliminiranje zapisnika jer bi operateri unosili podatke u tablicu u programu. Isto tako, međufazne kontrole mjerenja promjera tijekom namatanja koje bi se izvršavale prema dogovoru upisivale bi se u program, a kad izmjereni promjeri ne bi bili unutar tolerancija na kontrolnoj ploči kojoj ima pristup poslovođa pojavila bi se upozorenja te bi bio obavješten da postoji problem na određenoj radnoj jedinici. Broj radnih sati po namotu također bi bilo moguće izvući iz sustava jer bi taj podatak operateri upisivali na isti način kao i sada u zapisnik. Podatke poput broja namatalice, oznake operatera i vrste šablone bilo bi moguće uvrstiti na kontrolnu ploču s plana rada. U sljedećoj fazi nadogradnje sustava, mogli bi se razmotriti i mjerni senzori promjera, tako da operateri ne bi morali trošiti vrijeme na mjerenja već bi se promjer automatski mjerio i podatak se upisivao u tablice koje bi bile izvor za izradu kontrolnih ploča. Ovakvi projekti koji gotovo u potpunosti transformiraju procese u digitalne procese iziskuju mnogo vremena i financijskih resursa za implementaciju.

Na Slici 28. prikazana je kontrolna ploča koja bi bila vidljiva operaterima na radnim jedinicama. U lijevom kutu sadrži podatke o namotu, u desnom kutu oznake namatalice, šablone i operatera. Ovi podaci bili bi učitani već prije početka rada, a njih dodjeljuje poslovođa već prije početka namatanja, kod izrade plana rada. Unutarnji promjer cilindra koji se nakon postavljanja ponovno mjeri operateri bi upisivali na licu mjesta. Isto tako s vanjskim promjerom, čiji podatak bi se kod svake međufazne kontrole upisao u tablicu. Kod vizuala za promjer postoji i linija koja označava traženu vrijednost te dvije linije koje označavaju gornju i donju toleranciju. Podatak o satima rada bilo bi dobro uvrstiti na kontrolnu ploču na način da se kod prijave operatera počinje brojiti vrijeme. Dodatak za visinu upisivao bi operativni tehnolog, a taj podatak pojavio bi se na kontrolnoj ploči operatera. Posebne napomene namijenjene su za komunikaciju s poslovođom, ukoliko bi bilo potrebe nešto posebno istaknuti.

Poslovođa bi imao prilagođen izgled kontrolne ploče (Slika 29.) na način da bi mogao filtrirati, odnosno birati za koju radnu jedinicu želi vidjeti podatke. Nakon odabira željene radne jedinice prikazali bi se podaci o namotu, oznake operatera uz oznake namatalice i šablone, unutarnji i vanjski promjer kao na kontrolnoj ploči operatera te trenutni i ciljani radni sati. Uz to, dodatak bi bili podaci o cilindru i o skladištu gdje poslovođa mogao vidjeti ako su se cilindar i ostali dijelovi iz skladišta dostavili do radne jedinice. Ta dva podatka morao bi unositi u sustav skladištar nakon dostave dijelova i alata do radne jedinice.

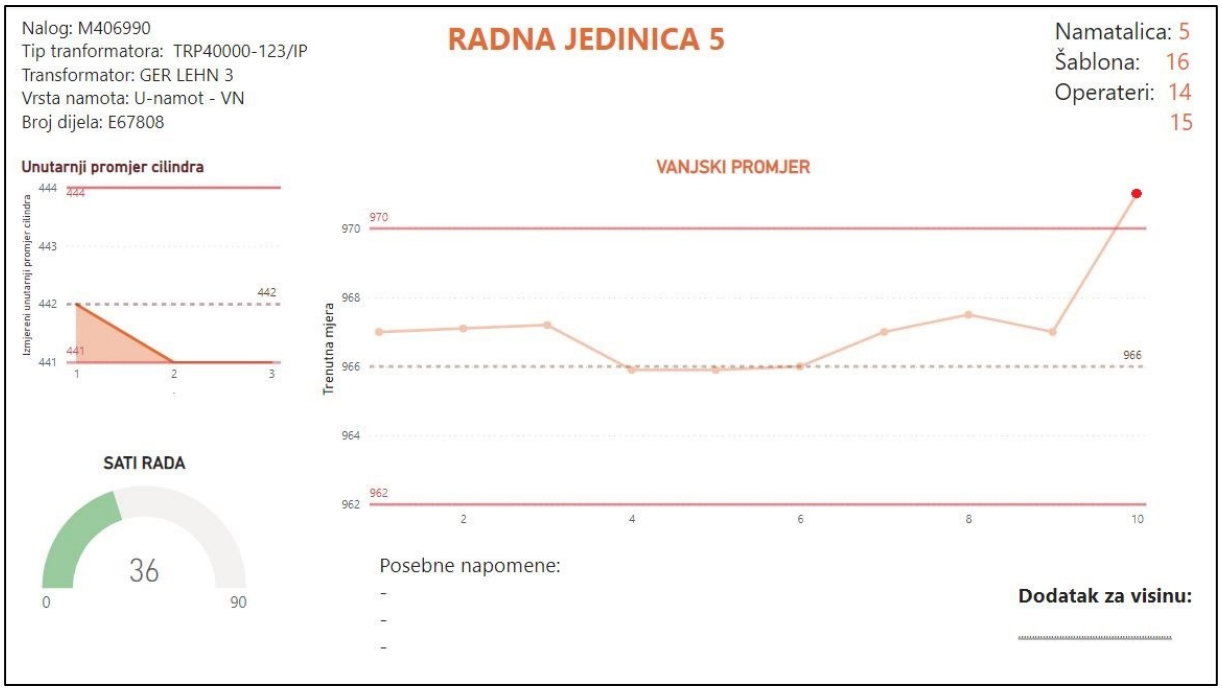

Slika 28. Kontrolna ploča za operatere [izrada autora]

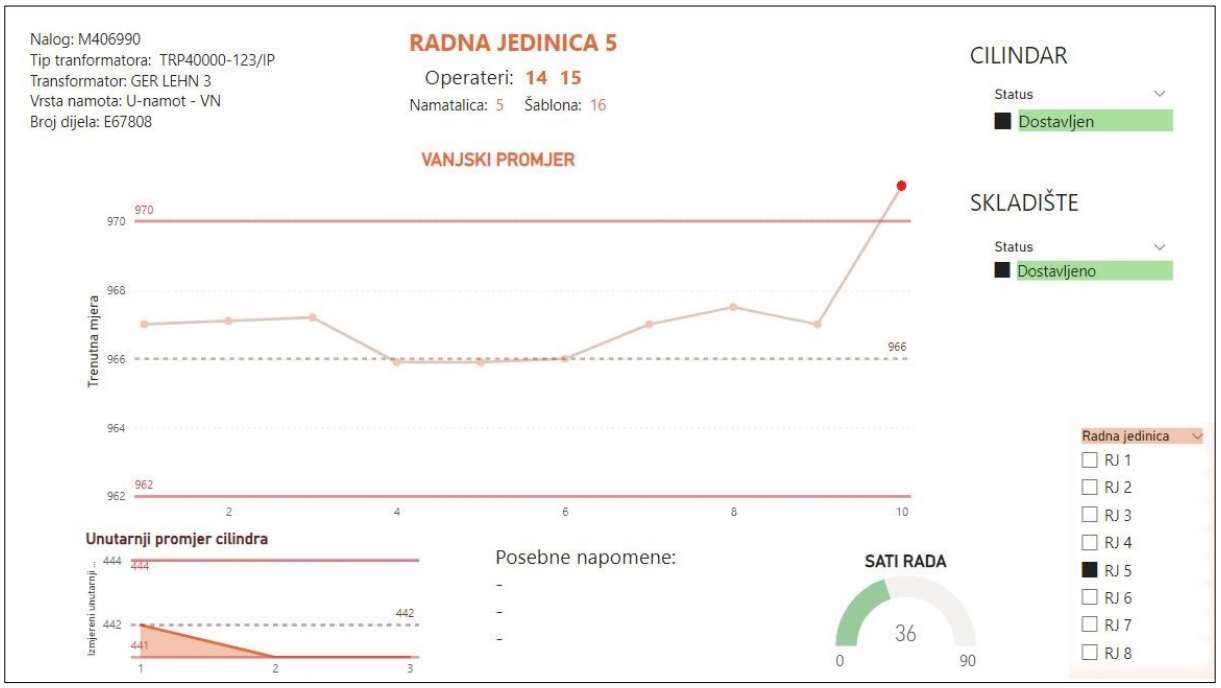

Slika 29. Kontrolna ploča za poslovođu [izrada autora]

Kad bi se podaci koristili na ovaj način, tablica pokazatelja koji se prate izgledala bi drugačije nego što je je to na Tablici 4.. Tablica 5. prikazuje pokazatelje koji se prate uz navedena poboljšanja. Vidljivo je da za sve podatke postoji baza podataka s tablicama koja se kasnije koristi kao izvor za izradu prilagođenih kontrolnih ploča. Ako bi se koncept kontrolnog lista koji se šalje u montažu zajedno s gotovim namotom zadržao, bilo bi dobro da se kontrolni list u Excelu automatski popunjava s istim podacima koji se koriste u Power BI-u tako da poslovođa ne mora prepisivati te podatke. Na ovaj način nema prepisivanja podataka ili ručnog upisivanja. Podatak se uvijek upisuje samo jednom, u tablicu u bazi podataka i koristi za izradu prilagođenih kontrolnih ploča ili popunjavanje kontrolne liste.

Kao što je u ovome radu predložen način digitalizacije i vizualizacije podataka za jedan proces u proizvodnji transformatora, sličan princip može se primijeniti i na sve druge odjele i procese. Tada bi cijeli pogon mogao biti umrežen i pripadati Industriji 4.0 uz sve prednosti koje takva tvornica nudi, a opisane su u teorijskom dijelu rada. U tom slučaju kontrolne ploče bile bi prilagođene različitim pozicijama radnika i različitim odjelima. Podaci bi svima koji ih trebaju bili vrlo brzo dostupni, a pristup jednostavan, no takva transformacija je veliki i skupi projekt za čiju implementaciju treba vremena te podrška, znanje i zalaganje cijele tvrtke.

Tablica 5. Tablica pokazatelja koji se prate uz prijedlog poboljšanja [izrada autora]

	POKAZATELJI KOJI SE PRATE				
OPERACIJA	**PODACI**	**TKO PRIKUPLJA**	**GDJE SE ZAPISUJE**	**TKO KORISTI**	**NAČIN ZAPISIVANJA**
Namataona	Vanjski promjer namota	Operater	Tablica u bazi podataka, na tabletu	Poslovođa, Montaža	Digitalno ●
Namataona	Unutarnji promjer cilindra	Operater	Tablica u bazi podataka, na tabletu	Poslovođa, Montaža	Digitalno ●
Namataona	Broj namatalice	Dodjeljuje poslovođa	Tablica u bazi podataka, na računalu poslovođe	Operater, Montaža	Digitalno ●
Namataona	Vrsta šablone	Dodjeljuje poslovođa	Tablica u bazi podataka, na računalu poslovođe	Operater, Montaža	Digitalno ●
Namataona	Oznaka operatera	Dodjeljuje poslovođa	Tablica u bazi podataka, na računalu poslovođe	Operater, Montaža	Digitalno ●
Završna kontrola	Smjer namatanja i broj zavoja prema crtežu	Poslovođa	Kontrolni list	Montaža	Digitalno ●
Namataona	Radni sati po namotu	Operater pomoću sustava	Tablica u bazi podataka, na tabletu	Tehnolog, Prodaja	Digitalno ●
Međufazna kontrola namatanja	Vanjski promjer namota	Operater (ili mjerni senzori)	Tablica u bazi podataka, na tabletu	Poslovođa	Digitalno ●
Međufazna kontrola namatanja	Visina namota	Operativni tehnolog	Tablica u bazi podataka, na računalu tehnologa	Operater	Digitalno ●
Zaštita na radu	Ozljede na radu	Poslovođa	Baza	Zaštita na radu	Digitalno ●

8.6.2. Prijedlog poboljšanja s dodatnim pokazateljima

U ovome dijelu rada biti će predloženi neki od ključnih pokazateljima koji bi se mogli pratiti na ovome procesu, ali uz dodatna mjerenja i bilježenja. Svaki od pokazatelja bio bi poticaj za svakodnevna poboljšanja, ali je potrebno prvo uložiti vremena i financijskih resursa da se uopće počnu pratiti ove mjere. S obzirom da ključnih pokazatelja ima gotovo beskonačno i prilagođavaju se određenom procesu ili operaciji koji prate, ovdje će ih biti predloženo nekoliko koji bi bili korisni za proces namatanja u smislu produktivnosti, smanjenja zaliha i čekanja te ekološkog utjecaja i nepotrebnog gubitka.

- DOH – engl. *Days of Inventory on Hand* -pokazatelj koji pokazuje koliko brzo se troše zalihe, u ovom slučaju koliko dugo namoti čekaju u skladištu namota prije transporta u odjel montaže, ali i koliko dugo gotovi cilindra čekaju postavljanje na šablonu.
- Predviđeni otpad/stvarni otpad – pokazatelj uz koji bi mogli pratiti koliko je otpada bilo predviđeno (zbog ugovora s dobavljačima i tehničko-dobavnim uvjetima), a koliko je otpada stvarno ostalo nakon završetka namota.
- Korišteni materijal/Otpadni materijal×100 – stopa otpada – otpad je uvijek gubitak, pa bi ovaj pokazatelj mogao potaknuti na praćenje i konstantni trud na smanjivanju otpada, a time i nepotrebnih troškova.
- OEE – engl. *Overall Equipment Effectiveness* – pokazatelj za mjerenje produktivnosti proizvodnje, uključujući samo ispravne namote zadovoljavajuće kvalitete i bez zaustavljanja strojeva za namatanje.
- Prekovremeni sati/planirani sati×10 – pokazatelj koji može tehnologu ukazati na problem s proizvodnjom ako je vrijednost ovog KPI-a veća nego što se to očekuje.

9. ZAKLJUČAK

S obzirom na dinamične i složene proizvodne sustave, tvrtke se suočavaju s mnogim izazovima. Potražnja potrošača za inovativnošću, brzinom isporuke i kvalitetom raste, a umreženi digitalni sustavi uvelike mogu pridonijeti rješavanju tih izazova te proizvodne procese pomoći učiniti uspješnima u ostvarenju ciljeva. Ključni pokazatelji uspješnosti tvrtkama omogućavaju praćenje procesa i mogućnost za brzu reakciju radnika ili rukovoditelja u slučaju anomalija u procesu. KPI-evi su objektivni dokaz napretka prema cilju, a mjere ono što je potrebno da bi taj cilj postigli. KPI-evi mogu biti pouzdani samo ako su i podaci koji se koriste kod njihovih izračuna pouzdani. Točna i pravodobna informacija vrlo je važna za dobre poslovne odluke, a uz napredne tehnologije vizualizacija podataka olakšava njihovu interpretaciju. Potreba za vizualizacijom podataka raste kako raste i broj podataka, a digitalne tehnologije omogućavaju brzi i relativno jednostavni prikaz velike količine podataka. U alatima za obradu i vizualizaciju podataka moguća je i analiza podataka bez puno prethodnog znanja o statistici što olakšava korištenje i implementaciju takvih alata u svaki tim.

U projektu je detaljno opisan dijagramima i skicama proces namatanja bakrenih namota za transformatore. Opisani su načini prikupljanja i korištenja pokazatelja, prikazan je tok informacija te mapa procesa u kojoj su navedene sve akcije, mjerenja i odluke od početka namatanja do završenog namota. Takvim prikazima moguće je jednoznačno definirati proces i jasno vidjeti gdje se koji podatak prikuplja i zapisuje. Predloženi su postupci za poboljšanje koji bi smanjili vrijeme koje radnici i poslovođa troše na upisivanje istih podataka, smanjila bi se mogućnost ljudske greške, a uz digitalizirane interaktivne vizualne prikaze poslovođa bi u trenutku mogao reagirati na mjere koje su van tolerancija. Uz kontrolne ploče operatera i poslovođe koje koriste pokazatelje koji se već prate, predloženo je i nekoliko KPI-eva koji bi u ovome procesu mogli biti poticajni za poboljšanje procesa i kvalitete te smanjenje otpada.

Digitalna transformacija tvornice u budućnosti će omogućiti povezane sustave koji će olakšati donošenje odluka, optimizirati proizvodne procese te osigurati transparentnost podataka koji će se koristiti za izračun korisnih pokazatelja te izradu prilagođenih kontrolnih ploča za potrebe svakog odjela.

LITERATURA

[1] Perić E. INDUSTRIJA 4.0. Hrvatska gospodarska komora [Internet] Dostupno na: https://www.hgk.hr/documents/hgk-industrija-4058d8c59722f1e.pdf, Pristupljeno: 16. svibnja 2022.

[2] Reza MNH, Malarvizhi CAN, Jayashree S, Mohiuddin M. Industry 4.0-Technological Revolution and Sustainable Firm Performance. In: 2021 IEEE International Conference on Emerging Trends in Industry 40, ETI 40 2021. Institute of Electrical and Electronics Engineers Inc.; 2021. doi: 10.1109/ETI4.051663.2021.9619363

[3] Stankov I, Gotseva D. An Overview of Security and Risk Management in Business Intelligence Systems. In: 3rd International Conference on High Technology for Sustainable Development, HiTech 2020 - Proceedings. Institute of Electrical and Electronics Engineers Inc.; 2020. doi: 10.1109/HiTech51434.2020.9363990

[4] Varga M, POSLOVNA INTELIGENCIJA: CILJEVI I METODE [Internet]. Dostupno na: http://www.informatika.efzg.hr, Pristupljeno: 18. svibnja 2022.

[5] What are BI tools and the types of BI software | Predictive Analytics Today. [Internet] Dostupno na: https://www.predictiveanalyticstoday.com/top-business-intelligence-tools/, Pristupljeno: 18. svibnja 2022.

[6] Kajáti E, Miškuf M, Papcun P. Advanced analysis of manufacturing data in Excel and its Add-ins. In: SAMI 2017 - IEEE 15th International Symposium on Applied Machine Intelligence and Informatics, Proceedings. Institute of Electrical and Electronics Engineers Inc.; 2017. p. 491–6. doi: 10.1109/SAMI.2017.7880359

[7] Top Business Intelligence Trends 2022: What 2,396 BI Professionals Really Think | BI_survey.com [Internet] Dostupno na: https://bi-survey.com/top-business-intelligence-trends, Pristupljeno: 19. svibnja 2022.

[8] Lindberg CF, Tan S, Yan J, Starfelt F. Key Performance Indicators Improve Industrial Performance. In: Energy Procedia. Elsevier Ltd; 2015. p. 1785–90. doi: 10.1016/j.egypro.2015.07.474

[9] What is a Key Performance Indicator (KPI)? | KPI.org. [Internet] Dostupno na: https://kpi.org/KPI-Basics, Pristupljeno: 24. svibnja 2022.

[10] How to develop KPIS / performance measures | KPI.org [Internet] Dostupno na: https://kpi.org/KPI-Basics/KPI-Development, Pristupljeno: 24. svibnja 2022.

[11] Kerzner H. PROJECT MANAGEMENT METRICS, KPIs, AND DASHBOARDS A Guide to Measuring and Monitoring Project Performance Second Edition. New York: International Institute for Learning; 2013.

[12] Kang N, Zhao C, Li J, Horst JA. Analysis of key operation performance data in manufacturing systems. In: Proceedings - 2015 IEEE International Conference on Big Data, IEEE Big Data 2015. Institute of Electrical and Electronics Engineers Inc.; 2015. p. 2767–70. doi: 10.1109/BigData.2015.7364078

[13] Brundage MP, Bernstein WZ, Morris KC, Horst JA. Using Graph-based Visualizations to Explore Key Performance Indicator Relationships for Manufacturing Production Systems. In: Procedia CIRP. Elsevier B.V.; 2017. p. 451–6. doi: 10.1016/j.procir.2016.11.176

[14] Podsečki N. Usporedba alata za vizualizaciju podataka [Internet]. Dostupno na: https://urn.nsk.hr/urn:nbn:hr:131:330672 Pristupljeno: 1. lipnja 2022.

[15] Gemignani Z. Better Know a Visualization: Small Multiples | JuiceAnalytics [Internet] Dostupno na: https://www.juiceanalytics.com/writing/better-know-visualization-small-multiples, Pristupljeno:

[16] What is SQCDP Board? | DigiLEAN [Internet]. Dostupno na: https://www.digilean.com/what-is-sqcdp/, Pristupljeno: 3. lipnja 2022.

[17] Visual Management Boards | VMT [Internet]. Dostupno na: https://v-m-t.co.uk/visual-management-boards/, Pristupljeno: 3. lipnja 2022.

[18] Juričić V. Karakteristike softvera za vizualizaciju podataka. Politehnika. 2020;3(2):19–26. doi: 10.36978/cte.3.2.2

[19] Daniel G. Murray. Tableau your data! Indianapolis: John Wiley & Sons; 2013.

[20] Tableau [Internet]. Dostupno na: https://www.tableau.com/, Pristupljeno: 15. lipnja 2022.

[21] Qlik [Internet]. Dostupno na: https://www.qlik.com/, Pristupljeno: 15. lipnja 2022.

[22] Plotly | Srce [Internet]. Dostupno na: https://www.srce.unizg.hr/files/srce/docs/edu/R/lekcijaplotly.html, Pristupljeno: 16. lipnja 2022.

[23] Plotly [Internet]. Dostupno na: https://plotly.com/, Pristupljeno: 16. lipnja 2022.

[24] Excel [Internet]. Dostupno na: https://www.microsoft.com/hr-hr/microsoft-365/excel, Pristupljeno: 16. lipnja 2022.

[25] Power BI [Internet]. Dostupno na: https://apps.microsoft.com/store/detail/power-bi-desktop/9NTXR16HNW1T?hl=hr-hr&gl=HR, Pristupljeno: 17. lipnja 2022.

[26] Power BI [Internet]. Dostupno na: https://powerbi.microsoft.com/en-za/desktop/, Pristupljeno: 17. lipnja 2022.

[27] Ali SM, Gupta N, Nayak GK, Lenka RK. Big data visualization: Tools and challenges. In: Proceedings of the 2016 2nd International Conference on Contemporary Computing and Informatics, IC3I 2016. Institute of Electrical and Electronics Engineers Inc.; 2016. p. 656–60. doi: 10.1109/IC3I.2016.7918044

[28] Oey E, Harno SSS, Zain C. Developing integrated performance dashboards with power BI - A case study in a medium-size manufacturer. In: Proceedings of 2021 International Conference on Information Management and Technology, ICIMTech 2021. Institute of Electrical and Electronics Engineers Inc.; 2021. p. 265–70. doi: 10.1109/ICIMTech53080.2021.9535105

[29] Production Process | StudySmarter [Internet]. Dostupno na: https://www.studysmarter.us/explanations/business-studies/business-operations/production-process/, Pristupljeno: 20. lipnja 2022.

[30] Sundar R, Balaji AN, Satheesh Kumar RM. A review on lean manufacturing implementation techniques. In: Procedia Engineering. Elsevier Ltd; 2014. p. 1875–85. doi: 10.1016/j.proeng.2014.12.341

[31] The Five Principles of Lean [Internet]. Dostupno na: https://theleanway.net/The-Five-Principles-of-Lean, Pristupljeno: 21. lipnja 2022.

[32] Value Stream Mapping [Internet]. Dostupno na: https://www.lean.org/lexicon-terms/value-stream-mapping/, Pristupljeno: 22. lipnja 2022.

[33] Quick and practical tips for effective virtual process mapping | lean.org [Internet]. Dostupno na: https://www.lean.org/the-lean-post/articles/quick-and-practical-tips-for-effective-virtual-process-mapping/, Pristupljeno: 22. lipnja 2022.

[34] Končar [Internet]. Dostupno na: https://koncar-dst.hr/, Pristupljeno: 29. lipnja 2022.