

Primjena umjetne inteligencije u strateškom upravljanju proizvodnjom

Korona, Karlo

Master's thesis / Diplomski rad

2024

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:235:886660>

Rights / Prava: [In copyright](#) / [Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-12-27**

Repository / Repozitorij:

[Repository of Faculty of Mechanical Engineering and Naval Architecture University of Zagreb](#)



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Karlo Korona

Zagreb, 2024.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Mentori:

Doc. dr. sc. Miro Hegedić

Student:

Karlo Korona

Zagreb, 2024.

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

Zahvaljujem se doc.dr.sc. Miru Hegediću, te firmama Kontakt d.o.o., Teši Tunolov d.o.o. i Cromaris d.d. na pomoći i informacijama potrebnima za izradu ovog rada.

Karlo Korona



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

Središnje povjerenstvo za završne i diplomske ispite

Povjerenstvo za diplomske ispite studija strojarstva za smjerove:

Proizvodno inženjerstvo, inženjerstvo materijala, industrijsko inženjerstvo i menadžment,
mehatronika i robotika, autonomni sustavi i računalna inteligencija



Sveučilište u Zagrebu	
Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa: 602 - 04 / 24 - 06 / 1	
Ur.broj: 15 - 24 -	

DIPLOMSKI ZADATAK

Student: **Karlo Korona**

JMBAG: 0069083596

Naslov rada na hrvatskom jeziku: **Primjena umjetne inteligencije u strateškom upravljanju proizvodnjom**

Naslov rada na engleskom jeziku: **Application of Artificial Intelligence in Strategic Manufacturing Management**

Opis zadatka:

Integracija umjetne inteligencije (UI) u strateško upravljanje proizvodnjom označava značajnu promjenu u načinu rada industrije. Ova integracija povećava efikasnost i donosi inovativne pristupe rješavanju složenih proizvodnih izazova. Prediktivna analitika i sposobnosti strojnog učenja UI omogućuju bolje odlučivanje, optimizirajući korištenje resursa i proizvodnih procesa. Ova transformacija je ključna za stjecanje konkurentne prednosti na brzo razvijajućem globalnom tržištu. Istraživanje uloge UI u proizvodnji označava korak prema tehnološki naprednoj i efikasnoj industrijskoj budućnosti.

U radu je potrebno:

1. Razraditi uvodne koncepte umjetne inteligencije (UI) i njene uloge u strateškom menadžmentu, te pružiti povijesni pregled razvoja UI i strateškog upravljanja.
2. Proučiti i analizirati prve oblike menadžmenta te istražiti kako se razvoj UI uklapa u povijest i evoluciju menadžmenta.
3. Detaljno istražiti klasične pristupe menadžmentu i usporediti ih s neoklasičnim pristupima, s posebnim naglaskom na ulogu UI u njihovoj modernizaciji.
4. Istražiti i opisati primjene UI u kontekstu strateškog upravljanja, uključujući konkretne primjere i studije slučaja iz prakse.
5. Predstaviti primjer implementacije UI u proizvodnom poduzeću, analizirati proces implementacije i evaluirati dobivene prednosti, ili alternativno analizirati kako neko poduzeće integrira UI u svoj strateški pristup.

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

Zadatak zadan:

Datum predaje rada:

Predviđeni datumi obrane:

7. ožujka 2024.

9. svibnja 2024.

13. – 17. svibnja 2024.

Zadatak zadao:

Predsjednik Povjerenstva:

Doc.dr.sc. Miro Hegedić

Prof. dr.sc. Ivica Garašić

SADRŽAJ

1	UVOD.....	1
2	PRVI OBLICI MENADŽMENTA	2
3	KLASIČNI PRISTUP.....	3
3.1	Max Weber – Birokratski pristup.....	3
3.2	Henry Fayol – Administrativni pristup	4
3.3	Frederick Winslow Taylor – Znanstveni pristup	5
3.4	Ford.....	5
3.4.1	Pokretna proizvodna inteligencija.....	7
3.4.2	Radnik – kupac	8
4	NEOKLASIČNI PRISTUP	10
4.1	Motivacija i potrebe	10
4.1.1	Abraham Maslow – Maslowljeva hijerarhija potreba.....	11
4.1.2	Frederick Herzberg – dvo-faktorska teorija.....	12
4.1.3	Douglas McGregor – teorija X i Y.....	12
4.2	Počeci umjetne inteligencije	13
5	STRATEŠKI MENADŽMENT	14
5.1	Glavne komponente strateškog menadžmenta.....	14
5.1.1	Strateg - menadžer	14
5.1.2	Konkurentska prednost	15
5.1.3	Vizija i misija.....	15
5.1.4	Vanjska analiza (prilike i prijetnje).....	16
5.1.5	Interna analiza (prednosti i slabosti).....	18
5.1.6	SWOT analiza	18
5.1.7	Izrada i implementacija strategije	19
6	DOBA UMJETNE INTELIGENCIJE.....	21
6.1	Umjetna inteligencija u proizvodnim pogonima.....	21
6.2	Machine learning – strojno učenje	22
6.3	Vrste učenja.....	23
6.3.1	Nadzirno učenje	23
6.3.2	Nenadzirno učenje.....	23
6.3.3	Podržano učenje	23
6.4	Tehnike učenja	24
6.4.1	Neuronske mreže.....	24
6.4.2	Duboko učenje	25
6.4.3	Stablo odlučivanja.....	26
7	PRIMJENA UMJETNE INTELIGENCIJE U STRATEŠKOM UPRAVLJANJU	27
7.1	Prediktivno održavanje	27
7.2	Osiguranje kvalitete	28
7.3	Predviđanje potrošnje energije.....	28
7.4	Upravljanje opskrbnim lancem	29
7.5	Optimizacija procesa.....	29

7.6	Zaštita i sigurnost	30
7.7	Dizajn	30
7.8	Izazovi	30
8	PRIMJENA UMJETNE INTELIGENCIJE U INDUSTRIJI LOVA I PRERADE RIBE	32
8.1	Umjetna inteligencija u sortiranju ulovljene ribe	32
8.2	Problem sortiranja srdele i inćuna	33
8.2.1	Idejno rješenje	37
8.2.2	Klasifikacija riba i treniranje modela	39
8.2.3	Rezultati	43
8.2.4	Robot	45
8.2.5	Diskusija	48
8.3	Umjetna inteligencija kao osnova poslovanja u uzgoju ribe	48
8.3.1	Problem planiranja količina lova ribe	50
9	ZAKLJUČAK	52
	LITERATURA	53

POPIS SLIKA

Slika 1 Piramide u Egiptu [2]	2
Slika 2 Grafički prikaz utroška vremena po automobilu i broju proizvedenih automobila po godinama [6].....	7
Slika 3 Ford-ovi radnici na pokretnoj traci [6].....	8
Slika 4 Malowljeva hijerarhija potreba [10]	11
Slika 5 Prikaz utjecaja higijenskih i motivacijskih faktora [11]	12
Slika 6 Grafički prikaz dijelova PESTEL analize [15]	17
Slika 7 SWOT analiza [17]	19
Slika 8 Grafički prikaz slojeva neuronske mreže [21]	24
Slika 9 Usporedba strojnog učenja (engl. <i>Machine Learning</i>) i dubokog učenja (engl. <i>Deep Learning</i>) [22]	25
Slika 10 Prikaz stabla odlučivanja za problem vremenske prognoze [23].....	26
Slika 11 Prikaz statistike utjecaja umjetne inteligencije na različite sektore [24]	27
Slika 12 Statistika riboprerađivačke industrije za 2022. [33]	33
Slika 13 Ulov na koći (srdele i inćuni).....	34
Slika 14 Pokretna traka za sortiranje ribe u pogonu firme Teši Tunolov	35
Slika 15 Pokretna traka za sortiranje ribe u pogonu firme Teši Tunolov	35
Slika 16 Radnici koji odvajaju inćune od srdele na pokretnoj traci.....	36
Slika 17 Inćun [34]	37
Slika 18 Srdela [34].....	37
Slika 19 Shema sustava za sortiranje ribe	38
Slika 20 Segmentacija na temelju rubova	41
Slika 21 Segmentacija na temelju rubova	41
Slika 22 Segmentacija metodom bounding box	42
Slika 23 Rezultati prepoznavanja inćuna	43
Slika 24 Rezultati prepoznavanja srdela	43
Slika 25 Rezultati prepoznavanja sa promjenom orijentacije	44
Slika 26 Rezultati prepoznavanja sa devijacijama u obliku ribe.....	44
Slika 27 Prikaz rubnih slučajeva	45
Slika 28 Delta robot [37].....	46
Slika 29 Delta roboti u prehrambenoj industriji [38]	47
Slika 30 Cromaris-ovo mrjestilište u Ninu [39]	49

POPIS KRATICA

Oznaka	Opis
AI	Umjetna inteligencija (engl. <i>Artificial intelligence</i>)
ML	Strojno učenje (engl. <i>Machine Learning</i>)
ROI	Povrat investicije (engl. <i>Return Of Investment</i>)

SAŽETAK

U radu je opisana evolucija menadžmenta od radnih početaka, preko prvog proučavanja menadžmenta u drugoj industrijskoj revoluciji pa do neoklasičnog pristupa koji se prilagođava sve do danas. Henry Ford je bio pionir u mnogočemu, pa tako i u menadžmentu čemu svjedoče neke od njegovih politika koje su ostale uvriježene u industriji poput 40 satnog radnog tjedna, U neoklasičnom pristupu veći fokus se stavlja na radnikovo raspoloženje, motivacije, potrebe i osjećaje. Dok su Weber, Fayol i Taylor bili imena koja su obilježila klasični pristup, Maslow, Herzberg i McGregor su dali svoje teorije u neoklasičnom pristupu. Strateški menadžment je još jedna evolucija menadžmenta koji najveći fokus stavlja na, kako i ime govori, strategiji, kako kratkoročnoj tako i dugoročnoj. Napravljen je uvod u umjetnu inteligenciju, a kasnije je prikazana njena primjena u riboprerađivačkoj industriji. Navedena su dva problema, sortiranja srdela i inćuna i predviđanja izlova ribe u uzgajivačkoj industriji, koji su već, ili mogu biti, uspješno riješeni umjetnom inteligencijom i strojnim učenjem.

Ključne riječi: evolucija menadžmenta, strateški menadžment, umjetna inteligencija, strojno učenje

SUMMARY

The paper describes the evolution of management from work beginnings, from the first study of management in the second industrial revolution to the neoclassical approach that has been adapting to this day. Henry Ford was a pioneer in many ways, including in management, as evidenced by some of his policies that remained mainstream in industry such as 40 hours of work week, in A neoclassical approach, greater focus is placed on the worker's mood, motivations, needs, and feelings. While Weber, Fayol, and Taylor were the names that marked the classic approach, Maslow, Herzberg, and McGregor gave their theories in a neoclassical approach. Strategic management is another evolution of management that places the greatest focus on, as the name suggests, strategy, both in the short and long term. An introduction to artificial intelligence was made, and later its application in the fish processing industry was presented. Two problems are listed, sorting sardines and anchovies and predicting the amount of fish that needs to be caught in the farming industry, which have already, or may be, successfully solved by artificial intelligence and machine learning.

Keywords: Management evolution, Strategic Management, artificial Intelligence, machine learning

1 UVOD

U ovom diplomskom radu će se obraditi tema strateškog pristupa proizvodnji i sve većeg utjecaja umjetne inteligencije na gotovo sve industrije. Strategiju se može opisati kao stazu po kojoj bi se jedno poduzeće trebalo kretati. Zato je izuzetno bitno odabrati pravu stazu za naše poduzeće, jer iako jedna staza može biti dobra za nekog drugog ne mora biti za nas. Koliku ulogu u tome imaju menadžeri, koliko okolina i drugi faktori saznat ćemo na kraju ovog projekta.

Umjetna inteligencija je pojam o kojem svaki dan čujemo sve više i više. Koristimo je na platformama poput internetskih pretraživača godinama, a da toga nismo ni svjesni. Iako se često o toj novoj tehnologiji govori u superlativima, za mnoge je ona prijetnja. Čujemo da će milijuni ljudi diljem svijeta izgubiti posao jer će ih zamijeniti umjetna inteligencija, pa se mnogi iz očitih razloga protive njenom razvitku. Većina novih tehnologija koje dolaze do krajnjih kupaca, stvaraju se radi potreba industrije, a umjetna inteligencija nije iznimka. Sa uvođenjem sve više senzora i skupljanjem sve većih količina podataka, industriji je trebalo rješenje kako će ih što brže i kvalitetnije obrađivati. Naravno svaka novina koja radi tako velike promjene ima svojih prednosti i nedostataka i možda trenutno nije za svaku firmu ili poduzeće, no neminovno je da će svi trebati biti na oprezu jer promijene koje su događaju su nikad veće i nikad brže.

Riboprerađivačka industrija je kruh i život za mnoge stanovnike priobalja republike Hrvatske, kako kroz povijest tako i danas no zbog novih regulativa kojima se ograničava izlov ribe i nedostatka radne snage nalazi se u izazovnim vremenima. To je industrija koja se u suštini minimalno mijenja kroz svoju povijest, pa je i sa opravdanjem možemo nazvati primitivnom. Prva velika promjena u ribarstvu je bila dolaskom motora na unutarnje izgaranje čime su ribari mogli graditi veće brodove i loviti više ribe, ali princip rada je ostao isti. Krajem 20 stoljeća morska riba prestaje biti isključivo hrana obale, nego su je počeli jesti i kupovati ljudi iz unutrašnjosti, pa dolazi potreba za opsežnijim sortiranjem i pakiranjem ribe te u konačnici potreba za većom količinom te se riba počinje uzgajati. U radu su prikazane dvije primjene umjetne inteligencije koju nisu budućnost, već sadašnjost i samo je pitanje vremena kada će se i drugi prikloniti ovoj novoj tehnologiji.

2 PRVI OBLICI MENADŽMENTA

Ljudi kao vrsta imaju potrebu živjeti u zajednicama. Od samih početaka čovječanstva, ljudi su se udruživali u manje skupine i plemena. U tim zajednicama prvi puta pojavljuje jedna osoba koja je odgovorna za planiranje skupljanja hrane, odabira skloništa, upravljanja zalihama, određivanja zadaća drugima u zajednici, odnosno po prvi puta imamo nekoga koga danas možemo nazvati menadžerom ili rukovoditeljem. Kako čovječanstvo evoluirala i razvijala se dolaze sve veće zajednice i veći projekti pa se tako u drevnom Egiptu, oko 3200 godina prije Krista, radi tada najveći projekt čovječanstva, piramide.

Pretpostavlja se da je na piramidama radilo između 30 i 50 tisuća radnika. Svaki je radnik bio svrstan u jedan od 5 timova koji je brojao 200 radnika, koje su se sistemski udruživali do sustava od 2000 radnika koji je bio jedna enklava. Ovdje se po prvi puta može vidjeti jednu ozbiljnu hijerarhiju proizvodnog pogona gdje imamo glavne menadžere cijelog projekta pa sve do najniže rangiranih rukovoditelja koji su vodili timove od 200 radnika [1].



Slika 11 Piramide u Egiptu [2]

3 KLASIČNI PRISTUP

Do dolaska druge industrijske revolucije, većina ljudi je bila zaposlena u manjim radnjama i manufakturama. Krajem 19. stoljeća počinje druga industrijska revolucija. Događaju se najveće promijene za svijet do tada. Najveći okidači revolucije su novi izvori energije, nafta i električna energija. Sa novim izvorima energije dolaze i novi strojevi koji olakšavaju i uvelike ubrzavaju čovjekov rad. Proizvodnja je nikad veća, a radi te promjene puno ljudi koji su bili zaposleni u poljoprivredi dolazi u novoizgrađene tvornice. Isto tako prijevoz je postao puno kvalitetniji i dostupniji što je značilo veći promet ljudi i robe. Grade se željeznice, ceste postaju kvalitetnije, a prijevoz brodom postaje sve dostupniji. Međutim iako se efikasnost rada uvelike povećala radi pojave prvih strojeva, u toj prvoj industriji nisu postojali gotovo nikakvi standardi. Tako na primjer nije postojao standard za radnikovu plaću, koliko je sati morao raditi dnevno, za koju radnju ili zadatak je trebalo koliko vremena itd. Uglavnom kako su na tržište došli kompletno novi poslovi nitko nije znao što očekivati i ponuditi osobi koja će ih izvršavati. Nažalost, radi toga je puno ljudi u tim počecima bilo iskorištavano te su radili ispod granica normalnih ljudskih uvjeta [3].

Radi sve te silne ekspanzije se manja poduzeća udružuju u veća te po prvi puta u povijesti imamo pojavu velikih kompanija u kojima radi puno radnika na različitim poslovima i radi toga dolazi potreba za menadžmentom. U ovoj teoriji menadžmenta istaknula su se 4 imena: Max Weber, Henry Fayol, Frederick Winslow Taylor, i Henry Ford. Svaki je donio neka svoja razmišljanja i ideje, ali kada bi najjednostavnije morali objasniti, Weber je gledao širu sliku organizacije, Fayol se bavio menadžerima, Taylor detaljnom analizom rada radnika, a Ford je bio najbolji realizator svega toga. Mnoge ideje i principi se podudaraju između ova tri teoretičara, ali svatko je došao do njih sa svojim kutom gledanja što dodatno potvrđuje ispravnost njihovih misli.

3.1 Max Weber – Birokratski pristup

Max Weber bio je njemački teoretičar koji se bavio sociologijom, ekonomijom i industrijom. Bio je začetnik ideje birokratskog sustava u industriji, odnosno vjerovao je da svaki sustav treba biti posložen kao državni organi. Preciznost, brzina, kvalitetno vođenje papirologije i diskretnost su bile neke od stvari kojima je težio. Zatim, svakom zaposleniku je bio podijeljen posao za koji je on bio najkompetentniji, a svi zaposlenici su potom bili podijeljeni u odjele kako bi bolje međusobno funkcionirali. Zaposlenici i odjeli imaju točno definirane uloge i

zadaje u kojima su odgovorni za ono što se napravi. Time bi se povećala učinkovitost cijele organizacije [4].

Weber je zagovarao da upravljanje treba biti organizirano u slojeve. U takvom sustavu svaki sloj bi pratio i bio odgovoran za one ispod sebe, ali isto tako bio pod nadzorom sloja iznad. Ova hijerarhijska struktura ocrtava linije komunikacije, delegiranje i podjelu odgovornosti [4].

Jednakost svih pred kompanijom. Nepotizam je tema koja je aktualna i danas, a po Weber-u vidimo da je bila i prije 100 godina. On je govorio kako se zaposlenici trebaju zapošljavati, plaćati i kasnije napredovati isključivo po kvaliteti svojeg rada i da uvjeti i ugovori trebaju biti standardizirani za cijelu kompaniju [4].

Strogo poslovno okruženje. Odnosi između radnika bi trebali biti isključivo profesionalni. Uređenje prostora isto tako hladno i bez osobnosti. To se radi iz razloga kako bi se na poslu mogle donositi odluke koje su objektivno najbolje za kompaniju, bez da išta subjektivno ulazi u raspravu [4].

3.2 Henry Fayol – Administrativni pristup

Teorija Henry Fayol-a bazirala se na komunikaciji menadžmenta sa radnicima. U svojoj knjizi koju objavljuje 1916. godine piše o 14 principa menadžmenta. Među njima su nabrojani autoritet, disciplina, timski duh, opći interes iznad osobnog... Fayol je shvatio kako je izuzetno bitno dobro obrazovati menadžere koji će kasnije navoditi radnike, te im usaditi vrijednosti kompanije. Osim 14 principa ima i 5 funkcija po kojima bi menadžer trebao koristiti svoje radno vrijeme a to su: planiranje, organiziranje, upravljanje, koordiniranje i kontroliranje [5].

Davao je menadžerima veliku moć, a radnicima gotovo nikakvo pravo glasa zbog čega danas neki kritiziraju takav način vođenja. Efikasnost i profiti su stavljeni na prvo mjesto, a o radnici su dolazili na zadnje mjesto. To je bilo moguće jer je bilo puno radne snage na tržištu pa su tvornice birale samo one koje će se prilagoditi sustavu dok osu ostali koji su imali nešto protiv ostajali bez posla. Danas više od sto godina kasnije, poduzeća rade gotovo sve kako bi se maksimalno prilagodila svojim zaposlenicima. Naravno uzrok je jasan, nedostatak radne snage. Međutim da se o Fayol-u ne govori samo u negativnom kontekstu, njegov obol menadžmentu je velik. Na njegovim principima sa pojedinim izmjenama su se kroz povijest razvijali odnosi između menadžera i njihovih podređenih [5].

3.3 Frederick Winslow Taylor – Znanstveni pristup

Frederick Winslow Taylor je bio mladi student strojarstva koji je tek počinjao raditi međutim primijetio je za vrijeme svog rada u čeličani da većina radnika zabušava za vrijeme svog posla. Tada radnici nisu bili plaćeni za obavljeno odnosno nisu postojale norme koliko je netko morao napraviti nego su bili plaćeni samo za vrijeme koje su na poslu. Taylor je brzo shvatio da se treba napraviti nekakav oblik sistema kojim bi se pratio i unaprijedio rad svakog radnika, pa je zato uveo 4 principa upravljanja [5].

Prvo, shvaća da se ništa ne može pratiti i uspoređivati ako nemamo konkretne podatke. Tako naglašava važnost praćenja i sistemskog zapisivanja podataka kako bi se kasnije lakše pregledavali i uspoređivali [5].

Drugo, svaki radnik nije rođen i nema kvalitete da bi obavljao svaki posao. Od velike je važnosti staviti pravog radnika na pravo radno mjesto i tako najbolje iskoristiti njegov potencijal. I dan danas se često dogodi, pogotovo u velikim kompanijama, gdje su radnici stavljeni na krivu poziciju, a da ih je prebaciti na „njihovo“ područje, bili bi puno efikasniji i samim time zadovoljniji. Osim toga Taylor isto naglašava da radnike treba dodatno educirati i trenirati kako bi što kvalitetnije obavljali svoj rad [5].

Treće, radnik je osnova svakog proizvodnog pogona i zato se prema njemu treba ponašati sa dostojanstvom. Za razliku od prije gdje su radniku nametnuti poslovi i načini izvođenja, Taylor naglašava kako je bitno radniku objasniti zašto nešto radi i zašto mora to raditi na taj način. Kada radnik shvaća svoj posao i može dobiti na odgovore na svoja pitanja, ima veće zadovoljstvo u obavljanju svog posla, sam radnik želi zaraditi više, a tako i poduzeće zarađuje više [5].

Zadnji princip je taj da mora postojati sinergija između radnika i menadžmenta. Ako radnik shvaća da njegovi nadređeni isto tako rade kako i on umjesto da ljenčare, a i ako menadžment shvaća koliko njegovi podređeni rade i da ne zabušavaju, tada postoji uzajamno poštovanje i poduzeće se može razvijati [5].


3.4 Ford

Ako postoji jedan sinonim za drugu industrijsku revoluciju onda bi to bio Henry Ford. Iako Ford nije bio teoretičar klasičnog pristupa menadžmentu, zasigurno je bio njegov najbolji primjer u praksi te je utabao put mnogima koji će doći nakon njega. Ford je imao viziju napraviti

auto radničke klase. U njegovo vrijeme auto je bio predmet prestiža i nešto što su si samo najbogatiji mogli priuštiti. Međutim on je 1908. predstavio svijetu Model T i napravio revoluciju u civilnom transportu. Međutim kako je bio pionir u mnogočemu, osim što je prema vanka napravio kvalitetan automobil dostupan gotovo svakome, prava jedna revolucija događala se daleko od očiju javnosti u njegovim proizvodnim pogonima. Nakon prve izvrsne godine, potražnja je bila toliko visoka da je morao napraviti još jednu tvornicu, tada najveću na svijetu. Pazi se na sve detalje, pa se tako kod projektiranje tvornice stavio fokus na dobru rasvjetu i ventilaciju, što nije bio čest slučaj do tada [6].

Kako je Ford krenuo raditi „punom parom“, trebala mu je stručna pomoć za ustrojstvo radnika pa mu dolazi Frederick Taylor koji implementira svoje principe rada u proizvodnju. Kao pioniri klasičnog pristupa menadžmentu, Ford i Taylor su se dobro slagali i zajedno su dijelili mišljenje da radnik treba raditi ono što mu se kaže i ne razmišljati previše svojom glavom. Zanimljiv citat Henry Ford-a iz tog vremena je „Zašto svaki put kad tražim par ruku, one dolaze sa mozgom?“. To nam govori kakvo je mišljenje Ford imao o svojim radnicima. Vrlo je jasno da se primjedbe, ali i potencijalni savjeti za rješavanje radnika nisu pretjerano slušali. Sve promjene koje su rađene, rađene su praćenjem brojki i statistika. Kako će se svijet i industrija evoluirati taj način poslovanje će se uvelike promijeniti [6].

Jedan od glavnih ciljeva je bio smanjiti nepotrebno potrošeno vrijeme i bolje specificirati poslove. Tako su svi proizvodni pogoni posloženi tako da se što manje vremena gubi u prijevozu i čekanju na iduću operaciju. Dobar primjer toga je da je cilindar motora prije „putovao“ 1220 metara, a poslije implementacije već navedenih principa smanjio se na malo više od 90 metara [6]. Osim na vremenu napravljeno je puno ušteda na smanjenju škarta odnosno viška materijala. Zbog svega toga produktivnost se povećala, a jer su troškovi smanjeni mogla se smanjiti i prodajna cijena što je još više pojačalo prodaju, a to najbolje prikazuje ovaj graf.



Slika 22 Grafički prikaz utroška vremena po automobilu i broju proizvedenih automobila po godinama [6]

3.4.1 Pokretna proizvodna inteligencija

U prvih 5 godina proizvodnje Modela T promjene su se događale doslovno na tjednoj osnovi, međutim inženjere u Ford-u je još mučila jedna stvar. Kod sklapanja automobila, automobil je stajao na mjestu i radnici su dolazili do automobila sa svojim dijelovima, što znači da je u ovom dijelu proizvodnje najviše vremena odlazilo na kretanje radnika od skladišta dijelova i alata do mjesta montaže. Kako bi riješili taj problem inženjeri su otišli u jednu veliku klaonicu u Chicagu. Tamo su vidjeli nešto što će kasnije implementirati u svoj sustav i tako promijeniti automobilsku, ali i općenito proizvodnu povijest a to je pokretna proizvodna linija. U klaonicu su ulazile cijele krave te je u roku od 35 minuta meso bilo izrezano i zapakirano (inače za taj posao dvojici radnika je trebalo 8-10 sati). Radilo se to na način da je svaki radnik imao svoj dio krave koji je rezao i usavršio se za taj svoj dio mesa sa kojim je radio, a još bitnije je da je radnik bio stacioniran a meso je dolazilo njemu, a ne obrnuto kao kod Ford-a gdje su radnici dolazili automobilu [6].

Tu tehniku su implementirali u tvornicu gdje su prvo testirali pokretnu liniju na proizvodnji manjih dijelova, a na kraju na cijelom automobilu. U roku od par mjeseci od uvođenja trake već su se vidjeli vrhunski rezultati, te je vrijeme proizvodnje cijelog automobila smanjeno 8 puta [6].



Slika 33 Ford-ovi radnici na pokretnoj traci [6]

3.4.2 Radnik – kupac

Posao radnika u Ford-u tih godina bio je jako zahtijevan. Radnici su se stalno morali privikavati na nove promijene, njihov rad se maksimalno iskorištavao, nije bilo zabušavanja i pratio im se svaki korak kako bi se proces optimizirao. Gledajući sve to navedeno sa poslovne strane ima savršenog smisla, međutim treba na to gledati sa ljudske strane. Radnici su često radili do granica izdržljivosti i zbog toga su često mijenjali posao u potrazi za nečim boljim. Tada je Henry Ford donio odluku koja je potresla Ameriku a to je da je uveo „\$5 a day“ politiku odnosno da su radnici plaćeni 5 dolara za 8 sati svog rada (danas bi to iznosilo oko 320 dolara na dan). Dotadašnja minimalna plaća je iznosila \$2.34 i to za devet sati rada. Vijest je odjeknula cijelom zemljom, te je već idući dan novih 10 000 potencijalnih radnika došlo pred tvornice tražiti posao [6].

Naravno g. Ford nije to učinio isključivo iz ljubavi prema svojim radnicima, nego jer je vidio problem koji nadolazi. Prvo, pokretna traka radi kao jedno tijelo. To znači da ako jedan dio pokretne trake ne funkcionira cijela traka staje, a često se događalo da ljudi iz revolta odlaze sa trake i time zaustavljaju cijelu proizvodnju. Zatim Ford je planirao uvesti rad u 3 smjene tako da se radi 24 sata dnevno u odnosu na dvije smjene po devet sati. I posljednje, svaki put kada treba zamijeniti radnika, novog radnika treba naučiti poslu za što je potrebno dosta novca i vremena [6].

Sve navedeno je pozitivno utjecalo na proizvodnju pa je tako promjena radne snage sa 400% 1913. pala na 16% 3 godine kasnije, profit se udvostručio, a cijena Modela T je pala sa \$525 na \$345. Ako pogledamo ovu zadnju brojku a to je cijena automobila i usporedimo plaću koja je se čak par godina kasnije popela na 6 dolara dnevno, možemo zaključiti da je u 60-70 dana rada Ford-ov zaposlenik mogao sebi priuštiti automobil [6].

Drugim riječima Henry Ford je stvorio nešto što je za Ameriku do tada bila nepoznanica, a to je srednji stalež. Radničku klasu koja je od svog rada mogla dobro živjeti i tako ostvariti svoj „američki san“. Vraćajući se na ono prije o povećanju plaće vidimo najbitniji razlog te promijene, a to je da je Ford stvorio od radnika kupca za svoj proizvod. No nisu kupci bili samo njegovi radnici. Kako je Ford bio ogromna kompanija koja je radila promijene na cijelu Ameriku, tako su i druge kompanije morale dizati plaću kako bi zadržale svoje radnike. Preko noći Ford je dobio zadovoljne i efikasne radnike, puno bolju prodaju svojih vozila i time veću zaradu. Da se nije odlučio za takav potez pitanje je kome bi uspio prodati svoja vozila i bili se kompanija održala. Interesantan je i podatak da je firma 1926. uvela sustav od 40 radnih sati u tjedno, odnosno 8-satno radno vrijeme od ponedjeljka do petka koje se zadržalo do danas [6].

4 NEOKLASIČNI PRISTUP

Neoklasična teorija stvorena je na osnovama klasične teorije. Klasična teorija koncentrirana na sadržaj posla i upravljanje fizičkim resursi dok je neoklasična stavila veći naglasak na pojedinca i grupu i općenito odnose na radnom mjestu. Neoklasična teorija ukazala je na ulogu psihologije i sociologija u razumijevanju ponašanja pojedinca i grupe u organizaciji [7].

Bihevioralni pristup koji je osnova neoklasičnog pristupa su razvili teoretičari koji su promatrali slabosti klasičnog pristupa. Klasični pristup je imao 3 postulata a to su učinkovitost, proces i principi. Neki rukovoditeljski znanstvenici smatrali su da takav način vođenja ignorira važne aspekte organizacije, a najviše njih se odnosi na ljudsko ponašanje. Stoga je bihevioralni pristup bio usmjeren na razumijevanje čimbenika koji utječu na ljudsko ponašanje na poslu.

Bihevioralni znanstvenici misle da je klasični pristup isključivo mehanički, što otkriva da degradira ljudski duh. Biraju fleksibilnije organizacijske strukture i radna mjesta izgrađena oko sposobnosti i talenta prosječnih zaposlenika [7].

4.1 Motivacija i potrebe

Jedan od središnjih stupova bihevioralnog pristupa je proučavanje motivacije i potreba na radnom mjestu. Whiseand i Rush (1988) objasnile su motivaciju kao spremnost pojedinca da učini neke radnje kojima će zadovoljiti svoje potrebe. Kasnije su Wregner i Miller (2003) opisali motivaciju kao nešto što je potaknulo pojedince da poduzmu radnju usmjerenu na cilj. Isto tako nedavna definicija koju je pridonio Fuller et.al. (2008) kaže da je motivacija osobni intenzitet, smjer i ustrajnost za postizanje određenog cilja [8].

Kao što vidimo nitko točno ne može objasniti i reći što je motivacija te se njena definicija kroz povijest do danas mijenja. To je zato što motivacija nije opipljiva i nije nešto što možemo točno precizirati ili svrstati u neki obrazac. Motivacija uvelike varira između pojedinaca i sredina u kojima ljudi rade, ali neke osnovne stavke su u većini slučajeva iste.

Iz radova Abrahama Maslowa, Fredericka Herzberga i Douglasa McGregora, teoretičari ponašanja ističu važnost intrinzične motivacije i ispunjavanja potreba više kvalitete za angažman i zadovoljstvo zaposlenika.

4.1.1 Abraham Maslow – Maslowljeva hijerarhija potreba

Abraham Maslow prvi je put u svoj rad iz 1943. godine uveo koncept hijerarhije potreba pod nazivom „Teorija ljudske motivacije”, a zatim u svojoj knjizi „Motiviranost i osobnost”. Ova hijerarhija govori da su ljudi motivirani ispuniti osnovne potrebe prije nego što prijeđu na druge, naprednije potrebe. Dok su se neke od postojećih škola razmišljanja u to vrijeme fokusirale na problematična ponašanja, Maslow je bio više zainteresiran za učenje što ljude čini sretnima i što čine kako bi postigao taj cilj [9].

U podnožju Maslowove piramide nalaze se fiziološke potrebe, uključujući zrak, vodu, hranu, sklonište i spavanje. Ti temeljni zahtjevi ključni su za opstanak i temelj su na kojem se temelje potrebe višeg reda. Kada se zadovolje fiziološke potrebe, pojedinci teže sigurnosti i zaštiti, tražeći stabilnost i predvidljivu okolinu. Treća razina obuhvaća društvene potrebe, kao što su pripadnost, ljubav i prihvaćanje, tjerajući pojedince da stvore smislene odnose i traže prihvaćanje unutar društvenih skupina. Pomicanjem hijerarhije pojedinci slijede potrebe poštovanja, uključujući samopouzdanje i poštovanje drugih, težeći prepoznavanju, poštovanju i postignuću [9].

Na vrhuncu piramide leži samoaktualizacija, koja predstavlja ispunjenje čovjekova potencijala i potragu za osobnim rastom, kreativnošću i samoispunjenjem.

Gledajući sve navedeno sa točke menadžmenta možemo bolje shvatiti potrebe i želje naših zaposlenika. Trebamo im prvo dati plaću koja će im moći osigurati normalan život. Poslovi moraju biti sigurni, prvenstveno da su ljudi sigurni da im je zdravlje zaštićeno, a zatim da su ljudi i psihološki osjećaju sigurno u svom radnom okruženju. Zaposlenici se trebaju osjećati kao da su dio zajednice koja ih cijeni i poštuje, a na kraju svojim zaposlenicima trebamo dati mogućnost da se ostvare kroz unaprjeđenja posla ili dodatna obrazovanja koja su im potrebna [9].



Slika 44 Maslowljeva hijerarhija potreba [10]

4.1.2 Frederick Herzberg – dvo-faktorska teorija

Za razliku od Maslowa koji je hijerarhijski prikazao čovjekove potrebe i motivaciju, Herzberg ima drugačiji pristup. On govori kako postoje određeni faktori koji stvaraju zadovoljstvo (motivacijski faktori) i nezadovoljstvo (higijenski faktori) kod zaposlenika [11].

Higijenski faktori su: politika organizacije i administracija, nadzor, međuljudski odnosi, radni uvjeti, plaća, status i sigurnost.

Motivacijski faktori su: postignuće, priznanje, zanimljiv posao, odgovornost, napredovanje, osobni rast i razvoj

Zaključak bi mogli prikazati ovako:



Slika 55 Prikaz utjecaja higijenskih i motivacijskih faktora [11]

Odnosno, higijenskim faktorima možemo spriječiti nezadovoljstvo međutim ne možemo stvoriti zadovoljstvo. Isto tako motivatorima ne možemo spriječiti nezadovoljstvo, ali možemo stvoriti zadovoljstvo.

4.1.3 Douglas McGregor – teorija X i Y

Teorija X i teorija Y suprotni su stilovima upravljanja koje je predložio Douglas McGregor šezdesetih godina prošlog stoljeća, a koji pružaju uvid u različite pretpostavke o ljudskoj prirodi i ponašanju na radnom mjestu [12].

Pretpostavke teorije X su da prosječni zaposlenik ne voli posao i pokušava ga pobjeći kad god je to moguće, ne voli promjene i odgovornost te ga treba stalno usmjeravati. Budući da zaposlenik ne želi raditi, mora ga se uvjeriti, prisiliti ili upozoriti kaznom kako bi postigao organizacijske ciljeve. Potreban je strogi nadzor upravitelja, pa menadžeri usvajaju diktatorski stil [12].

S druge strane pretpostavke teorije Y su da zaposlenici mogu doživjeti svoj posao kao opuštajući i poželjan. Vježbaju svoje fizičke i mentalne napore na svojem poslu, te se njihove mogućnosti i potencijal koriste maksimalno. Radnik radi više jer zna da će njegov rad biti

prepoznat i nagrađen. Drugim riječima, kreativnost, snalažljivost i inovativna potencijalnost zaposlenika mogu se iskoristiti za rješavanje organizacijskih problema [12].

Tako možemo reći da teorija X predstavlja pesimističan pogled na prirodu i ponašanje zaposlenika na poslu, dok teorija Y predstavlja optimističan pogled na prirodu i ponašanje zaposlenika na poslu. Inače McGregor je bio uzor Abrahamu Maslowu, a jednom je prilikom htio dokazati efektivnost teorije X i Y pa je napravio istraživanje u tvornici u Kaliforniji. Zaključak je bio da tvornica ne može funkcionirati isključivo koristeći teoriju Y pošto ljude treba netko usmjeriti i biti autoritet, odnosno da opet treba koristiti i dijelom teoriju X [12].

4.2 Počeci umjetne inteligencije

Korijeni umjetne inteligencije mogu se pratiti još u antičko doba, uz filozofska ispitivanja prirode inteligentnih i mehaničkih uređaja osmišljenih da oponašaju ljudske sposobnosti. Međutim, moderno doba umjetne inteligencije počelo je 1950-ih, a pioniri kao što su Alan Turing i John McCarthy postavili su teorijski temelj [13].

Alan Turing je o umjetnoj inteligenciji razmišljao na način da ljudi koriste dostupne informacije kako bi riješili probleme i donijeli odluke, pa zašto strojevi ne mogu učiniti istu stvar? To je bio logičan okvir njegovog rada iz 1950. godine, računalnih strojeva i inteligencije u kojem je raspravljao kako izgraditi inteligentne strojeve i kako testirati njihovu inteligenciju. Međutim, prije 1949. računalima je nedostajao ključni preduvjet za inteligenciju: nisu mogla pohranjivati naredbe, samo ih izvršavati. Drugim riječima, računalima se moglo reći što da rade, ali se nisu mogli „sjetiti“ što trebaju napraviti. Drugo, računarstvo je bilo iznimno skupo. Početkom 1950-ih cijena zakupa računala koštala je do 200.000 dolara mjesečno, pa su samo prestižna sveučilišta i velike tehnološke tvrtke mogle priuštiti rad sa takvim strojevima [13].

U 1960-ima i 1970-ima, istraživanje umjetne inteligencije fokusiralo se prvenstveno na simboličku umjetnu inteligenciju, koja je koristila logiku i simbole kako bi predstavljala znanje i riješila probleme. U ovo doba razvijeni su ekspertni sustavi koji su oponašali sposobnost odlučivanja ljudskih stručnjaka u specifičnim područjima. Iako su ti sustavi pokazali obećanje u područjima kao što su medicina i financije, bili su ograničeni svojom nesposobnošću da se nose s nesigurnošću i uče iz podataka [13].

5 STRATEŠKI MENADŽMENT

Kako se menadžment razvijao kroz povijest razvijale su se određeni pristupi kojima bi se kvalitetnije moglo pristupiti proizvodnji. Strateški pristup je jedan od tih pristupa, a glavna je ideja da se strategije koje su uključene u upravljanju cijelom kompanijom primjene i u proizvodnju. Primarni cilj je povećanje učinkovitosti, kvalitete i fleksibilnosti u proizvodnim procesima što na kraju naravno znači više zarade za to poduzeće i veća otpornost na promjene na tržištu.

5.1 Glavne komponente strateškog menadžmenta

Kada bi raščlanjivali glavne komponente strateškog menadžmenta, po knjizi Johnosna, Scholesa i Whittingtona *"Exploring Corporate Strategy: Text and Cases"* [14] to bi bile: strateg, konkurentska prednost, vizija i misija, vanjske analiza, unutarnja analiza, stvaranje i implementacija strategije.

5.1.1 Strateg - menadžer

Strateg je osoba koja osmišlja i provodi strategiju određenog pogona ili poduzeća, a može imati različite funkcije pa bi ih mogli nazivati voditeljima, rukovoditeljima, direktorima, predsjednicama, vlasnicima ili neki univerzalni termin bi bio menadžer. To je osoba koja je odgovorna za svaki uspjeh ili ne uspjeh koji njegova organizacija doživi. Svaka od glavnih komponenti koje će se objasniti detaljnije u idućem tekstu ne znače ništa ako ih netko ne zna prepoznati i implementirati [14].

Ne postoji univerzalna savršena strategija za neko poduzeće ili za neku industriju. Uzmimo za primjer ljevaonice željeza. Svaka ljevaonica radi vrlo slične procese i proizvode, međutim da je usporediti poslovne politike par ljevaonica iz iste države, a kamoli sa drugih krajeva svijeta, vidjeli bi koliko i u toj „primitivnoj“ industriji postoji razlika. To nam govori i da ne postoji univerzalno dobar menadžer odnosno strateg.

Ako se jedan strateg naučio voditi jedno poduzeće i sa svojom tehnikom rada napravio tamo dobre rezultate, to ne mora značiti da će sa istim pristupom u drugom poduzeću napraviti ni približno dobre rezultate. Stoga je od velike važnosti da je strateg objektivan, nepristran i da može realno ocijeniti situaciju u kojoj se on i njegovo poduzeće nalazi. Mnoge su kompanije propale iz razloga što su njihovi čelnici bili previše samouvjereni u svoje metode i nisu željeli promijene u svom načinu rada [14].

Iz navedenog možemo zaključiti da dobra strategija na papiru ili nekog konkurenta ne znači ništa ako je strateg ne može kvalitetno implementirati u svoj sustav.

5.1.2 Konkurentska prednost

Strateško upravljanje usmjereno je na stjecanje i očuvanje konkurentske prednosti u onoj djelatnosti u kojoj poduzeće nadmašuje konkurente. Tu prednost poduzeće može imati u imovini ili u znanjima/informacijama koje konkurenti ne posjeduju. Primjerice, tijekom velikih recesije posjedovanje velikih količina gotovine pruža značajnu prednost, što omogućuje akviziciju konkurenata u poteškoćama [14].

U recesiji smanjenje dugotrajne imovine također može biti korisno. Na primjer, Apple se bez svojih proizvodnih pogona oslanja na ugovorne proizvođač. Sa druge strane, Sony je sa svojih 57 proizvodnih pogona ima jednu sigurnost, ali je firma zbog toga stvorila značajna dugovanja. Konkurentska prednost nije statična što znači da ako je određeno poduzeće ima u jednom trenutku ne znači da će je uvijek imati. Stoga poduzeća moraju težiti trajnoj konkurentske prednosti kontinuiranom prilagodbom vanjskim i unutarnjim promjenama [14].

Korištenje interneta za izravnu prodaju, komunikaciju i e-trgovinu postaje ključni izvor konkurentske prednosti. Tvrtke imaju koristi od minimiziranih poslovnih troškova, bolje službe za korisnike, učinkovitosti, poboljšanih proizvoda i veće profitabilnosti. Internet je promijenio ponašanje potrošača zauvijek, te je na svakom poduzeću izazov hoće li se uspjeti prilagoditi promjenama koje se događaju gotovo na dnevnoj osnovi [14].

5.1.3 Vizija i misija

Misija i vizija temeljni su stupovi strateškog upravljanja koji organizacijama pružaju saznanja za budućnost. Služe kao orijentacijska svjetla, oblikujući identitet, svrhu i težnje organizacije. U danas mnoge organizacije na viziju gledaju kao na pitanje „Što bi htjeli postati kao organizacija?“. Tako da izradu te jedne rečenice u koju mnoge organizacije probaju opisati što jesu i što bi htjele postati često zovemo prvim korakom u izradi strategije.

Prije nego što se uđe u shvaćanje misije kako ne bi bilo zabune da se ta dva pojma odmah razjasne. Misija je vezana uz sadašnjost i definira osnovnu svrhu organizacije, dok je vizija vezana uz budućnost, prikazujući željenu destinaciju organizacije. Iako nisu iste, jedna drugu upotpunjuju te ne mogu funkcionirati jedna bez druge [14].

Misija sadrži temeljnu ideju organizacije. Sažeto opisuje zašto organizacija postoji, kome služi, i vrijednost koju želi pružiti. Taj skup naputaka, informacija i ideja usklađuje zajedničke napore svih zaposlenika i vlasnika prema istoj svrsi. Dobro izrađena misija ne samo da komunicira bit organizacije već služi i kao moralni kompas, usmjerava donošenje odluka i realizacije istih u skladu s njezinim temeljnim vrijednostima [14].

Nasuprot tome, izjava o viziji slika je budućnosti koju organizacija želi stvoriti. Riječ je o ambicioznoj deklaraciji okrenutoj budućnosti koja nadilazi sadašnjost i postavlja uvjerljiv smjer za rast i razvoj. Vizija je skica kako uspjeh izgleda pa tako pruža inspiraciju i motivaciju svima koji su povezani s organizacijom. Izjave o misiji i viziji zajedno čine filozofske temelje strateškog upravljanja. Misija služi kao sidro, utemeljenje organizacije u njenoj svrsi, dok vizija djeluje kao kompas, upućujući na budućnost postignuća i uspjeha [14].

U okviru strateškog upravljanja, izjave misije i vizije nisu statičke izjave već dinamične instrukcije koje se razvijaju s promjenjivom situacijom na tržištu. Prilagođavaju se vanjskim promjenama, unutarnjem rastu i novim prilikama. Kako se organizacije kreću po složenosti poslovnog okruženja, ta vodeća načela postaju sastavni dio donošenja odluka [14].

5.1.4 Vanjska analiza (prilike i prijetnje)

Analiza okruženja u strateškom upravljanju je proces u kojem organizacije moraju shvatiti vanjske čimbenike koji utječu na njihovo poslovanje i poslovanje njihovih konkurenata. Ova komponenta služi kao temeljni korak u procesu strateškog upravljanja, pružajući informacije koje su ključne za donošenje informiranih odluka i oblikovanje učinkovitih strategija [14].

Analiza okoliša u svojoj srži uključuje sustavno ispitivanje vanjskog okoliša u kojem djeluje organizacija. Ovo okruženje oblikovano je mnoštvom čimbenika, često kategoriziranih koristeći okvire poput PESTEL analize. PESTEL analiza je akronim pojmova politička (engl. *Political*), ekonomska (engl. *Economic*), društvena (engl. *Social*), tehnološka (engl. *Technological*), pravna (engl. *Legal*) i ekološka (engl. *Environment*). Rezultatima te sveukupne analize moguće je imati kvalitetan uvid u istraživanja tržišta, kreiranje marketinških strategija, razvoj proizvoda i donošenje boljih odluka za organizaciju [14].

U političkom području organizacije procjenjuju stabilnost vlade, politike i propise koji bi mogli oblikovati njihovo operativno okruženje. Ekonomski čimbenici utječu na gospodarske uvjete,

kao što su inflacijski tečajevi, devizni tečajevi i ukupni gospodarski rast, što može značajno utjecati na dinamiku tržišta. Društveni čimbenici istražuju demografske trendove, kulturne utjecaje i društvena stajališta koja mogu utjecati na ponašanje i preferencije potrošača. Tehnološka dimenzija uključuje procjenu tehnološkog napretka i inovacija koje bi mogle poremetiti ili poboljšati trenutačnu poslovnu praksu. Ekološka pitanja odnose se na ekološke čimbenike, uključujući održivost i propise o okolišu, koji su postali sve važniji u oblikovanju korporativnih strategija. Posljednji, pravni čimbenici obuhvaćaju pravni okvir unutar kojeg organizacija djeluje, rješavajući pitanja kao što su usklađenost, ugovori i sudski rizici [14].

Važnost vanjske analize leži u njejoj sposobnosti da otkrije prijetnje i prilike prisutne u okolišu u kojem se poduzeće nalazi. Identificirajući nove trendove i potencijalne izazove, organizacije se mogu proaktivno pozicionirati da kapitaliziraju povoljne uvjete i učinkovito se kreću kroz prepreke [14].

Na primjer, razumijevanje promjene preferencija potrošača ili nadolazećih regulatornih promjena može poslužiti kao temelj za donošenje strateških odluka povezanih s razvojem proizvoda, marketingom i usklađivanjem. Osim toga, analiza okoliša nije jednokratni pothvat, već kontinuirani proces. Poslovno okruženje je dinamično, podložno stalnim promjenama, i organizacije moraju redovito preispitivati i ponovno procjenjivati svoje analize kako bi ostale u skladu s promjenjivim uvjetima. Ta je prilagodljivost ključna za održavanje strateške važnosti i konkurentnosti [14].



Slika 66 Grafički prikaz dijelova PESTEL analize [15]

5.1.5 Interna analiza (prednosti i slabosti)

Interna analiza je jedan od glavnih procesa u strateškom upravljanju preko kojeg organizacija analizira interne resurse, sposobnosti i kompetencije organizacije kako bi otkrili svoje prednosti i slabosti. Preko interne analize saznajemo što sve organizacija posjeduje interno što može doprinijeti njenoj konkurentskoj prednosti. Ovaj proces uključuje sveobuhvatnu procjenu različitih elemenata, uključujući ljudski kapital organizacije, fizičke resurse, tehnološku infrastrukturu i nematerijalnu imovinu kao što su brend i intelektualno vlasništvo [14].

Ljudski kapital značajna je središnja točka interne analize. To uključuje vještine, znanje i stručnost radne snage. Ocjenjivanjem kompetentnosti radne snage pomaže se u utvrđivanju područja stručnosti koja se mogu iskoristiti za konkurentsku prednost [14].

Fizički resursi obuhvaćaju materijalnu imovinu kao što su proizvodni objekti, distribucijske mreže i tehnološka infrastruktura. Procjena tih resursa ključna je za utvrđivanje sposobnosti organizacije da zadovolji operativne zahtjeve i podrži strateške inicijative. Tehnološke sposobnosti čine još jednu kritičnu dimenziju interne analize. To uključuje procjenu tehnološke infrastrukture organizacije, inovacijskih procesa i integracije tehnologije u poslovanje. Tehnološki razvijena organizacija bolje je pozicionirana da se prilagodi promjenama u industriji, poboljša operativnu učinkovitost i kapitalizira nove prilike. Nematerijalna imovina, uključujući robne marke, patente i vlastite tehnologije, ima ključnu ulogu u unutarnjoj analizi. Ova sredstva doprinose konkurentskoj prednosti organizacije i pozicioniranju na tržištu [14].

Utvrđivanje unutarnjih prednosti i slabosti, kao i već prije odrađena vanjska analiza se često provjeravaju SWOT analizom.

5.1.6 SWOT analiza

SWOT analiza jedan je od najstarijih i najšire usvojenih strateških alata diljem svijeta. Izvorna SWOT analiza, pod nazivom SOFT pristup (ime kasnije promijenjeno u SWOT iz marketinških razloga) osmišljena je kao alat u jednom od najranijih strateških planskih okvira, nazvanom sustav planova u Silicijskoj dolini 60 ih godina prošlog stoljeća [14].

Kao glavni autor SOFT pristupa, Albert Humprey je naglasio da na sva konkretna pitanja treba odgovarati sa obzirom na vanjske i unutarnje čimbenike. Sa godinama se SWOT analiza prihvaća sve više, pa se tako 80-ih godina uvrštava kao bitna metoda planiranja u poslovnim

školama. Do danas je ta ista analiza ostala gotovo ne promijenjena i baš radi svoje jednostavnosti funkcionira vrlo dobro u različitim industrijama [16].

<p>S – Snage</p> <ul style="list-style-type: none"> • Što radite dobro? • Koje su jake strane vašeg proizvoda /usluga? • Koje prednosti imate u odnosu na konkurenciju? • Imate li pristup nekim važnim resursima? • Jeste li vlasnik prestižne tehnologije? • Jeste li vlasnik nekog patenta • Imate li troškovne prednosti nad ostalima? • Imate li dobre odnose s kupcima? 	<p>W – Slabosti</p> <ul style="list-style-type: none"> • Koje su slabosti vašeg proizvoda ili usluge? • Što možete popraviti? • Što radite loše? • Imate li loš imidž, lošu reputaciju među kupcima? • Imate li visoke troškove? • Nedostaju li vam ključne kompetencije? • Nedostaju li vam marketinške vještine?
<p>O – Prilike</p> <ul style="list-style-type: none"> • Koji vanjski faktori mogu biti iskorišteni ako se ukaže prilika? • Postoji li nezadovoljena tržišna potreba? Možete li ući na nova tržišta ili nove segmente? • Očekuje li se dolazak novih tehnologija? • Očekuju li se neke zakonske promjene ili slabljenje nekih trgovačkih barijera? 	<p>T – Prijetnje</p> <ul style="list-style-type: none"> • Što radi konkurencija? • Je li vjerojatan ulazak novih konkurenata? • Povećava li se prodaja supstitutivnih proizvoda? • Mijenjaju li se neke zakonske regulative? • Mijenjaju li se potrebe i ukusi potrošača?

Slika 77 SWOT analiza [17]

5.1.7 Izrada i implementacija strategije

Izrada strategije predstavlja temelj strateškog upravljanja. To je kompliciran proces koji zahtjeva sveobuhvatno razumijevanje organizacije i njenog okruženja [14].

Izrada strategije se događa na različitim organizacijskim razinama, korporativnoj, poslovnoj i funkcionalnoj. Svaka razina doprinosi općem cilju usklađivanja aktivnosti organizacije sa svojom misijom i vizijom, osiguravajući održiv i kvalitetan pristup ostvarenju dugoročnih ciljeva [14].

Na vrhuncu organizacijske hijerarhije, strategija na korporativnoj razini definira opseg i smjer cijelog poduzeća. Ta se razina strategije bavi pitanjima diversifikacije, spajanja i preuzimanja te raspodjele resursa među različitim poslovnim jedinicama. Njime se određuje glavni ton organizacije, određuju industrije u kojima djeluje i sinergije koje ona nastoji iskoristiti [14].

Pomicanjem razine prema dolje, strategija na poslovnoj razini usredotočuje se na to kako se organizacija natječe unutar određenog segmenta poslovanja ili industrije. Ovdje je naglasak na stjecanju prednosti pred konkurentima i donošenjem konkretnijih odluka. Pošto se nalazi između korporativne razine i funkcionalne cilj joj je zadovoljiti zahtjeve najviše korporativne razine, ali imajući na umu mogućnosti funkcionalne razine [14].

Najniža razina strategije je funkcionalna i u toj se razini sve odluke donesene sa vrha „kristaliziraju“: Tako se strategija na funkcionalnoj razini bavi se pitanjem realizacijom na razini unutar funkcionalnih odjela, kao što su marketing, ljudski resursi, proizvodnja i istraživanje i razvoj. Te su strategije često usmjerene na poboljšanje učinkovitosti poslovanja poduzeća unutar odjela i cilj ih je uskladiti što je više moguće sa korporativnom i poslovnom strategijom [14].

Kada smo sagledali sve ključne komponente za izradu kvalitetne strategije i kada smo tu istu strategiju raščlanili po slojevima poduzeća vrijeme je za implementaciju. Što je strategija bolje i detaljnije razrađena, imajući u vidu što je više pojedinosti i detalja, biti će je lakše implementirati. U početku implementacije je od ekstremne važnosti pratiti kako se poduzeće ponaša odnosno kako zaposlenici prihvaćaju nove promijene, te ako postoje neke nejasnoće i problemi da se od početka riješe [14].

6 DOBA UMJETNE INTELIGENCIJE

Jedan od najbrže rastućih alata koji nam upravo može pomoći u strateškom planiranju, ali i u puno drugih sektora je umjetna inteligencija (engl. *Artificial intelligence* (AI)). Umjetna inteligencija malo po malo ulazi u gotovo svaki aspekt naših života. Od medicine, analize velikih skupova podataka i autonomnih vozila do umjetnosti, sveprisutnost umjetne inteligencije je neupitna. Međutim, sve veća prisutnost umjetne inteligencije osim što otkrila rješenja za brojne izazove i probleme, dovela je i do mnoštva drugih pitanja.

Osim isključivo tehnološkog pogleda na umjetnu inteligenciju, trebamo gledati i društveni aspekt odnosno kakve će promjene to napraviti na tržištu rada te gospodarskih struktura i raspodjele resursa. Hoće li od toga profitirati pojedinci ili je ovo tehnologija koja će svima unaprijediti i poboljšati život.

Nadalje, integracija umjetne inteligencije u različite aspekte naših života uvodi etičke i moralne dvojbe. Budući da AI sustavi donose odluke i komuniciraju s ljudima, nepredviđene posljedice i potencijalne pristranosti ugrađene u algoritme mogu dovesti do neželjenih posljedica pa su znanstvenici potaknuti na kritičko ispitivanje etičke strane te tehnologije.

Sveprisutna implementacija umjetne inteligencije nas dovodi u područje dosad neviđenih mogućnosti, ali istovremeno zahtijeva razumijevanje izazova koji prate ovu tehnološku revoluciju. Koliko je ta tehnologija jaka, kako se trebamo postaviti prema njoj, hoće li zamijeniti čovjeka? Na ta pitanja i brojna druga će se probati odgovoriti u ovom radu.

6.1 Umjetna inteligencija u proizvodnim pogonima

Integracija umjetne inteligencije u proizvodne pogone predstavlja nešto složeniji proces od klasične digitalizacije i integracije informacijskih tehnologije. U tom kontekstu digitalizacija i informacijske tehnologije mogu se smatrati preduvjetima i temeljima koji su neophodni za uspješnu implementaciju rješenja umjetne inteligencije i strojnog učenja (engl. *Machine Learning* (ML)). Iz toga proizlazi simbioza AI/ML koja s uspostavljenom digitalizacijom i informacijskim tehnologijama stvara sustav iz kojeg se izvlače novi, složeniji i bolji podaci.

Nova iskustva unutar industrije naglašavaju potencijal AI/ML za znatno povećanje isplativosti, učinkovitosti i produktivnosti u različitim primjenama. Novim tehnikama tako možemo pratiti prediktivno održavanje, proizvodnju u stvarnom vremenu kako bi se smanjili neočekivani

kvarovi, osiguranje kvalitete za otkrivanje neispravnosti proizvoda, energetska predviđanje održivosti, sigurnosti i zaštite za rješavanje cyber sigurnosnih rizika te puno veća mogućnost vizualizacije dizajna što ubrzava stvaranje novih proizvoda i ne usporava proizvodnju [18].

Međutim, uključivanje umjetne inteligencije u proizvodne procese i pogone zahtijeva ogromne pripreme i investicije kako bi se napravili pravi preduvjeti. Prvo, zahtijeva velika kapitalna ulaganja za potrebnu hardversku i softversku infrastrukturu za učinkovito prikupljanje i obradu podataka. Drugo, postoji izazov u zapošljavanju osoblja s znanjem u AI/ML područjima i osposobljavanju postojećeg osoblja za rad sa novim tehnologijama. I posljednje iako umjetna inteligencija u proizvodnji u nekim slučajevima pokazuje vrhunske rezultate, nitko ne može garantirati da će se umjetna inteligencija dobro uklopiti u naš sustav i ako se i uklopi hoće li davati rezultate koje smo očekivali da bi se opravdala tako velika investicija [18].

Dodatni izazovi uključuju potencijalno pojavljivanje nenamjernih sigurnosnih rizika pri integraciji umjetne inteligencije u industrijske pogone, potencijalno povećanje energetske i ekološke otiske zbog računalno intenzivnih modela te značajnu promjenu između interakcije čovjeka i stroja što sa sobom opet nosi društvene aspekte koji se ne mogu gledati isključivo kroz brojke [18].

6.2 Machine learning – strojno učenje

Strojno učenje je grana umjetne inteligencije koja obuhvaća različite algoritme i modele osmišljene za učenje, prepoznavanje skrivenih uzoraka i donošenje odluka na temelju prikupljenih podataka. Danas gotovo sve veće kompanije koriste strojno učenje kako bi poboljšali kvalitetu svojih usluga/proizvoda. Neki od komercijalnijih primjera sa kojima se susrećemo svakodnevno su: Google (nudi nam najbolje moguće rezultate na temelju naše pretrage), Youtube (nudi nam videozapise koji bi nas mogli zanimati), Uber (u trenutku našeg traženja vožnje nam nudi najbolju moguću opciju s obzirom raspoložive vozače), Spotify (na temelju glazbe koju slušamo predlaže nešto slično)... Gledajući te primjere vidimo da strojno učenje nije budućnost nego sadašnjost i da se sa tom tehnologijom već koristimo [19].

U industriji se isto širi popularnost strojnog učenja jer nosi puno prednosti koje prije radi ne mogućnosti analiziranja takvih skupova podataka nisu mogle biti ostvarive. Glavne razloge zbog kojih danas koristimo strojno učenje možemo svrstati u kategorije: planiranje, praćenje u realnom vremenu i dizajn.

6.3 Vrste učenja

6.3.1 Nadzirno učenje

Nadzirno učenje je najtočniji i najkorišteniji oblik strojnog učenja te se zasniva na tome da čovjek stroju da grupirane i označene skupine podataka pa onda stroj iz njih izvlači podatke i zaključke. Kod ovog tipa učenja točno znamo kakve podatke pružamo stroju i kakve ćemo podatke moći očekivati [20].

Nadzirno učenje se dijeli na klasifikaciju i regresiju. Kod klasifikacije očekujemo jasnu izlaznu varijablu (na primjer da/ne), a kod regresije imamo linearnu vezu između ulaznih i izlaznih podataka (koristi se kod prognoze vremena, na tržištu nekretnina..)

Danas se nadzirno učenje primjenjuje u puno industrija a neki primjeri su: predviđanju cijena nekretnina, klasifikacija jesu li bankovne transakcije lažne ili ne, utvrđivanje faktora rizika za bolest, utvrđivanje jesu li podnositelji zahtjeva za kredit niskorizični ili visokorizični i što je najbitnije u proizvodnim pogonima a to je predviđanje kvarova mehaničkih dijelova industrijske opreme [20].

6.3.2 Nenadzirno učenje

Kod nenadzirnog učenja stroju dajemo podatke, međutim ti podaci nisu kategorizirani pa stroj sam mora pronalaziti skrivene uzorke. Nenadzirno strojno učenje vrlo je korisno kada se trebaju prepoznati uzorci potrebni za donošenje odluka. Uobičajeni algoritmi koji se koriste su skriven Markov model, k-means, hijerarhijsko grupiranje i „*Gaussian mixture models*“. [20].

6.3.3 Podržano učenje


Metodu podržanog učenja je metoda najbližnja čovjekovom razmišljanju, a mogli bi je opisati kao metodu u kojoj se nagrađuju željeni rezultati ponašanja i kažnjavaju neželjeni. Možemo za primjer uzeti banku. Ako imamo implementiran sustav podržanog učenja u banci i čovjek traži kredit koji mu sustav odobri i kasnije on taj kredit vrati, sustav sam sebe „nagradi“, odnosno shvaća da ide u pravom smjeru. Naravno ako se dogodi suprotno, odnosno osobi se odobri kredit na temelju podataka koje sustav posjeduje, a ta osoba ne vrati kredit sustav se „kažnjava“. Iz ovog primjera možemo primijeti sličnost razmišljanju prave osobe. Naravno što sustav više radi i ima više iskustva, točnije i točnije će moći prognozirati ishod događaja. Međutim baš radi svoje velike kompleksnosti ovi sustavi, iako daju dobre rezultate, ne koriste se često [20].

6.4 Tehnike učenja

6.4.1 Neuronske mreže

Neuronske mreže su najsnažnija tehnika strojnog učenja i općenito trenutno jedan od najsnažnijih alata u svijetu. Neuronske mreže funkcioniraju na sličan način ljudskom mozgu i tako uče stroj da procesira podatke. Stanice u ljudskom mozgu koje se zovu neuroni tvore jednu ogromnu i kompleksu mrežu putem koje međusobno razmjenjuju informacije elektro signalima. Na vrlo sličan način umjetna inteligencija oponaša rad mozga i sa svojim umjetnim neuronima tako razmjenjuje podatke [21].

Svaka neuronska mreža sastoji se od više slojeva : ulaznog sloja, jednog ili više skrivenih slojeva i izlaznog sloja. Svaki se čvor povezuje s drugima i ima vlastitu pridruženu težinu i prag. Ako je izlaz bilo kojeg pojedinačnog čvora iznad navedene vrijednosti praga, taj se čvor aktivira, šaljući podatke sljedećem sloju i tako u niz čime dobivamo mrežu. Arhitektura neuronske mreže započinje ulaznim slojem, gdje se obrađuju značajke podataka te se kategoriziraju i šalju dalje. Skriveni slojevi, smješteni između ulaznih i izlaznih slojeva, služe kao motor za procesiranje primljenih podataka koji se kad se obradu idu prema izlaznim slojevima . Izlazni sloj, završna faza mreže, daje izlazni podatak koji može biti binaran (na primjer da/ne) ili složeniji ovisno o kompleksnosti problema [21].




Slika 88 Grafički prikaz slojeva neuronske mreže [21]

6.4.2 Duboko učenje

Pojmom dubokog učenja smatramo složene neuronske mreže koje imaju nekoliko skrivenih slojeva s milijunima umjetnih neurona povezanih u jednu veliku mrežu. Težina predstavlja vezu između dva čvora. Težina je pozitivan broj ako jedan čvor aktivira drugi ili negativan ako jedan čvor potiskuje drugi. Čvorovi s većom težinom imaju veći utjecaj na druge čvorove [22].

Teoretski, duboke neuronske mreže mogu mapirati bilo koju vrstu unosa na bilo koju vrstu izlaza, međutim potrebno im je i puno više osposobljavanja u usporedbi s drugim metodama strojnog učenja. Trebaju milijune primjera podataka za obuku, a ne možda stotine ili tisuće koje bi jednostavnija mreža mogla trebati. Prednost je naravno ta što kod ostalih tehnika učenja čovjek mora ručno učiti stroj odnosno pokazivati mu koje podatke da veže uz koje značajke spajajući to dvoje, a kod dubokog učenja stroj sve to radi sam, odnosno vidimo da duboko učenje spada pod vrstu nenadziranog učenja [22].



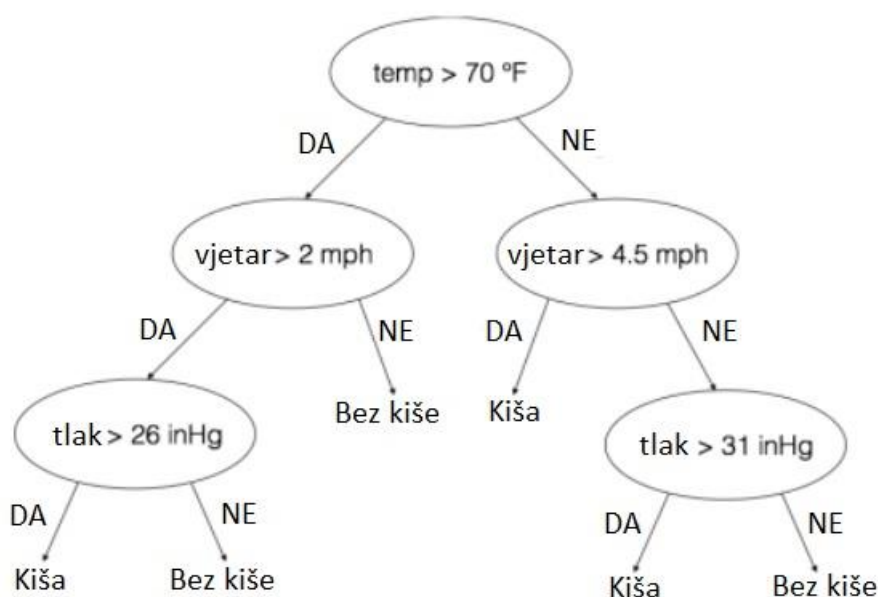
Slika 99 Usporedba strojnog učenja (engl. *Machine Learning*) i dubokog učenja (engl. *Deep Learning*) [22]

6.4.3 Stablo odlučivanja

Stabla odlučivanja spadaju pod nadzornu vrstu učenja, a izgledaju kao dijagrami toka, počevši od korijenskog čvora s određenim pitanjima, što vodi do grana koje imaju potencijalne odgovore. Poveznice zatim dovode do (internih) čvorova odlučivanja, koji postavljaju više pitanja koja dovode do više rezultata. To se nastavlja sve dok podaci ne dostignu posljednji čvor [23].

Stabla odlučivanja dijelimo na klasifikacijska i regresijska. Klasifikacijska stabla utvrđuju da li se neki događaj dogodio ili nije odnosno ima izlazni podatak da/ne. S druge strane, regresijska stabla predviđaju stalne vrijednosti na temelju prijašnjih podataka ili izvora informacija. Na primjer, mogu predvidjeti cijenu benzina ili hoće li kupac kupiti jaja (uključujući koju vrstu jaja i u kojoj trgovini) [23].

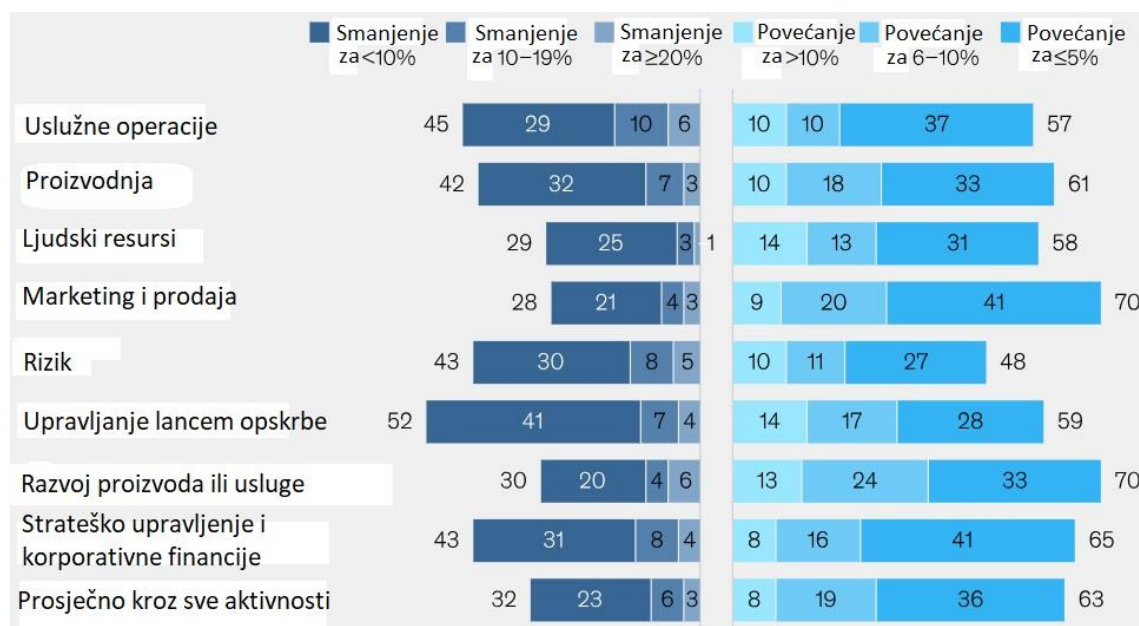
Takva vrsta odlučivanja je dosta složenija u odnosu na klasifikacijska stabla i više se odnosi na algoritme programiranja kako bi se predvidjelo što će se vjerojatno dogoditi, s obzirom na prijašnje ponašanje ili trendove.



Slika 1010 Prikaz stabla odlučivanja za problem vremenske prognoze [23]

7 PRIMJENA UMJETNE INTELIGENCIJE U STRATEŠKOM UPRAVLJANJU

Svi navedeni alati koje smo spomenuli i koje nosi sa sobom napredak umjetne inteligencije imaju krucijalnu ulogu u razvitku industrije 4.0. Umjetna inteligencija tvrtkama omogućuje prikupljanje i analizu obilnih količina podataka, prepoznavanje uzoraka, te automatizaciju procesa. Isto tako omogućujući brže i informiranije odluke koje poboljšavaju poslovanje i razvoj proizvoda. U ovom poglavlju će se obraditi utjecaj umjetne inteligencije na konkretne proizvodne procese, ali i njeni utjecaji na dizajniranje novih proizvoda.



Slika 1111 Prikaz statistike utjecaja umjetne inteligencije na različite sektore [24]

7.1 Prediktivno održavanje

Prediktivno održavanje se zasniva na očitavanju podataka sa senzora koji su instalirani na strojevima kako bi što bolje mogli predvidjeti kvarove. Odnosno cilj nam je što kvalitetnije predvidjeti kada nam je vrijeme za servis i tempirati ga da se on ne dogodi pre prano kada ćemo možda baciti alat kojeg još možemo koristiti, ali ne i pre kasno kako se ne bi dogodilo oštećenje stroja. Ako imamo neko malo poduzeće sa par strojeva navedena primjena nam možda toliko i ne znači, ali u velikim sustavima sa velikim brojem strojeva i male uštede mogu značiti puno.

Tako uzmimo za primjer jednu studiju [25] odrađenu na kompaniji ZF Friedrichshafen koja je proizvođač dijelova za automobilsku industriju. U njihovoj proizvodnji su im jako bitni strojevi za honanje kojima obrađuju zupčanike za automobile. Unutar stroja za honanje nalazi se jedan prsten kojeg treba redovito mijenjati, a ako se ne zamijeni na vrijeme može napuknuti i napraviti

veliku štetu stroju. Sa druge strane kompanije želi što manje prstena promijeniti radi troška samog prstena, a i vremena u kojem stroj ne radi. Kako riješili taj problem instalirali su senzore na strojeve kako bi prikupili što veći broj podataka. Najviše vremena je potrošeno u prikupljanje i kategoriziranje velikog broja podataka kako bi algoritam mogao početi raditi. Izlazne podatke su podijelili u dva odgovora: puknuće i bez puknuća. Primjenjivali su različite kombinacije tehnika strojnog učenja poput stabla odlučivanja i neuronskih mreža. Na kraju su uspjeli sa jednim oblikom stabla odlučivanja dobiti točnost od 99% u predviđanju puknuća prstena.

Po jednoj drugoj studiji [26] tvornice u prosjeku imaju 15 sati zastoja tjedno, a u automobilskoj industriji svaka minuta zastoja košta oko 20 000 \$.

Iz tih razloga prediktivno održavanje je jedan od najvažnijih razloga zašto se umjetna inteligencija i strojno učenje sve više i više istražuju i koriste u industriji.

7.2 Osiguranje kvalitete

Osiguranje kvalitete u proizvodnji odnosi se na procese koje proizvođači koriste kao dio sustava upravljanja kvalitetom za održavanje dosljednih, očekivanih razina kvalitete proizvoda koje proizvode. Osiguranje kvalitete važno je u svakom proizvodnom okruženju, ali je ključno za određene vrste proizvođača kao što su oni u automobilskoj industriji i dobavljači dijelova visoke preciznosti jer bi neodržavanje visokog standarda kvalitete moglo dovesti do ozljede ili smrti.

Dolazak umjetne inteligencije i strojnog učenja donijeli su povećanje kontrole kvalitete u širokom spektru primjena u svim proizvodnim industrijama. Neki modeli neuronskih mreža pokazali su se odličnim, a u nekim slučajevima nadmašiti tradicionalne metode za otkrivanje nesavršenosti proizvedenih proizvoda. To je posebno važno za aditivnu proizvodnju, gdje obilježja kao što su gustoća i poroznost mogu imati značajne učinke na mehanička svojstva konačnog proizvoda [27].

7.3 Predviđanje potrošnje energije

Predviđanje potrošnje energije u proizvodnim procesima koristi se sve više zbog suzbijanja utjecaja na okoliš i jačanja održivosti. Koristeći podatke koji obuhvaćaju temperaturu, vlagu, korištenje rasvjete, korištenje postrojenja i povijesnu potrošnju energije, regresijski modeli mogu predvidjeti profile potrošnje energije za cijelo postrojenje i za izolirane procese. To se pokazalo posebno bitno u sektorima s visokom energetsom potrošnjom, kao što su rudarstvo i proizvodnja čelika [28].

7.4 Upravljanje opskrbnim lancem

Umjetna inteligencija ima ogroman potencijal za transformaciju operacija u lancu opskrbe, poboljšanje donošenja odluka i učinkovitosti. U istraživanju McKinsey iz 2022. [24] ispitanici su istaknuli upravljanje opskrbnim lancem kao područje s najvećim uštedama troškova induciranim umjetnom inteligencijom. Umjetna inteligencija donosi vrijednost planiranju opskrbnog lanca, što obuhvaća proizvodnju, upravljanje inventarom i distribuciju proizvoda. Obradom opsežnih podataka u stvarnom vremenu, alati upravljani umjetnom inteligencijom povećavaju točnost predviđanja potražnje, omogućujući tvrtkama optimizaciju planova proizvodnje i inventara na različitim lokacijama i odabir isplativih logističkih rješenja.

Rani primjenitelji umjetne inteligencije u upravljanju opskrbnim lancem svjedočili su smanjenju logističkih troškova od 15%, povećanju zaliha od 35% i poboljšanju razina usluga od 65%. Iako provedba alata umjetne inteligencije za proizvodne pogone može uzrokovati troškove, anketa glavnih izvršnih direktora više od 150 poduzeća pokazala je da 70% dogovorene umjetne inteligencije donosi snažan ROI (engl. *Return Of Investment*) odnosno povrat investicije. Isto tako, integracija umjetne inteligencije u opskrbne lance nije namijenjena smanjenju mogućnosti zapošljavanja u upravljanju opskrbnim lancem. Umjesto toga, cilj joj je stvoriti nove putove, ublažavajući potencijalne rizike povezane s usvajanjem novih tehnologija [24].

7.5 Optimizacija procesa

Već dugo vremena kompanije traže način kako da ljudima skrate ili ih u potpunosti odvoje od repetitivnih zadataka. To se radi prvo jer ako imamo repetitivni zadatak njega puno jednostavnije možemo zadati stroju ili umjetnoj inteligenciji da rade nego nešto složenije. Sa druge strane, čovjek nema veliko zadovoljstvo raditi repetitivne zadatke jer i on zna da to može raditi stroj čime se ne ostvaruje njegov potencijal. Iz sličnog razloga raste sve više se koristi umjetna inteligencija kako bi smanjila utjecaj čovjekove greške, najviše u procesu kontrole kvalitete [27].

Nadalje AI može obraditi puno veće količine podataka u puno kraćem vremenu što najviše ima utjecaja na donošenje odluka u realnom vremenu gdje umjetna inteligencija gotovo odmah može prepoznati promjenu u podacima i dati čovjeku signal i savjet za donošenje odluke.

Značajna primjena AI/ML u proizvodnji je korištenje digitalnih blizanaca, virtualnih replika proizvodnih jedinica ili objekata unutar simuliranih okruženja. U studiji iz 2023. [29] istaknute

su znatne koristi digitalnih blizanaca koji se temelje na umjetnoj inteligenciji/ML u opsežnim operacijama pametne proizvodnje. Digitalni blizanci pružaju značajna smanjenja vremena simulacije u usporedbi s konvencionalnim metodama, omogućujući analizu podataka u realnom vremenu i kontrolu procesa.

7.6 Zaštita i sigurnost

Umjetnom inteligentnom može se poboljšati sigurnost radnika i kritične opreme u tvornicama. Može se upotrijebiti i za ublažavanje rizika kibernetičke sigurnosti koji proizlaze iz sve većeg broja umreženih proizvoda u proizvodnom pogonu. Računalni program temeljen na dubokom učenju može vizualno identificirati nesigurna ponašanja zaposlenika ili identificirati prisutnost neovlaštenog osoblja unutar objekta. Modeli učenja bez nadzora mogu se kombinirati sa sustavima stručnjaka za otkrivanje anomalija jer su podaci dobiveni operativnom tehnologijom predvidljivi [30].

7.7 Dizajn

Faza projektiranja obuhvaća izradu ili modifikaciju proizvoda i procesa, uključujući digitalno ili fizičko modeliranje i stroga ispitivanja kako bi se osigurala izvedivost i usklađenost s proizvodnim ciljevima. Ovaj proces dizajna zahtijeva testove za svaku novu iteraciju, što zahtijeva značajno vrijeme, rad i ulaganje materijala kako bi se pristupilo optimalnom ishodu. Nove tehnike umjetne inteligencije i strojnog učenja revolucioniraju taj proces uvođenjem prediktivnog modeliranja, generativnog dizajna i učenja podrškom [31].

Generativni dizajn uključuje uporabu umjetne inteligencije za istraživanje projektnog prostora za proizvod ili proces na temelju zahtjeva koje pružaju korisnici. Kako bi se to postiglo, umjetna inteligencija prvo se obučava na velikom broju postojećih dizajna. Taj pristup omogućuje istraživanje širokog raspona mogućnosti dizajna u kraćem vremenskom razdoblju. Tada se dizajner može usredotočiti na odabir iz generiranih dizajnerskih alternativa [31].

7.8 Izazovi

Dosada su nabrojane sve stvari u kojima je umjetna inteligencija izuzetno sposobna i dobra za industriju i čovječanstvo, međutim kako to inače biva sa nečim što je novo i sa sobom nosi ogromne promijene, umjetna inteligencija sa sobom nosi određene izazove i rizike koje moramo imati na umu.

Prvo, cijeli bit umjetne inteligencije, odnosno strojnog učenja je da toj tehnologiji pružamo velike količine podataka koje ona obrađuje i zatim daje neke izlazne podatke. Tako se otvaraju

pitanja o vjerodostojnosti i točnosti ulaznih podataka u jedan takav sustav. Ako stoj uči od krivih podatak sigurno ne može njihovom analizom dati točne izlazne podatke.

Potrošnja energije je isto velik problem koji sa sobom nose tako kompleksi sustavi. Kako se umjetna inteligencija razvijala i postajala složenija, bili su potrebni puno veći kompjuterski sustavi koji bi to mogli pratiti. Od 2012. godine do danas u prosjeku se kompjuterska snaga potrebna za programe umjetne inteligencije udvostručavala svakih 3.4 mjeseca. U jednoj studiji [32], se navodi da je utjecaj na okoliš proizveden od strane računala za treniranje jedne složene neuronske mreže jednak utjecaju 60% životnog vijeka jednog prosječnog automobila.

I na kraju implementiranje tako složenih sustava zahtijeva ogromne vremenske i financijske troškove i temeljne promjenu u funkcioniranju proizvodnih pogona. Odnos čovjeka i stroja je desetljećima bio gotovo nepromijenjen te je taj „suživot“ funkcionirao bez većih izazova, međutim sada između čovjeka i stroja stavljamo treće tijelo koje mijenja puno toga. Nije bitno koliko je neka tehnologija dobra i efikasna na papiru, nego koliko se dobro može uklopiti u postojeći sustav. Pošto umjetna inteligencija raste nevjerojatnom brzinom i širi se u sve pore industrije, mnoge kompanije je implementiraju „na silu“ nemajući dovoljna znanja ili pravi plan uvođenja u sustav što može stvoriti dodatne probleme i revolt kod određenog dijela radnika. A često se sve to radi bez razgovora sa zaposlenicima. Mnogi od njih strahuju da će umjetna inteligencija dovesti do otpuštanja i potrebe za puno većim dokazivanjem. Ista stvar se dogodila dovođenjem strojeva u drugoj industrijskoj revoluciji. Neki radnici su izgubili radno mjesto jer su strojevi mogli puno bolje raditi njihove radnje, ali je zato velikoj većini radnika olakšan i unaprijeđen posao.

8 PRIMJENA UMJETNE INTELIGENCIJE U INDUSTRIJI LOVA I PRERADE RIBE

Industrija lova i prerade ribe je jedna od najstarijih na obali Jadrana. Naši najstariji gradovi su stvarani uz obalu gdje su riba i plodovi mora bili glavni izvor hrane. Od tih prvih dana pa do danas, mnogo toga se promijenilo, ali još uvijek se možemo pohvaliti da imamo vrhunsku ribu i čisto more.

Međutim, u zadnje vrijeme situacija nije idealna za tu industriju. Hrvatsko ribarstvo već se četvrtu godinu zaredom suočava s krizom, prvo zbog pandemije COVID-19 i *lockdowna* tijekom kojih su bili zatvarani restorani, a i turističke sezone 2020. i 2021. nisu bile na razini prethodnih, uz smanjenu potražnju za izvozom, a od prošle godine zbog enormnog rasta cijena goriva i svih drugih troškova. Mnogi su ribari zbog toga tijekom prošle godine bili dovedeni na rub egzistencije, no primjenom mjera Europske unije i Ministarstva poljoprivrede za poticaje ribarstvu, kao i kakvom-takvom stabilizacijom cijena goriva u zadnje vrijeme, stvari su se donekle popravile, iako su još uvijek daleko od dobrih.

Osim toga, radna snaga je veliki problem. U ribarstvu i preradi ribe, poslovi su mukotrpniji, u teškim uvjetima koji nisu pogodni za većinu ljudi te je zato vrlo teško pronaći radnike. Firme se unazad par godina sve češće okreću uvozu radnika pa je tako normalno u pogonima za preradu ribe pronaći većinski udjel stranih radnika, najviše sa prostora dalekog istoka.

Zbog svega navedenog, vrlo je jasno da riboprerađivačkoj industriji treba pomoć. Može li i kako umjetna inteligencija pomoći hrvatskom ribarstvu, uzgoju i preradi ribe?

Kako bi se dao odgovor na najbitnija pitanja, razrađena su dva problema. Prvo, može li umjetna inteligencija smanjiti potrebu za uvozom radne snage u industriji prerade ribe? Drugo, može li umjetna inteligencija pomoći u predviđanju potreba tržišta kako bi se optimizirala proizvodnja u industriji uzgoja ribe?

8.1 Umjetna inteligencija u sortiranju ulovljene ribe

Prvi problem koji će se obraditi je problem nedostatka radne snage i kako umjetna inteligencija i nove tehnologije mogu pomoći u tome. Kako rješavanje ovog problema ne bi bilo temeljeno na pretpostavkama i informacijama sa interneta, ostvaren je kontakt sa firmom Teši Tunolov d.o.o. koja se bavi lovom ribe u Jadranu, a njezin pogon za sortiranje i obradu ribe se nalazi u industrijskoj zoni Poličnik, nedaleko od Zadra.

Firma je osnovana 1994. godine, a najveće postignuće firme je izgradnja pogona za sortiranje i preradu koji je otvoren 2016. godine. Firma trenutno broji 35 radnika, od kojih su 12 strani

državljeni (što znači da su strani radnici zastupljeni 34%)). Najviše stranih radnika je zaposleno radi potreba sortiranja ribe i za ispomoć na kočama (ribarskim brodovima).

Količina potrebnih radnika isto ovisi o lovostaju (najčešće u siječnju veljači i dijelom svibnja) i ulovu koji izuzetno varira ali na dobre dane se ulovi 3-6 tona srdela i inćuna.

Tunolov koji je i u imenu firme je jedna od grana firme, međutim najveći dio firminog prometa odnosi se na lov odnosno prodaju neobrađenih srdela i inćuna, te mariniranih srdela i inćuna.

8.2 Problem sortiranja srdela i inćuna

Plava riba je jedna od najvećih hrvatskih izvoznih proizvoda i nevjerojatno bogatstvo jadranskog mora. Naše more je vrlo raznoliko, te obiluje raznim vrstama plave i bijele ribe, međutim što se tiče ribolova dvije vrste su najzastupljenije, a to su srdela i inćun.

	Ulov i uzgoj (proizvodnja), t				Indeksi, ukupno 2022. 2021.
	2021.	2022.			
	ukupno	ukupno	ulov	uzgoj (proizvodnja)	
Ukupno	85 341	86 013	62 912	23 101	100,8
Ribe	82 543	82 983	60 978	22 005	100,5
Plava riba	61 046	60 573	57 302	3 271	99,2
Srdela	40 485	39 242	39 242	-	96,9
Inćun	11 621	13 912	13 912	-	119,7
Tuna	6 002	4 073	802	3 271	67,9
Plavica	1 144	1 667	1 667	-	145,7
Šarun	1 212	1 058	1 058	-	87,3
Ostale vrste	582	621	621	-	106,7
Ostala riba	21 497	22 410	3 676	18 734	104,2
Oslić	1 062	1 178	1 178	-	110,9
Trlja	793	647	647	-	81,6
Cipal	99	100	100	-	101,0
Ugor	36	35	35	-	97,2
Lubin	9 094	10 047	13	10 034	110,5
Komarča	7 783	7 736	230	7 506	99,4
Gira	102	95	95	-	93,1
Bukva	81	68	68	-	84,0

Slika 1212 Statistika riboprerađivačke industrije za 2022. [33]

Prema državnom zavodu za statistiku 2022. godine [33] se ulovilo 60 978 tona ribe svih vrsta, a od toga 39 242 tona iznosi srdela, a 13 912 tona iznosi inćun. Drugim riječima srdela i inćun iznose više od 87% ukupnog ulova ribe u Hrvatskoj. Iz tih brojkki je jasno vidljivo koliko te dvije sorte riba znače riboprerađivačkoj industriji.



Slika 1313 Ulov na koći (srdele i inćuni)

Srdela i inćun se love plivaricama, ribarskim brodovima koji velikim mrežama love ribu. Kada se riba izvadi iz mora na brodu se odmah stavlja u baje, velike spremnike u kojima se drži riba zajedno sa ledom kako bi zadržala svoju svježinu. Po dolasku u pogon dolazi na proizvodnu traku gdje kreće odvajanje srdele od inćuna i ostale ribe i nečistoća koje se mogu pronaći u ulovu.



Slika 1414 Pokretna traka za sortiranje ribe u pogonu firme Teši Tunolov



Slika 1515 Pokretna traka za sortiranje ribe u pogonu firme Teši Tunolov

Sortiranje ribe se izvodi na ovoj proizvodnoj traci. Riba se u velikim bajama ukrcava na traku kroz koju se tempira njen protok do radnika kako bi oni što brže, ali i točnije mogli odvojiti srdelu, inćun i ostale ribe koje se nađu a koje iznose 0.5.-1% od ukupnog izlova.



Slika 1616 Radnici koji odvajaju inćune od srdele na pokretnoj traci



Slika 1717 Inćun [34]



Slika 1818 Srdela [34]

Na ovim fotografijama vidimo srdelu i inćun. Laik, koji bi samo letimično pogledao ove dvije fotografije, bi možda rekao da se radi i o istoj ribi kolika je njihova sličnost. Netko tko se više puta susreo sa ove dvije vrste zna da je srdela veličinom nešto veća ima širu glavu, dok je inćun už i ima izraženiju plavu traku na vrhu leđa. Osim što je sličnost veoma visoka, radnici koji rade na sortiranju u pogonu ne dobivaju ribe ovako paralelno posložene jedne do drugih nego nabacane u razno raznim položajima, pa je potrebna velika preciznost i iskustvo svakog radnika kako bi što bolje odvojili te dvije vrste i naravno u ritmu koji diktira brzina trake. U prosjeku omjer ulova iznosi oko 70% inćuna i 30% srdele. Iz firme Teši Tunolov kažu kako je prosječna točnost u odvajanju srdele i inćuna oko 85%.

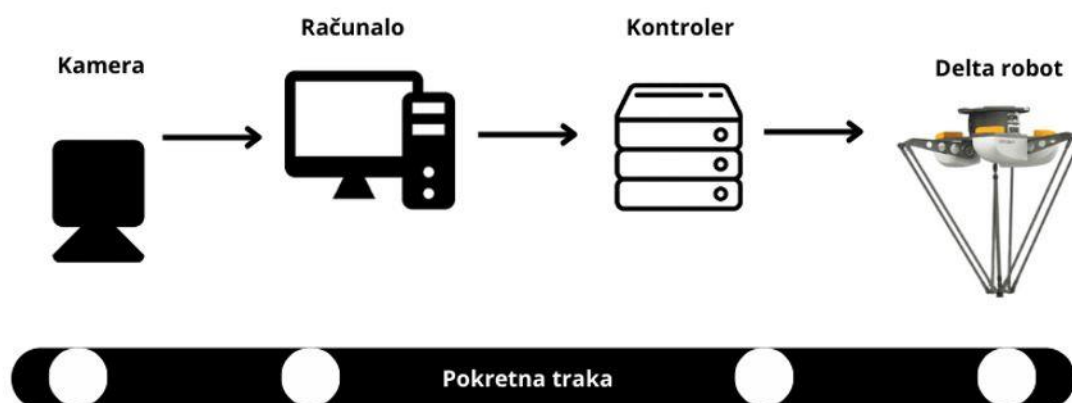
8.2.1 Idejno rješenje

U svrhu automatizacije proizvodnog pogona, potrebno je autonomno prepoznati vrstu ribe i sortirati ju bez pomoći operatera. U konkretnom slučaju, potrebno je raspoznati, tj. klasificirati, dvije vrste plave ribe Jadranskog mora: srdelu i inćun. Težini problema uvelike doprinosi minimalna vizualna distinkcija između navedenih vrsta.

Kako bi sistem mogao funkcionirati bez ljudske pomoći osmišljen je sustav od 5 elemenata, a oni su:

- Kamera
- Računalo
- Pokretna traka
- Kontroler
- Delta robot

Pokretna traka već postoji međutim bilo bi ju potrebno prilagoditi tako što bi joj se regulirala brzina i eventualno dužina kako bi bila efikasnija i više prilagođena robotskoj ruci.



Slika 1919 Shema sustava za sortiranje ribe

Slično rješenje je već detaljnije razrađeno u diplomskom radu [35].

Koraci sustava bili bi idući:

1. Fotografiranje

Na kameri imamo senzor koji nakon što prepozna kretanje ribe na pokretnoj traci stvori fotografiju te je šalje prema računalu na daljnju obradu

2. Obrada fotografije i prepoznavanje vrste

Fotografije iz kamere se šalju softveru koji po naučenom modelu može prepoznati radi li se o srdeli ili inćunu, te će na fotografiji sa bounding box-om označiti o kojoj se ribi radi i tu informaciju proslijediti dalje.

3. Slanje informacija o poziciji robotu

Računalo šalje robotu preko kontrolera informacije o poziciji ribe koju mora izvući. Naravno pošto se pokretna traka stalno kreće, pozicija ribe se mora izračunati ovisno o brzini trake ovisno od mjesta na kojem je fotografirana.

4. Odvajanje ribe sa pokretne trake

Robotska ruka treba što preciznije i brže izvući ribu čija je vrsta u manjini, odložiti u posebnu kutiju, te se vratiti u primarni položaj

Pošto je informacija i radova, a na kraju krajeva i realne primjene ove tehnologije vrlo malo, istraživanje je otežano. Na sreću, firma Kontakt d.o.o. koja je firma kćer firme HSTech d.o.o. iz Zadra već je radila istraživanja na ovu temu, te su ustupili dio svojih dobivenih rezultata, a autoru ovog diplomskog rada su objasnili cijeli proces te dali dopuštenje za korištenje svojih rezultata u ovom diplomskom radu. Naglasak je na dio pošto je navedeni projekt apliciran na natječaju za sufinanciranje od strane europske unije pa se ne smije izlaziti u javnost sa svim detaljima.

8.2.2 Klasifikacija riba i treniranje modela

Kako bi računalo uspješno moglo prepoznavati o kojoj se vrsti ribe na fotografiji radi potrebno ga je prvo „naučiti“ kako koja riba izgleda. Segmentacija slike je tehnika računalnog vida koja dijeli sliku u više segmenata ili regija kako bi se pojednostavnio prikaz slike. Cilj segmentacije je podijeliti sliku na značajne dijelove koji se mogu lakše analizirati ili obraditi. Svaki segment obično odgovara drugom objektu ili području unutar slike, kao što su objekti, granice ili područja od interesa [36].

Postoji nekoliko metoda segmentacije slike, uključujući:

1. Histogrami: Ova metoda dijeli sliku na prednji plan i pozadinu na temelju vrijednosti intenziteta piksela. Pikseli intenziteta iznad ili ispod određenog praga klasificiraju se kao prednji plan odnosno pozadina [36].

2. Segmentacija na temelju rubova: tim se pristupom utvrđuju granice ili rubovi na slici pomoću tehnika kao što je otkrivanje rubova, a zatim se pikseli grupiraju na temelju tih rubova [36].

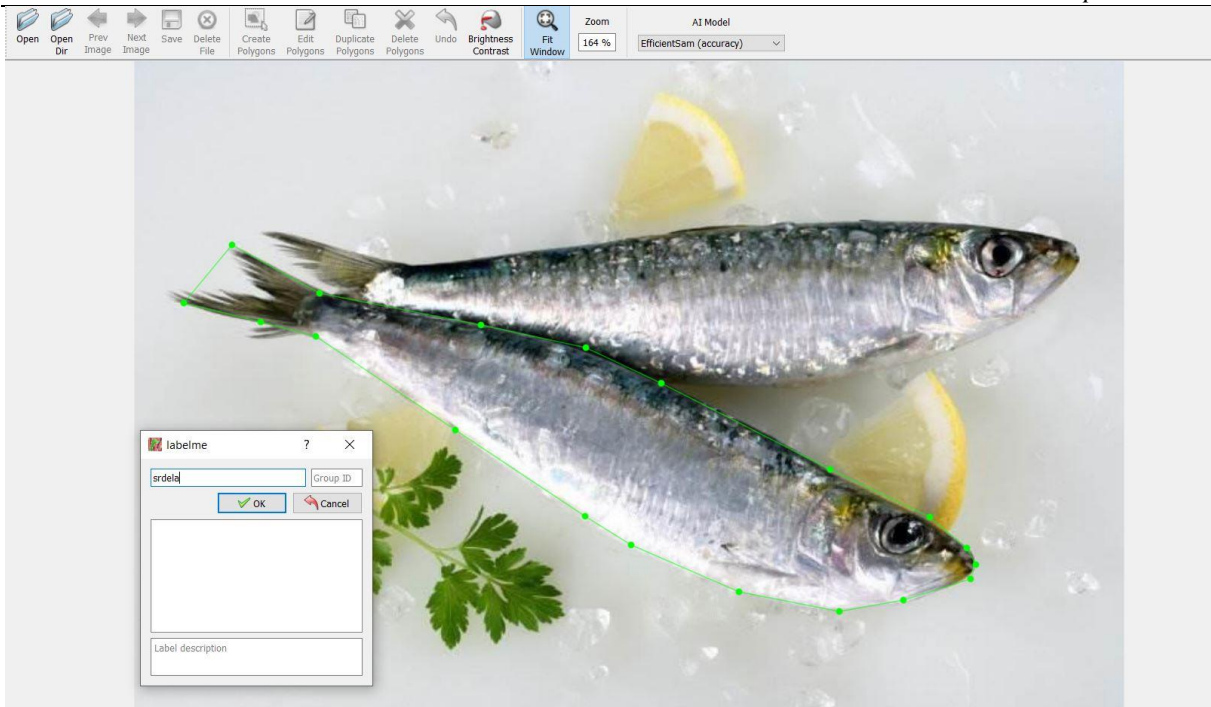
3. Regionalna segmentacija: Ova metoda grupira piksele u regije na temelju sličnosti boja, intenziteta, teksture ili drugih značajki. Uobičajene tehnike uključuju grupirane algoritme poput k-medijalne ili vodene transformacije [36].

4. Watershed segmentacija: algoritmi pretvaraju slike u sive tonove, a zatim generiraju topografsku kartu u kojoj je „visina” svakog piksela određena svjetlinom. Regije, granice i objekti mogu se izvesti iz kojih se formiraju „doline”, „grebeni” i „slivovi” [36].


5. Segmentacija temeljena na klasteriranju: metoda učenja bez nadzora, algoritmi klasteriranja dijele vizualne podatke u klustere piksela sa sličnim vrijednostima. Uobičajena varijanta je klasteriranje K-sredstava u kojem je k broj klastera. Vrijednosti piksela su iscrtane kao točke podataka, a k nasumične točke su odabrane kao središte klastera [36].

Za potrebe ovog projekta korištena je segmentacija na temelju rubova i segmentacija bounding box-om, a program koji je korišten je LabelMe. Segmentacija na temelju rubova daje točnije podatke jer se točno označi gdje je riba u odnosu na bounding box gdje obuhvatimo pravokutnikom određeni dio fotografije, ali je isto tako puno sporija metoda pa se bounding box koristi u većini slučajeva. U program se učitavaju fotografije koje trebamo segmentirati, u našem slučaju srdela i incuna, te se na tim fotografijama poligonima označuju ribe i daje im se klasa, srdela ili incun. Kako bi se osigurala što veća točnost, u firmi Kontakt ručno je uneseno i označeno preko 1000 fotografija srdele i 1000 fotografija incuna.

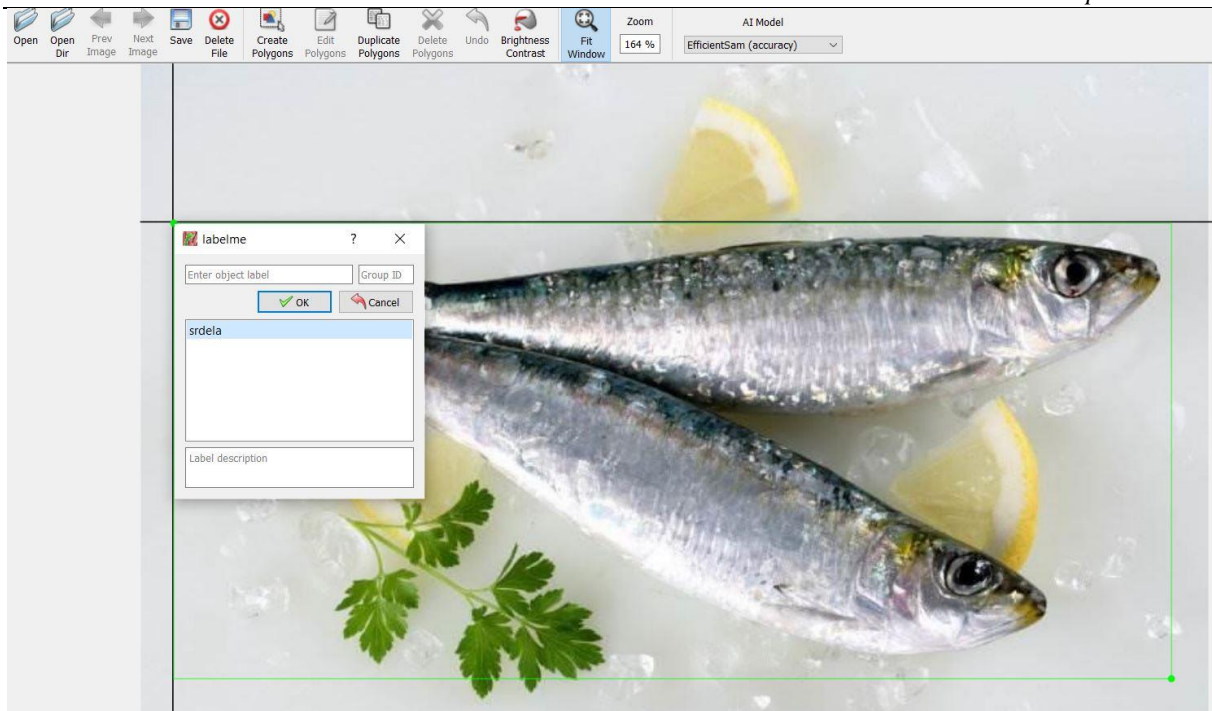
U slikama 20, 21 i 22 je prikazano je segmentiranje u istom softveru za segmentaciju slika sa kojim su radili u firmi Kontakt.



Slika 2020 Segmentacija na temelju rubova



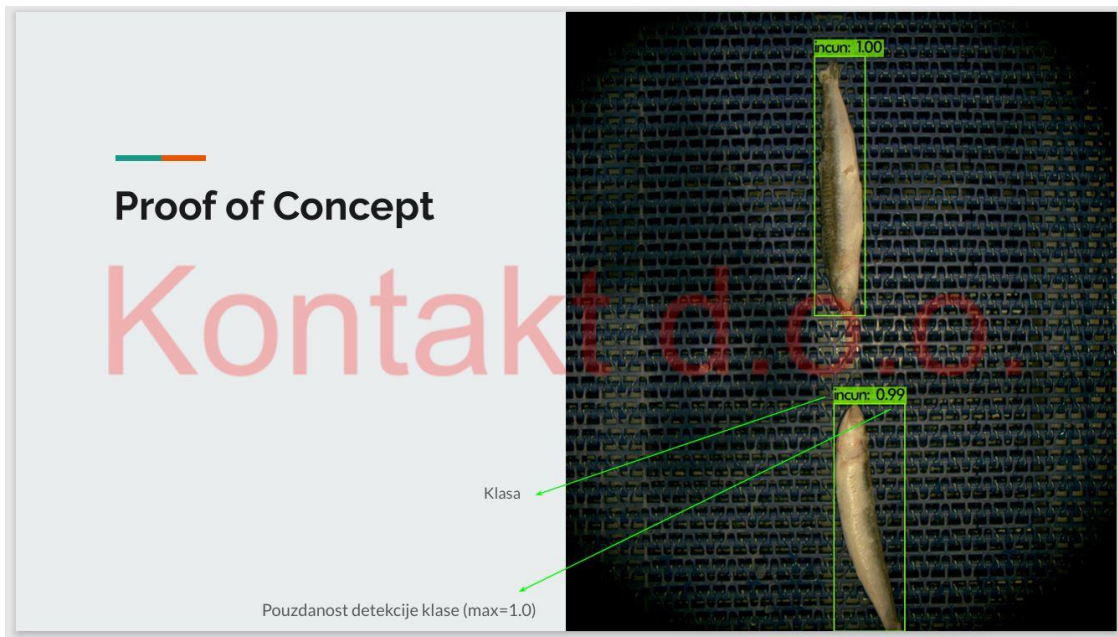
Slika 2121 Segmentacija na temelju rubova



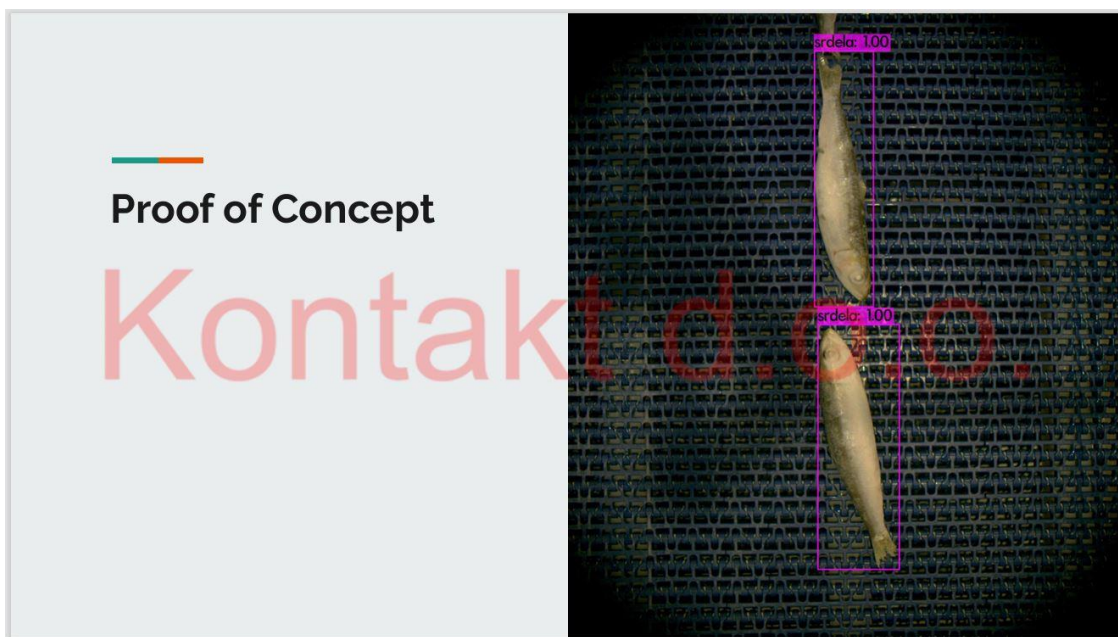
Slika 2222 Segmentacija metodom bounding box

Nakon što su se segmentirale sve fotografije srdele i inćuna i sortirale svake u svoju bazu podataka idući korak je učenje modela. Baza podataka je podijeljena u omjeru 80:20 odnosno 80% fotografija (oko 1600) su korištene za učenje modela, a 20% (oko 400) za testiranje. Kombinacijom koda u Python-u i softvera YOLO, program je istreniran, a u idućem poglavlju su prikazani rezultati koje je dobila firma Kontakt.


8.2.3 Rezultati



Slika 2323 Rezultati prepoznavanja incuna



Slika 2424 Rezultati prepoznavanja srdela



Slika 2525 Rezultati prepoznavanja sa promjenom orijentacije



Slika 2626 Rezultati prepoznavanja sa devijacijama u obliku ribe



Slika 2727 Prikaz rubnih slučajeva

Preliminarni rezultati pokazuju izrazito visoku točnost klasifikacije srdela i incuna od 99 % pri čemu su rubni slučajevi 2 i 3 pridodani klasi srdela. Ostvareni rezultat potvrđuje uspješnost odabranog pristupa na realnom prikazu uvjeta u proizvodnom pogonu Poličnik. Naš model uspješno klasificira srdele i incune neovisno o njihovoj veličini, orijentaciji i devijaciji u obliku. Preliminarni rezultati su ostvareni na ograničenom broju podataka te je moguća pristranost modela zbog čega se konačna točnost može razlikovati od prikazane.

Točnost klasifikacije u konačnoj realizaciji projekta ovisit će o vizualnoj reprezentaciji ribe na traci, načinu sortiranja riba u nepovoljnom položaju i ostatku implementacije sortirne trake (osvjetljenje, podrhtavanje kamere, mehanička izvedba sustava). Na temelju preliminarnih rezultata možemo procijeniti da uz optimalne uvjete rada i prikupljanje veće količine podataka, konačan model za klasifikaciju će ostvariti visoku točnost (> 97 %)

8.2.4 Robot

Robot kojim izdvajamo ribu sa pokretne trake mora imati nekoliko karakteristika, a najbitnije su da imaju velike brzine i akceleracije kako bi mogli pratiti pokretnu traku i da su delikatni jer ne smiju oštetiti ribu koju prenose. Roboti koji najviše odgovaraju ovoj primjeni su delta roboti. Delta roboti, također poznati kao paralelni roboti ili paukovi roboti, predstavljaju izvanredan napredak u području robotike. Ove robote karakterizira jedinstvena paralelna vezna struktura koja im omogućuje postizanje brzih i preciznih pokreta. Izvorno razvijen za zadatke koji

zahtijevaju brzo i precizno preuzimanje i postavljanje, delta roboti su od tada pronašli aplikacije u širokom rasponu industrija, od pakiranja hrane do sklapanja elektronike i šire.



Slika 2828 Delta robot [37]

Posebnost delta robota je paralelna kinematička struktura koja se sastoji od tri ili više ruku spojenih na zajedničku bazu i pokretnu platformu. Ruke se obično pokreću motorima kroz kuglaste zglobove, omogućujući samostalno kretanje po dužini. Paralelna konfiguracija pruža nekoliko prednosti u odnosu na tradicionalne serijske robote, kao što su povećana brzina, preciznost i krutost [37].

Dizajn delta robota inspiriran je prirodom, oponašajući pokrete određenih insekata poput pauka ili mrava. Ovaj bio-inspirirani pristup omogućio je inženjerima razvoj robota koji su ne samo visoko učinkoviti već i sposobni obavljati složene zadatke sa izuzetnom agilnošću i točnošću [37].

Jedna od najznačajnijih prednosti delta robota je njihova iznimna brzina. Zahvaljujući njihovoj paralelnoj strukturi i laganom dizajnu, delta roboti mogu postići ubrzanja i brzine koje daleko nadmašuju brzine konvencionalnih robotskih sustava. To ih čini idealnim za primjene koje zahtijevaju brzo i opetovano kretanje, kao što su brze montažne linije ili operacije pakiranja [37].



Slika 2929 Delta roboti u prehrambenoj industriji [38]

Osim brzine, delta roboti nude izvanrednu preciznost. Njihova kruta struktura i precizna kinematika omogućuju održavanje čvrstih tolerancija i ponovljivosti, osiguravajući dosljednu izvedbu tijekom duljih razdoblja. Ta je razina preciznosti ključna u industrijama u kojima čak i malo odstupanje može dovesti do nedostataka proizvoda ili problema s kvalitetom.

Nadalje, delta roboti su vrlo svestrani i prilagodljivi raznim zadacima i okruženjima. Njihov kompaktan otisak i fleksibilan dizajn čine ih pogodnima za integraciju u postojeće proizvodne linije ili prilagođene aplikacije. Bilo da se radi o nježnim elektroničkim komponentama, razvrstavanju farmaceutskih proizvoda ili sastavljanju složenih uređaja, delta roboti mogu se lako prilagoditi posebnim zahtjevima.

Zbog svih navedenih prednosti delta roboti su najidealnije rješenje za naš sustav.

8.2.5 Diskusija

U prošlim prikazani su rezultati koji su dobiveni kombinacijom umjetne inteligencije i računalnog vida koji pokazuju zavidnu uspješnost od čak 97% i predložen je idejni sustav koji bi te rezultate od onih testnih mogao prenijeti u stvarnost. To govori da ovakav sustav može pronaći realnu primjenu u jednom pogonu za preradu ribe. Hoće li ga taj isti pogon implementirati trebala bi provjeriti studija isplativosti. Da li bi se postojeća pokretna traka mogla prilagoditi novom načinu rada ili bi trebalo raditi sve iz početka je pitanje na koje bi se moglo odgovoriti daljnjom razradom ovog problema, ali dobivene prednosti su vrlo jasne.

Prvo kao što je već spomenuto ovaj sustav ima veću točnost od čovjekovog prepoznavanja i to za 13% (točnost radnika u sortiranju je oko 85%). Tom većom točnošću imamo čistiju sirovinu koja može postići veću cijenu na tržištu.

Drugo, ovaj sustav gotovo pa u potpunosti može zamijeniti čovjekov rad. To je prednost od velike važnosti kad je nedostatak radne snage prisutan u svim industrijama, a pogotovo u onim primitivnijima kao što su riboprerađivačka. Već sada u firmi Teši Tunolov većina radnika koja radi na sortiranju ribe su porijeklom sa Filipina, a ista je situacija u gotovo svim riboprerađivačkim pogonima.

I treće ovaj sustav bi sa vremenom i ulaganjem definitivno imao veću efikasnost i profitabilnost od radnika. Nakon što je napravljeno prvo ulaganje, u sustav ne treba osim održavanja ulagati dodatna sredstva, za razliku od radnika koji su trošak na mjesečnoj razini čak i onda kad je firma u lovostaju pa se osim posla u mariniranju ulovljene ribe ne radi ništa drugo. Robot i računalo mogu raditi u 3 smjene, 24 sata dnevno i to je činjenica kojoj se niti jedan radnik ne može približiti.

Iz svega navedenog vidimo očite prednosti, međutim može se postaviti i pitanje etičnosti ovakvog ili sličnog sustava koji u potpunosti mijenja ljudski rad. To pitanje bi bilo validno da stvarno ovaj sustav uzima nečiji posao, ali u situaciji gdje je firma primorana tražiti radnu snagu na drugom kraju svijeta, ovakvi sustavi će biti sve bolje i bolje prihvaćeni.

8.3 Umjetna inteligencija kao osnova poslovanja u uzgoju ribe

Nakon što se prikazalo kako umjetna inteligencija može olakšati ili u potpunosti zamijeniti čovjekov rad u sortiranju ribe, u ovom poglavlju navest će se još jedna primjena umjetne inteligencije u riboprerađivačkoj industriji.

Porijeklo ribe u riboprerađivačkoj ribi možemo podijeliti na divlju ribu koja se razmnožava i živi bez čovjekovog utjecaja, a imamo i ribu iz uzgoja koja u potpunosti ovisi o čovjeku. Uzgoj

ribe na ovim prostorima počinje 80-ih godina sa prvim mrjestilištem u Ninu koji otvara firma Cenmar (danas Cromaris), a javlja se iz potreba koje su aktualne i danas, a to je da je ne dovoljno bijele ribe u moru kako bi se zadovoljile potrebe potrošača, pa je pokrenuta ideja uzgoja ribe. Svoj život ribe započinju u mrjestilištu koje je podijeljeno na matičnjak, uzgojne jedinice od ličinačke faze preko metamorfoze do mlađi te odjela za proizvodnju zooplanktona i fitoplanktona, koji su ujedno i prva hrana ribe. Sve jedinice su odvojene, imaju zasebne filtracijske sustave, što omogućuje kreiranje optimalnih zoohigijenskih uvjeta. Proces proizvodnje prati prirodni foto period ribe s posebnom pažnjom na dobrobit životinja. Kad mlađ dosegne masu od 3-5 grama, u transportnim bazenima se prevozi do uzgajališta gdje se nastavlja njen uzgojni ciklus.

Cromaris je osnovala Adris grupa 2009. godine, a broj zaposlenih od tada je porastao više od četiri puta, odnosno danas zapošljava više od 600 radnika, uglavnom iz Zadra i okolice te su najveći svjetski proizvođač organske bijele ribe. To je firma koja godišnje ima preko 100 milijuna eura prihoda, proizvode oko 12 500 tona bijele ribe, a što je specifično da im gotovo 90% prihoda čini izvoz što je atipično za hrvatsku ekonomiju [39].

Uzgajaju brancine, oradu, hamu, gofa i zubatca, a kaveze za uzgoj imaju u zadarskom akvatoriju i u Istri. Uz to imaju dva velika pogona za obradu ribe, jedan u Zadru i jedan u Ninu.



Slika 3030 Cromaris-ovo mrjestilište u Ninu [39]

8.3.1 Problem planiranja količina lova ribe

Cromaris je u 2023. godini prodao preko 12 000 tona ribe, odnosno u prosjeku oko 30-35 tona dnevno. To su ogromne količine hrane za bilo koju kompaniju u prehrambenoj industriji, a pogotovo za jednu hrvatsku firmu, pa ne čudi da su 6. firma u svijetu u prodaji orade i brancina. Najveći kupci su prvenstveno u Italiji, a zatim u Austriji, Njemačkoj, Švicarskoj, Poljskoj...

Kada firma dnevno proda 30-35 tona ribe, treba imati dobro posložen proizvodni proces. Od primanja narudžbi, do spremanja i raspoređivanja tih narudžbi, pa do konkretnog lova i dobave te ribe u pogon i na kraju pakiranja i otpremanja. Ono što je jako bitno u tom proizvodnom procesu je predvidjeti odnosno prognozirati koliko će ribe trebati uloviti danas, sutra, prekосуtra ili do kraja tjedna.

Narudžbe za ribu dolaze isključivo od drugih firma odnosno firma radi b2b modelom, a vremenski najčešće dolaze dan ranije. Pošto je riba delikatan proizvod jer je njena svježina izuzetno bitna, jako je bitno znati koliko ribe treba uloviti kako se ne bi ulovilo pre malo da ne bude dovoljno za narudžbe, a opet ne previše kako se ne bi stvarali viškovi odnosno treba gađati nulu.

Do prije godinu dvije, u Cromaris-u su nekakva predviđanja radili ručno odnosno na iskustvo zaposlenih koji su radili u odjelu primanja narudžba pa su oni predviđali koliko će im ribe trebati. Osim svježine ribe potrebno što bolje predviđati ulov jer o njemu ovisi potreban broj radnika u pogonu i njihovo radno vrijeme, potreban broj brodova na moru pa tako i zaposlenih na njima, potreban broj ambalaža itd.

Vidimo kako ta jedna brojka o količini ribe koju treba uhvatiti nosi sa sobom puno drugih pitanja. Iz tog razloga su u Cromaris-u posegli za pomoći svojih partnera, iz iste grupacije Adris, u firmu Maistra čiji su programeri za potrebe Cromaris-a sastavili program prognožiranja prodaje ribe pomoću strojnog učenja koje se uči na podacima iz prošlosti za svakog kupca, te uspoređuje te podatke na tjednoj i na godišnjoj bazi.

Osim svega navedenog, nije spomenuta jedna jako bitna stavka koja još više otežava stvar zaposlenima u odjelu planiranja izlova, a to je da se ribe osim po vrsti mogu kupovati po klasi. Tako imamo klase 200-300 g, 300-400 g, 400-600 g, 600-800 g, 800-1000 g, 1.000-1.500 g, 1.500-2.000 g, 2.000-3.000 g, 3.000 g +

Klase su pretežito raspoređene Gausovom krivuljom odnosno većina ribe je u srednjim klasama dok je puno manje ekstrema, jako malih i jako velikih riba. Kako plivarica, brod koji vadi ribu

iz kaveza ne može birati koju će ribu izvaditi, nego može utjecati samo na količinu ribe koju vadi, zaposlenici iz prodaje i planiranja izlova moraju dobro posložiti narudžbe kako bi izlov bio što bolje iskorišten.

Tako za primjer da bi dobili 2 tone orade klase 1500-2000g trebamo ukupno izvaditi 14 tona orade, među kojima će biti 2 tone tražene klase. Sad se postavlja pitanje što će firma napraviti sa ostatkom ribe, odnosno oradom drugih klasa?

Tu u priču opet dolazi suradnja umjetne inteligencije gdje zajedno pokušavaju naći što idealniju količinu ribe koju će izloviti i prilagoditi narudžbe kako ne bi imali viškova, a ni manjka pa da ne mogu ispuniti određene narudžbe.

9 ZAKLJUČAK

Menadžment, odnosno nauka o upravljanju ljudima i resursima je kao živo tijelo koje se prilagođava vremenima u kojima se nalazi. Temelj je svakog poslovanja, od malog obrta do najvećih kompanija, pa nije ni čudo kako svako o njemu ima svoje mišljenje. U ovom radu ideja je bila prikazati evoluciju menadžmenta od najranijih dana do danas, jer ne možemo znati svoju budućnost ako ne znamo prošlost. Budućnost je svakako umjetna inteligencija, sviđalo se to nekom ili ne. Riboprerađivačka industrija je kruh mnogim obiteljima u Dalmaciji i jedna od grana industrija koja se više-manje nije mijenjala od svojih početaka. Usudio bih se reći da su dvije najveće promjene u riboprerađivačkoj industriji do sada bile izum motora sa unutarnjim izgaranjem, čime su se povećale veličine brodova, a time i količina ulova, a druga promjena bi bila uzgoj ribe koji u ovim krajevima počinje 80-ih godina prošlog stoljeća. Interesantno je zato bilo prikazati kako umjetna inteligencija može napraviti razlike u takvoj jednoj „primitivnoj“ industriji. Na primjeru sortiranja ribe prikazana je ideja potpuno automatiziranog sustava, te prvi rezultati dobiveni testiranjem tehnologije računalnog vida koja je prikazala zavidnu točnost. Unatoč prikazanim rezultatima, tek bi trebalo vidjeti kako bi se sustav ponašao u sustavima pogona gdje je malo toga savršeno. Na drugom primjeru prikazan je sustav prognoziranja narudžbi odnosno planiranja izlov ribe. Nažalost, firma Cromaris nije htjela ustupiti fotografije svog sistema zbog zaštite podataka. Nažalost, jer ima vrhunski sistem koji vrlo jednostavno optimizira sustav tako da se ne stvaraju ni viškovi ni manjkovi, kako u ribi, kako u potrošnim materijalima, kako u radnoj snazi, pa bi se opisivanjem uz te fotografije prednosti takvog sistema još više obogatio ovaj rad. Na kraju zaključak je da je umjetna inteligencija neizbježna u razvoju većine, a možda i svih industrija. Da će doći do otpuštanja dijela radnika koji će biti tehnološki višak to je sigurno, međutim slična stvar je bila i u drugoj industrijskoj revoluciji dolaskom prvih strojeva. Kako god bilo, na kraju dana, na menadžmentu je da učini svoje poduzeće što otpornijim na promjene, te da bude u toku sa vremenom, a ako to znači implementaciju umjetne inteligencije u neke dijelove svoga rada nitko neće bježati od toga. Tek nam je vidjeti što nam budućnost nosi, a na menadžerima je da budu spremni jer nadolazeće vrijeme nosi sa sobom velike promjene.

LITERATURA

- [1] Egyptians were the first recorded project managers-planning pyramids:
<https://planningengineer.net/egyptians-were-the-first-recorded-project-managers-planning-pyramids/> (19.2.2024.)
- [2] https://upload.wikimedia.org/wikipedia/commons/thumb/9/96/Pyramids_of_the_Giza_Necropolis.jpg/1200px-Pyramids_of_the_Giza_Necropolis.jpg (19.2.2024.)
- [3] Mohajan H.K. (2020.) *The Second Industrial Revolution has Brought Modern Social and Economic Developments*
- [4] Nickerson C. (2024.) *Bureaucratic Management Theory Of Max Weber*
- [5] Rahman H. (2012.) *Henry Fayol and Frederick Winslow Taylor's Contribution to Management Thought: An Overview*
- [6] Tomac N., Radonja R., Bonato J. (2019.) *Analysis of Henry Ford's contribution to production and management*
- [7] Neoclassical Theory Of Management <https://harappa.education/harappa-diaries/neoclassical-theory-of-management/>
- [8] Sahito Z., Vaisanen P. (2017.) *The Diagonal Model of Job Satisfaction and Motivation: Extracted from the Logical Comparison of Content and Process Theories*
- [9] Dar S. A. (2022.) *Maslow's Hierarchy of Needs Is still Relevant in the 21st Century*
- [10] <https://putpremasebi.hr/maslowljeva-hijerarhija-potreba/> (25.2.2024.)
- [11] Miro Hegedić (2020.) predavanje Menadžment Ljudskih potencijala
- [12] Douglas McGregor Theory X and Y
https://switcheducation.com/wpcontent/uploads/2017/06/SEB_LYO_McGregor_Thinker.pdf (25.2.2024.)
- [13] Rockwell A. (2017.) *The History of Artificial Intelligence*
- [14] Johnosn, Scholes, Whittington (2008.) *Exploring Corporate Strategy: Text and Cases*
- [15] <https://www.fespa.com/en/club-fespa-online/how-to-guides/how-to-conduct-a-pestle-analysis-to-get-the-global-picture> (30.4.2024.)
- [16] Puyt. R. W. (2023.) *The origins of SWOT analysis*
- [17] <https://arhiva-2021.loomen.carnet.hr/mod/book/view.php?id=973042&chapterid=144926&lang=de> (30.4.2024.)

- [18] Impact of Artificial Intelligence in Manufacturing: Pros and Cons <https://blog.radwell.com/impact-of-artificial-intelligence-in-manufacturing-pros-and-cons> (4.4.2024.)
- [19] Exploring the Algorithms Used by Tech Giants: YouTube, Netflix, Uber, Amazon, Facebook, Airbnb, Spotify, and Google <https://www.shamail.in/exploring-the-algorithms-used-by-tech-giants-youtube-netflix-uber-amazon-facebook-airbnb-spotify-and-google/> (4.4.2024.)
- [20] Neha SVST., Yadav Y., Goyal Y. (2024.) *Introduction to Machine Learning*
- [21] Artificial Neural Networks and its Applications <https://www.geeksforgeeks.org/artificial-neural-networks-and-its-applications/> (4.4.2024.)
- [22] Deep Learning vs. Machine Learning – What’s The Difference? <https://levity.ai/blog/difference-machine-learning-deep-learning> (4.4.2024.)
- [23] How Are Decision Trees Constructed In Machine Learning <https://prateekvjoshi.com/2016/03/22/how-are-decision-trees-constructed-in-machine-learning/> (4.4.2024.)
- [24] McKinsey (2022.) The state of AI in 2022—and a half decade in review <https://www.mckinsey.com/capabilities/quantumblack/our-insights/the-state-of-ai-in-2022-and-a-half-decade-in-review> (4.4.2024.)
- [25] An introduction to implementing AI in manufacturing <https://www.pwc.com/gx/en/industrial-manufacturing/pdf/intro-implementing-ai-manufacturing.pdf> (4.4.2024.)
- [26] Brosset P., Thieullent A.L., Patsko S., Ravix P., (2019.) *Scaling AI in Manufacturing Operations: A Practitioners' Perspective*
- [27] Industrializing Additive Manufacturing by AI-based Quality Assurance <https://blog.siemens.com/2021/10/industrializing-additive-manufacturing-by-ai-based-quality-assurance/> (5.4.2024.)
- [28] Karthick K., Dharmaprakash R., Sathya S. (2024.) *Predictive Modeling of Energy Consumption in the Steel Industry Using CatBoost Regression: A Data-Driven Approach for Sustainable Energy Management*
- [29] Zayed S. (2023.) *A review study on digital twins with artificial intelligence and internet of things: concepts, opportunities, challenges, tools and future scope*
- [30] Using Artificial Intelligence in Cybersecurity <https://www.balbix.com/insights/artificial-intelligence-in-cybersecurity/> (6.4.2024.)

-
- [31] Using AI for Product Design <https://careerfoundry.com/en/blog/product-design/ai-productdesign/#:~:text=Product%20designers%20can%20use%20AI,might%20behave%20in%20the%20future> (6.4.2024.)
- [32] B. Ross (2019.) *Practical AI-Powered Real-Time Analytics for Manufacturing: Lessons Learned From Design to Deployment*
- [33] Državni zavod za statistiku, Ribarstvo u 2022. <https://podaci.dzs.hr/media/g1cnriyc/polj-2023-7-2-ribarstvo-u-2022.pdf> (19.4.2024.)
- [34] <https://sheshnjak.github.io/dalmacija-ribolov/proizvodi.html> (30.4.2024.)
- [35] Cerpenić M. (2021.) *Razvoj sustava za robotsko sortiranje ribe primjenom metoda strojnog učenja*
- [36] What is image segmentation? <https://www.ibm.com/topics/image-segmentation>
- [37] <https://acrome.net/product/delta-robot> (25.4.2024.)
- [38] Robots lift pastry sales <https://www.controlsdrivesautomation.com/Kawasaki-Robots-lift-pastry-sales> (25.4.2024.)
- [39] <https://cromaris.com/hr/> (28.4.2024.)