VELEUČILIŠTE U KARLOVCU
Karlovac University of Applied Sciences

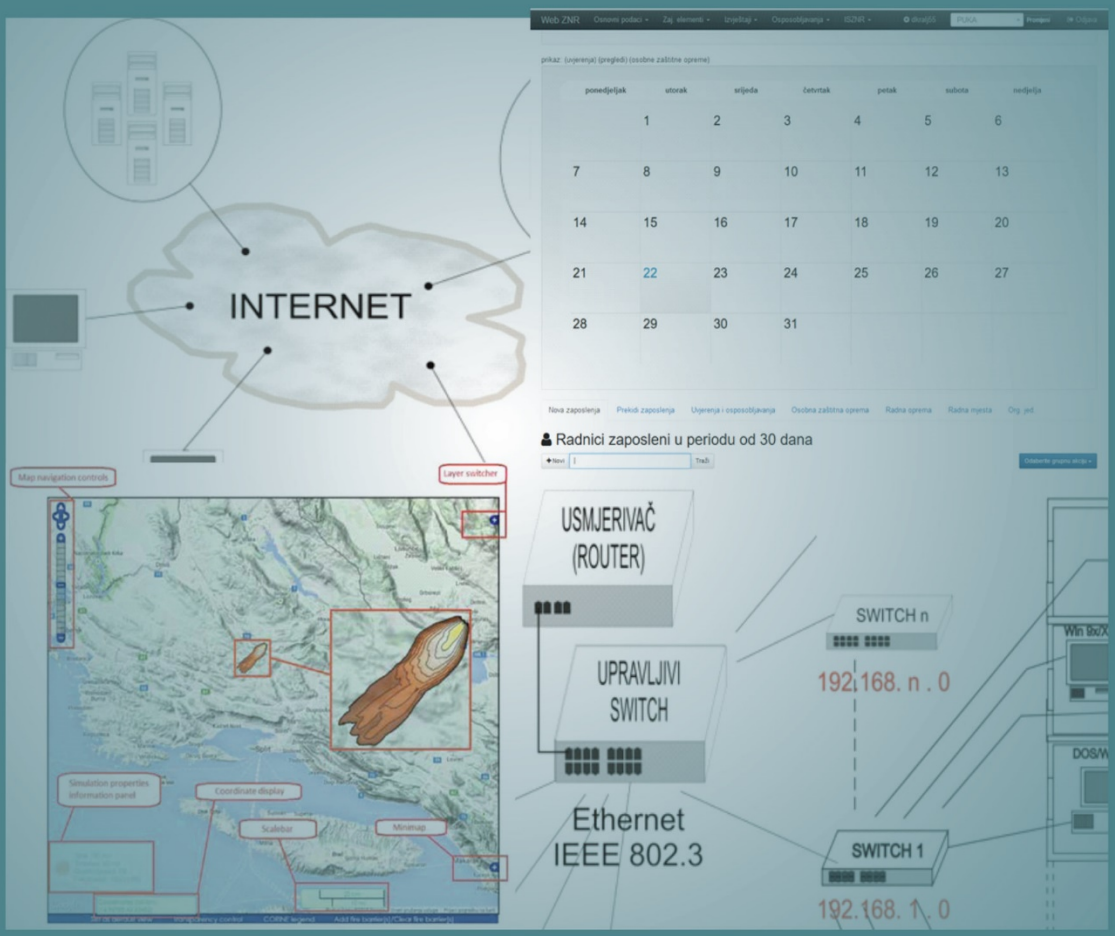

INFORMACIJSKI SUSTAVI U SIGURNOSTI I ZAŠTITI

Udžbenik za studente stručnog diplomskog studija Sigurnosti i zaštite

Damir Kralj

ISBN (*online*) 978-953-8213-24-3

Izdavač: Veleučilište u Karlovcu
Za izdavača: Ivan Štedul, v. pred.
Recenzenti: prof. dr. sc. Mario Cifrek, doc. dr. sc. Adam Stančić
Grafički urednik: dr. sc. Damir Kralj
Lektorica: Maja Kličarić

Objavljivanje ovog veleučilišnog udžbenika odobrilo je Povjerenstvo za izdavačku djelatnost Veleučilišta u Karlovcu Odlukom o izdavanju publikacije br. 7.5-13-2023-1

VELEUČILIŠTE U KARLOVCU
Studij sigurnosti i zaštite

Damir Kralj

INFORMACIJSKI SUSTAVI U SIGURNOSTI I ZAŠTITI

Udžbenik za studente stručnog diplomskog studija
Sigurnosti i zaštite

Karlovac, 2024.

Predgovor

Ovaj je udžbenik načinjen kao pomoć studentima stručnog diplomskog studija Sigurnosti i zaštite Veleučilišta u Karlovcu pri praćenju predavanja i spremanju ispita iz predmeta Upravljanje zaštitom na radu primjenom računala i Upravljanje zaštitom od požara primjenom računala. Obrađeno gradivo obuhvaća elementarne zahtjeve, metode i postupke prilikom uvođenja novog ili proširenja postojećeg računalno podržanog informacijskog sustava kao podrške poslovnom sustavu neke tvrtke, odnosno ljudske djelatnosti, a polazi od stava da je informacijski sustav zadovoljavajuće kakvoće neophodan za oblikovanje i obradu informacija na temelju kojih se donose ključne taktičke i strateške odluke na kojima se zasniva funkcija upravljanja poslovnim sustavom ili nekom njegovom sastavnicom. U osnovnom su obliku obuhvaćene temeljne faze od projektiranja sustava, odabira strojne i programske podrške, izvedbene problematike, pa do krajnje faze primjene sustava, odnosno, do konkretnih oblika primjene u taktički i strateški usmjerenim elementima upravljanja sigurnošću i zaštitom, kao i neke metode vrednovanja uspješnosti. Pri tome nije bila namjera od polaznika ovih predmeta načiniti potencijalne projektante informacijskih sustava već, naprotiv, oblikovati što spremnije ljudske potencijale koji će na svojim radnim mjestima moći razumjeti mogućnosti i značaj informatizacije u cilju unaprjeđenja funkcije upravljanja nekom djelatnošću unutar koje trebaju osigurati funkcionalnost sigurnosti i zaštite. Uloga korisnika, koji u suvremenim radnim okruženjima posjeduju ovakvo znanje, neprocjenjiva je pri analizi poslovnih sustava i aplikativnom projektiranju programske podrške. Ukratko, cilj je ovog udžbenika i nastavnih predmeta za koje je načinjen stvaranje ljudskih potencijala koji će biti sposobni razumjeti, nositi i unaprjeđivati postupak digitalne transformacije, kako u području sigurnosti i zaštite tako i u svim ostalim područjima ljudskih aktivnosti. Tijek predavanja prate i računalne vježbe u okviru kojih se polaznike nastoji upoznati s osnovama oblikovanja, optimiranja i povezivanja raznih oblika elektroničkih evidencija primjenom alata koji su sastavni dio profesionalnih programskih paketa za automatizaciju uredskog poslovanja u velikoj većini hrvatskih i svjetskih tvrtki, kao i s osnovama inženjerske grafike koja će im često ustrebati u budućem radu prilikom modeliranja raznih radnih postupaka. U udžbeniku je prikazan i analiziran i dio osnovnih primjera koji se obrađuju u sklopu auditornih vježbi. Polaznici će se upoznati i s nekim komercijalno dostupnim alatima za potporu upravljanju sigurnošću i zaštitom te s aktualnim prednostima, problemima i nedostacima ovakvih rješenja, kao i s aktualnim stupnjem razvoja domenske informacijsko-komunikacijske infrastrukture.

Karlovac, prosinac 2023.

Damir Kralj

SADRŽAJ

1. UVOD

Sveukupna povijest razvoja i napretka ljudskog društva zasniva se na razvoju i napretku raznih vrsta i oblika ljudskih djelatnosti koje, prije svega, jamče opstanak, a onda i napredak ovog društva. Svaka se ljudska djelatnost, bez obzira na vrstu i veličinu područja djelovanja, sastoji od niza nekakvih elementarnih poslova. Oni se ne provode nekim neodređenim i slučajnim redoslijedom, već su uglavnom određeni nekim tehnološkim ili drugim protokolom. Uobičajeno govorimo da ti elementarni poslovi zajedno čine tzv. *poslovni sustav* unutar kojeg postoji određeni *protok poslova*. Nadalje, poslovni sustavi podrazumijevaju postojanje nekog predmeta rada koji može biti materijalan i/ili nematerijalan. Logično je da, ako govorimo o *protoku poslova*, postoji i protok predmeta rada koji mora ući u sustav, pri čemu tijekom prolaska kroz sustav mijenja svoj oblik te naposljetku izlazi iz njega kao završen proizvod ili poluproizvod namijenjen daljnjoj obradi. Poslovni sustav dakle mora imati barem jedan ulaz i jedan izlaz, a ovisno o području djelatnosti i ustroju, u njega ulaze i izlaze materijali, energija i informacijski tokovi. Sustav koji preuzima informacije koje onda obrađuje i prezentira poslovnom sustavu i okolini naziva se *informacijski sustav*. Dobar informacijski sustav, iako se ponekad čini nevidljivim, „mozak" je poslovnog sustava i jamstvo je njegova preživljavanja. Informacijski sustav može biti manualan (još se uobičajeno kaže i „papirnat") ili podržan suvremenom informacijsko-komunikacijskom tehnologijom. U današnjim uvjetima poslovanja često kažemo da informacijski sustav predstavlja informacijski lik ili tzv. *alter ego* (iz latinskog, hrv. drugo „ja") poslovnog sustava.

Osvrnemo li se na naslov ovog udžbenika koji glasi *Informacijski sustavi u sigurnosti i zaštiti* te na nazive predmeta za koje je knjiga napisana Upravljanje zaštitom na radu primjenom računala i Upravljanje zaštitom od požara primjenom računala, možemo lako protumačiti ulogu i važnost suvremenih informacijskih sustava u upravljanju aktivnošću poslovnih sustava. Općenito, poslovni sustav dobiva informacije iz raznih unutarnjih i vanjskih izvora, a informacijski sustav ih obrađuje u nove i korisne informacije. Konačni je cilj informacijskog sustava snabdijevanje poslovnog sustava njemu korisnim informacijama potrebnim pri obavljanju poslova i donošenju poslovnih odluka odnosno odlučivanju. Odlučivanje je pretpostavka upravljanja poslovnim sustavom. U našem ćemo slučaju analizirati oblikovanje i primjenu informacijskih sustava namijenjenih upravljanju poslovnim podsustavima zaštite na radu i zaštite od požara kao ključnih elemenata cjelovitog poslovnog sustava sigurnosti i zaštite, no prije toga ćemo analizirati neke osnovne pojmove koji opisuju elemente i aktivnosti u okviru područja informacijskih sustava (Bourgeois, 2014; Strahonja, Varga i Pavlić, 1992).

1.1. Što su sustavi?

Teorija sustava je interdisciplinarna znanost koja se bavi opisivanjem i objašnjavanjem zakonitosti postanka, razvoja, organizacije i ponašanja nekog sustava. Cilj joj je stvaranje metoda i reda u proučavanju i rješavanju problema, što postiže razvojem apstraktnog sustava koji nastaje kao rezultat matematičkog opisa stvarnog sustava. Iako je jedan oblik opće teorije sustava već 20-ih i 30-ih godina promicao Ludwig von Bertalanffy, u znanstvenim je krugovima pojam teorije sustava zaživio tek 50-ih godina 20. stoljeća, i to na načelima ontologije, filozofije, fizike, biologije i inženjerstva. Poslije je ta teorija primijenjena na mnogobrojna druga područja, npr. na zemljopis, sociologiju, političke znanosti, organizacijske teorije, psihoterapiju te ekonomske znanosti. Danas je šest ključnih znanosti integrirano u teoriji sustava i sve su u međusobnom odnosu. To su opća teorija sustava (ima metodološki pristup u proučavanju teorije sustava), kibernetika, matematička teorija sustava (daje modele za upravljanje sustavima na apstraktnoj razini), teorija informacija, semiotika i informatika.

Jednostavnije rečeno, sustavom se smatra skup objekata koji mogu biti elementi sustava ili podsustavi, međusobno ujedinjeni i povezani, pri čemu objekti djeluju kao cjelina. Podsustavi se

prema potrebi mogu razložiti na svoje komponente, a elementi ne mogu. Svaki je sustav podsustav nekoga nadsustava koji se obično označava kao njegova okolina, a s kojim razmjenjuje tvari (materijale), energiju ili informacije. Nasuprot klasičnoj analizi teorije sustava, sustavna analiza proučava sustav kao dio okoline, a promjene koje se u njemu događaju tumači kao posljedicu prilagođavanja okolini. Glavno je obilježje sustava proces kojim se ulazne veličine transformiraju u izlazne. Dio ulaznih veličina transformira se u korisne izlazne veličine kojima se ostvaruje cilj sustava, a dio se troši na funkcioniranje samoga sustava, tj. transformira se u nekorisne (neiskoristive) izlazne veličine. Kako bi sustav mogao ostvarivati postavljene ciljeve njime se mora upravljati. Sustav bez upravljanja teži stanju maksimalne entropije koja se tumači kao kvantitativna mjera nereda u sustavu. Upravljanje sustavom, tj. njegovo održavanje u željenom stanju, svodi se na dodavanje novih informacija u sustav čime se smanjuje entropija. Za ostvarivanje ciljeva sustava, odnosno povećanje njegove učinkovitosti, ključni su postupci specijalizacije i integracije.

Opća teorija sustava zasniva se na kibernetici pa se pojmovi teorija sustava i kibernetika ponekad upotrebljavaju kao istoznačnice, jednako kao i pojmovi poput sustavne znanosti i kompleksnih sustava. O značenju pojma i području kibernetike bit će više riječi u sljedećem potpoglavlju (Kern i Petrovečki, 2009).

1.2. Osnovni pojmovi

Riječ **informatika**, kao uobičajeni pojam, pojavio se krajem šezdesetih godina 20. stoljeća u europskim zapadnim zemljama, osobito u Francuskoj i Njemačkoj. U literaturi se spominje da ga je 1962. godine osmislio Philippe Dreyfus, direktor Centra za elektroničko računanje francuske računalne tvrtke Bull. U to se doba posvuda u svijetu počelo govoriti o elektroničkim računalima i automatskoj obradi podataka/informacija. U Parizu je 1959. godine održan prvi Svjetski računalni kongres nakon kojeg je UNESCO 1960. godine osnovao Međunarodnu federaciju za obradu informacija (engl. *International Federation for Information Processing*, IFIP). U Francuskoj je zatim 1962. godine osnovano društvo za automatsku obradu informacija, a pri davanju imena tom društvu Dreyfus je došao na zamisao da spoji riječi u izrazu *information et électronique* (informacija i elektronika), pa je nastalo društvo *Société d´Informatique Appliquée* (iz francuskog, Društvo za primijenjenu informatiku). Tako je disciplina, koju su u SAD-u pretežito nazivali *computer science* (računalna znanost), dobila na francuskom jeziku naziv *informatique* (hrv. informatika). Nova je riječ tako dobro primljena da se brzo proširila, pa je već 1967. godine Francuska akademija (fra. *L´Académie française*) objavila definiciju informatike kao „znanosti o prikladnoj obradi podataka, osobito pomoću automatskih strojeva, koja se smatra potporom znanjima u području znanosti, ekonomije i društva". Kako su se u to doba snažno razvijale francusko-njemačke veze, to se odrazilo i u znanstvenoj suradnji, pa se taj naziv brzo proširio i u tadašnjoj Saveznoj Republici Njemačkoj koja je uz Francusku osnivač tadašnje Europske zajednice, današnje Europske unije. Treba napomenuti da je gotovo istodobno (1968. god.) riječju informatika A. I. Mihajlov, direktor VINITI-ja, glavne ustanove tadašnjega Sovjetskog Saveza za znanstvene informacije, označio znanstvenu disciplinu „koja proučava strukturu i svojstva (a ne posebne sadržaje) znanstvenih informacija". Bio je to naziv za disciplinu koju danas uglavnom nazivaju **informacijska znanost** (engl. *information science*) i koja je nastala iz bibliotekarstva, dokumentacije i srodnih disciplina, a sadržaji računalnih znanosti u toj su zemlji svrstavani u **kibernetiku**. Taj je terminološki otklon izazvao u to doba zbrku jer se u zemljama istočne Europe, pa i u bivšoj Jugoslaviji, naziv informatika upotrebljavao za sadržaje različite od onih u zapadnoj Europi. Dok je u zemljama Sovjetskoga bloka taj naziv dosljedno upotrebljavan za područje znanstvenih informacija, a računalne znanosti svrstavane u kibernetiku, u tadašnjoj Jugoslaviji bilo je nedosljednosti. U Hrvatskoj se ipak udomaćila zapadnoeuropska definicija, pa je tako npr. Pavle Dragojlović već 1971. godine izdao udžbenik *Informatika*, objavljen kasnije u više izdanja, u kojemu navodi da pojam informatika označava cijelo područje primjene automatske obrade

informacija u svim područjima ljudske aktivnosti pri čemu računalna tehnologija i njezina primjena čine temelj tog područja koje autor smatra opsežnim i višedisciplinarnim i predviđa mu brz razvoj. Zakonom je 1970. godine u Hrvatskoj osnovan Savjet za informatiku, a zatim se 1977. godine u Zakonu o informatičkoj djelatnosti, osim što se pod tom djelatnošću podrazumijeva izgradnja i povezivanje informacijskih sustava, navodi da pojam informatička oprema obuhvaća uređaje za automatsku obradu i prijenos podataka i informacija. Ne ulazeći dalje u raspravu o značenju općega pojma informatika, treba napomenuti da se danas u Europi pod tim nazivom misli na znanost koja se bavi primjenom informacijskih tehnologija s naglaskom na njihove tehnološke aspekte, dok u SAD-u taj naziv još uvijek nije u širokoj upotrebi jer se prednost daje tradicionalnom engleskom nazivu *computer sciences* (Deželić, 2009).

Kibernetika se kao pojam danas pojavljuje kao skupni naziv niza teorijskih disciplina i praktičnih postupaka koji se primjenjuju pri upravljanju i vođenju složenih sustava. Naziv je (grč. Κυβερνάω = upravljam, kormilarim) uveo američki matematičar Norbert Wiener (1894. – 1964.) u djelu *Kibernetika* (Cybernetics, 1948). Baveći se tijekom Drugog svjetskog rata problemima vođenja letjelica došao je na ideju da obradu informacija u elektroničkim napravama usporedi s misaonim procesima u ljudskom mozgu pa je predložio opće okvire za jedinstvenu teoriju koja obuhvaća ponašanje kako ljudskih bića tako i strojeva. Model sustava koji se pritom razmatra (kibernetički sustav) sastoji se od triju cjelina: podsustava osjetila kojima se prikupljaju informacije o trenutačnom stanju sustava, podsustava u kojem se iz prikupljenih informacija trenutačno stanje uspoređuje sa željenim stanjem te tako utvrđuje razlika (pogrješka) i podsustava koji utječe na ponašanje sustava tako što smanjuje nastale razlike. U takvu je sustavu ostvarena povratna veza kao osnovica stabilnoga djelovanja svih sustava. Primjerice, u slučaju kada čovjek želi dohvatiti neki predmet postoji povratna veza koja obuhvaća vid, misaoni proces u mozgu i poticaj mišićima koji pokreću šaku prema predmetu. Zatvaranjem očiju ta će se povratna veza prekinuti i postupak dohvaćanja predmeta bit će otežan. S obzirom na to da je stvaranje i pretvorba informacija osnovica djelovanja takvih sustava, sastavnim se dijelom kibernetike smatra i teorija informacija koju je razradio američki inženjer i znanstvenik Claude Shennon. S vremenom se pokazalo da je početna zamisao o jednoj sveobuhvatnoj teoriji upravljanja i vođenja bila previše optimistična. Tim se problemom danas bave mnoge znanstvene discipline koje se velikim dijelom oslanjaju na primjenu informacijske i komunikacijske tehnologije, dok se naziv kibernetika uglavnom rabi za komparativne studije ljudskoga živčanoga sustava i artefakata informacijske i komunikacijske tehnologije. Cjeloviti informacijski prostor ostvaren globalno umreženim računalima popularno se zove **kibernetički prostor** (engl. *Cyberspace*), a u znanstvenofantastičnoj literaturi naziv *kiborg* (od pojma kibernetički organizam) upotrebljava se za hipotetsko čovjekoliko biće kojemu su dodani umjetni organi ili cijeli dijelovi tijela. Ova teorija o kibernetičkom prostoru razlog je da danas u svijetu imamo niz regulatornih dokumenata koji umjesto pojmova kao što su npr. informatički kriminalitet ili računalni kriminalitet koriste nazive kibernetički kriminal ili kiberkriminal (engl. *cyber crime*) ili pak NATO-ovu platformu o kiberterorizmu (engl. *cyber terrorism*) i kiberratovanju (engl. *cyber warfare*). Što se tiče stvarnih osnova i postignuća koje bi vodile ostvarenju kibernetičkih organizama, nalazimo ih u području koje se naziva **robotika**. Razni oblici elektromehaničkih sustava vođeni informatičkim sustavima osnova su suvremene industrije gdje zamjenjuju ljudski rad kako u cilju povećanja produktivnosti tako i u cilju zaštite života i zdravlja radnika u specifičnim područjima ljudske djelatnosti (Wiener, 2007).

Dakle, ključni pojmovi bitni za razumijevanje obrade podataka i primjenu informacija su:

- PODATAK – sirovina koju moramo na određeni način prikupiti i obraditi kako bismo iz nje stvorili informacije
- INFORMACIJA – proizvod obrade podataka na temelju kojeg će se donijeti odluke važne za funkcije upravljanja poslovnim sustavom
- INFORMATIKA – znanost o oblikovanju, obradi, prijenosu, pohrani i korištenju informacija

- KIBERNETIKA – znanost o upravljanju mehaničkim, električnim, biološkim i dr. sustavima na osnovi potrebnih informacija
- ROBOTIKA – znanost koja se zasniva na kibernetici, informatici i primjeni naprednih tehnologija kako bi primjenom umjetne inteligencije stvorila strojne sustave koji imaju osobine bioloških sustava (biomehanika i osjet).

Treba spomenuti da se u praksi često govori o različitim „informatikama" ovisno o području primjene. Štoviše, znanstvena i stručna područja kao što su npr. ekonomija, prirodne znanosti, filozofija, organizacija rada, medicina i dr. školuju svoje informatičke kadrove. Ova činjenica proizlazi iz praktičnih potreba pojedinih područja djelatnosti. Naime, krenemo li od činjenice da je za oblikovanje odgovarajućeg informacijskog sustava potrebno najprije napraviti kvalitetnu analizu postojećeg poslovnog sustava, jasno je da ove aktivnosti moraju obuhvatiti znanja i vještine iz područja projektiranja temeljnih sustavskih (sistemskih) elemenata i specifičnih aplikativnih elemenata. Izgradnja jednog suvremenog informacijskog sustava/podsustava nužno dakle uključuje suradnju između sustavskih i aplikativnih projektanata i analitičara.

Jedno od takvih područja je „medicinska informatika". Ovaj se naziv pojavljuje početkom 70-ih godina 20. stoljeća u Europi, dakle u vrijeme kada je računalna tehnologija već prešla razinu elektroničkih sklopova visoke integracije, a primjene u medicini i zdravstvenoj zaštiti proširile su se u kliničkoj medicini u području dijagnostike te za terapijske potrebe. Razvijaju se zdravstveni informacijski sustavi, osobito za bolničke potrebe, a računala omogućuju provođenje opsežnih populacijskih istraživanja i dokumentaciju medicinske literature. Kada je u Velikoj Britaniji Kraljevsko povjerenstvo za medicinsku izobrazbu 1968. godine podnijelo svoje opsežno izvješće, smatralo je potrebnim preporučiti da se teme povezane s tom novom tehnologijom uvedu i u medicinsku nastavu. Povjerenstvo je u izvješću istaknulo da će „elektronička računala sa svojim utjecajem na opremu, postupke i način razmišljanja imati prevažan udio u radu svih liječnika u budućnosti da bi ih se potpuno prepustilo stručnjacima; svaki liječnik treba barem naučiti razumjeti njihova temeljna načela i mogućnosti". U isto su se vrijeme krajem šezdesetih godina i drugdje u svijetu pojavila slična razmišljanja. Bilo je to vrijeme kada su se povezale računalne znanosti i medicina, odnosno kada se pojavila nova medicinska struka – medicinska informatika. U nas se naziv medicinska informatika spominje već u prvim skriptama za predmet Primjena elektroničkih računala u zdravstvenoj zaštiti (autor: Gjuro Deželić) napisanima 1971. godine za istoimeni predmet koji je 1970. godine uveden kao obvezatan predmet u sklopu studija medicine na Medicinskom fakultetu u Zagrebu. Medicinska informatika namjerno je ovdje navedena kao primjer aplikativnog područja jer se područje sigurnosti i zaštite života i zdravlja u znatnom dijelu poklapa sa zadaćama i ciljevima zdravstvene zaštite. Iz ovog je razloga dio primjera u ovoj knjizi koji prikazuju uspješno realizirane dijelove i funkcionalnosti informacijskih sustava uzet iz objavljene projektne dokumentacije Središnjeg zdravstvenog informacijskog sustava Republike Hrvatske (CEZIH) (Deželić, 2009).

1.3. Upravljanje sigurnošću i zaštitom

Iz prethodnih razmatranja možemo zaključiti da se primjena suvremenih računalima podržanih informacijskih sustava u području sigurnosti i zaštite svodi na praćenje protoka poslova unutar poslovnog sustava sigurnosti i zaštite, prikupljanje podataka u pojedinim fazama, obradu tih sirovih podataka i pretvaranje u informacije kojima se snabdijevaju pojedine razine upravljanja, čime se postiže višeslojni sustav upravljanja poslovnim sustavom. Naravno, svako elementarno područje sigurnosti i zaštite − zaštita na radu (ZNR) i zaštita od požara i zaštita okoliša (ZO), ima svoje specifične protoke poslova i vrste informacija te stoga, osim osnovnih pravila analitike i projektiranja, ima neke svoje specifičnosti.

Postoji li posebno aplikativno područje informatike u domeni sigurnosti i zaštite?

Zasad ne. Pretraživanje pisanih i mrežnih sadržaja pruža informaciju samo o jednom naslovu, tj. knjizi koja se bavi tematikom o ovom području. Američki stručnjak u području sigurnosti i zaštite Charles W. Ross, objavio je knjigu pod naslovom *Computer Systems for Occupational Safety and Health Management* (hrv. *Računalni sustavi za upravljanje zaštitom na radu i zaštitom zdravlja*). Autor je objavio dva izdanja ove knjige. Prva je verzija objavljena 1984. godine i obrađuje ideje i nastojanja autora da, potaknut pojedinim naprednim informatičkim projektima u američkoj javnoj upravi i velikim tvrtkama sredinom 70-ih godina 20. stoljeća, oblikuje računalno podržani informacijski sustav za upravljanje zaštitom na radu u tvrtki u kojoj je bio zaposlen. Dok prvo izdanje knjige opisuje implementaciju ovog sustava na računalnoj mreži zasnovanoj na velikom središnjem računalu (engl. *mainframe*) i terminalima, drugo dopunjeno i prošireno izdanje, objavljeno 1991. godine, donosi proširenje pristupa i prikaz prilagodbe ovog projekta osobnim računalima koja su u to vrijeme postala informatička, odnosno tehnološka osnova za razvoj informacijskih sustava. Apstrahiramo li tehnološku osnovu izvedbe, oba ova izdanja imaju vrlo veliku vrijednost u aplikativnom pristupu razvoju informacijskih sustava u domeni sigurnosti i zaštite. Autor daje vrlo dobre i slikovite prikaze raznih praktičnih primjera (radnih scenarija) i vlastitih promišljanja koja i današnjim stručnjacima sigurnosti i zaštite mogu biti od velike pomoći u razumijevanju i provođenju aktivnosti uvođenja, proširenja i/ili održavanja računalima podržanih informacijskih sustava u domeni sigurnosti i zaštite (Ross, 1991).

Približavanjem Europskoj uniji (EU), Republika Hrvatska (RH) je sve više usklađivala svoje zakonodavstvo s EU i počela je implementirati europske direktive za zaštitu na radu. Prije ulaska u EU, Republika Hrvatska je bila korisnica pristupnog programa kroz projekte IPA 2007 i IPA 2012 kojima je glavni cilj bio uspostaviti učinkovit sustav i mrežu institucija za zaštitu na radu uz povezivanje postojećih i novih baza podataka, kao i sustava upravljanja zaštitom na radu. Razmjena informacija i iskustava među sudionicima koji su na njoj radili omogućila je bolju povezanost svih relevantnih podataka o bolesnim i ozlijeđenim radnicima, analizu podataka i izradu zaključaka na temelju tih analiza, što je doprinijelo razvoju učinkovitog poslovnog sustava zaštite zdravlja i sigurnosti na radu kao jačanju svijesti o potrebi izgradnje sveobuhvatnog informacijskog sustava. Stjecanjem punopravnog članstva u EU od Hrvatske se tražilo da kao država nastavi pratiti i usklađivati svoje zakonodavstvo sa zakonodavstvom EU, odnosno njegovim direktivama i normama. Međunarodna organizacija rada (engl. *International Labour Organization*, ILO) je povodom međunarodnog dana sigurnosti i zdravlja na poslu, 28. travnja 2017. godine, predstavila ideju prikupljanja i obrade podataka vezanih uz ZNR na međunarodnom planu (Franović i Kralj, 2021). Prema njihovim procjenama tada je bilo 313 milijuna ozljeda na radu, a te ozljede na radu smanjuju BDP za 4 %. Vrlo je važno da zemlje povećaju svoje kapacitete za prikupljanje i analizu podataka o ZNR-u u svrhu prevencije. Slične inicijative i preporuke nalazimo i u SAD-u. Iz prethodno navedenih regulatornih obveza i svjetskih preporuka slijedi obveza i nužnost informatizacije pojedinih segmenata kao i oblikovanja nacionalne informacijske infrastrukture u domeni sigurnosti i zaštite (Franović i Kralj, 2021).

Na sadržaj

2. ODNOS POSLOVNOG I INFORMACIJSKOG SUSTAVA

Na slici 2.1. prikazane su usporedne funkcionalne blok-sheme jednog stvarnog (poslovnog) i njemu pripadajućeg informacijskog sustava.

Pretpostavimo da:

- svaki stvarni odnosno „poslovni" sustav ima skup svojih poslovnih funkcija koje mogu biti organizirane u više funkcionalnih podsustava, o čemu ovisi i stupanj složenosti cjelokupnog poslovnog sustava

- se svaki sustav, kao i njegovi podsustavi, temelji na organizaciji i obradi nekakvih podataka (ulazi) i „preradi" tih podataka u informacije (izvješća).

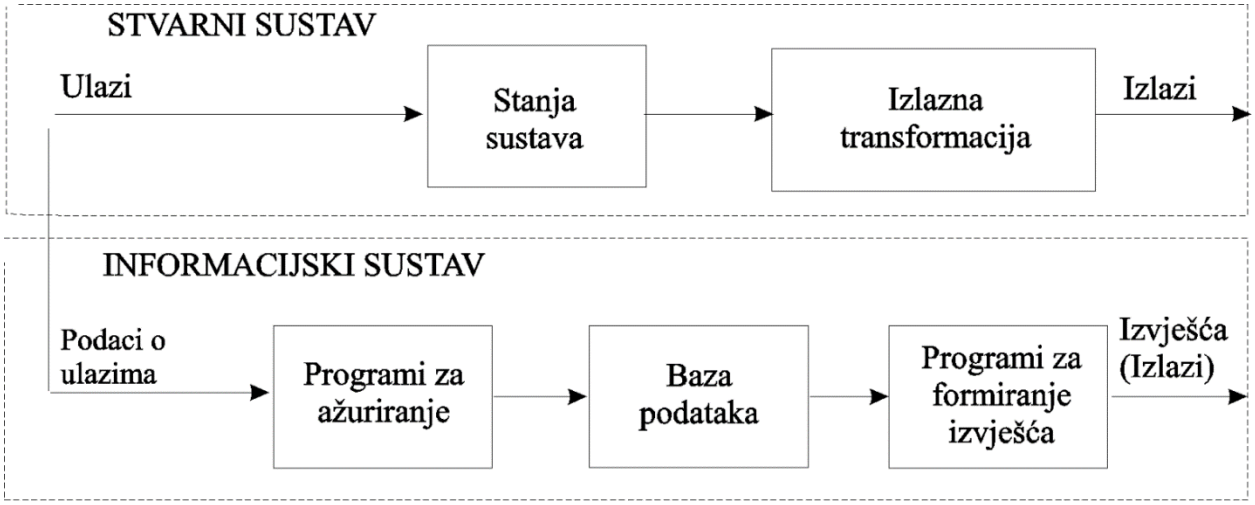

Slika 2.1. Model odnosa stvarnog (poslovnog, proizvodnog) i informacijskog sustava (izvor: autor)

Ulazi u stvarni odnosno poslovni sustav mogu biti materijali (sirovine), osobe, energija i/ili nematerijalni (apstraktni) sadržaji koji izazivaju određene promjene sustava. Njegovim se djelovanjem oni transformiraju te izlaze u nekom drugom obliku. U informacijski sustav ulaze podaci o ulazima u poslovni sustav koji se ažuriraju kroz programe (postupke) za ažuriranje i upisuju u bazu podataka (registre). Na temelju ovih ažuriranja i upisa oblikuju se izvješća koja prate transformacije ulaza u stvarnom sustavu, a sadržaj tih izvješća čine informacije o izlazima iz stvarnog sustava.

Slika 2.2. prikazuje protok podataka od ulaza do izlaza u okviru jednog jednostavnog informacijskog ciklusa. Zamislimo da skup podataka čine podaci o studentima kao što su: matični broj, prezime, ime, e-adresa i potpis studenta. Ove sirove podatke potrebno je na neki način organizirati, tj. na neki normirani način pripremiti za daljnju obradu. Pretpostavimo da je potpisna lista jedan takav obrazac kojeg nastavnik daje studentima kako bi prikupio podatke o njima i njihovom prisustvu na predavanju. Nakon prikupljanja podataka, čiju točnost i svoju prisutnost potvrđuju studenti vlastoručnim potpisom, nastavnik može pristupiti daljnjoj obradi. Daljnja obrada može biti ručna ili podržana računalima. Bez obzira na tehnologiju obrade njezin su rezultat informacije na osnovu kojih nastavnik donosi daljnje odluke važne za upravljanje kolegijem. Dobivene se informacije pohranjuju kako bi se stanje kolegija moglo uspoređivati sa stanjem sljedećih akademskih godina (npr. pada li ili raste prisutnost studenata na predavanjima), i na osnovi toga okvirno procijenila npr. tematska zanimljivost nastavnog sadržaja. Može se reći da slika 2.2. prikazuje jedan jednostavni (elementarni) informacijski sustav. Povratna veza od izlaznog toka informacija na modul postupka obrade predstavlja skup informacija koje se pohranjuju u sustavu obrade kako bi oblikovale skup elemenata znanja koji bi trebao predstavljati

referentnu točku za unaprjeđenje samog postupka obrade podataka u informacije te uz druge vanjske čimbenike doprinijeti unaprjeđenju kvalitete i napredne klasifikacije izlaznih informacija kao naprednog temelja za donošenje kvalitetnih odluka za upravljanje poslovnim sustavom. Detaljniji prikaz ove koncepcije prikupljanja znanja u cilju osiguranja referentne točke obrade, prikazan je na slici 2.3. U praksi, procijenjeno vrijeme za postizanje ovakve referentne točke zavisi od vrste postavljenih ciljeva.

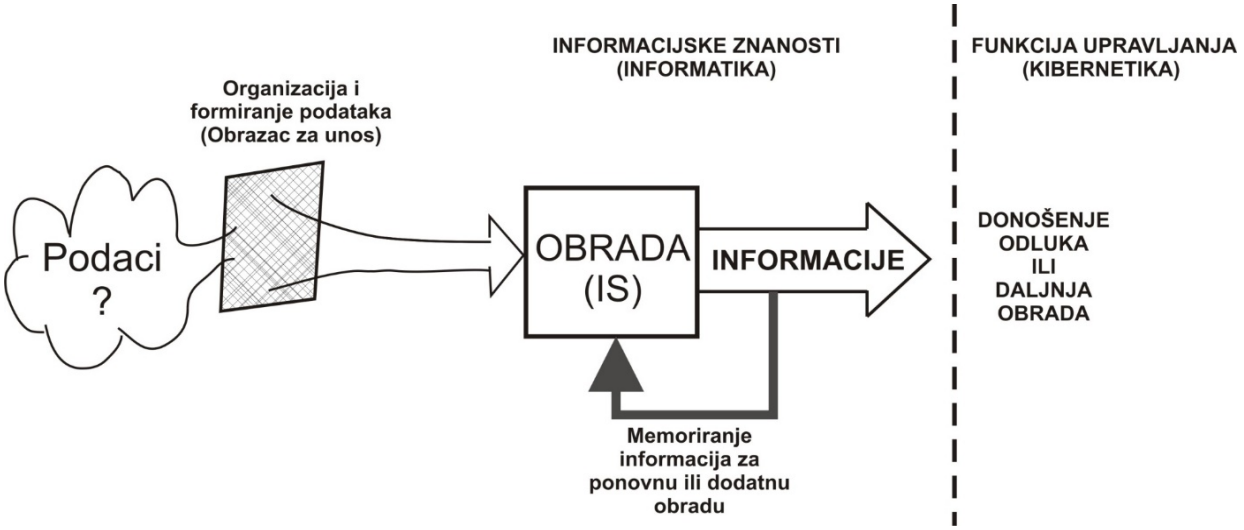

Slika 2.2. Funkcionalni prikaz jednostavnog informacijskog ciklusa (izvor: autor)

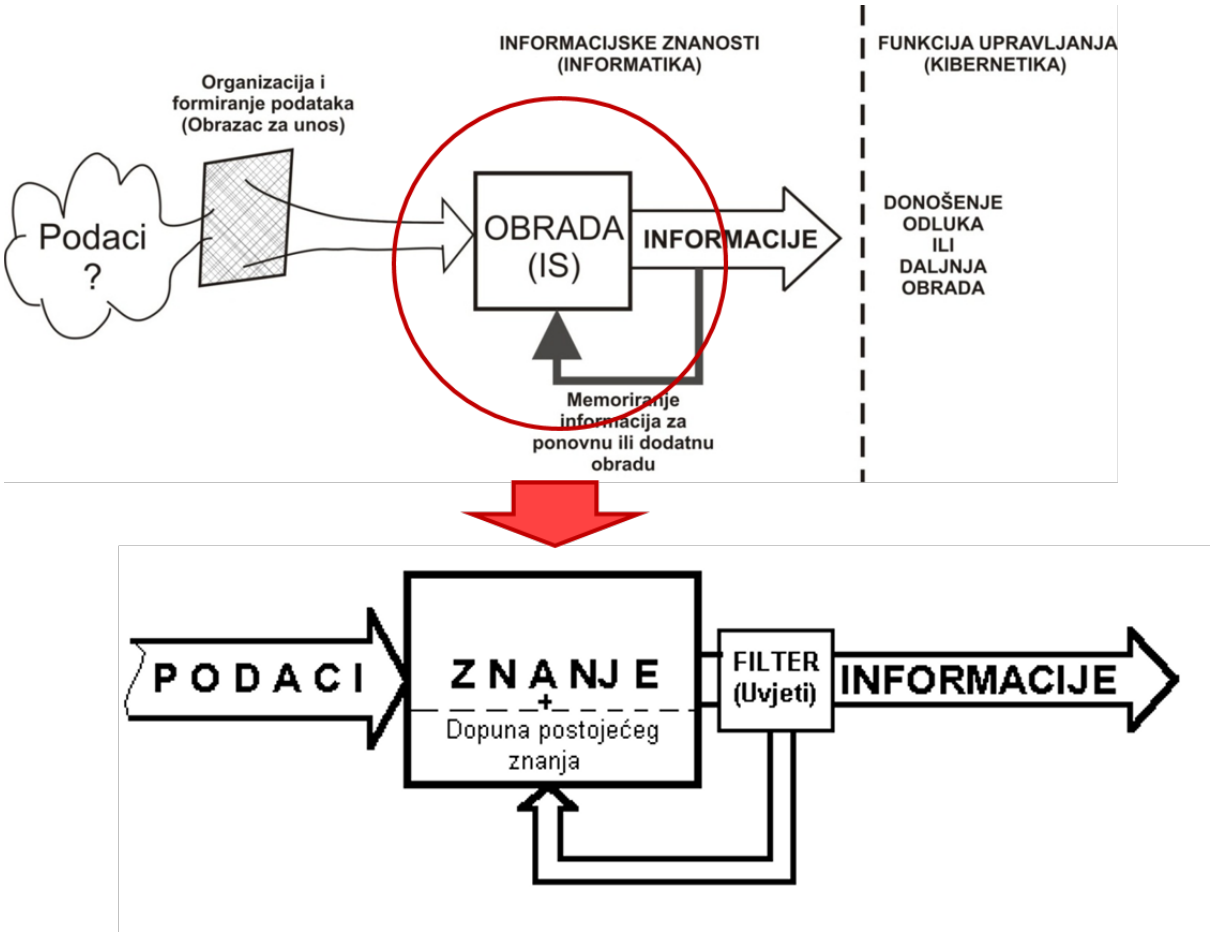

Slika 2.3. Evaluacija rada poslovnog sustava oblikovanjem referentne točke (izvor: autor)

Slika 2.4. prikazuje daljnje proširenje koncepcije evaluacije poslovanja poslovnog sustava postavljanjem i unaprjeđenjem skupa znanja koji čini referentnu točku u okviru pripadajućeg informacijskog sustava.

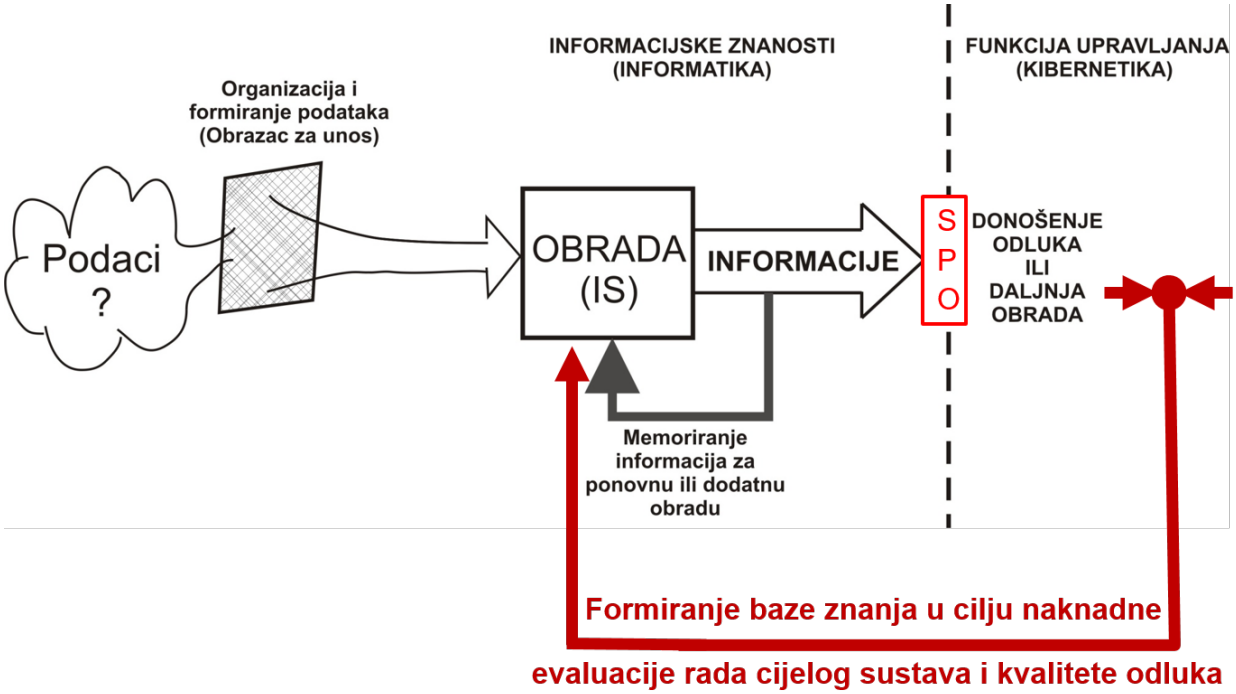

Slika 2.4. Daljnje proširenje koncepcije evaluacije rada primjenom referentne točke (izvor: autor)

Može se vidjeti da u okviru ove proširene koncepcije, osim internih informacija, referentnu točku dopunjuju i informacije iz uže i/ili šire okoline poslovnog sustava. Za ostvarenje ovakvog razvojnog puta vrlo je važno postavljanje razvojnih ciljeva. Ove ciljeve možemo okvirno podijeliti u tri skupine:

- kratkoročni ciljevi (do 1 godine)
- srednjoročni ciljevi (od 1 do 5 godina)
- dugoročni ciljevi (od 5 do 15, pa i više godina).

Uvođenje osnovnog razvojnog oblika informacijskog sustava i prikupljanje prvih elemenata znanja za njegovo unaprjeđenje predstavlja dakle kratkoročni cilj ostvariv u očekivanom razdoblju od godine dane. Povećanje količine referentnog znanja i njegova daljnja sistematizacija predstavlja srednjoročni cilj za čije je postizanje potrebno prosječno vrijeme od jedne do pet godina rada i kontinuiranog razvoja. Postizanje proširene koncepcije procjene ukupne kvalitete rada poslovnog sustava skupljanjem internog i eksternog poslovnog iskustva (ono što znamo o sebi i kako nas drugi vide) te ostvarenje napredne funkcije upravljanja cjelokupnim sustavom, ulazi u dugoročne ciljeve za čije je ostvarenje prosječno potrebno od 10 do 15 godina kontinuiranog razvoja. Akumulacijom znanja i njegovim organiziranjem u radne smjernice u obliku baze znanja moguće je uz primjenu sustava inferencije formirati napredne sustave za pomoć pri donošenju odluka (oznaka SPO na slici 2.4.).

2.1. Osnove upravljanja znanjem

SMJERNICE – **skup tvrdnji i/ili postupaka** (algoritama) koje su rezultat dogovora struke i uzete su kao ispravan i uspješan način rješavanja nekog problema (zadatka). Nemaju zakonsku

težinu norme, ali određuju pravilno postupanje u praksi, npr. pristupanje postupku rješavanja problema liječenja neke bolesti na optimalan način.

BAZA ZNANJA – **skup smjernica** i drugih tvrdnji koji je organiziran (najčešće hijerarhijski) i indeksiran za lak i brz pristup kako bi korisnici u stvarnom vremenu došli do tražene informacije, kao npr. pristupanje nekoj smjernici pretraživanjem po traženom pojmu (simptomu, nazivu bolesti, medikaciji i sl.).

EKSPERTNI SUSTAV (ES) − sadrži **ukupnost znanja nekog** (stvarnog ili hipotetskog) **stručnjaka** u pojedinoj znanstveno-stručnoj disciplini (npr. kardiologiji) **zapisanog u velikoj bazi znanja** koji primjenom umjetne inteligencije (engl. *Artificial Intelligence*, AI) omogućava npr. prikaz svih zdravstvenih poremećaja vezanih za specifični skup simptoma i njihovu vjerojatnost (s obzirom na simptome) te preporuča daljnje dijagnostičke postupke na osnovu njihove mogućnosti razlučivanja, stupnja invazivnosti, cijene i njihove neugode za pacijenta.

SUSTAV ZA POMOĆ PRI ODLUČIVANJU (SPO) – (engl. *Decision Support System*, DSS) je **dinamička nadgradnja ES-a** koja primjenom umjetne inteligencije omogućava nekom stručnjaku (npr. liječniku) da **na temelju poznavanja stanja sustava** (npr. status, alergije, aktualna ukupna medikacija kod pacijenta i sl.) **i rezultata iz ES-a** lakše odluči o daljnjim postupcima (Averweg, 2012).

2.2. Vrste ciljeva

Informacijski sustavi moraju nužno podržavati ostvarivanje zadanih ciljeva poslovnih sustava. Za neki ograničeni poslovni sustav postoje tri razine ciljeva:

- dnevno-operativna (transakcijski, rutinski poslovi)
- taktička (niža i srednja razina rukovođenja)
- strateška (najviša razina upravljanja).

Vratimo li se na proširenu koncepciju evaluacija rada primjenom referentne točke, prikazanu na slici 2.4., i postavljanje razvojnih ciljeva, može se postaviti analogija između razvojnih ciljeva informacijskog sustava i zadanih ciljeva pripadajućeg poslovnog sustava. Kratkoročni razvojni ciljevi odgovaraju dnevno-operativnim ciljevima, srednjoročni su taktički ciljevi, a dugoročni su strateški ciljevi za čije je ostvarenje potrebno znatno duže vrijeme. U široj se literaturi može pronaći podatak da je za dugoročne ciljeve potrebno od 15 do 50 godina, no to je karakteristično još za vrijeme prije 2000. godine. Današnji stupanj ubrzanog tehnološkog razvoja, velike poslovne konkurentnosti i globalnog umrežavanja znatno je skratio ove vremenske raspone. Slika 2.5. daje trokutni prikaz razina ciljeva poslovnog sustava i pitanja na koja pojedina razina daje odgovore: Što proizvodimo? Kako ostvarujemo tu proizvodnju? Zašto održavamo i razvijamo poslovni sustav? U današnjim uvjetima poslovanja strategija bi trebala davati odgovor i na pitanje: Što ako se promjene vanjski čimbenici?

Slika 2.6. prikazuje razine ciljeva, aktivnosti koje se na pojedinoj razini provode u svrhu ostvarivanja ciljeva te čimbenike okoline koji utječu na njihovo oblikovanje. Na najnižoj razini (operativnoj), na kojoj iz okoline u sustav ulazi neka sirovina i prerađuje u neki izlazni proizvod, nužno je vršiti analizu procesa i na temelju rezultata donositi operativne planove. Na temelju ovih rezultata taktička razina vrši analize i donosi planove sustava u smislu unaprjeđenja operative te pruža projekcije stanja putem pivot-tablica strateškoj razini koja po potrebi vrši redefiniciju strateških ciljeva sustava. Na strateške ciljeve znatno utječu ciljevi nadređenog sustava (čiji je

razmatrani sustav integralni dio). Ovi ciljevi postavljaju kriterije za očekivano unaprjeđenje mogućnosti razmatranog sustava što opet dovodi do mogućnosti redefinicije strategije.

Slika 2.5. Osnovne razine ciljeva poslovnog sustava i pitanja na koja daju odgovore (izvor: autor)

Slika 2.6. Ciljevi i aktivnosti poslovnog sustava u odnosu na okolinu (izvor: autor)

Slika 2.7. prikazuje znatno složeniju hijerarhiju ciljeva koja se odnosi na složene poslovne sustave kao što su velika poduzeća ili veliki državni sustavi (npr. cjelokupni sustav ZNR-a ili vatrogastva na razini države). Vidi se da je situacija znatno složenija s obzirom na razine ciljeva i organizacijsku hijerarhiju, tj. razine upravljanja. Ukupni ciljevi oblikuju se u skladu s postavljenom vizijom cjelokupnog poslovnog sustava i definirane misije putem koje će se postavljena vizija ostvariti.

VIZIJA predstavlja sliku idealne budućnosti poslovnog sustava i daje odgovor na pitanje: Što poslovni sustav želi ostvariti u budućnosti? Ona je stoga usmjeravajući čimbenik za usmjeravanje zaposlenika i rukovodstva u određenom smjeru.

MISIJA označava osnovnu funkciju ili zadatak poslovnog sustava i razlikuje se od sustava do sustava. Dobro definirana misija je temelj za izvođenje ciljeva, strategije i planova.

STRATEGIJA definira područje u kojem poslovni sustav djeluje i razloge njegovog postojanja. U okviru strategije utvrđuju se izvori konkurentskih prednosti, razlikovne sposobnosti koje proizlaze iz tih prednosti te posebna pozicija koju će poslovni sustav zauzeti.

Ukupni ciljevi poslovnog sustava (dugoročni, strateški) izvode se iz misije i dalje raščlanjuju na područja ključnih rezultata po nižim organizacijskim jedinicama sve do pojedinaca – zaposlenika poduzeća. Povezivanje ciljeva vertikalno i horizontalno je vrlo složena i osjetljiva

zadaća jer su ciljevi vrlo često međusobno uvjetovani i rijetko se mogu promatrati odvojeno. Svaki je cilj podržan od jednog ili više ciljeva ili on sam podržava ostvarenje nekog drugog cilja.

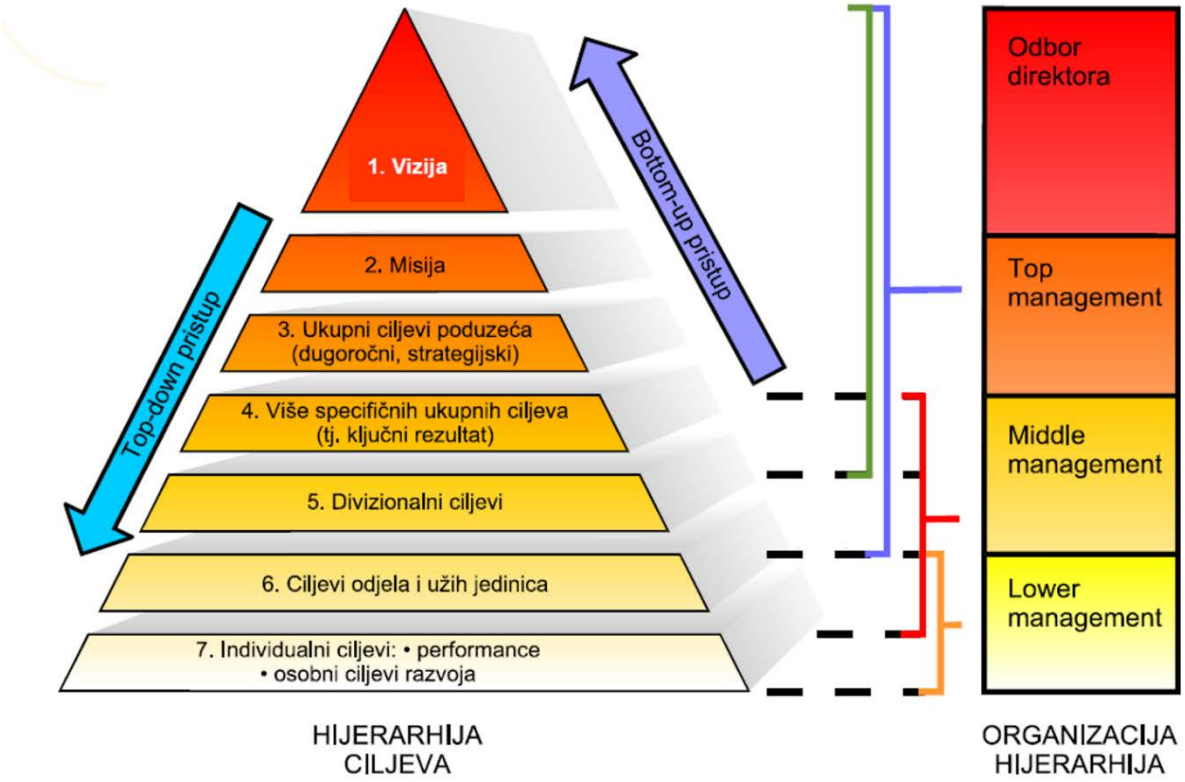

Slika 2.7. Odnos ciljeva i organizacijske hijerarhije (izvor: autor)

Postoje dva temeljna pristupa postavljanju ciljeva: odozgo prema dolje (*top-down*) i odozdo prema gore (*bottom-up*). Prema *top-down* pristupu viša razina menadžmenta određuje ciljeve nižoj razini i tako sve do izvršitelja pojedinih zadataka. Prednosti ovog pristupa su u jedinstvu i usklađenosti ciljeva. Nedostatak je nedovoljna motiviranost podređenih. Prema *bottom-up* pristupu ciljevi se određuju obrnutim smjerom, a nadređeni trebaju samo uskladiti utvrđene ciljeve. Prednost je ovog pristupa velika motiviranost zaposlenika da se ciljevi ostvare. Nedostatak je česta konfliktnost među ciljevima. Praksa je pokazala da nema čistih pristupa u postavljanju ciljeva, već se uvijek primjenjuje određena kombinacija spomenutih pristupa. Na postavljanje ciljeva uvijek utječu određene interne i eksterne interesne skupine. Interne interesne skupine čine menadžeri i zaposlenici. Eksterne interesne grupe čine konkurenti, kupci, vlada, dioničari te različite vladine i nevladine organizacije.

2.3. Spremnost za uvođenje informacijskog sustava

Uvođenje nove koncepcije informacijskog sustava u postojeći poslovni sustav neke djelatnosti opsežan je i zahtjevan projekt za čiji je početak stvaranja i ostvarenje potrebno sagledati cijeli niz čimbenika i pokazatelja. Prije svega je potrebno izvršiti detaljnu analizu ustroja poslovnog sustava te analizu svih razina upravljanja poslovnim sustavom. Uvođenje računalno podržanog poslovnog sustava u nekoj djelatnosti nužno zahtijeva promjene, koje su često i iterativne, a u cilju prilagodbe i optimizacije postojećeg poslovnog sustava u skladu s pretpostavljenim logičkim modelom računalno podržanog informacijskog sustava. Ako se razvoj jednog takvog projekta promatra s gledišta teorije promjena, pri čemu se faze promjena ponašanja pojedinca preslikavaju na cijelu zajednicu, potrebno je još u razdoblju *kontemplacije* (u fazi stvaranja svijesti o potrebi promjene)

prema raspoloživim pokazateljima analizirati čimbenike uspjeha i neuspjeha u postupku uvođenja novih tehnologija u poslovanje. Faze razvoja i napretka projekta međusobno se smjenjuju po tzv. „spirali promjena" (Prochaska, DiClemente i Norcross, 1993) kao što prikazuje slika 2.8.

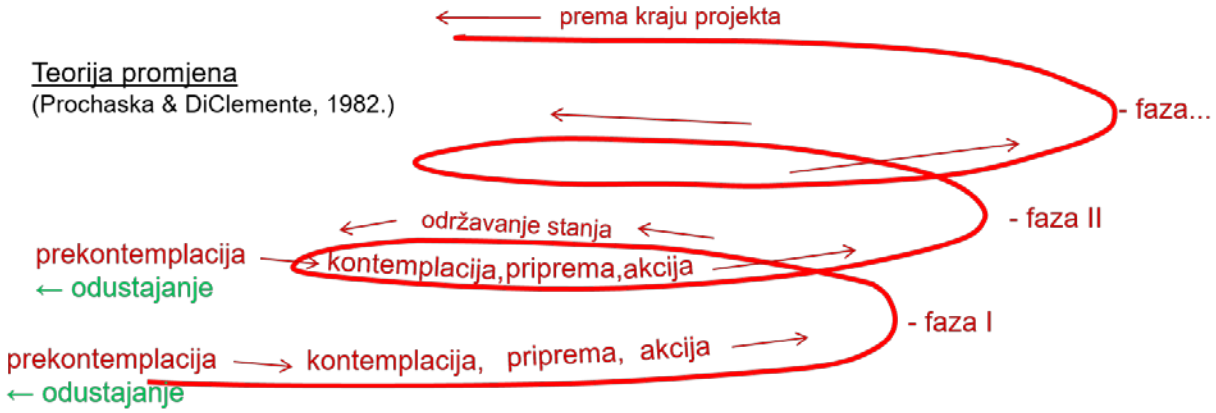

Slika 2.8. Faze projekta (promjena) smjenjuju se po „spirali promjena"
(izvor: autor prema predlošku Prochaske i DiClementea)

Prema psiholozima Prochaski i DiClementeu, predstavnicima teorije promjena, ovakav je model ponašanja svojstven svim procesima životnih promjena. Svakoj fazi promjene predstoji stanje *pretkontemplacije* u kojem još ne postoji svijest o potrebi uvođenja promjene u život pojedinca ili zajednice. U ovom smo stanju još uvijek skloni odustajanju (bijegu) od početka neke promjene i tražimo razne izgovore (razloge) koji bi ga poduprli i opravdali. Nakon toga slijedi stanje *kontemplacije* u kojem se oblikuje svijest o potrebi uvođenja promjene, a onda pripreme za pokretanje promjene i sama akcija, tj. izvršavanje potrebnog niza mjera i postupaka za izvršenje jedne faze promjene, odnosno projekta.

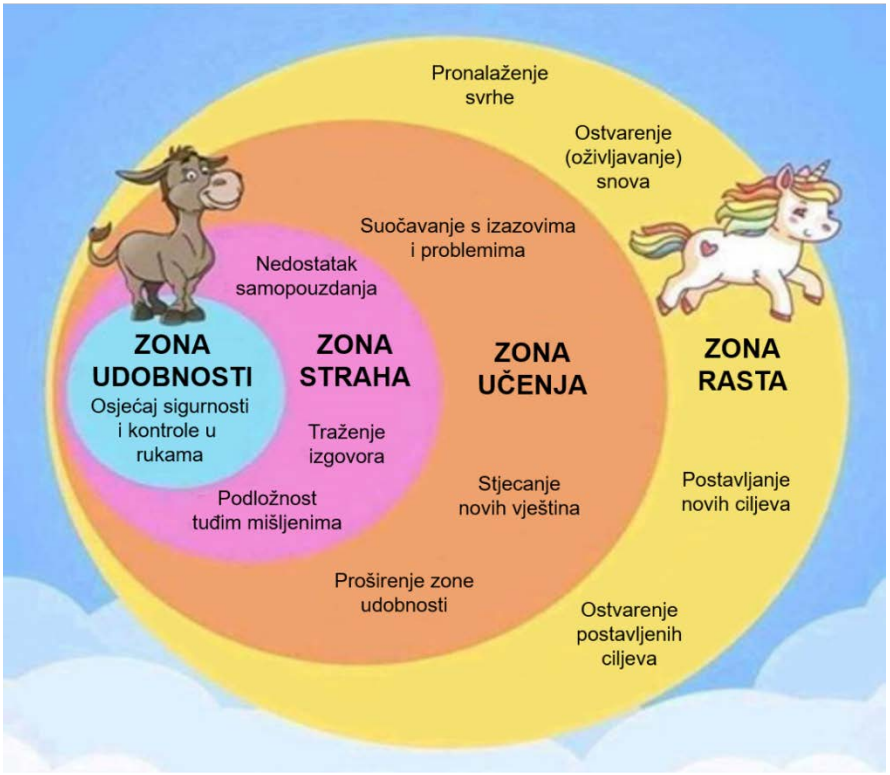

Slika 2.9. Put promjena od zone udobnosti do zone rasta (prijevod autora prema ilustraciji: Larry Kim, https://www.MobileMonkey.com)

Ovakav je model promjena prije svega osmišljen kako bi opisao problem pokretanja i provođenja neke promjene u slučajevima ovisničkog ponašanja (odvikavanje od pušenja, alkohola,

droge, početak i provođenje redukcijske dijete i sl.), no primjenjiv je i na pokretanja raznih promjena, odnosno početaka i provođenja projekata, gdje se zahtijeva pomak iz tzv. zone udobnosti. Ovaj put promjena stanja iz zone udobnosti, preko zona straha i učenja do zone rasta, ilustrativno je prikazan na slici 2.9. Naša zona udobnosti je bihevioralni prostor u kojem se naše aktivnosti i ponašanja uklapaju u rutinu i šablone koji minimaliziraju stres i rizik. To nam daje osjećaj mentalne stabilnosti i sigurnosti. Koristi koje imamo od toga su očigledne: prevladava osjećaj zaštićenosti, stres je manji i razina tjeskobe (*anksioznosti*) niža. Ideja zone udobnosti je stara više od sto godina. Naime, još su 1908. godine psiholozi objasnili da stanje relativne udobnosti daje mogućnost ostvarivanja stabilnih rezultata, ali ako želimo unaprijediti svoja postignuća, neophodno nam je stanje relativne tjeskobe – prostor u kojem nam je razina stresa povišena. Taj se prostor naziva prostor „optimalne tjeskobe" i nalazi se malo izvan naše zone udobnosti. S druge strane, ako postoji previsoka razina tjeskobe, stres može biti prevelik, a naša produktivnost i postignuća slabija. Važno je zato da izlazak iz zone udobnosti bude postupan i da uvijek imamo na umu zašto je to za nas korisno (Pilar, 2020).

Za mjerenje pokazatelja uspjeha pojedine faze promjene (projekta) važno je razdoblje između pojedinih faza (stupnjeva spirale). Kao što je prikazano na slici 2.10., oslanjajući se na teoriju promjena, psiholog Kurt Lewin (1947/1951) utvrdio je da prije početka svake faze promjena (faze razvoja nekog projekta) predstoji neko stanje mirovanja ili zamrznutosti nakon čega slijedi stanje odmrzavanja, zatim faza napretka projekta (jedan stupanj spirale) i na kraju opet stanje zamrznutosti. Sastavni i ključni korak u postupku prihvaćanja inovacija, a koji prethodi stanju odmrzavanja, naziva se „spremnost" (engl. *readiness*). Upravo je u tom stanju postupka promjene potrebno mjeriti pokazatelje koji upućuju na uspješnost prethodne razvojne faze i spremnost sustava za prihvaćanje inovacije, tj. sljedeće faze napretka projekta (Lewin, 1976).

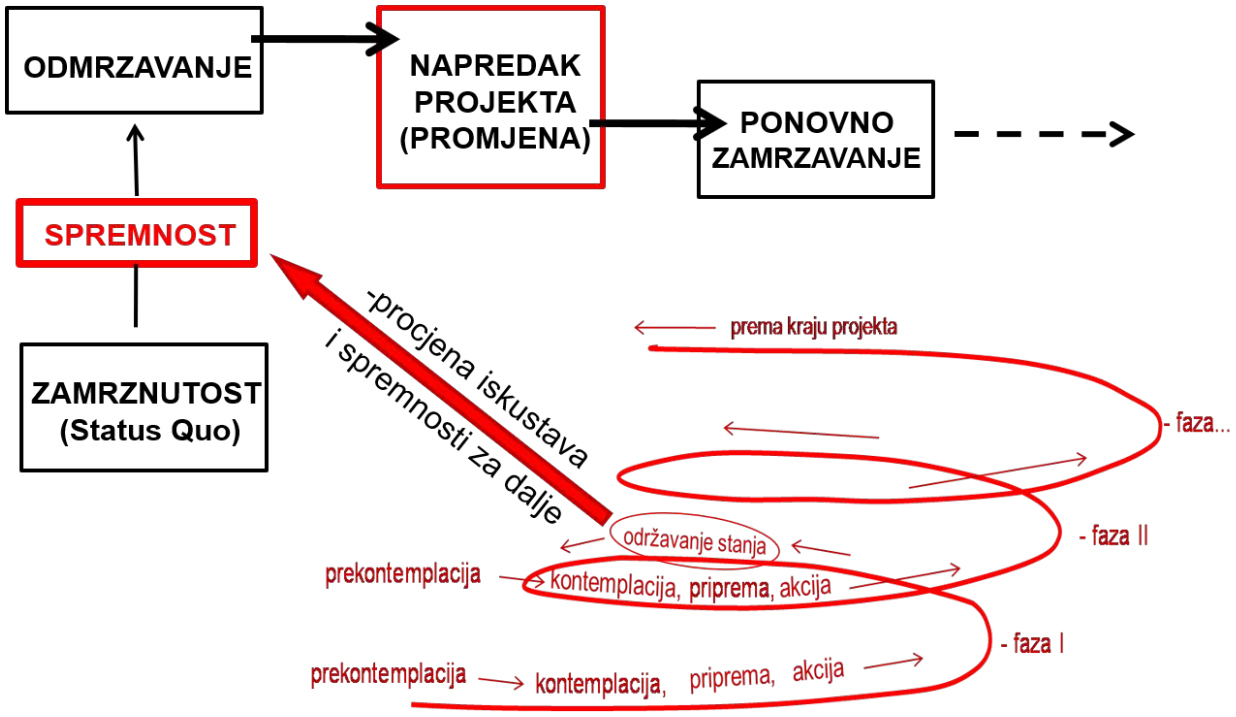

Slika 2.10. Ispitivanje spremnosti pri prijelazu između dviju faza projekta prema Lewinu (izvor: autor)

Slika 2.11. prikazuje tijek i daje opis promjena prema Lewinovoj teoriji promjena. Ovo smjenjivanje stanja treba promatrati u kontekstu prethodno opisane spirale promjena i kretanja iz zone udobnosti u zonu rasta.

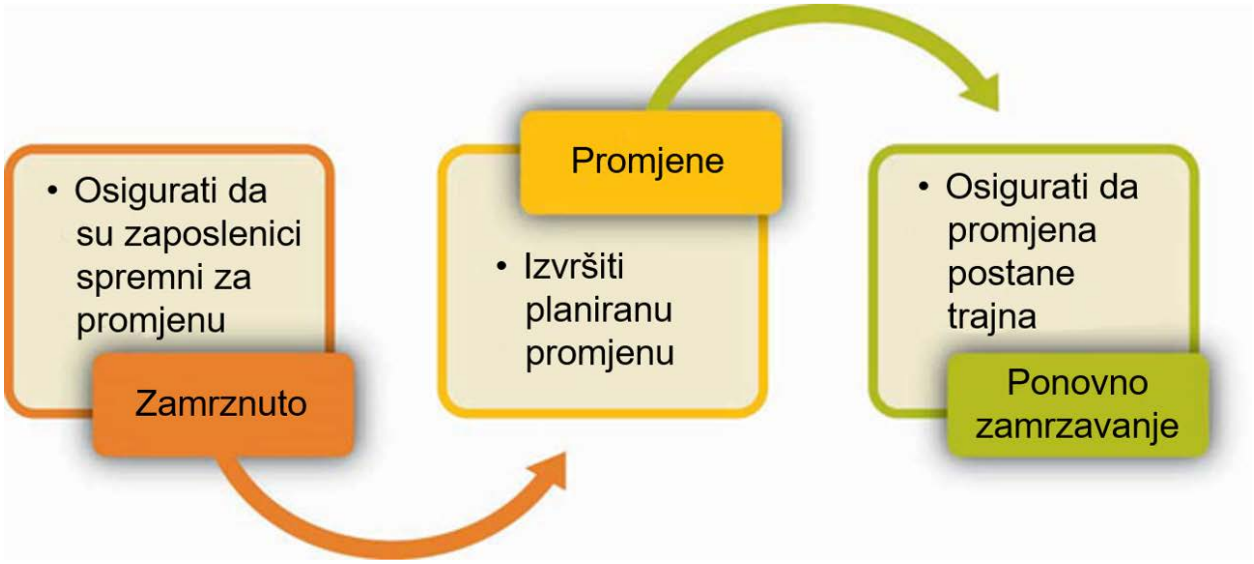

Slika 2.11. Opis pojedinih faza promjena prema Lewinu (izvor: autor)

Na slici 2.12. prikazan je slijed aktivnosti koje treba poduzeti i pripreme koje treba napraviti kako bi se planirana promjena izvršila te kako bi ostala trajna (odnosno, kako bi se postiglo ponovno zamrzavanje).

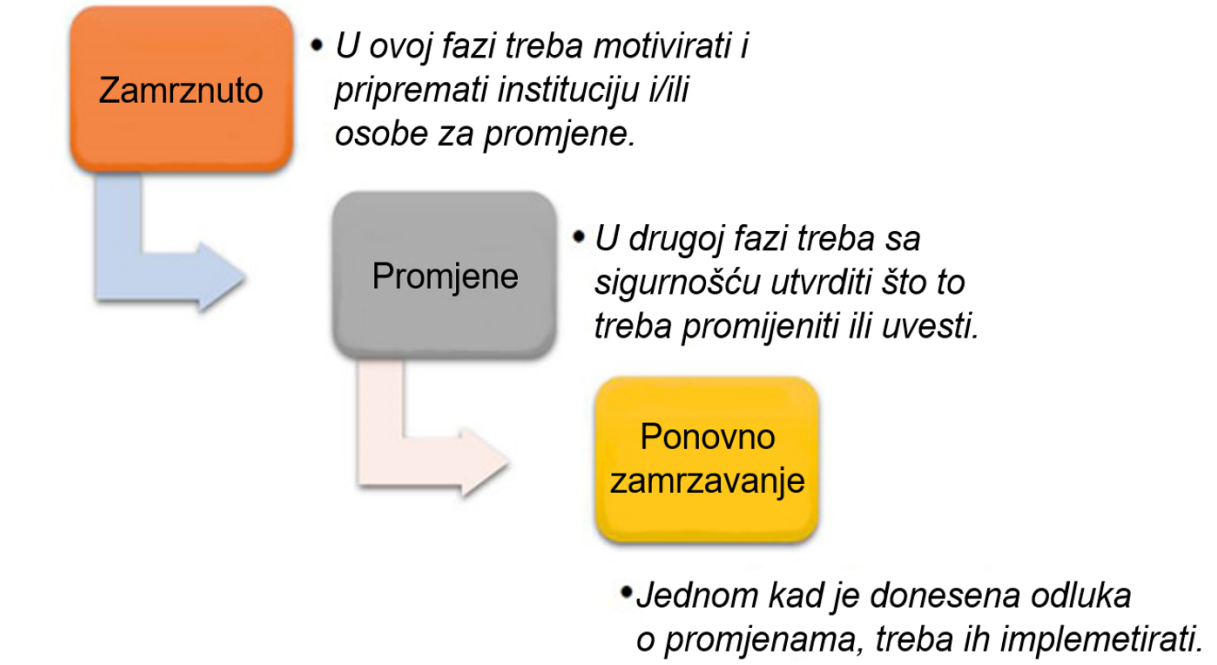

Slika 2.12. Aktivnosti koje treba provesti u okviru pojedine faze promjene (izvor: autor)

Kako svaka promjena u životu koja nas gura izvan naše zone komfora izaziva u nama povećanu tjeskobu (*anksioznost*) i predstavlja stres, unutar svake tvrtke ili institucije prilikom pokretanja neke promjene (pokretanja projekta) tjeskoba se projicira na cijeli kolektiv kao tzv. organizacijska tjeskoba. Slika 2.13. prikazuje dijagram promjene organizacijske tjeskobe tijekom provođenja promjena od stanja odmrzavanja do ponovnog zamrzavanja promjena.

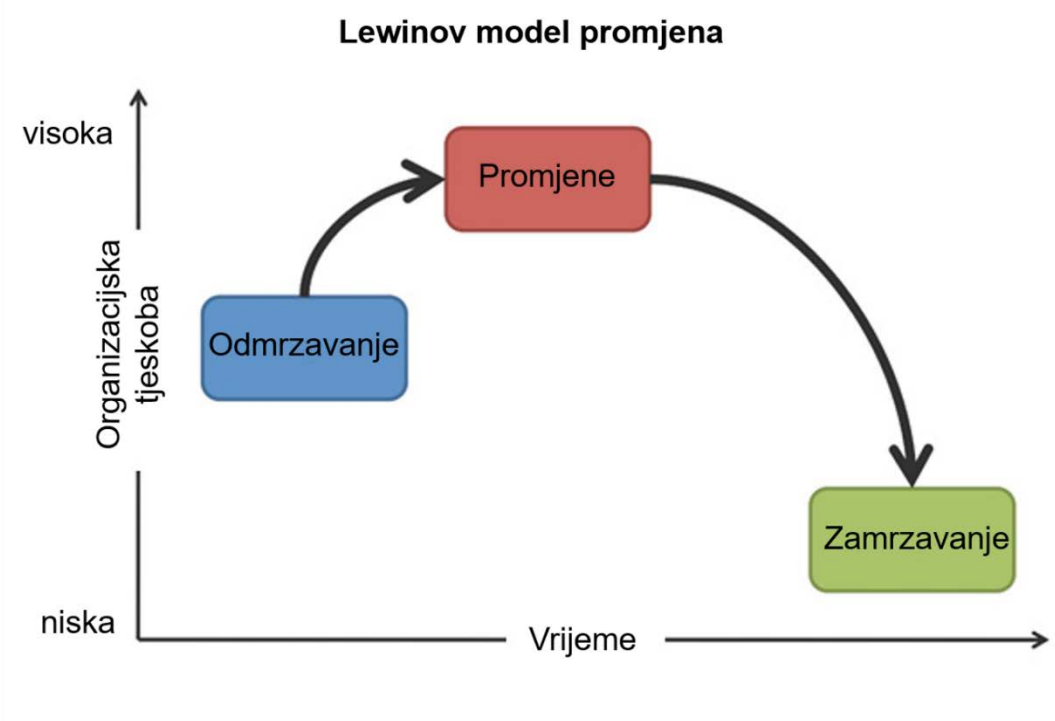

Slika 2.13. Razine organizacijske tjeskobe tijekom jednog ciklusa promjene prema Lewinu (izvor: autor)

Prije samog odmrzavanja stanja i početka promjena, kao što je prikazano na slici 2.10., potrebno je izvršiti procjenu spremnosti cjelokupnog sustava za provođenje planiranih promjena. Lewin u tom kontekstu govori o „polju sila" (engl. *force field*). Postoje sile koje doprinose uspješnom provođenju planiranih promjena i sile koje koče napredak. Mjerenje, odnosno procjena spremnosti, svodi se na mjerenje skupova pokazatelja. Dakle, pokazatelji koji se pri tome mogu mjeriti istovremeno su čimbenici uspjeha naredne faze (ili općenito samog početka projekta) i dijele se na one koji podupiru i one koje koče promjenu, te na tehnološke (stupanj razvoja i dostupnost) i netehnološke (ljudske, socijalne, organizacijske). Najčešće to mogu biti sljedeći pokazatelji:

- svijest i stavovi društva, rukovoditelja i neposrednih izvršitelja o potrebi uvođenja novih tehnoloških rješenja
- stupanj aktualnog tehnološkog razvoja i primjenjivost u ostvarenju ideje
- stupanj obrazovanja i angažman u daljnjem stjecanju znanja i rukovoditelja i neposrednih izvršitelja unutar poslovnog sustava
- ekonomski pokazatelji u smislu financijskih mogućnosti za ostvarenje projekta kao i mogućnosti povrata uloženih sredstava kroz pozitivne učinke projekta
- organizacijski pokazatelji u smislu međusobnog smislenog povezivanja pojedinih ustrojbenih cjelina poslovnog sustava
- zadovoljstvo korisnika usluga novim mogućnostima i pravima koja proizlaze iz mogućnosti novog sustava
- pokazatelji koji govore o uvođenju tzv. „dodanih vrijednosti" koje doprinose daljnjem unaprjeđenju kakvoće usluga koje se pružaju korisniku usluga poslovnog sustava.

U skladu s navedenim, općenito se može reći da je svako mjerenje pokazatelja unutar poslovnog sustava u području neke ljudske djelatnosti ustvari mjerenje spremnosti za novu razvojnu fazu koje je zasnovano na mjerenju pokazatelja koji su rezultat radnog iskustva i zadovoljstva dosadašnjim stupnjem razvoja. Mjerenje spremnosti poslovnog sustava za uvođenje računalno podržanog informacijskog sustava pogotovo je preporučljivo u slučajevima sustava s vrlo ograničenim proračunom kao što su upravni i javnozdravstveni. Na ovaj se način mogu

utvrditi prednosti, nedostaci i problemi prije samog početka razvojnog projekta i izrade studije izvodivosti i CBA (engl. *cost-benefit analysis*) (Khoja i ostali, 2007).

2.4. Neka pojašnjenja pojmova i stavova iz prakse

U dosadašnjim smo razmatranjima u osnovnim crtama analizirali odnos poslovnog (stvarnog) i informacijskog sustava, temeljne razloge za uvođenje računalne podrške u informacijski sustav, važnost organizacije znanja u cilju osiguravanja referentne točke za unaprjeđenje poslovnih ciljeva, hijerarhiju ciljeva koje informacijski sustav mora podržati te oblike ljudskog ponašanja koji mogu podržavati ili kočiti razvoj budućeg informacijskog sustava. U ovom ćemo odjeljku razmotriti neke različitosti i specifičnosti pojedinih pojmova i stavova zatečenih u praksi.

U praksi i literaturi često se za poslovni sustav koriste i nazivi: stvarni, realni i objektni sustav.

Važno je naglasiti da ćemo u daljnjim analizama i prikazima za skup funkcionalnosti i postupaka stvarnog sustava koristiti naziv poslovni sustav (PS), a za njemu odgovarajući računalno podržan informacijski sustav naziv informacijski sustav (IS) bez obzira na to do koje je mjere unutar njega implementirana računalna podrška. Ponekad možemo susresti pojedince pa čak i IT stručnjake koji projektiraju ili vode informacijske sustave koji se drže definicija prikazanih na slici 2.14. U prikazanom slučaju za poslovni sustav složen od više podsustava, informacijskim sustavom se podrazumijeva skup informacijskih podsustava koji su međusobno potpuno integrirani (informacijski potpuno povezani), dok se sustav unutar kojeg postoje prekidi u povezanosti pojedinih informacijskih podsustava, naziva informatičkim sustavom.

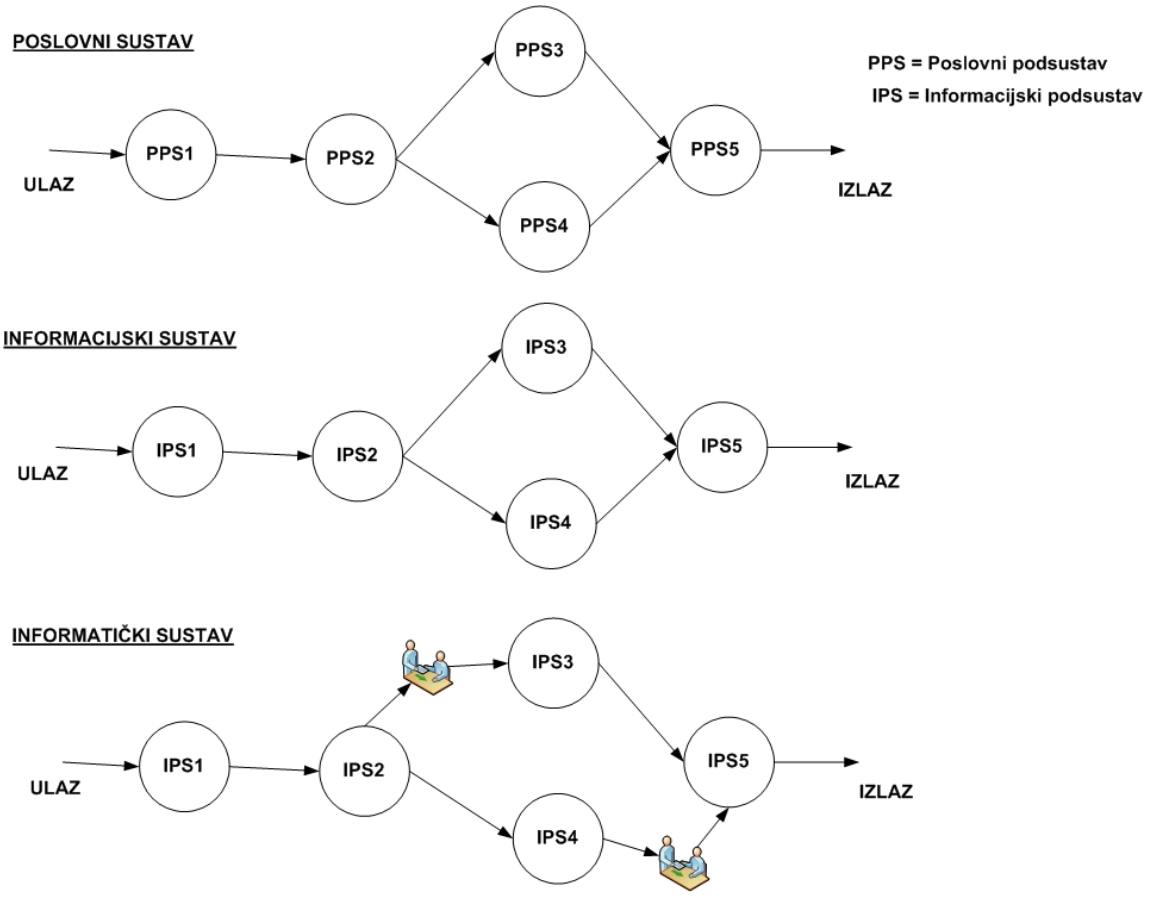

Slika 2.14. Primjer nekih specifičnih definicija IS-a u praksi (izvor: autor)

U našim ćemo daljnjim razmatranjima koristiti naziv informacijski sustav, odnosno skraćenicu IS za sve računalima podržane sustave bez obzira na to do koje je mjere računalna potpora uvedena.

Nadalje, osim ovih uobičajenih poslovnih informacijskih sustava (PIS), pod informacijskim sustavom u praksi možemo podrazumijevati razne ugrađene nadzorno-upravljačke sustave (NUS) za upravljanje i regulaciju procesa koji na temelju nekih mjerenih veličina oblikuju informacije o vrijednostima izlaznih veličina bez obzira na to jesu li ostvareni primjenom računala opće namjene ili mikrokontrolerima. Ovi sustavi također mogu biti jednostavni i složeni.

Na sadržaj

3. OSNOVE PROJEKTIRANJA INFORMACIJSKIH SUSTAVA

3.1. Planiranje, analiza, projektiranje...

Postupak analize postojećeg fizičkog i logičkog modela postojećeg PS-a, a zatim oblikovanja budućeg logičkog i prilagodba fizičkog modela primjenom budućeg IS-a koji se temelji na poslovnim zahtjevima i zahtjevima krajnjih korisnika može rezultirati u više iteracija u smislu usklađenja. Općeniti hodogram ovog postupka prikazan je na slici 3.1.

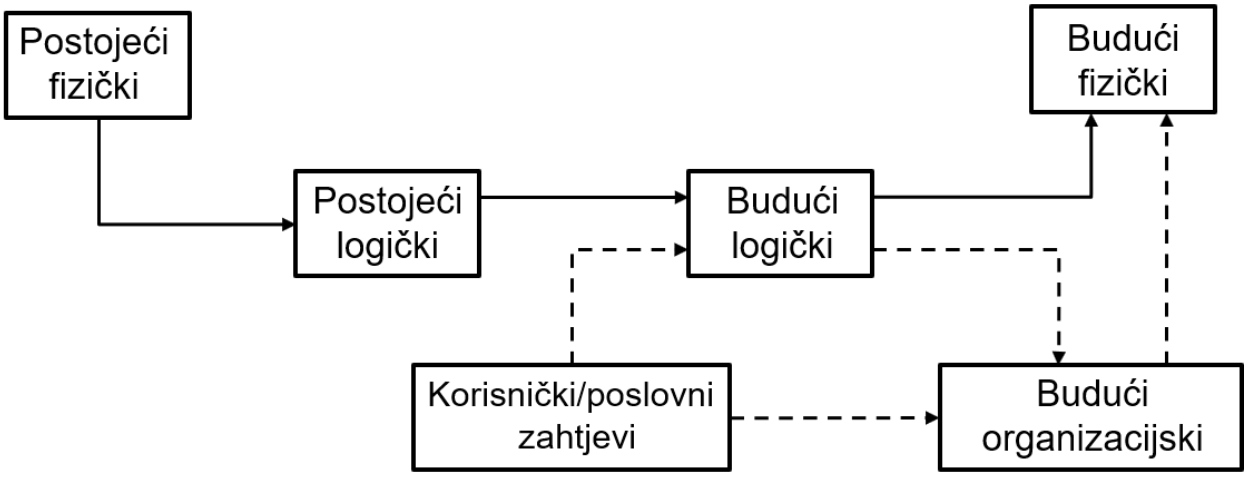

Slika 3.1. Općeniti hodogram analize PS-a i razvoja IS-a (Fertalj & Kalpić, 2006)

Složenost postupka projektiranja IS-a proizlazi iz složenosti poslovnog sustava koji on treba podržavati i/ili unaprijediti. U tom smislu projektiranje IS-a obuhvaća niz aktivnosti kao što su:

- strateško planiranje
- analiza poslovnog i proizvodnog procesa
- analiza tokova informacija, materijala i energije
- definiranje i/ili izrada programske podrške
- nabava strojne podrške
- obuka korisnika (jedna od najvažnijih aktivnosti) itd.

Ove aktivnosti treba organizirati kroz projekt. Projekt je skup organiziranih poslova koje treba obaviti u određenom roku da bi se izradio „proizvod" jer završeni IS predstavlja proizvod koji je rezultat postupka projektiranja i realizacije. Sudionike projekta koji su nužni za postupak analize PS-a i projektiranje novog IS-a čine:

- korisnici (oni koji primjenjuju novi informacijski sustav)
- menadžeri (koji upravljaju poslovnim sustavom, ali koji su i korisnici)
- informatičari (projektanti sustava, analitičari, programeri itd.).

Ove osnovne skupine sudionika imaju definirane uloge u projektu. **Korisnici** poznaju postojeći način rada i znaju postaviti informacijske zahtjeve. **Menadžeri** se trebaju upoznati sa stvarnim mogućnostima i koristima uvođenja informacijskog sustava, dati smjernice, ocijeniti različite mogućnosti i osigurati uvjete razvoja. **Informatičari** i **korisnici** analiziraju PS i daju

zahtjeve na budući IS. **Informatičari** po uspješno provedenoj analizi mogu samostalno oblikovati i izgraditi IS.

Tijekom analize PS-a, a kasnije i projektiranja IS-a, nužno je poznavati i poštivati pretpostavljene ciljeve PS-a (kratkoročne, srednjoročne, dugoročne), imajući u vidu da novooblikovani IS mora podržati pretpostavljene ciljeve PS-a. Pored ovih ciljeva, treba se držati i ključnih funkcionalnih ciljeva projektiranja. **Ciljeve projektiranja IS-a** možemo sažeti u nekoliko natuknica:

- informacijski sustav treba odgovarati zahtjevima korisnika i zadovoljavati poslovne ciljeve
- informacijski sustav treba biti pouzdan unutar zadanih granica
- informacijski sustav treba biti cijenom prihvatljiv.

Ove ciljeve treba ostvariti primjenom **informacijskog inženjerstva** kojeg možemo opisati kao:

- skup metoda postupaka razvoja i izgradnje informacijskog sustava
- inženjerski pristup izgradnji informacijskog sustava i upravljanju informacijama
- sustavnu primjenu prikladnog skupa metoda, tehnika i alata na čitav proces razvitka informacijskih sustava.

Primjena informacijskog inženjerstva trebala bi osigurati prevenciju elementarnih problema još u ranoj fazi projektiranja, a najčešći problemi ove vrste su:

- izrada neodgovarajućeg sustava (ispravni programi − neispravan rezultat)
- prekoračenje planiranog vremena i planiranih financijskih sredstava
- neelastičnost u primjeni
- teškoće u održavanju.

Na temelju dosadašnje prakse i iskustava razlikujemo tzv. tradicionalni i suvremeni pristup projektiranju IS-a. Tradicionalni (*ad hoc*) pristup karakteriziraju:

- odvojene aplikacije
- usmjerenost operativnoj razini poslovanja
- analiza vođena konvencionalnim poslovnim aktivnostima
- dokumentacija narativnog karaktera
- nedostatak formalne preporuke o tome kako nešto treba napraviti
- usmjerenost opisu rješenja računarskim (stručnim) izrazima (problem razumljivosti).

Ovaj pristup treba izbjegavati što je više moguće, jer iako u početku sve izgleda jednostavno, svaki će se sustav kad-tad „zakomplicirati”, a tada problem postaje složeniji nego da se krene s projektiranjem otpočetka. Nasuprot ovom pristupu, suvremeni pristup koji proizlazi iz načela informacijskog inženjerstva koji odlikuju:

- integrirane aplikacije
- usmjerenost taktičkoj i strateškoj razini
- naglasak na strukturi, podacima i odgovarajućim procesima
- korištenje grafičkih tehnika
- sustavni (korak po korak) pristup razvoju
- dokumentiranje problema konceptualnim i logičkim modelima.

Temelj ovog suvremenog pristupa su **metode** i **tehnike**. Tehnika je skup precizno određenih procedura za provođenje standardne zadaće (način provedbe dijela faze), a metoda je smišljen i organiziran skup procedura uz korištenje dobro definirane notacije (skup procedura za provedbu neke od faza razvitka). Skup metoda i tehnika koje se koriste, a koje posjeduju zajednički idejni pristup, naziva se **metodologija**.

Metodologija nam mora osigurati sljedeće elemente informacijskog inženjerstva:

- komunikaciju između sudionika uključenih u razvoj IS-a
- skup metoda i tehnika koji će omogućiti da se zadaci izvršavaju na standardni način i provjerenim načinima rada
- učinkovit nadzor s ciljem uočavanja pogrešaka u ranim fazama
- elastične promjene poslovanja i tehnologije (npr. odvajanjem analize i oblikovanja)
- razvojnu strategiju kojom će se ukloniti *ad hoc* rješavanje problema
- posvećivanje pažnje analizi poslovanja u dovoljnoj mjeri.

Metodološki pristup projektiranju i razvoju IS-a u stvarnosti mora obuhvatiti:

- specifične (izabrane) modele za opisivanje sva tri temeljna aspekta (podatke, postupke i sredstva)
- pravila i načela za primjenu izabranih modela (skup metodoloških preporuka za ostvarenje određenog pristupa, redoslijed i način obavljanja pojedinih aktivnosti, dokumentaciju, način upravljanja projektom i sl.)
- automatizirana sredstva pomoću kojih će se izabrani modeli i metodološke preporuke moći ostvariti i omogućiti analitičarima, projektantima i korisnicima što lakšu izvedbu, dijagnostiku i eventualne kasnije promjene strukture i karakteristika.

Ključni postupak u projektiranju je **modeliranje** IS-a. Modeliranje je skup metoda i tehnika za izradu modela koji odgovaraju dijelovima stvarnog sustava:

- Izrada modela podataka / oblikovanje podataka (engl. *data modelling*):
  - model podataka – ŠTO su podaci, odnosno što opisuju podaci
    - konceptualni model − opisuje podatke i veze između podataka, najčešće model entiteti − veze (engl. *entity − relationship model*)
    - logički model – opisuje strukturu podataka i logičkih datoteka, najčešće relacijski model podataka (engl. *relational data model*).

- Izrada modela procesa/funkcija (engl. *process modelling, functional decomposition*):
  - model funkcija i procesa – KAKO se prikupljaju, obrađuju i distribuiraju podaci
    - model funkcija − oblikuje se razlaganjem (dekompozicijom) funkcija, iterativno od vrha prema dolje (od globalnih funkcija do osnovnih procesa)
    - model procesa – opisuje obradu podataka promatranog sustava, najčešće dijagram toka podataka (engl. *data-flow diagram*).

- Izrada modela događaja:
  - model događaja – KADA se podaci obrađuju
    - razmatranje učinka koji događaji imaju na procese i podatke te opis stanja, npr. dijagram promjene stanja (engl. *state transition diagram*).

- Modeliranje resursa/sredstava:
  - izvršitelji − TKO obrađuje podatke, GDJE se nalaze podaci i GDJE se obrađuju podaci.

- Modeliranje programa
  - struktura (programskih) modula IS-a, primjerice strukturnim kartama (Fertalj i Kalpić, 2006 ; Strahonja, Varga i Pavlić, 1992).

3.2. Sastavnice informacijskog sustava

U kontekstu današnjeg stupnja razvoja i primjene informacijsko-komunikacijske tehnologije, suvremene poslovne informacijske sustave (PIS) promatramo kao skup sastavnica. U praksi i literaturi ponekad se nazivaju i komponentama ili resursima. Sastavnice informacijskog sustava su:

- organizacijska
- ljudska
- podatkovna
- programska
- sklopovska
- mrežna.

Organizacijsku sastavnicu (engl. *orgware*) čine organizacijski postupci, metode i načini povezivanja i usklađivanja svih sastavnica u cjelinu. Ova sastavnica predstavlja ukupnost standarda, mjera, postupaka i propisa kojima se funkcionalno i vremenski usklađuje rad svih ostalih sastavnica kako bi tvorile skladnu cjelinu. Funkcionalno usklađivanje preostalih sastavnica naziva se koordinacijom, dok se njihovo vremensko usklađivanje naziva sinkronizacijom rada sustava. Ova sastavnica definira organizacijsku strukturu poslovnog sustava, raspored profila kadrova unutar te strukture te sigurnosne pristupne razine koje se tim profilima dodjeljuju unutar IS-a.

Ljudsku sastavnicu (engl. *lifeware*) čine kadrovi – timovi stručnjaka, analitičara, programera i svih ljudi koji bez obzira na funkciju i namjeru sudjeluju u radu IS-a. Zajedno s organizacijskom sastavnicom čini ključne sastavnice za definiranje uloga pojedinaca u poslovnom sustavu i razina ovlasti unutar IS-a (autorizacija i autentikacija pojedinaca u sustavu). Obje se ove sastavnice reguliraju kroz podsustav za upravljanje ljudskim potencijalima (engl. *Human Resource Management*, HRM). Ova je sprega ključna za upravljanje svim segmentima PS-a, pa tako i za upravljanje ZNR-om i ZOP-om u kontekstu ovog udžbenika. Zasniva se na ispravnom izboru i raspoređivanju kadrova u skladu s njihovim sposobnostima i specijalnostima, što je ustvari osnova oblikovanja i održavanja organizacijske i ljudske sastavnice.

Podatkovna sastavnica (engl. *dataware*) je zadužena za organizaciju baze podataka i informacijskih resursa (projektiranje baza podataka).

Programska sastavnica (engl. *software*) predstavlja nematerijalne elemente: uvježbanost i metode vezane uz organizaciju, upravljanje, obrađivanje i korištenje rezultata obrade, ukupnost ljudskog znanja ugrađenog u strojeve, opremu i uređaje (*software & firmware*). Uobičajeno je da je pohranjena na neki memorijski medij.

Sklopovska sastavnica (engl. *hardware*) čini materijalnu osnovu, odnosno obuhvaća računala, pisače i ostalo sklopovlje namijenjeno isključivo ili pretežno obradi podataka i informacija.

Mrežna sastavnica (engl. *netware*) je kombinacija materijalno tehničke (sklopovlja) i nematerijalne sastavnice (programska podrška) koja omogućava komunikaciju unutar mreže, a to su sklopovlje, prijenosni mediji i programi za komunikaciju koji nisu sastavni dijelovi računala. Organizacijska sastavnica ima ključan utjecaj na mrežnu sastavnicu jer su današnje mreže

hijerarhijski organizirane i nastoje u stopu pratiti organizacijske i arhitektonske zahtjeve suvremenih PIS-a, a koje su definirane dokumentima organizacijske sastavnice (Panian i ostali, 2010).

3.3. Standardne metode za analizu PS-a i razvoj IS-a

Metodologija je znanost o cjelokupnosti svih oblika i načina istraživanja pomoću kojih se dolazi do objektivnog i sustavnog znanja. Primijenjeno na projektiranje i gradnju IS-a, metodologija projektiranja IS-a je znanost o metodama i tehnikama te njihovoj primjeni (Pavlić, 1996). Ove nas metode i tehnike vode u procesu modeliranja nekog sustava, a završni model, koji proizlazi iz ovog procesa, mora na što bolji i razumljiviji način opisati analizirani sustav. Može se reći da je glavni doprinos metodologije oblikovanje formalnog skupa preporuka za oblikovanje modela novog IS-a. Kako su poslovni sustavi kroz povijest postajali sve složeniji, postavljali su i sve teže kriterije na razvojne metodologije, što je izravno utjecalo na promjene (unaprjeđenje) koncepcije u cilju savladavanja složenosti poslovnih sustava. Razvijen je vrlo velik broj raznih metodologija i metoda, no danas se uglavnom svode na dvije skupine – standardne (tradicionalne) i agilne. U ovom ćemo odjeljku opisati nekoliko standardnih komercijalnih metoda za analizu PS-a i projektiranje IS-a koje su glavne predstavnice pojedinih analitičko-razvojnih paradigmi.

3.3.1. Metoda BSP

Metodu BSP (engl. *Business Systems Planning*) za analizu PS-a te planiranje i razvoj IS-a, razvila je tvrtka IBM za vlastite potrebe tijekom 70-ih i 80-ih godina 20. stoljeća. Zasniva se na dva temeljna suvremena strateška opredjeljenja:

- definiranju opće strukture IS-a na temelju poslovnih postupaka (funkcija) kao relativno najstabilnijih komponenti stvarnog sustava (za razliku od organizacijske strukture i načina upravljanja i odlučivanja, koji mogu biti relativno brzo promjenjivi)
- modelu podataka kao temelj IS-a, s obzirom na činjenicu da je neophodno upravljati podacima kao posebnom cjelinom u sustavu.

Temeljni cilj BSP metode je osigurati izradu IS-a koji će biti maksimalno integriran u poslovni sustav i koji će podržavati kako kratkoročne (operativne) tako i dugoročne (strateške) ciljeve poslovnog sustava. Osim toga BSP želi postići i sljedeće:

- pružiti rukovodnom osoblju mogućnost određivanja stvarne potrebe za IS-om bez obzira na parcijalne interese
- baziranjem na postupcima poslovnog sustava, koji su stabilni bez obzira na organizacijske promjene, želi osigurati dug životni vijek IS-a
- ojačati povjerenje rukovoditelja u brzi povrat investicije kroz pozitivne efekte IS-a
- ostvariti dobre odnose osoba u informatičkom odjelu s korisnicima kroz efikasan IS kao preduvjet za kvalitetnu suradnju na daljnjem razvoju IS-a
- omogućiti da osoblje prihvati podatke kao zajedničko vlasništvo kojim treba upravljati radi opće dobrobiti, a iznad parcijalnih interesa.

Kao što se vidi na slici 3.2., BSP primjenjuje *top-down* planiranje, a zatim *bottom-up* projektiranje i razvoj IS-a. Treba imati u vidu da je BSP metoda nastala u vrijeme manje složenosti sustava (za današnje pojmove), a glavna paradigma oblikovanja je bila proceduralna (programi s neprekinutim skupom instrukcija uz skokove na pojedine dijelove ovisno o uvjetima grananja

procedure). Ove su se činjenice odrazile i na oblik završnog dokumenta projekta koji je bio oblikovan u narativnom obliku, vrlo nepregledan, često dužine i od više stotina stranica.

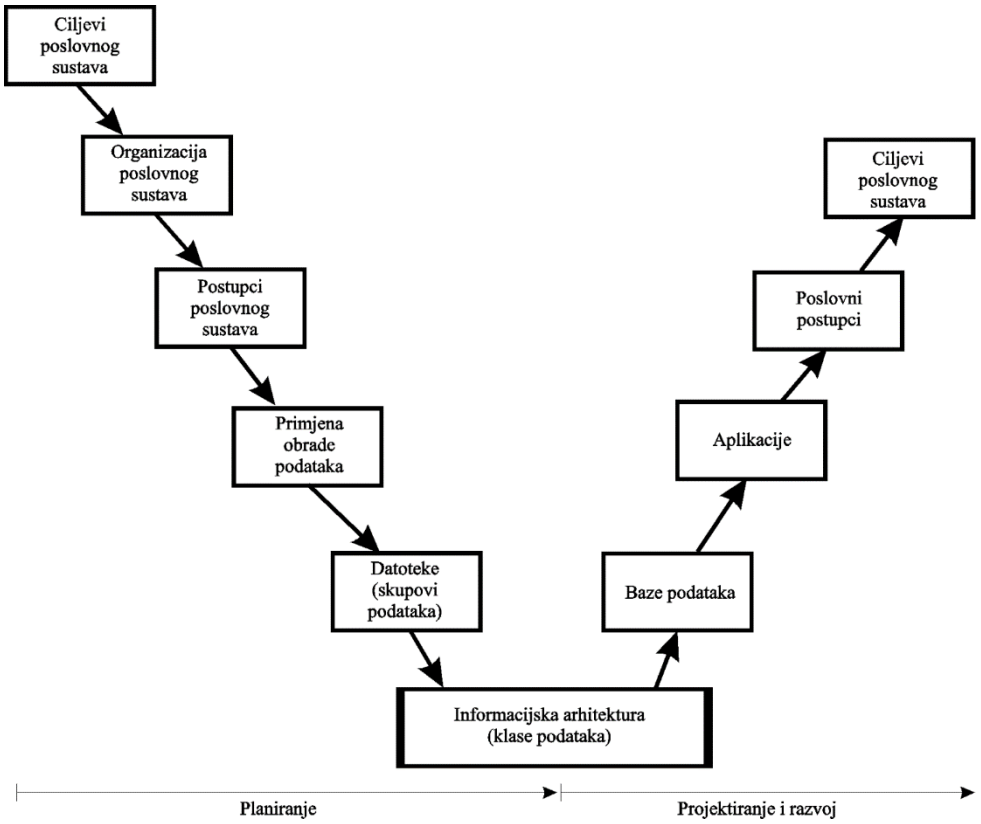

Slika 3.2. *Top-down* planiranje i *bottom-up* projektiranje i razvoj prema BSP metodi (izvor: autor)

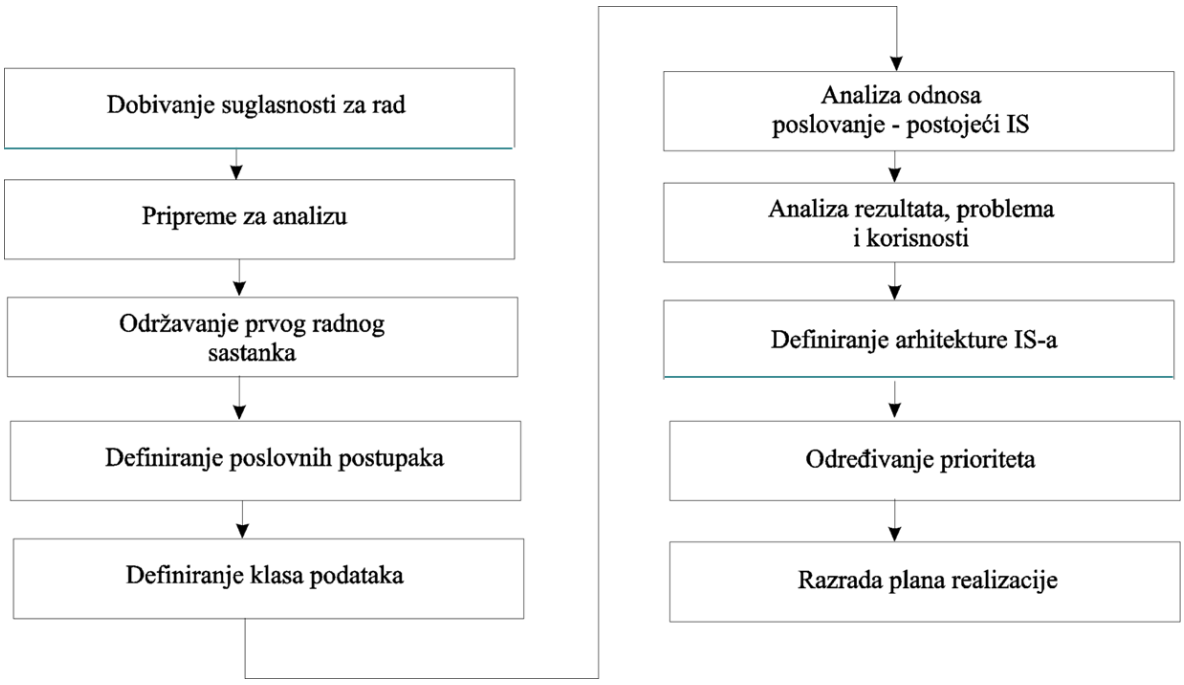

Slika 3.3. Aktivnosti u metodi BSP (izvor: autor)

S obzirom na to da se BSP metoda bavi analizom poslovnih sustava i teorijom informacija, ona nije ovisna o promjenama tehnologije. Neovisno o tome što je nastala 70-ih godina 20. stoljeća (zadnja revizija 1984. godine), još je i tijekom 90-ih imala veliku primjenjivost jer je hodogram aktivnosti u metodi BSP, prikazan na slici 3.3., svojstven i metodologijama koje su nastale nakon nje (IBM, 1978).

3.3.2. Metoda strukturne analize i specifikacije sustava

Metoda strukturne analize i specifikacije sustava ili skraćeno SASS (Tom DeMarco, 1978) za svoje temeljno načelo, kao i prethodno opisana metoda BSP, koristi funkcionalnu dekompoziciju, tj. razlaganje poslovnog sustava na niz funkcija i podfunkcija koristeći postojeće znanje o poslovnom sustavu. No za razliku od prethodne metode, ova metoda nastoji prikazati analizu i specifikaciju sustava prvenstveno grafički sa što manje teksta. Tom DeMarco, autor knjige *Structured Analysis and System Specification*, koja na vrlo interesantan i susretljiv način opisuje ovu metodu, uspoređujući klasičnu i strukturnu analizu kaže: „...tekst odmah uranja u detalje ranije skupljenih koraka, dok strukturna varijanta najprije nastoji prikazati veliku sliku, s namjerom da glatko prijeđe put od apstrakcija do detalja. Staromodni pristup je jednodimenzionalan (narativni opis je uvijek jednodimenzionalan), a strukturna varijanta je višedimenzionalna." (DeMarco, 1978). Slika dakle vrijedi tisuću riječi jer čitanje teksta predstavlja serijsko prihvaćanje podataka čime otežava konstrukciju narativno opisivanog predmeta u glavi, dok slika omogućuje paralelno prihvaćanje svih bitnih elemenata bez dodatne konstrukcije.

Sama analiza je studija nekog problema prije poduzimanja neke akcije. U specifičnom području razvoja računalnih sustava ona se svodi na studiju nekog poslovnog područja ili aplikacije koje su usmjerene na specifikaciju novog sustava. Glavni proizvod analize sustava je specifikacijski dokument. Naziv ovog dokumenta je različit kod različitih organizacija, ali ga DeMarco predstavlja kao novi termin, a to je **ciljni dokument** (engl. *target document*). Ovaj dokument sadrži specifikaciju kompletnog sustava i govori što sve u projektu sustava mora biti ostvareno da bi se smatrao uspješnim. Iz ove činjenice proizlazi i vrlo velika i odgovorna uloga analitičara sustava koji mora iznijeti vrlo složene i različite skupine zadaća kao što su: veza s korisnicima, specifikacija sustava, studija troškova (engl. *cost-benefit study*), analiza izvedivosti i proračun predstojećih troškova. Sve ove zadaće upućuju na težinu položaja analitičara sustava i naglašavaju obrambeni karakter strukturne analize, a to je da glavna briga analize nije postizanje uspjeha, već izbjegavanje neuspjeha. Gotovo najvažniji čimbenik je dobra povezanost s korisnicima jer ako ovaj kontakt nije dobar i analitičar na ispravan način ne shvati zahtjeve korisnika neuspjeh je neminovan.

Glavni alati kojima se ova metoda koristi su sljedeći:

- Dijagrami toka podataka − (engl. *Data Flow Diagrams*) predstavljaju prikaz mreže međuovisnih postupaka i glavni su alat za prikaz analize i funkcionalnu dekompoziciju.
- Rječnik podataka − (engl. *Data Dictionary*) skup zapisanih konvencija za opis podataka, toka podataka i sučelja.
- Strukturirani narativni jezik − (engl. *Structured English*) normirani jezik, skup termina kojim se što jezgrovitije može prikazati bit sustava i njegovih postupaka unutar dijagrama toka podataka.
- Tablice odlučivanja − (engl. *Decision Tables*) tablice koje ukazuju na to koja će akcija unutar nekog postupka biti prihvaćena pod određenim uvjetima. Imaju dakle više ulaza i, ovisno o postojećim uvjetima, više izlaza.
- Stabla odlučivanja − (engl. *Decision Trees*) binarna stabla kod kojih svaki čvor koji nije završni predstavlja jednu odluku. Stabla odlučivanja koriste uglavnom analitičari

kojima se tablice odlučivanja čine nepreglednim i dosadnim jer stabla su ipak više grafički prikaz (slika).

Za ilustraciju dosad navedenog o strukturnoj analizi i specifikaciji sustava, prikazat ćemo razliku između klasične metode i strukturne metode strukturnim alatima. Slika 3.4. prikazuje grafički prikaz životnog ciklusa klasičnog projekta sustava.

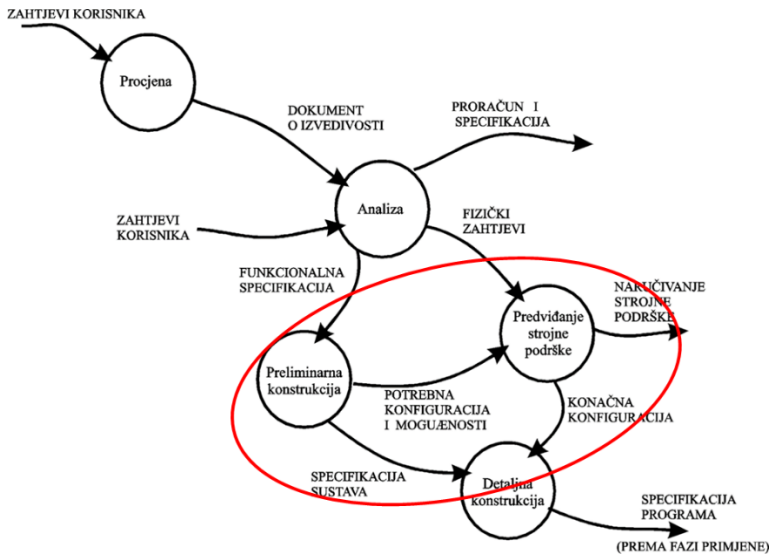

Slika 3.4. Grafički prikaz životnog ciklusa klasičnog projekta sustava (izvor: autor prema DeMarco, 1978)

Pod terminom „klasični" podrazumijevamo tehnologiju analize koja vrlo malo uključuje ili uopće ne uključuje strukturne metode. Vidi se da ulaze u analizu čine: dokument o izvedivosti, koji je dobiven procjenom na temelju zahtjeva korisnika, te zahtjevi korisnika. Faza analize ima četiri izlaza: ciljni dokument (funkcionalna specifikacija), fizičke zahtjeve, proračun i specifikaciju, ali može ih imati i više. Ukratko, ovakav je pristup neki put vrlo iterativnog karaktera jer zahtijeva pokusnu procjenu konfiguracije opreme, preliminarnu konstrukciju sustava, raspored datoteka i podataka, analizu sredstava (diskova i jezgre sustava) te niz drugih informacija važnih za planiranje projekta kako bi se uopće mogao napraviti proračun troškova i specifikacija sustava. Tek kada se ovaj dio posla obavi na zadovoljavajući način, može se pristupiti detaljnoj konstrukciji sustava i krenuti u fazu izvođenja. Klasični pristup dakle često rezultira iteracijama jer zahtijeva pokusnu procjenu konfiguracije opreme i preliminarnu konstrukciju sustava s obzirom na resurse. Najčešće rezultira u sekvencijalnim i nepreglednim narativnim opisima, tj. potrebno je puno papira za mali napredak (Tko se sjeća početka?).

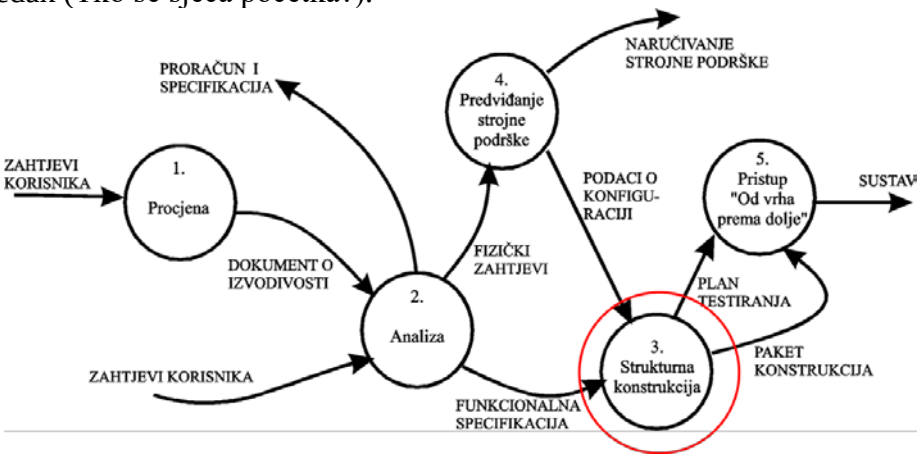

Slika 3.5. Grafički prikaz životnog ciklusa projekta temeljenog na strukturnoj metodi (izvor: autor prema DeMarco, 1978)

Slika 3.5. prikazuje životni ciklus projekta temeljenog na strukturnoj analizi. Razvoj sustava prikazan je grafički u pet strukturiranih postupaka (koraka). Prve faze projekta podsjećaju na klasičnu metodu, ali primjena strukturne tehnologije na početku konstrukcije sustava daje značajne efekte. Sada na mjestu prijašnje „preliminarne konstrukcije" nalazimo dakle jednu verziju strukturne konstrukcije (može se zvati i kompozitna konstrukcija ili konstrukcija s pristupom „od vrha prema dolje"). U daljnjim je fazama projekta znakovita i primjena strukturnog modeliranja uz implementaciju metode „od vrha prema dolje" te raznih testiranja. Da bismo odgovorili na pitanje što se krije u postupku pod nazivom „strukturna konstrukcija" potrebno je izvršiti daljnju dekompoziciju i vidjeti od čega se ovaj postupak sastoji.

Na slici 3.6. vidimo rezultat funkcionalne dekompozicije postupka tj. čvora broj 3. „strukturna konstrukcija".

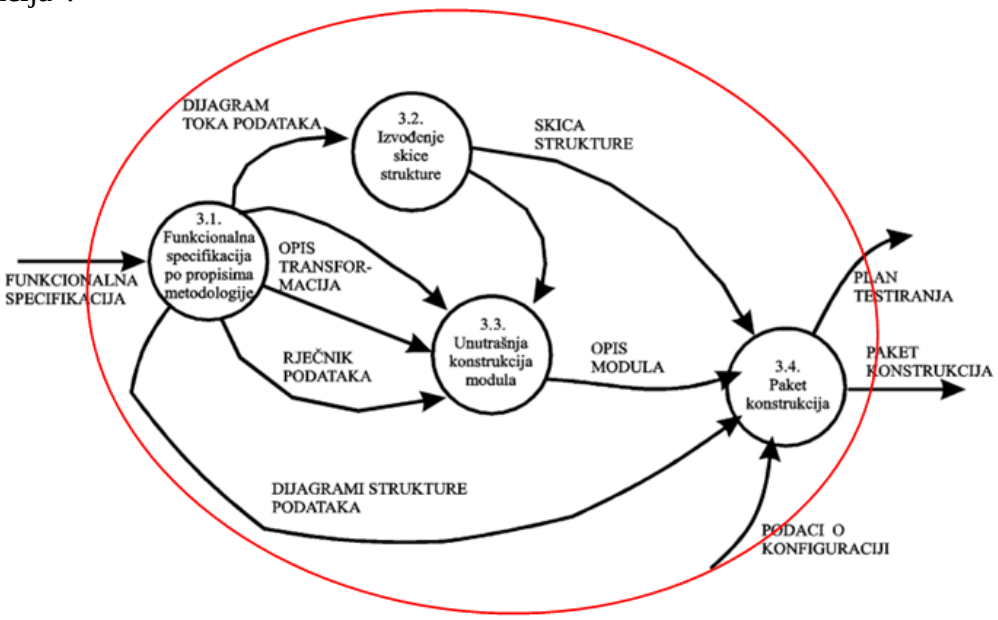

Slika 3.6. Grafički prikaz unutrašnjosti postupka br. 3 „strukturna konstrukcija" (izvor: autor prema DeMarco, 1978)

Očito je da se ovaj postupak sastoji od četiriju drugih postupaka koji obuhvaćaju: funkcionalnu specifikaciju prema propisima metodologije kako bi ciljni dokument bio logički jasan i jednoznačan, izvedbu skice strukture, konstrukciju pojedinih modula sustava i na kraju definiciju paketa konstrukcija. Paket konstrukcija u svom konačnom obliku obuhvaća: strojnu podršku, operacijske sustave, programske alate, sustave za upravljanje bazama podataka i dr.

Na sličan se način kako je ovdje napravljena dekompozicija postupka br. 3 vrši i funkcionalna dekompozicija postupaka stvarnog poslovnog sustava i analizira njihova struktura te struktura njihovih funkcija i podataka. Prati se struktura svakog podatka i njegov životni vijek s obzirom na događaje koji ga stvaraju, mijenjaju ili koriste. Uz ovako generiran ciljni dokument uvijek je moguće održavati i prestrukturirati postojeći IS. Nedostatak ove metode u primjeni kod vrlo velikih i složenih sustava je taj da se vodeći računa o podacima pomalo gubi ukupna slika sustava i otežava faza konstrukcije i implementacije.

Važno je naglasiti da svaki projekt počinje kontaktom analitičara sustava s korisnicima koji iznose svoje zahtjeve na temelju kojih se vrše daljnje procjene i analize. Ako ovaj segment nije dobro ostvaren, cijeli projekt vrlo lako može propasti. Ovo načelo vrijedi za sve metode jer od korisnika dobro opisan poslovni sustav osigurava analitičarima i konstruktorima informacijskog sustava lakši rad, a samim korisnicima kasnije bolji kontakt s računalnim aplikacijama, a time i ugodniji rad (DeMarco, 1978).

3.3.3. Metoda ISAC

Metoda ISAC (engl. *Information Systems work and Analysis of Changes*, hrv. rad na informacijskim sustavima i analiza promjena) razvijena je u Švedskoj na idejama B. Langeforsa (teorijska analiza IS-a), a osmislila ju je istoimena radna skupina utemeljena 1971. godine (Lundeberg, Goldkuhl i Nilsson, 1981). Unutar deset godina svog razvoja uspjela je postati široko primjenjivanom metodom u skandinavskim zemljama u poslovnim i akademskim područjima. Kao rezultat desetogodišnjeg rada nastala je knjiga *Information Systems Development − a Systematic Approach* čiji su autori Mats Lundberg, Göran Goldkuhl i Anders Nilsson, koja je 1981. godine doživjela i švedsko i englesko izdanje, što je posljedica interesa i ostalog dijela Europe za ovu metodu. S obzirom na to da je opis metode uglavnom popraćen praktičnim primjerima koji zahtijevaju detaljne prikaze, ovdje će biti riječi samo o temeljnim svojstvima i postupcima ove metode.

Prema ISAC metodi u specifikaciji i razvoju IS-a polazi se od analize objektnog (stvarnog) sustava, i to najprije od analize promjena, kojom je potrebno ustanoviti možemo li doista u određenim postupcima razviti informacijski sustav ili su potrebne promjene drugačijeg tipa. Kada analiza promjena pokaže da se doista može primijeniti IS, pristupa se analizama i projektiranju IS-a u cilju stvaranja modela koji s različitih gledišta opisuju IS. Dobiveni modeli služe kao baza za ostvarenje IS-a. ISAC metoda dijeli ukupne poslove na dvije vrste poslova:

- **problemski orijentirane poslovi** − u središtu ovih poslova su korisnici, njihovi problemi i potrebe. Ovi poslovi obuhvaćaju proučavanje aktivnosti i analize informacija.
- **poslove orijentirane podacima** − unutar ovih poslova razmatraju se mogućnosti i ograničenja različitih pomagala (npr. računalne opreme i programskih alata). Ovi poslovi obuhvaćaju konstrukciju sustava podataka i adaptaciju opreme.

Kada se izvrši analiza promjena može se dakle pristupiti sljedećim aktivnostima grupiranim u dvjema prije navedenim skupinama poslova, a to su:

- **proučavanje aktivnosti** − služi za izdvajanje IS-a, odnosno definiranje ulaza i izlaza IS-a u budućoj organizaciji.
- **informacijska analiza** − opisuje što će prethodno izdvojeni budući IS sadržavati. Analiza počinje opisivanjem traženih rezultata IS-a koji postaju cilj aktivnosti koje će se provoditi. Proučavaju se i nositelji informacija i neophodni postupci.
- **konstrukcija sustava podataka** − svrha joj je konstruirati rješenje sustava podataka koji je neovisan od fizičke opreme za IS koji je opisan u informacijskoj analizi. Izvode se potrebne računalne rutine, definira se struktura podataka i vrši konstrukcija programa. Posebna se pažnja posvećuje mogućnostima održavanja, prilagodljivosti i pouzdanosti pri upotrebi.
- **adaptacija opreme** − cilj je ove aktivnosti određivanje koja će se specifična oprema koristiti i prilagoditi o opremi neovisnom rješenju konstrukcije sustava podataka.

Na slici 3.7. prikazan je razvoj informacijskih sustava po metodi ISAC u širem smislu koji ukratko opisuje tvrdnje iznesene na početku.

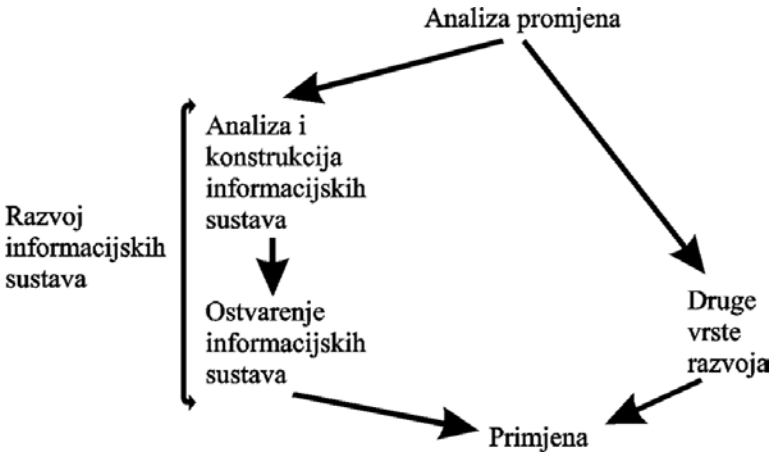

Slika 3.7. Razvoj informacijskih sustava po ISAC metodi u širem smislu (Lundeberg, Goldkuhl i Nilsson, 1981)

Na kraju je potrebno spomenuti neka temeljna načela ISAC metode:

1. Informacijski sustavi razvijaju se onda kada stvarno postoji potreba za njima (vrlo važna stvar za analizu promjena).
2. Informacijski sustavi razvijaju se samo onda ako u nekom smislu pozitivno pridonose aktivnostima organizacije (vrlo važna stvar za analizu aktivnosti).
3. Informacijski sustavi razvijaju se na takav način da korisnici razumiju što sadrže i čemu služe (vrlo važna stvar za informacijsku analizu).
4. Informacijski sustavi razvijaju se tako da ih je moguće mijenjati kada se za to ukaže potreba i nisu ograničeni samo jednom određenom vrstom računalne opreme (vrlo važna stvar za konstrukciju sustava podataka).
5. Informacijski sustavi razvijaju se tako da su djelotvorni i prilagođeni tehničkoj opremi koju koriste (vrlo važna stvar za adaptaciju opreme) (Lundeberg, Goldkuhl i Nilsson, 1981).

3.3.4. Objektno orijentirana metoda

Dosad navedene metode temeljile su se uglavnom na, možemo reći, konvencionalnim načelima proceduralnih programa i programskih jezika. Proceduralni program izgrađen je na ideji funkcionalnosti, tj. program nešto radi, a taj se rad izvodi na podacima. Iz tog se razloga proceduralni program smatra zbirkom procedura ili funkcija, a podaci otvoreno teku kroz program kao što prikazuje slika 3.8.

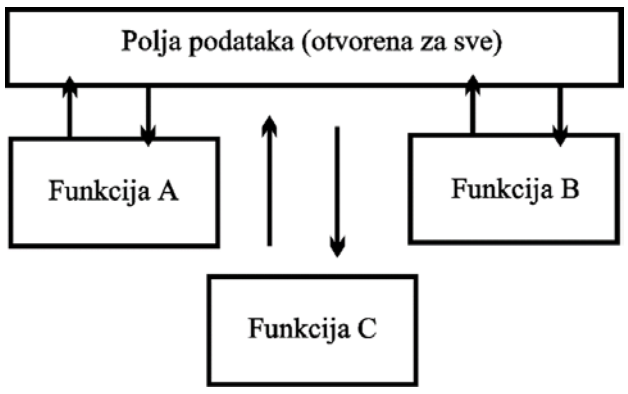

Slika 3.8. Tok podataka u proceduralnom programu (izvor: autor)

Nasuprot ovom načelu organizacije, u novije se vrijeme pojavilo tzv. objektno orijentirano programiranje (OOP) i objektno orijentirani programski sustavi (OOPS), a nešto kasnije razvila se i objektno orijentirana metoda za projektiranje informacijskih sustava. Objektno orijentirani program smatra se zbirkom objekata (što uključuje i podatke i metode njihove upotrebe) koji međusobno komuniciraju porukama s ciljem da se obavi neki posao kao što to prikazuje slika 3.9.

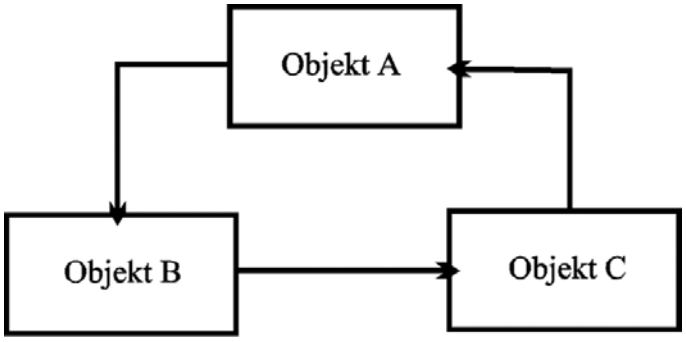

Slika 3.9. Tok poruka u objektno orijentiranom programu (izvor: autor)

Prvo pitanje, koje se nameće samo po sebi, glasi: Što je uopće objekt? Bruce Eckel, autor jednog od najboljih priručnika za objektni C++ pod nazivom *Using C++*, ukratko kaže: „Objekt je sve što ima granice." (Eckel, 1989). No objekte možemo bolje opisati kao podatkovne strukture u memoriji koji mogu biti manipulirani cjelokupnim sustavom (strojnom i programskom podrškom) i koji omogućuju opisivanje visoke razine (engl. *high-level description*) koja je dopuštena za korisničko sučelje visoke razine. Objekti imaju atribute (engl. *descriptors*) koji upućuju na razne stvari kao što su imena, pokazivači i oznake. Ovi atributi također omogućuju informaciju o tipu objekta i opis mogućnosti djelovanja primijenjenih na neki određeni objekt (Daintith i Wright, 2008).

Drugo je pitanje: Zašto uopće treba primjenjivati objektni pristup i pisati programe na takav način? Odgovor na ovo pitanje „leži" u dosadašnjoj programerskoj praksi. Dok su proceduralni programi relativno kratki i jednostavni programer može lako pratiti tok podataka u njima i imati potpunu kontrolu na zadovoljavajućoj razini. U američkom ratnom zrakoplovstvu piloti borbenih zrakoplova mogućnost mentalnog zadržavanja i istovremenog upravljanja mnogim čimbenicima nazivaju svjesnost situacije ili SA (engl. *situational awarness*). Kada zadaća programera postane presložena, a proceduralni program veći, održavanje zadovoljavajućeg SA postaje gotovo nemoguće jer programer postaje preopterećen i nije više sposoban uspješno upravljati razvojem programa. Primjene tzv. tehnika strukturiranog programiranja bile su prvi pravi pokušaji da se razmrsi složena logička mreža i područja međuovisnih podataka. Te tehnike određuju kako treba ostvariti logiku da bi se moglo pristupiti procedurama (logički tok) i mnogim drugim stvarima čija je namjena prisiliti programera da ostane organiziran. Međutim, bez obzira na to što su sve tehnike strukturiranog programiranja postigle, one nisu uspjele zaštititi otvoreni tok podataka kroz program. Naime, složenost je i dalje ostala glavni problem jer što je više podataka, to je potrebno više logike za njihovu kontrolu, a time je sve više podataka i logike potrebno za kontrolu ovih prethodnih podataka i logike, i tako ukrug. Ovo na neki način podsjeća na kotrljanje grude po snijegu koja tako postaje sve veća i veća. Kako bi se ovaj problem složenosti donekle riješio počelo se s razvojem i primjenom objektno orijentiranih programskih jezika i programa. Što donosi objektno orijentirani pristup? Može se reći da objektno orijentirani pristup ima tri glavne osobine koje ga čine privlačnim, a to su: apstrakcija podataka, nasljeđivanje i *polimorfizam.* Središnja je značajka objekt koji obuhvaća definiciju strukture podataka i definirane procedure u jednostrukoj strukturi. Objekti su dijelovi razreda i svaki dio ima svoje vlastite varijable. Razred sadrži formu apstraktnih tipova podataka. Definicija razreda određuje svojstva objekata sadržanih u tom razredu: moguće su hijerarhijske strukture razreda u kojima objekti nekog razreda nasljeđuju svojstva od razreda-roditelja kao dodatak eksplicitno definiranim svojstvima tog razreda. Ovo

olakšava dijeljenje računalnog koda (programskih odsječaka) jer korisnici mogu „naslijediti" objekte iz skupa kodova (programskih odsječaka) već sadržanih u programskom sustavu. Nasljeđivanje dakle određuje sposobnost nekog objekta da svoje podatke i funkcionalnost automatski izvodi iz nekog drugog objekta. Apstrakcija podataka poznata i pod nazivom *enkapsulacija* nije ništa drugo nego skrivanje podataka, odnosno prikrivanje nekih dijelova struktura podataka u programu od običnog pogleda kako bi se izbjegla neoprezna i pogrešna izmjena. Podacima mogu pristupiti i izmijeniti ih jedino oni dijelovi programa kojima ti podaci pripadaju, ili drugim riječima, ni jedan objekt ne može i ne smije pristupiti unutrašnjim podacima drugog objekta. Očito je da je prava namjena tehnike apstrakcije podataka prikrivanje i upravljanje složenošću. *Polimorfizam* je mogućnost dobivanja različitih odziva objekata na iste poruke u različitim slučajevima, a temelji se na dvije tehnike: generičkim operatorima i dinamičkom vezanju tipova. Objektno orijentirani pristup temelji se na sposobnosti pridruživanja imena generičkih poruka jednoj ili više procedura. Procedure (funkcije) nekog objekta, često nazivane metode (engl. *methods*), aktiviraju se porukama koje su objektu poslane od nekog drugog objekta. Kada objekt primi poruku, jezik prevoditelj određuje koja će se akcija izvesti ovisno o razredu ili tipu objekta. Iz ovoga slijedi da je u objektno orijentiranom programskom sustavu temeljna kontrolna struktura − **protok poruka**. Programer identificira objekte iz stvarnog svijeta vezane za problem koji rješava i procesne zahtjeve ovih objekata, vrši njihovu *enkapsulaciju* u definicije razreda i rješava komunikacije između objekata. Program je tada zapravo simulacija stvarnog svijeta u kojem objekti puštaju poruke drugim objektima kako bi pokrenuli neke akcije. Primjer najkompletnijeg ostvarenja OOPS-a su programski jezici Smalltalk, Actor, Objective-C i Object Pascal, dok se ovaj koncept u velikoj mjeri pojavljuje i u konvencionalnim jezicima kao što su C++ i CLOS, koji za razliku otprije spomenutih dopuštaju i tzv. višestruko nasljeđivanje (Eckel, 1989).

Kao što su prvo nastali proceduralni i strukturirani programski jezici, a zatim na njima temeljene klasične i strukturne metode za analizu i projektiranje informacijskih sustava, tako su prvo razvijeni objektno orijentirani programski jezici na temelju kojih je razvijen objektno orijentirani pristup analize stvarnog poslovnog sustava i projektiranja njegovog informacijskog sustava. Može se reći da su 70-te i 80-te godine 20. stoljeća bile godine strukturnih tehnika, dok su 90-te godine 20. stoljeća bile godine početka uspona i prihvaćanja objektno orijentiranih metoda.

Da bi se iskoristila snaga objektno orijentirane tehnologije za konstrukciju uspješnog i prilagodljivog objektno orijentiranog sustava, potrebno je naći odgovore na niz pitanja: Kako inicijalno prepoznati objekte? Koje su njihove osobine? Kakve su veze između objekata? Kakvi su njihovi međusobni utjecaji? Odgovor na ova pitanja može dati OBA (engl. *Object Behavior Analysis*, hrv. analiza ponašanja objekata), metoda koja predstavlja prvi korak u objektno orijentirani svijet. Tradicionalne metode uopće ne barataju ovim pojmovima i pitanjima. OBA predstavlja objektno orijentirani pristup analizi „korak po korak". Koraci su sljedeći:

1. **Identifikacija ponašanja** − obuhvaća razgovor s korisnicima o budućoj aplikaciji, o tome što rade, s kim i kako komuniciraju, po kojem redoslijedu i kakvi su rezultati pojedinih akcija.

2. **Definiranje objekata** − podrazumijeva određivanje izvođenja inicijalnih ponašanja koja su definirana u prethodnom koraku. Treba utvrditi tko je ili što je odgovorno za pojedina ponašanja.

3. **Klasifikacija objekata** − podrazumijeva grupiranje objekata prema sličnostima u ponašanju (funkcijama) i stanju (obliku). Ovo je temeljno načelo za OBA-u, a da bi se ono provelo treba promatrati koji među različitim objektima imaju slično ponašanje. Na primjer, upitamo li nekoga da nam nabroji osobine jabuke, reći će nam da je ona okrugla, crvena, ima koru, sjemenke i jestiva je. Zamolimo li istu osobu da nam nabroji osobine

imitacije jabuke, reći će nam, na primjer, da nije jestiva, ali da je okrugla i crvena. Ljudi uglavnom inicijalno identificiraju objekte, njihova stanja, a zatim koriste osobine ponašanja da bi razlikovali i izoštrili granice između skupina ili kategorija. U ovom se primjeru, uzmemo li u obzir ulogu jabuke u životu čovjeka, njezino ponašanje klasificira kao jestivi objekt.

4. **Identifikacija međusobnih odnosa** − podrazumijeva crtanje preliminarne skice međusobnih odnosa objekata na temelju rezultata dosadašnjih koraka (objekata, njihovog ponašanja i objekata grupiranih prema ponašanju).

5. **Modeliranje postupaka** – konačni postupak koji podrazumijeva određivanje koji objekti pokreću aktivnosti i identificiranje sekvenci tih aktivnosti. Da bi se to učinilo treba primijeniti bilješke prikupljene i razvijene u prvom koraku zajedno s rezultatima svih dosadašnjih koraka kako bi se „pokrenuo" model aplikacije. Također je potrebno specificirati životne cikluse objekata i njihov status u različitim dijelovima ciklusa.

Rezultat OBA-e je specifikacija zahtjeva zapisana u obliku zahtijevanih ponašanja koja ocrtavaju primarne objekte i njihovu organizaciju. Ova specifikacija uključuje i objekte izvedene iz grupiranja po ponašanju (engl. *superordinate objects*) koji se često mapiraju u superrazrede tijekom konstrukcije i primjene te objekte iz stvarnog svijeta (engl. *subordinate objects*) iz kojih su izvedene apstrakcije i koji se često mapiraju u konkretne podrazrede. Bilješke (dokumentacija) dobivene tijekom primjene OBA-e posebno su korisne pri detaljnom planiranju rada korisničkog sučelja. Korištenjem OBA-e u analizi objektno orijentiranih sustava, postižemo specifikaciju ponašanja koja naglašava visok stupanj višestruke upotrebljivosti (engl. *reusability*) dijelova sustava, što znatno doprinosi redukciji veličine programskog koda te omogućava ostvarenje čiste i razumljive strukture objektno orijentirane aplikacije.

Unatoč svemu prethodno navedenom trebamo biti svjesni činjenice da je objektno orijentirani pristup započeo svoj intenzivniji razvoj i uspon početkom 90-ih godina te je još uvijek kao metodologija podložan daljnjem razvoju i napretku. Prema Edwardu Yourdonu (Embley, Kurtz i Woodfield, 1992), jednom od najpoznatijih analitičara informacijskih sustava i teoretičara ove metodologije, informatički se svijet dijeli uglavnom na dvije skupine. Prvu skupinu čine ortodoksni poklonici objektne tehnologije koji je smatraju pojasom za spašavanje 90-ih godina nadalje te zastupaju ideju da bi sve IS-ove konstruirane dosadašnjim metodologijama trebalo odbaciti i ponovo izvesti uz primjenu objektno orijentiranog pristupa. Drugu skupinu čine oni koji tvrde da je objektno orijentirani pristup „staro vino u novim bocama" te da je nastao iz dosadašnjih pokušaja što efikasnijeg strukturiranja programskog koda. Ova skupina smatra da se mogu primjenjivati i hibridne metode koje su kombinacija npr. objektne i strukturne metode, iako je u praksi uobičajeno da ako netko analizira i projektira IS na objektno orijentiranom načelu, onda i programski sustav izvodi u nekom od jezika kao što su Objective C, Ada ili Smalltalk jer je prilično teško zamisliti kako bi se prethodne studije ostvarile npr. u COBOL-u.

Na kraju treba istaknuti da uvijek treba imati na umu da je objektno orijentirani pristup nastao kao efikasno sredstvo za borbu protiv složenosti analiziranih sustava. Ako stvarna složenost ne postoji, sve što ćemo dobiti upotrebom ove metodologije je nepotrebna složenost programskog sustava i nepotrebni troškovi. Nije zato loše uvijek napraviti probni projekt jer objektne vježbe ne moraju uvijek biti ugodne i zabavne, već mogu pokazati ono što nismo željeli saznati, ali nas mogu poštedjeti velikih problema i troškova u koje bismo mogli zapasti neprimjerenom primjenom ove metodologije. Treba istaknuti da svi današnji objektno orijentirani sustavi za razvoj programske podrške podržavaju i objektnu i proceduralnu paradigmu programiranja (Eckel, 1989; Embley, Kurtz i Woodfield, 1992).

3.4. Standardne metode za razvoj programske podrške

U prethodnom su odjeljku opisane kompletne glavne predstavnice pojedinih analitičko-razvojnih paradigmi (proceduralne, strukturne i objektne). U nastavku ćemo ukratko obraditi neke standardne ili tradicionalne metode usmjerene na razvoj programske podrške kao funkcionalne osnove novog IS-a. Moglo bi se reći da su se metode strukturne analize, koje su kasnije proizišle iz metode SASS, bile općeprihvaćene i takve su se zadržale u primjeni do današnjih dana. No s obzirom na sve veću složenost PS-a, što implicira i složenost IS-a, na području razvoja programske podrške težilo se unaprjeđenju modularnog razvoja uz što kraće vrijeme planiranja i razvoja aplikacija. Težište se sve više stavljalo na kratke sastanke razvojnih timova, bolju povezanost članova timova u okviru razvojnog projekta te uključivanje korisnika u procjenu pojedinih razvojnih faza.

3.4.1. Model vodopada

Na slici 3.10. prikazan je klasični razvojni model vodopada (engl. *waterfall*) kojeg možemo smatrati tradicionalnim modelom razvoja programske podrške. Glavna su mu obilježja:

- slijedno napredovanje iz faze u fazu
- ne dozvoljava naknadne promjene rezultata prethodnih faza
- primjeren je velikim projektima (investicijama)
- prikladan je za dobro definirano okruženje gdje postoje razrađene procedure ručne obrade ili za računalski sustav koji treba unaprijediti.

Nedostaci ovog modela:

- problem u slučaju pogrešaka ili novih/promijenjenih zahtjeva
- slijed uvođenja prema gore (*bottom-up*): moduli, podsustavi, sustav
- sustav nije upotrebljiv dok nije gotov u potpunosti
- problem predodžbe o proizvodu na temelju pisane specifikacije (mora biti poznat u potpunosti prije početka razvoja).

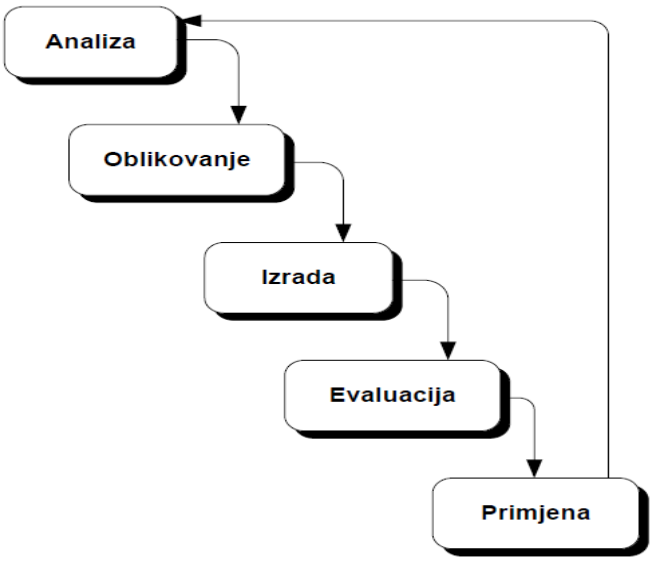

Slika 3.10. Klasični model vodopada (*waterfall*) (Fertalj i Kalpić, 2006)

Kao unaprjeđenje klasičnog modela vodopada razvijeni su pseudostrukturni i radikalni (strukturni) modeli koji su prikazani na slici 3.11.

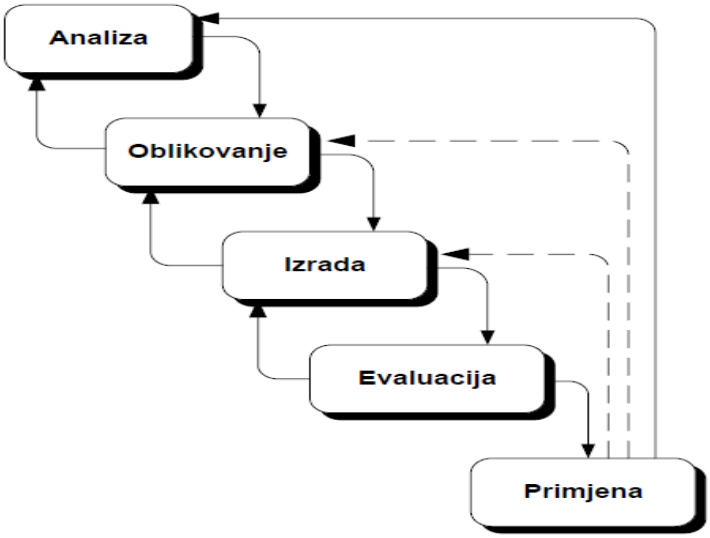

Slika 3.11. Pseudostrukturni i radikalni modeli vodopada (Fertalj i Kalpić, 2006)

Pseudostrukturni model vodopada odlikuju:

- povratna veza i mogućnost promjene rezultata prethodnih faza
- uvođenje prema dolje (*top-down*): prvo moduli na višim pa na nižim razinama
- primjena tehnika strukturiranog programiranja.

Strukturni (radikalni) model:

- omogućava da se aktivnosti različitih faza mogu obavljati istovremeno
- uvodi korištenje rječnika podataka, 4GL i generatora aplikacija
- prikladan je za primjenu kada se unaprijed ne zna konačni izgled sustava
- prikladan je za primjenu kada se prvo mora načiniti (papirnati) model sustava.

3.4.2. V-model

V-model predstavlja modificiranu i unaprijeđenu verziju modela vodopada. Ovaj je model nastao 1992. godine u Njemačkoj za potrebe Ministarstva obrane. Naziv modela potječe od činjenice da se proces razvoja programske podrške predstavlja u vidu dijagrama u obliku slova V. Slovo V u nazivu modela isto tako označava važnost verifikacije i validacije u procesu. Kao što je prikazano na slici 3.11., kodiranje predstavlja ishodište V-modela, pri čemu su analiza i dizajn na lijevoj, a testiranje i održavanje na desnoj strani. Sve faze kod V-modela su sekvencijalne, što znači da sljedeća faza može početi tek kada se završi prethodna. Za razliku od modela vodopada gdje se tijek aktivnosti neprestano provodi prema dolje, kod V-modela nakon implementacije slijedi povratak prema gore, što omogućava vraćanje iz procesa koji dolaze kasnije u procese koji su već izvršeni ranije. Kod modela vodopada pozornost se posvećuje dokumentima i artefaktima, dok se V-model usredotočuje na aktivnosti i ispravan rad sustava.

Da bi sustav ispravno radio, on mora proći kroz tri faze: testiranje pojedinačnih modula s integracijom, testiranje integriranog sustava i završno testiranje. Cilj je testiranja pojedinačnih modula uz postepenu integraciju da se razvojni tim uvjeri da je svaki aspekt sustava ispravno implementiran. S druge strane, cilj testiranja integriranog sustava je taj da dokaže da sustav kao cjelina radi ono što se od njega očekuje. Može se dakle zaključiti da ove dvije faze služe za provjeru je li sustav ispravno i u potpunosti implementiran prema napravljenom projektu.

Završnim testiranjem, kojeg češće provode naručioci programske podrške nego projektni tim, provjerava se jesu li svi zahtjevi korisnika u potpunosti implementirani.

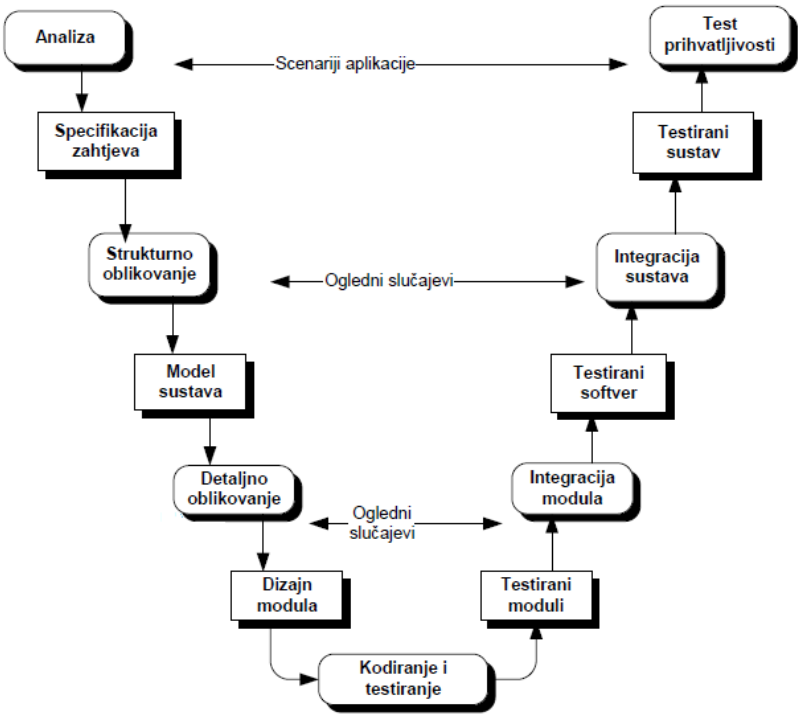

Slika 3.12. V-model životnog ciklusa programske podrške (Fertalj i Kalpić, 2006)

3.4.3. Spiralni model

Spiralni model, prikazan na slici 3.13., ima četiri faze: planiranje (1), analiza rizika (2), inženjering (3) i evaluacija (4). Projekt razvoja programske podrške više puta prolazi kroz ove faze u iteracijama (u ovom modelu nazvane spirale).

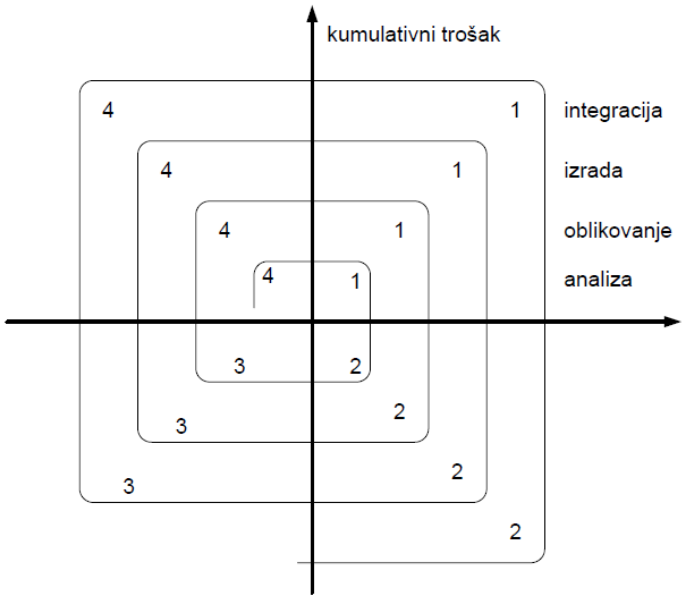

Slika 3.13. Spiralni model životnog ciklusa razvoja programske podrške (Fertalj i Kalpić, 2006)

Osnovna spirala, koja počinje od faze planiranja, prikuplja zahtjeve i procjenjuje rizik. Svaka sljedeća spirala gradi se na osnovnoj spirali. Zahtjevi se prikupljaju tijekom faze planiranja. U fazi

analize rizika poduzima se proces identifikacije rizika i alternativnih rješenja. Prototip se proizvodi na kraju faze analize rizika. Programska podrška (program) se proizvodi u fazi inženjeringa, zajedno s testiranjem na kraju faze. Faza evaluacije omogućuje korisniku da ocijeni izlaz projekta prema podacima prije nego se projekt nastavi do sljedeće spirale. Faze analize rizika prikazane su na slici 3.14. Na početku svake faze provodi se procjena rizika i nastoje se utvrditi mogući rizici kako bi se razriješili prije nastavka (uklanjanjem ili svođenjem na najmanju moguću mjeru). Ako je rizik prevelik, projekt se prekida.

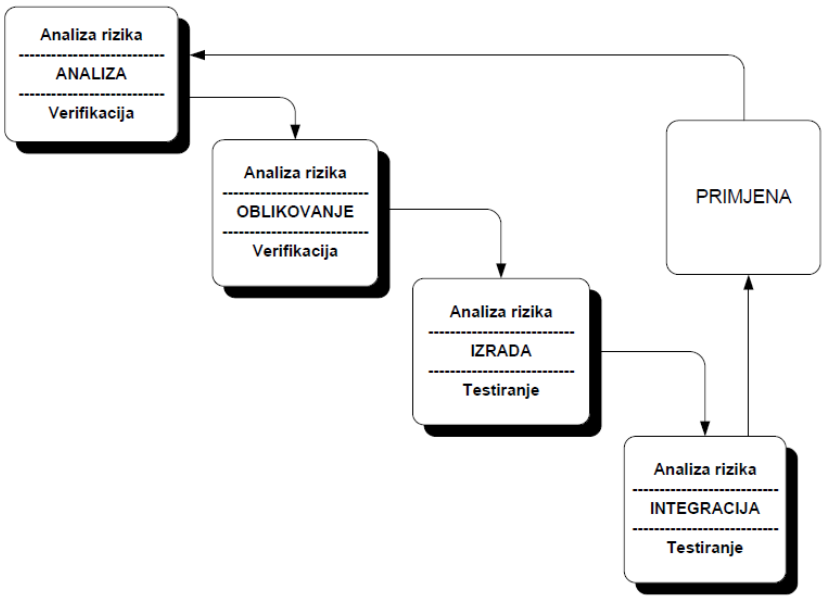

Slika 3.14. Analize rizika sa svakom od razvojnih faza (Fertalj i Kalpić, 2006)

Prednosti spiralnog modela su:

- reduciranje rizika (primjenom spiralnog modela minimiziraju se rizici i greške pri izradi sustava)
- dobra kontrola troškova (procjena troškova može se lako izvršiti, zbog čega krajnji kupac ima dobru kontrolu administriranja novog sustava)
- aktivno sudjelovanje korisnika (interakcija s korisnikom omogućava ravnomjeran razvoj programskog proizvoda koji zadovoljava sve potrebe korisnika).

Nedostaci mogu biti:

- ograničena primjena (pogodan je za velike i složene projekte)
- neophodno znanje o rizicima (model zahtijeva veliku vještinu u evaluaciji neizvjesnosti i rizika)
- složenost modela (spiralni model ima striktno definiran protokol razvoja, kojeg je ponekad teško ispoštovati).

3.5. Agilne metode razvoja programske podrške

Najveći problem tradicionalnih metoda poput modela vodopada je nedovoljna fleksibilnost. Uz svoju krutu strukturu ne dopuštaju promjenu zahtjeva i okolnosti razvoja proizvoda koji su utkani u samu srž razvoja programske podrške, stoga agilne metode podržavaju stalne promjene, i oblikuju se tako da se upravo njima mogu prilagoditi. Osnovna načela agilnih metoda su donesena 2001. godine na sastanku skupine vodećih softverskih stručnjaka na skijalištu Snowbird u američkoj saveznoj državi Utah, te se taj sastanak smatra začetkom agilne metodologije. U svom su proglasu naglašavali kako su pojedinci i interakcije među njima važniji od procesa i alata koji se koriste u razvoju te kako je funkcionalnost i ispravnost programske podrške važnija od sveobuhvatne dokumentacije. Složili su se i da je suradnja s naručiteljem važnija od pregovora o ugovoru te da je odziv na promjene u cjelokupnom procesu važniji od praćenja plana razvoja. U nastavku će se ukratko analizirati metode Kanban, Scrum i Ekstremno programiranje, jer su one najzastupljenije u suvremenim razvojnim projektima (ATLASSIAN, 2023).

3.5.1. Kanban

Kanban svoje korijene vuče iz ranih 40-ih 20. stoljeća kojeg je razvio inženjer Taiichi Ohno u japanskoj automobilskoj tvrtki Toyota. Naziv se može prevesti kao kartica ili tablica, a razvijen je kako bi se poboljšala produktivnost rada u skladu s *Just-In-Time* pristupom, tako da se cijeli distributivni lanac sa svim svojim elementima popiše i standardizira kako bi se olakšalo upravljanje svim procesima. David J. Anderson je 2004. godine [ ] primijenio Toyotina načela na IT industriju tako da je kreirao danas široko korištenu kanban ploču. Važno je napomenuti kako Kanban sam po sebi nije metodologija te ne definira nikakve načine izrade programskog rješenja. Njegovim se korištenjem može unaprjeđivati razvojni proces članova tima te im pomoći da nauče bolje raspoređivati posao i vlastito vrijeme. Glavna značajka Kanbana je vizualizacija razvojnog procesa pomoću fizičke ili digitalne ploče. Kao što je prikazano na slici 3.15., kanban ploča je podijeljena na stupce koji predstavljaju različite faze dovršenosti zadatka, gdje se najčešće koristi jednostavna podjela na zadatke koji se još nisu počeli izvršavati (*to do*), one koji se izvršavaju (*doing*) i one koji su dovršeni (*done*). Iako je podjela jednostavna, ona daje jako dobar uvid u trenutnu količinu posla te vrlo jednostavno omogućava svim članovima tima i vanjskim promatračima da vide u kojoj je fazi projekt.

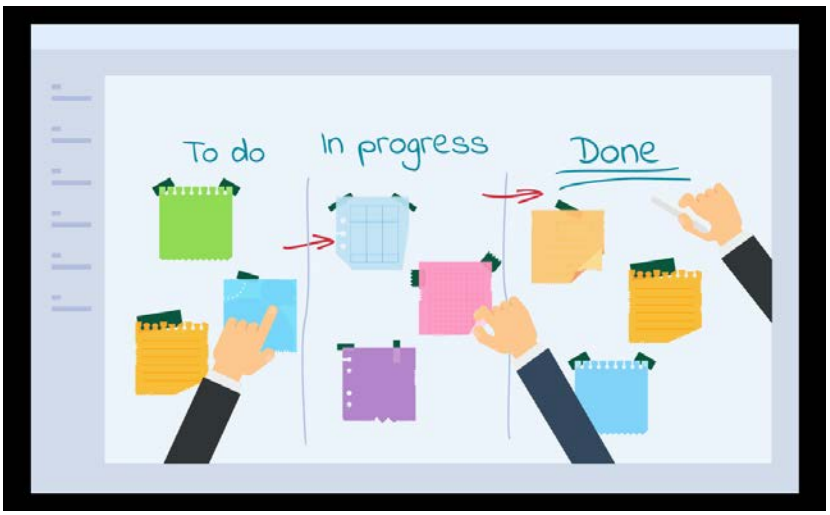

Slika 3.15. Jednostavna kanban ploča (ATLASSIAN, 2023)

Uz samu vizualizaciju zadataka, bitno je ograničiti i količinu aktivnog posla. Ne smije se dopustiti da pojedinci istovremeno rade na previše zadataka pa se potiče završavanje jednog po jednog zadatka kada je to moguće. To poboljšava fokusiranost na trenutne zadatke i olakšava

upravljanje projektom jer pruža realniju sliku trenutnog stanja projekta. Razlog zašto se Kanban koristi i u drugim agilnim metodama je taj što omogućava razvoj u malim inkrementima i jasnu vizualizaciju ponekad apstraktnih zahtjeva u više manjih zadataka koji se puno lakše definiraju i čiji se razvoj lakše prati (ATLASSIAN, 2023).

3.5.2. Scrum

Scrum je naziv za skup procesa koji se koristi za inkrementalni razvoj softvera koji propisuje mali broj artefakata koji se moraju formirati i održavati te događaja koji se moraju slijediti kako bi se smanjilo vrijeme potrebno za upravljanje i ostalo više vremena za razvoj. Svaka iteracija u Scrumu naziva se sprint i najčešće traje jedan ili dva tjedna. Ovisno o vrsti projekta, rezultat svakog sprinta može biti neki modul rješenja ili isporučiva verzija proizvoda koja se šalje na testove prihvatljivosti. Scrum je ime zapravo dobio prema izrazu scrum u ragbiju (slika 3.16.). Taj se izraz koristi za situaciju nakon prekida kada se protivnički timovi zbijaju na hrpe i bore za posjed lopte. Svakim je prekidom (scrumom) tim sve bliže cilju i zauzima nove pozicije. Na putu prema cilju, tim ne pokušava i ne može predvidjeti sve situacije koje se mogu dogoditi u igri, već se stalno prilagođava trenutnoj situaciji na terenu, a glavni mu je cilj progurati loptu što bliže protivničkoj liniji i postići zgoditak.

Slika 3.16. Primjer scruma u ragbiju (Kukhnavets, 2019)

Članovi tima se tijekom scrum procesa mogu baviti složenim prilagodbama klijentima, dok istovremeno isporučuju proizvode najviše vrijednosti. Tri najosnovnije karakteristike Scruma su da je lagan, jednostavan za razumjeti, ali težak za savladati.

Scrum proces se sastoji od skupa radnji koje se svako malo ponavljaju prema zadanom planu tima u skladu sa svojim potrebama i mogućnostima. Proces se sastoji od tima, vlasnika proizvoda (engl. *Product Owner*), *Scrum mastera* te događaja i artefakata. Proces je određen pravilima kojih se svi trebaju pridržavati. Na slici 3.17. prikazan je scrum proces.

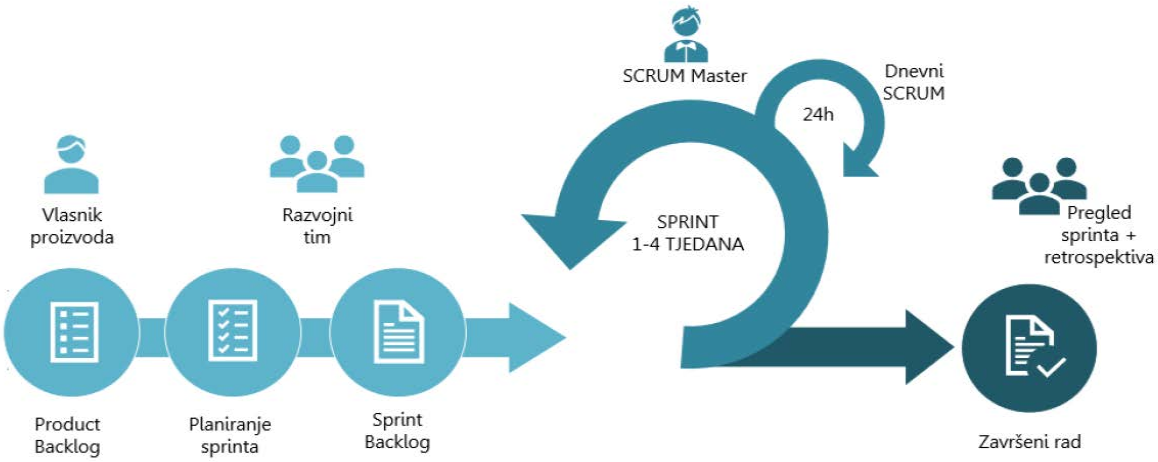

Slika 3.17. Scrum proces (Kukhnavets, 2019)

Svaki proces započinje idejom za proizvod, što bi se moglo usporediti s inicijacijom projekta u tradicionalnom pristupu vođenja projekata. Ideja se prenosi na *Product Ownera* koji sastavlja *Product Backlog,* odnosno popis svih elemenata koje taj proizvod treba sadržavati kako bi u konačnici predstavljao funkcionalnu i smislenu cjelinu radi zadovoljenja svih potreba naručitelja i korisnika. Iz samog planiranja tzv. sprinta nastaje *Sprint Backlog* koji predstavlja zadatke koji su prema prioritetima izabrani i trebaju biti izvršeni u sljedećem razvojnom ciklusu odnosno sprintu. Nakon izrade *Backloga* slijedi planiranje sprinta. *Scrum Sprint* predstavlja jedan ciklus izrade proizvoda koji završava jednim manjim, ali konačnim rješenjem cjelokupnog projekta. Svaki se dan tijekom sprinta vode dnevni sastanci (*Daily Scrum*). To su kratki sastanci od 15 minuta u kojima se raspravlja o poslu kojeg su obavljali od zadnjeg dnevnog Scruma i o poslu kojeg imaju namjeru napraviti do sljedećeg. Po završetku sprinta očekuje se da su svi zadaci izvršeni i da su funkcionalnosti *Sprint Backloga* razvijene, testirane, dokumentirane i spremne za isporuku. Nakon toga slijedi osvrt i retrospektiva obavljenog posla. *Sprint Retrospective* predstavlja događaj u kojem se tim fokusira na sam ciklus koji je iza njih te se analizira cijelo razdoblje kako bi se pronašli odgovori na pitanja:

- Što smo dobro napravili?
- Što smo loše napravili?
- Kako smo mogli bolje?
- Što možemo promijeniti?

Takvim se pristupom omogućuju da sljedeća iteracija sprinta bude kvalitetnija i produktivnija, a da se oni kao tim unaprjeđuju i prilagođavaju okolini. U Scrum metodologiji često se koristi scrum ploča. To je fizička ili digitalna tablica koja timovima služi za vizualizaciju elemenata *Sprint Backloga*. Ploča je podijeljena na stupce unutar kojih se postavljaju zadaci. Nazive stupaca timovi mogu prilagoditi svojim potrebama, ali to su najčešće faze projekta ili faze procesa (za napraviti, u tijeku i gotovo). S ovakvim pregledom zadataka, projekt dobiva na transparentnosti i jasnoći te potiče interakciju i diskusiju. Dionici projekta mogu dati svoj *input* što se tiče radnih zadataka te je svima uvijek jasno što trenutno radi i u kojem je stadiju projekt. Možemo dakle reći da je na neki način u ovu metodu uveden i kanban pristup.

Scrum metoda je najpoznatija i najrasprostranjenija agilna metoda. Logično je stoga zaključiti da sadrži većinu pozitivnih aspekata agilnog vođenja projekata. Najviše se ističe pozitivna strana fleksibilnosti i prilagodbe klijentu. Scrum metoda zamišljena je da bude fleksibilna tijekom cijelog životnog vijeka projekta. To pruža nadzorne mehanizme za planiranje izdanja, a zatim i za upravljanje varijablama projekta kako on napreduje. Ovo omogućava organizacijama da u bilo

kojem trenutku izmjene projekt i njegove rezultate stvarajući time najbolje izdanje. Iako je velika uključenost klijenta i njegova neprestana suradnja s razvojnim timom većinom pozitivan aspekt Scrum metode, ponekad ono otežava razvoj projekta. Nedostatak ovog načina rada je taj što česte i konstantne promjene te česti sastanci produljuju proces razvoja. Nerijetko se događa da ni sam klijent ne zna točno verbalizirati svoje zahtjeve te se tada broj iteracija povećava, zadovoljstvo pada, a rok predaje se odgađa. Osim toga, postoje klijenti koji su ili udaljeni ili nisu navikli na taj način rada i tada prilagodba postaje zahtjevna. Postoji još jedna stavka koja je većinom pozitivna, ali u određenim situacijama ima negativan aspekt, a to je veličina tima. Ova je metoda idealna za manje organizacije i timove, i iako se može primijeniti i na većim timovima, nije ju lako provesti. Optimalna veličina razvojnog tima je sedam članova (prihvatljivo je od pet do devet članova).

3.5.3. Ekstremno programiranje

Ekstremno programiranje (engl. *eXtreme Programming*, XP) jedna je od popularnijih agilnih metoda. Njezin je začetnik Kent Beck koji je 1996. godine razvio ovu metodu za situacije kada su zadaci nejasni ili se često mijenjaju, s orijentacijom na male timove i sveukupno zadovoljstvo dionika projekta (Beck i Andres, 2012). U primarni je plan postavljeno zadovoljstvo klijenta s redovitom komunikacijom, pravodobnom suradnjom i isporukom programskog proizvoda − onda kada klijent to treba. Razvojni tim reagira na promjenu zahtjeva čak i u kasnim fazama razvojnog ciklusa. Naglasak je na radu u timu gdje su klijent i razvojni programeri partneri, a okruženje je jednostavno što razvojni tim čini produktivnijim i zadovoljnijim. Ekstremno programiranje temelji se na pet osnovnih vrijednosti, a to su:

- komunikacija
- jednostavnost
- povratna informacija
- hrabrost
- poštovanje.

Kao pripadnica agilnih metoda, i XP metoda isporučuje proizvod u niz manjih dijelova pri čemu je svaki u potpunosti integriran i funkcionalan dio krajnjeg proizvoda. Četiri glavna procesa razvoja sustava XP-om su planiranje, dizajn, programiranje i testiranje. Na slici 3.18. prikazan je odnos tih procesa.

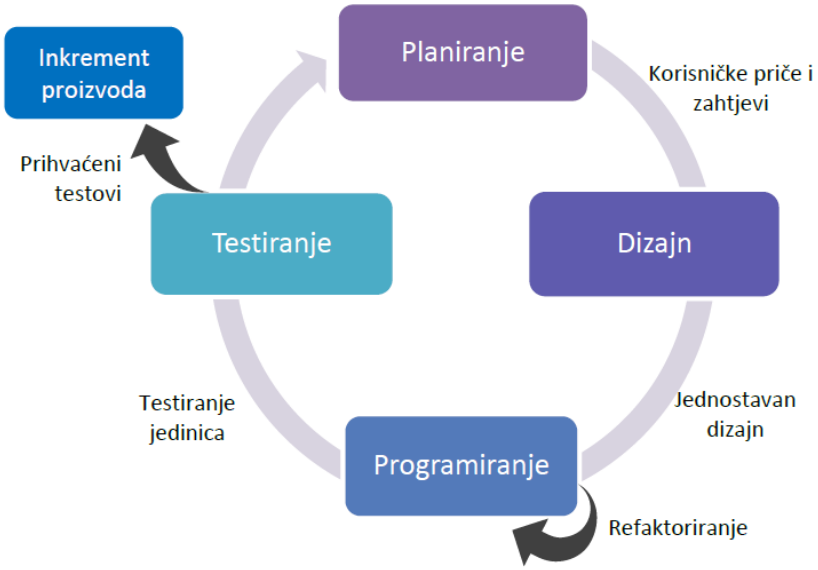

Slika 3.18. Procesi razvoja u XP metodi (Mall, 2015)

U XP metodi se u planiranju umjesto klasične dokumentacije za definiranje zahtjeva koriste korisničke priče. U njima korisnici u par rečenica opisuju što bi sustav iz njihove perspektive (bez tehnički zahtjevnih termina) trebao raditi. Njihova je svrha planiranje razvoja i vremena dostave inkrementa proizvoda. Aktivnosti se u agilnom duhu ne moraju isplanirati na početku projekta, već prije početka određene iteracije. Pri planiranju se procjenjuje trajanje ispunjenja određene korisničke priče u pojedinoj iteraciji. Tijekom procesa programiranja unaprijed se kreiraju testovi kako bi se znalo koje će se funkcionalnosti konkretno razviti te kako bi se uštedjelo na vremenu. Jedna od poznatih odlika XP metode je programiranje u paru, pri čemu jedna osoba programira, a druga je kontrolira. Programski se kod često integrira te je vlasništvo nad cjelokupnim programskim rješenjem zajedničko kako bi svatko mogao raditi izmjene i popravke na bilo kojem dijelu koda.

Glavna prednost ove metodologije i razlog zašto je puno razvojnih timova koristi je jednostavnost. Ne koristi se previše dokumentacije i ne troši se puno vremena na planiranje. Proizvod se razvija u manjim inkrementima s jednostavnijim kodom kojeg svatko može mijenjati i ispravljati. Programiranje u paru donosi mogućnost ranog uočavanja grešaka i dijeljenje znanja, pri čemu je zadovoljstvo razvojnog tima veće. Projekti koji se ovom metodologijom provode su najčešće manji i jednostavniji s fokusom na brzoj isporuci, a ne kompleksnom dizajnu. Kao i kod Scruma, česta testiranja i povratne informacije od korisnika donose u svakoj iteraciji kvalitetniji i bolji proizvod, a time se postiže zadovoljstvo klijenata.

Najočitiji nedostatak Ekstremnog programiranja bila bi nemogućnost primjene ove metode na velike timove i projekte. Uz to se veže i nedovoljno dokumentiranje i praćenje prethodnog i budućeg rada. U većim bi sustavima zbog nedostatka dokumentacije moglo doći do konfuzije i neorganiziranosti. Osim toga, velika usmjerenost na kod a minimalna na dizajn nije u svakom slučaju idealna s obzirom na to da je dizajn vrlo važan pri izradi programskih rješenja.

3.6. Zajednička obilježja i potrebni postupci za sve metode

Bez obzira na to što se prethodno obrađene metode razlikuju kako po pristupu i načinu provođenja analize PS-a tako i po pristupu i načinu projektiranja i vođenja razvojnog ciklusa programske podrške kao osnove novog računalno podržanog IS-a, one uvijek polaze od razgovora s korisnicima o budućim podacima, funkcijama i postupcima u okviru sustava. Ovaj razgovor obavlja, kao uostalom i cijelu predstojeću analizu i projekt, analitičar sustava. Od dobro provedene analize zavisit će i uspjeh projektiranog IS-a. U slučajevima uvođenja računalno podržanih poslovanja u malim poduzećima, gdje se primjenjuju razna druga (često parcijalna) rješenja, vrlo važnu ulogu ima i kontakt između programera i korisnika koji će buduću aplikaciju koristiti u svom radu. Ako ova suradnja ne uspije, korisnik je nezadovoljan dobivenom uslugom (i završnim proizvodom) i često na kraju želi promijeniti i programsku podršku i dobavljača, što rezultira neplaniranim velikim troškovima, a osim toga izaziva kod korisnika sumnju u kompletnu računalnu i informacijsku tehnologiju (dugoročni problem).

U suvremenoj je praksi uočena nužna potreba za provođenjem sljedećih mjera i postupaka:

- ako se radi projektima uvođenja IS-a u velike poslovne sustave i ustanove koje posluju na ograničenom proračunu više je nego preporučljivo napraviti procjenu spremnosti organizacijskih, ljudskih, tehničkih, komunikacijskih i dr. čimbenika
- ono što navedene metode ne navode (ili možda implicitno podrazumijevaju), a praksa je pokazala kao nužno i neophodno, potreba je za edukacijom korisnika:
    - o razlozima uvođenja prije samog pokretanja projekta
    - o načinu upotrebe po uvođenju sustava u tzv. „produkcijsku fazu”

  - o novim funkcionalnostima u skladu s daljnjim razvojem IS-a

- prije pokretanja projekta obavezno treba izvršiti studiju izvodivosti projekta i ispitati spremnost populacije i poslovnog sustava (pogotovo kod velikih projekata) te zakonsku usklađenost budućeg IS-a s postojećim zakonskim okvirima
- ako se usvajaju strane norme, preporuke, dobra praksa i inicijative ili ako je izvođač projekta strana tvrtka, obavezno treba izvršiti lokalizaciju planiranog rješenja kako u semantičkom (potpuno jezično i pojmovno prevođenje) tako i u legislativnom (prilagodba zakona i propisa) smislu.

Neki od problematičnih primjera u novijoj hrvatskoj praksi:

- Prije uvođenja središnjeg zdravstvenog informacijskog sustava (CEZIH) nije provedena procjena spremnosti što je izazvalo niz problema u postupku implementacije, kao i veliko negodovanje korisnika u rasponu od protesta i ljutnje pa sve do odbijanja korištenja IS-a. U nekim slučajevima nije bilo ni izvedivo zbog nerazvijene komunikacijske mreže (nemoguće povezivanje ili prespora veza prema internetu). Prilikom procjene spremnosti utvrdilo bi se:
  - o u kojoj mjeri korisnici poznaju informacijsko-komunikacijsku tehnologiju
  - o u kojoj su mjeri educirani za rad na računalu
  - o imaju li u svojim ordinacijama već potrebnu računalnu opremu koja zadovoljava propisane specifikacije
  - o postoji li mogućnost spajanja na internet (žično ili bežično), i ako da, kolika je propusnost te veze
  - o zadovoljstvo korisnika s izgledom i mogućnostima novih klijentskih aplikacija i usvojile bi se eventualne preporuke za promjene i unaprjeđenja.

  Trebalo je isto tako izvršiti uvodnu edukaciju u kojoj bi se korisnicima objasnile sve razine očekivanih ciljeva kako bi shvatili širu sliku, a time bili motiviraniji za doprinos uspjehu IS-a.

- Prilikom pokušaja uvođenja jednog stranog dispečerskog informacijskog sustava u okviru Ministarstva unutarnjih poslova, prije svega nije provjerena funkcionalna primjenjivost u domaćem okruženju. Nije izvršena edukacija ni o svrsi uvođenja, ni o osnovnim scenarijima primjene i rukovanja. Programska podrška izbacivala bi poruke o pogreškama samo na stranom jeziku proizvođača. Na isporučenoj ispisnoj opremi upravljački paneli također bi ispisivali obavijesti na samo jednom stranom jeziku. Uslijed neuspjele koordinacije s proizvođačem (zasnovane na delegiranju neupućenih i nepripremljenih pregovarača na strani naručitelja) i neuspješnih pokušaja korištenja, cijeli je sustav napušten, a iskoristiva oprema prenamijenjena za korištenje u ostatku postojećeg složenog IS-a.

3.7. Analiza izvedivosti i troškova-koristi

Studija izvedivosti (engl. *feasibility study*) s uključenom analizom troškova-koristi (engl. *cost-benefit analysis*, CBA) predstavlja analizu i procjenu potencijala investicije te pomaže u procesu donošenja odluke o ostvarenju investicije i financijskoj uspješnosti. U obzir uzima sve koristi i nedostatke te prikazuje opravdanost realizacije velikih projekata u financijskom i ekonomskom smislu. Dio studije izvedivosti je i CBA analiza kojom se analiziraju i prezentiraju sve koristi i svi troškovi projekta, odnosno prikazuje se cjelokupan pozitivan i negativan utjecaj projekta u organizacijskom, financijskom, društvenom, gospodarskom te ekološkom smislu.

Analiza i izrada studije izvedivosti primjenjuje se dakle kod velikih projekata s mogućim većim rizikom uspjeha tijekom provođenja životnog ciklusa razvojnog projekta. Obuhvaća mjerenje korisnosti, praktičnosti i isplativosti projekta IS-a. Trebala bi se raditi tijekom planiranja, ali i kasnije (npr. nakon faze analize). Nakon odluke o pokretanju projekta složenost i opseg projekta mogu se promijeniti pa početno izvediv projekt može postati neizvediv a, praktično gledano, točnost procjene izvedivosti može rasti s dubinom analize. Praktično gledano, ova je analiza detaljna provjera projekata koju provode sistem analitičari. Procjenjuje se je li projekt izvediv s obzirom na raspoloživa sredstva i omogućuje li poboljšanja. O provedenim procjenama radi se izvješće o izvedivosti i prezentira se relevantnim sudionicima zbog komentara i mišljenja. Ova procjena može biti dio idejnog rješenja, a ponekad tako i izgleda. Ako se tijekom faza životnog ciklusa ukaže za to potreba, moguć je i eventualni povratak u studiju izvedivosti, što vodi u reviziju izvješća.

Osnovni elementi analize izvedivosti su:

- operativna izvedivost
- tehničko-tehnološka izvedivost
- vremenska izvedivost
- ekonomska izvedivost.

Operativna (organizacijska) izvedivost obuhvaća procjenu hitnosti rješavanja problema (planiranje) i procjenu prihvatljivosti rješenja (kasnije faze). Odgovora na pitanja: Vrijedi li rješavati problem? Rješava li predloženo rješenje problem? i pritom procjenjuje sljedeće pokazatelje:

- performance – protočnost i odziv sustava s obzirom na ulaze
- informacije – dovoljne, pravodobne, prikladne, ažurne, točne i korisne
- ekonomiju – problemi troškova, mogućnosti ušteda
- kontrolu – sigurnost i zaštita podataka
- učinkovitost – poboljšanje upotrebe raspoloživih resursa (ljudi, oprema, novac itd.)
- usluge – poželjni i pouzdani servisi, elastičnost i mogućnost prilagodbe i zadovoljstvo.

Isto tako treba odgovoriti na pitanja: Koji su stavovi korisnika o rješenju? Hoće li se sustav koristiti? Ova pitanja obuhvaćaju procjenu stupnja podrške uprave i prihvaćanje od krajnjih korisnika, tj. otpora njihovoj budućoj ulozi ili tehničkom rješenju te prijedloge kako ih prevladati. Uvođenje novog IS-a izaziva promjenu radnog okruženja i radnih procedura pa je potrebna prilagodba promjenama. Procjena upotrebljivosti vrši se najčešće na prototipu sustava i obuhvaća tri pokazatelja:

- krivulju učenja – vrijeme osposobljavanja potrebno za postizanje pune primjene
- lakoću korištenja – jednostavno sučelje za početnike i povremene korisnike, a složenije operacije za iskusne korisnike
- zadovoljstvo – ponuđenom rješenju korisnik daje prednost pred postojećim.

Tehničko-tehnološka izvedivost odgovora na pitanja: Može li se sagraditi? Može li se kupiti? U okviru ovog elementa izvedivosti nastoje se procijeniti četiri pokazatelja:

Procjena mogućih rješenja i alternativa − daje procjenu stanja na tržištu opreme, procjenu postojećih rješenja u drugim organizacijama (tamo gdje je moguće) i procjenu primjenjivosti različitih tehnologija

Primjenjivost rješenja ili tehnologije − daje procjenu u smislu jednostavne primjenjivosti tehnologije. Pojedine sredine zagovaraju najsuvremeniju tehnologiju (engl. *state-of-the-art*), naprednost i zanimljivost. Međutim, većina je sklona zreloj i dokazanoj tehnologiji koja pruža veću sigurnost i bolju podršku.

Raspoloživost tehnologije − bavi se mogućnostima nabave tehnologija, pri čemu se podrazumijeva da je primjenjiva. Ako je riječ o gotovom rješenju (IS iz „dućana"), daje procjenu ima li to rješenje potrebne karakteristike i treba li ga i u kojoj mjeri prilagoditi ili doraditi.

Stručnost − pruža procjenu postoji li u okviru projekta potrebna stručnost za primjenu predviđene tehnologije. Bez obzira što se npr. radi o najnovijoj tehnologiji, treba imati u vidu da se i najnovija tehnologija može svladati. Procjenjuje se također postoji li potrebna vještina za očekivani završetak prema planu i rasporedu aktivnosti, jer je bitno da se usvajanje tehnologije i njezina primjena završe na vrijeme.

Vremenska izvedivost odgovora na pitanja: Kada će biti gotovo? Može li biti gotovo na vrijeme? Kroz prihvatljivost vremenskog rasporeda razmatra se opravdanost rokova s obzirom na raspoloživu stručnost. Očekivano vrijeme završetka može biti poželjno ili obvezno. Ako su rokovi čvrsti, nesigurni (u smislu termina završetka) projekt treba prekinuti ili odgoditi. Ako se radi o tzv. poželjnim rokovima, može se predložiti alternativni vremenski plan. U svakom slučaju, bolje je isporučiti ispravan sustav dva mjeseca kasnije nego neispravan ili beskoristan na vrijeme.

Ekonomska izvedivost odgovora na pitanja: Isplati li se graditi? Treba li graditi? Procjenjuju se tri ključna pokazatelja: trošak razvoja sustava, trošak primjene sustava te analiza (i usporedba) ukupnih troškova-koristi.

Trošak razvoja sustava (fiksni trošak) prikazuje apsolutni iznos, početnu procjenu i ažuriranja tijekom napretka projekta. Primjer ovih troškova su: plaće i honorari osoblja, trošak opreme procijenjen nakon odabira tehničkog rješenja, troškovi izobrazbe i sl.

Trošak primjene sustava (varijabilni trošak) je relativan iznos, ovisan o upotrebi. Primjeri ovih troškova su npr. režije (struja, telefon), održavanje (ljudski rad) i obnova licenci.

Analiza i usporedba ukupnih troškova-koristi (CBA) nastoji dati procjenu isplativosti i potreba gradnje IS-a. Troškovi i korist mogu biti mjerljivi i nemjerljivi. Mjerljivi su npr. cijena opreme, iznos plaća, prodaja i prihod. Nemjerljivi su npr. zadovoljstvo korisnika, brzina odlučivanja i dobra referenca. Financijski trošak i korist mogu se izraziti formulama:

- razlika korist-trošak u nekom razdoblju (engl. *Net Present Value*)
- povrat investicije (korist-trošak)/trošak (engl. *Internal Rate of Return*)
- trenutak u kojem korist nadvlada trošak (engl. *Payback Point*).

Na slici 3.19. prikazan je primjer jedne CBA analize dan tablično i grafički.

Trošak / Korist	Godina 0	Godina 1	Godina 2	Godina 3	Godina 4	Godina 5	Godina 6
Trošak razvoja	(418,040 $)						
Primjena i održavanje		(15,045 $)	(16,000 $)	(17,000 $)	(18,000 $)	(19,000 $)	(20,000 $)
Faktor za kamatu 12%	1.000	0.893	0.797	0.712	0.636	0.567	0.507
Trenutna vrijednost	(418,040 $)	(13,435 $)	(12,752 $)	(12,104 $)	(11,448 $)	(10,773 $)	(10,140 $)
Kumulativni trošak	(418,040 $)	(431,475 $)	(444,227 $)	(456,331 $)	(467,779 $)	(478,552 $)	(488,692 $)
Korist od novog IS	0 $	150,000 $	170,000 $	190,000 $	210,000 $	230,000 $	250,000 $
Faktor za kamatu 12%	1.00	0.893	0.797	0.712	0.636	0.567	0.507
Trenutna vrijednost	0 $	133,950 $	135,490 $	135,280 $	133,560 $	130,410 $	126,750 $
Kumulativna korist	0 $	133,950 $	269,440 $	404,720 $	538,280 $	668,690 $	795,440 $
	0	1	2	3	4	5	6
Ukupno	(418,040 $)	(297,525 $)	(174,787 $)	(51,611 $)	70,501 $	190,138 $	306,748 $

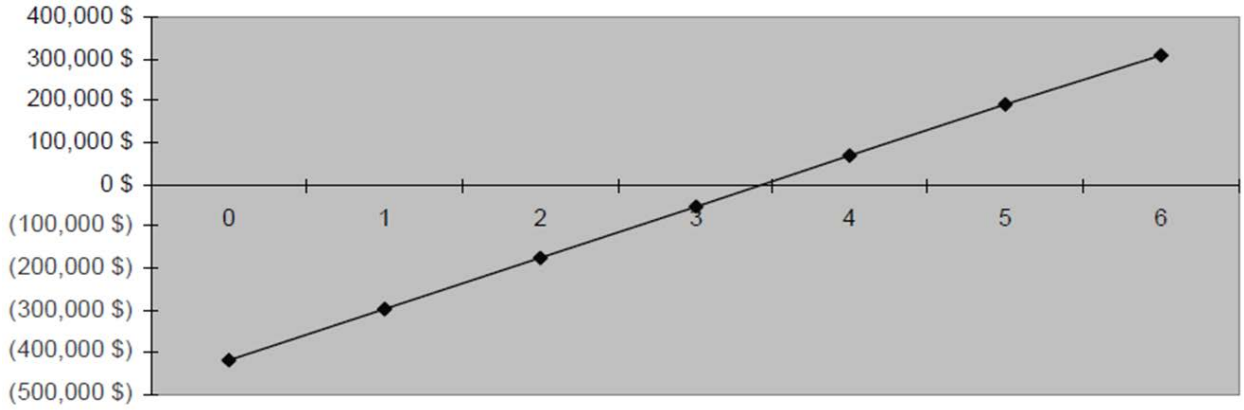

Slika 3.19. Prikaz jedne CBA analize (Fertalj i Kalpić, 2006)

CBA računa troškove i korist projekta kao trenutnu vrijednost (engl. *Present Value*, PV) pri čemu oznaka $ označava novčanu jedinicu u bilo kojoj valuti. Današnja vrijednost onoga što će postati $1.00 nakon 'n' godina u budućnosti, ako uzmemo u obzir kamate 'I', iznosi:

$$PV = 1/(1 + I)^n = (1 + I)^{-n}$$

Razlika predstavlja kamatu koja se može zaraditi tim novcem. Na primjer:

− troškovi razvoja od $100.000 imaju trenutnu vrijednost od $100.000
− korist projekta u iznosu od $30.000 za pet godina uz kamatnu stopu od 8 % ima trenutnu vrijednost od samo:

$$\$30.000 / (1 + 0.08)5 = \$20.417$$

Povrat investicije (engl. *Return On Investment*, ROI) daje postotak povrata investicije, odnosno postotak relativnog iznosa koristi projekta:

$$ROI = (\text{ukupna korist} – \text{ukupan trošak}) / (\text{ukupan trošak})$$

ROI se obično dijeli s dužinom projekta kako bi se dobio godišnji ROI. Nizak ROI (~ manji od 10 % godišnje) može pokazivati da je korist preniska da bi bila isplativa.

Na slici 3.19. vidimo da se kumulativni trošak nakon 3,5 godina izjednačio s kumulativnom koristi koja je nakon toga sve veća. Negativne vrijednosti (troškovi) prikazane su u zagradama (Fertalj i Kalpić, 2006).

3.8. Uspješnost projekata izgradnje informacijskih sustava

Kroz povijest razvoja informacijskih sustava neuspješni ishodi projekata nisu bili rijedak slučaj. Općenito su najčešći razlozi za to bili:

- složenost aplikacija
- nedostatak usmjerenosti korisniku
- zanemarivanje okruženja organizacije
- pretjerani optimizam
- izostanak praćenja napretka
- nedostatak komunikacije između korisnika i izvođača.

U Hrvatskoj se uglavnom nisu istraživali, a informacije o neuspješnim projektima nerado su se objavljivale. Autori jedne od domaćih studija Kalpić, Fertalj i Mornar (2001) utvrdili su da su najčešći uzroci neuspjelih projekata kod nas:

- loša organizacija i vođenje projekata:
    - oslonac na vanjske voditelje i savjetnike, delegirano upravljanje projektima, nerealno planiranje, formalno izvještavanje o napretku, formalni nadzor nad projektom te podcijenjena uloga vlastitih stručnjaka.

- loša izvedba projekata:
    - neodgovarajuća analiza sustava, pogreške u dizajnu i kontroli kvalitete, neodgovarajuća CASE pomagala i krivo korištenje, pa čak i svojevrsna zloporaba CASE pomagala.

Treba naglasiti da su mnogi sustavi propali ili su bili odbačeni jer su izvođači pokušavali napraviti lijepa programska rješenja, a nisu razumjeli suštinu organizacije i poslovanja.

Promašaji i pogreške događaju se i u naprednim zemljama. Neki od primjera pogrešaka kako u PIS-ima tako i u nadzorno-upravljačkim sustavima su:

London Ambulance System (1992):

- Sustav se nakon uvođenja dva puta „raspao” radi niza pogrešaka, naročito onih zbog upravljanja. Neposredni trošak bio je relativno nizak (£9 mil.), ali se vjeruje da su neki ljudi umrli jer se do njih nije stiglo na vrijeme.

Taurus (1993):

- Projekt sustava automatiziranih transakcija Londonske burze prekinut je nakon pet godina razvoja i troška od £75 mil. te posljedičnog gubitka klijenata od £450 mil. Ukupni se gubici nisu mogli izračunati.

Denver Airport (1994):

- Nepouzdanost softvera za upravljanje prtljagom uzrokovala je odgodu otvaranja zračne luke u trajanju od 16 mjeseci uz troškove od 1.1 mil. $/dan.

Ariane 5 (1996):

- U lanseru je eksplodirala raketa radi niza pogrešaka u programskoj podršci.

Neki od primjera pogrešaka vezanih za nadzorne i upravljačke sustave su i:

- Challenger (*space shuttle*) − niz pogrešaka u dizajnu
- *Teleskop Hubble* − pogreške u dizajnu i propusti u testiranju
- *Mars Climate Orbiter* (satelit) − problem navigacije zbog raskoraka između engleskog i metričkog mjernog sustava.

Konzultantska tvrtka The Standish group (http://www.standishgroup.com) provodila je istraživanja o uspješnosti realizacije IS-a u svijetu početkom 90-ih i od 2000. godine.
Rezultati istraživanja 1994. godine prikazani su u izvješću *The CHAOS Report*:

- Prosječni trošak projekta:
  - velike kompanije: 2,32 M$
  - srednje kompanije: 1,33 M$
  - male kompanije: 434 K$
- Prosječno prekoračenje troškova: 189 %
- Prosječno prekoračenje rokova: 222 %
- Projekti završeni na vrijeme, u okviru predviđenih sredstava, sa svim predviđenim funkcijama: 16,2 %
- Projekti završeni i u funkciji, ali uz veće troškove, dulje trajanje i/ili reduciranu funkcionalnost: 52,7 %
- Prekinuti projekti: 31,1 %.

Rezultati istraživanja provedenog 2002. godine pokazali su znatno bolje rezultate:

- 34 % potpuno uspjelih projekata
- 17 % potpuno neuspjelih projekata

Ovo udvostručenje uspješnih i prepolovljen broj potpuno neuspjelih projekata unutar jedne dekade svakako treba pripisati napretku razvojne metodologije, iskustava i usvojene dobre prakse.

Što u okviru razvojnih projekata treba izbjeći?

Slika 3.20. prikazuje *Tradicionalnu priču o razvoju* koja kroz karikaturu prikazuje životni ciklus jednog projekta od zahtjeva korisnika do završnog proizvoda.

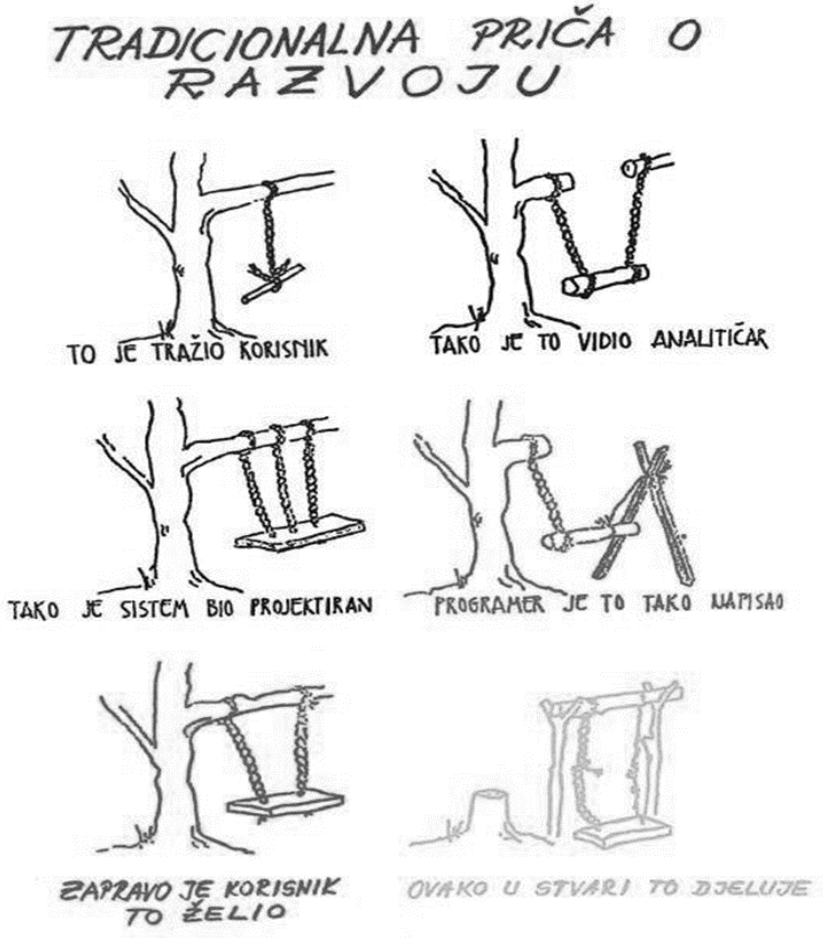

Slika 3.20. *Tradicionalna priča o razvoju* (Fertalj& Kalpić prema: Awad, 1985)

Kako bi se izbjegli ključni razlozi neuspjeha treba se pridržavati sljedećih preporuka za provođenje analize PS-a:

- tehnike i pomagala ne znače puno bez ispravnog pristupa:
  - postupak analize mora biti prilagođen korisniku
  - ključno je razumjeti suštinu organizacije i način poslovanja.
- ono što korisnik želi često nije i ono što korisnik stvarno treba:
  - da se priča o klasičnom razvoju ne bi ponavljala rade se modeli sustava (postojeći fizički i logički, budući logički itd.).
- treba izbjegavati „paralizu" analize:
  - postupak ponavljanog modeliranja postojećeg sustava i vrednovanja modela može utrošiti značajno vrijeme na modeliranje nečega što će vjerojatno biti izmijenjeno ili zamijenjeno.
- ne pretjerivati s modeliranjem postojećeg sustava! (Fertalj i Kalpić, 2006).

Na sadržaj

4. MODELIRANJE INFORMACIJSKOG SUSTAVA

U prošlom poglavlju istaknuto je da je modeliranje ključni postupak u projektiranju IS-a. Naveden je niz elemenata stvarnog sustava koji možemo modelirati u skladu s primijenjenom metodologijom projektiranja. U nastavku ćemo obraditi osnove funkcionalnog modeliranja (modeliranja procesa) i modeliranja podataka.

4.1. Modeliranje procesa

Na slici 4.1. prikazan je primjer funkcionalnog modeliranja procesa (postupka) „Upis". Ovaj model procesa slijedi scenarij prema kojemu student u okviru ulaznih tokova prikuplja potrebnu dokumentaciju s kojom pristupa unutarnjim tokovima procesa pri čemu se provjerava kompletnost dokumentacije. Ako ona nije kompletna, vraća se studentu na dopunu (nakon dopune se postupak ponavlja). Ako je dokumentacija kompletna, provodi se postupak upisa koji rezultira dvama unutarnjim postupcima (upis studenta u evidencije i objava na oglasnoj ploči) i jednim izlaznim tokom (uručenje indeksa). No kako student ne može bilo kada doći na upis, potreban je i neki model događaja koji će inicirati proces. U praksi je taj događaj oglas o početku i trajanju upisnog roka. Isto tako, mora postojati i neki model izvršitelja koji će biti zaduženi za provođenje procesa upisa. U ovom su slučaju to studenti, službenice studentske referade i tajništvo. U ovom je modelu, pored funkcionalnog modela, dodan i element modela događaja, kao i element modela izvršitelja, odnosno modela resursa koji obuhvaća izvršitelje unutar IS-a.

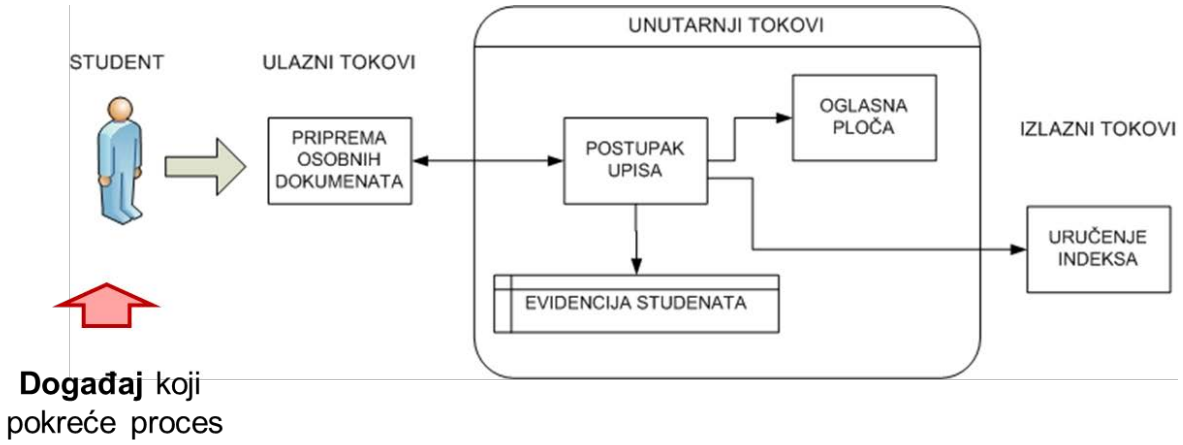

Slika 4.1. Model procesa „Upis" (izvor: autor)

Na slici 4.2. dan je primjer funkcionalnog modeliranja postupka „Upis" primjenom dijagrama toka podataka (DTP). Dijagram toka podataka (engl. *Data Flow Diagram*, DFD) je grafički način prikaza toka podataka kroz sustav od izvorišta do odredišta kroz praćenje procesa koji te podatke transformiraju. Primjenjuju se pritom standardni grafički oblici − simboli.

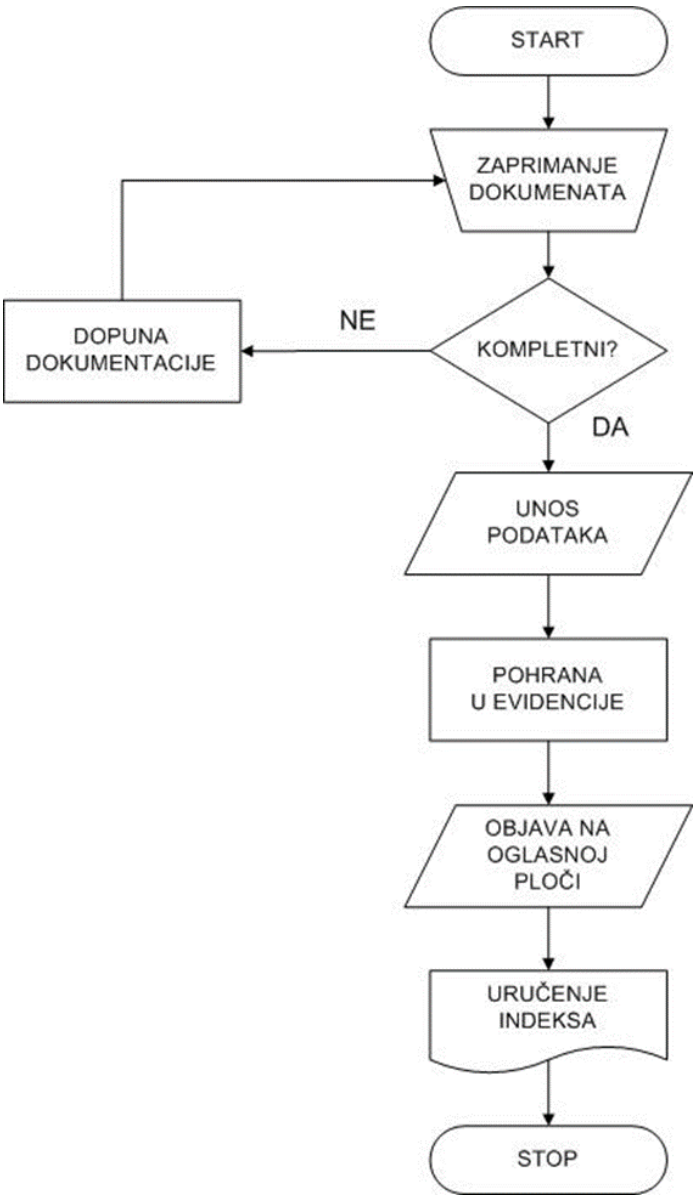

Slika 4.2. Dijagram toka podataka za proces „Upis” (izvor: autor)

Funkcionalno modeliranja procesa „Upis” može se izvršiti i primjenom tzv. pseudokoda, tj. jednostavnim rječnikom zapisanih postupaka:

```
start
zaprimi dokumente
provjeri kompletnost:
   ako su nepotpuni vrati na dopunu
   ako su potpuni idi dalje
unesi podatke u evidenciju
pohrani matične podatke
objavi na oglasnoj ploči
uruči studentu indeks
stop
```

Iz ovih se dvaju modela već nazire organizacija i logička struktura budućeg programskog koda, no oni još nisu funkcionalni modeli toka programa jer im nedostaju modeli događaja (vremena izvršavanja) i resursa (npr. izvršitelji i njihove ovlasti) (Strahonja, Varga i Pavlić, 1992).

4.2. Modeliranje podataka

Postupak i razine modeliranja podataka načelno su prikazane na slici 4.3.

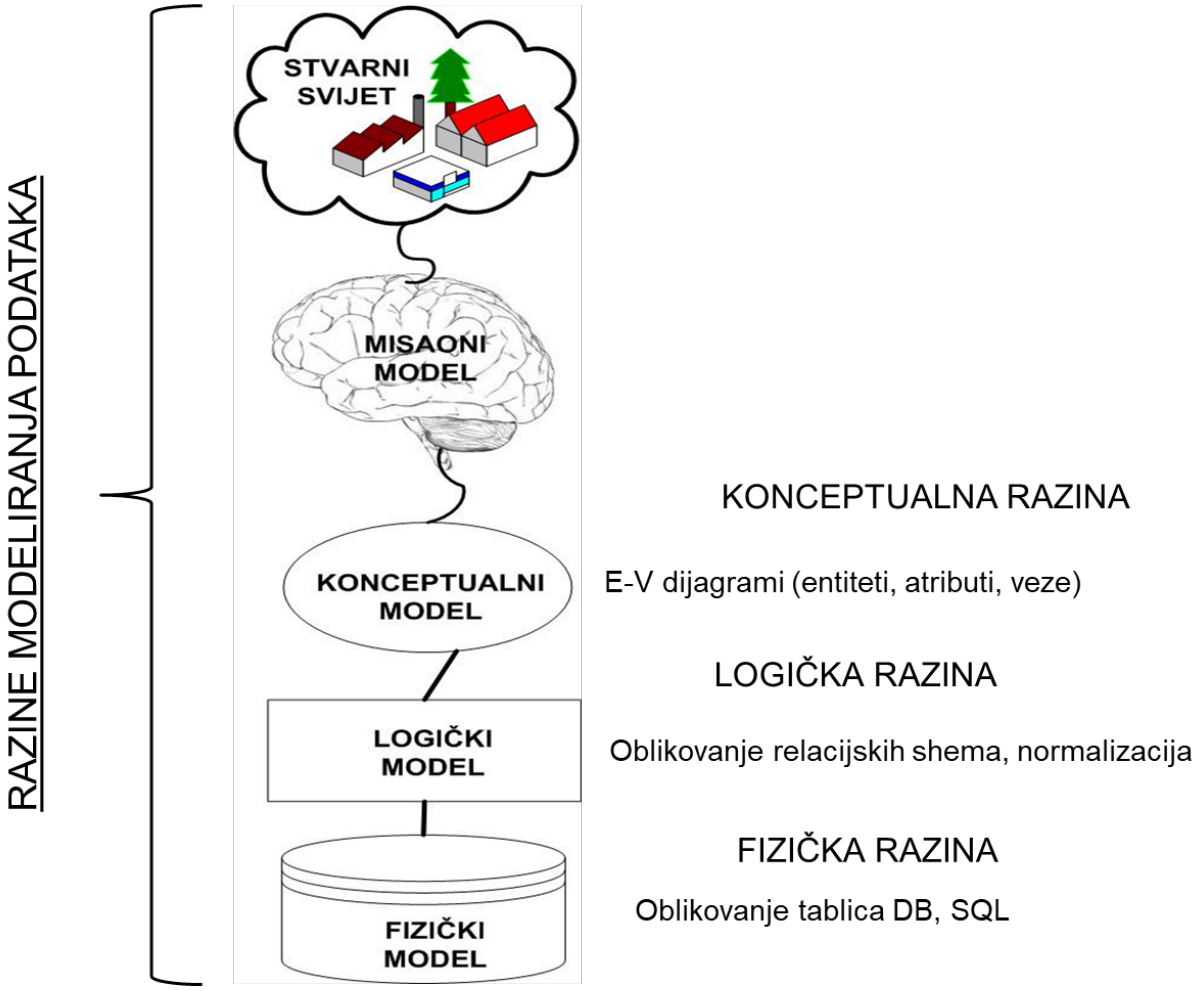

Slika 4.3. Razine modeliranja podataka (izvor: autor)

Osnovna opća metoda modeliranja podataka je **apstrakcija**, odnosno zanemarivanje svojstava nekog objekta promatranja koji nisu bitni za svrhu objekta u promatranom kontekstu.

Klasifikacija je vrsta apstrakcije kod koje se apstraktni ili stvarni objekti identificiraju, opisuju i grupiraju u klase (tipove) prema zajedničkim svojstvima.

Sve **pojave objekata** unutar klase imaju jednake tipove atributa (obilježja), ali se atributi pojedinih pojava objekata mogu razlikovati po vrijednosti (npr. unutar objekta OSOBA postoje pojave objekta „24375, Ivo Ivić" i „25678, Pero Perić").

Generalizacija je apstrakcija kod koje se uspostavlja veza između više klasa objekata niže razine (podklasa, podtipova) s klasom više razine tzv. superklasom (nadtipom).

Specijalizacija je metoda suprotna generalizaciji, tj. obuhvaća klasifikaciju od najviše razine prema najnižoj (OSOBA → STUDENT → „24375, Ivo Ivić").

Niže razine klasa imaju više posebnih svojstava, npr. na najnižoj razini zajedničkih svojstava imamo pojavu stvarnog objekta: „24375, Ivo Ivić". Postupak i smjer generalizacije i specijalizacije prikazan je na slici 4.4.

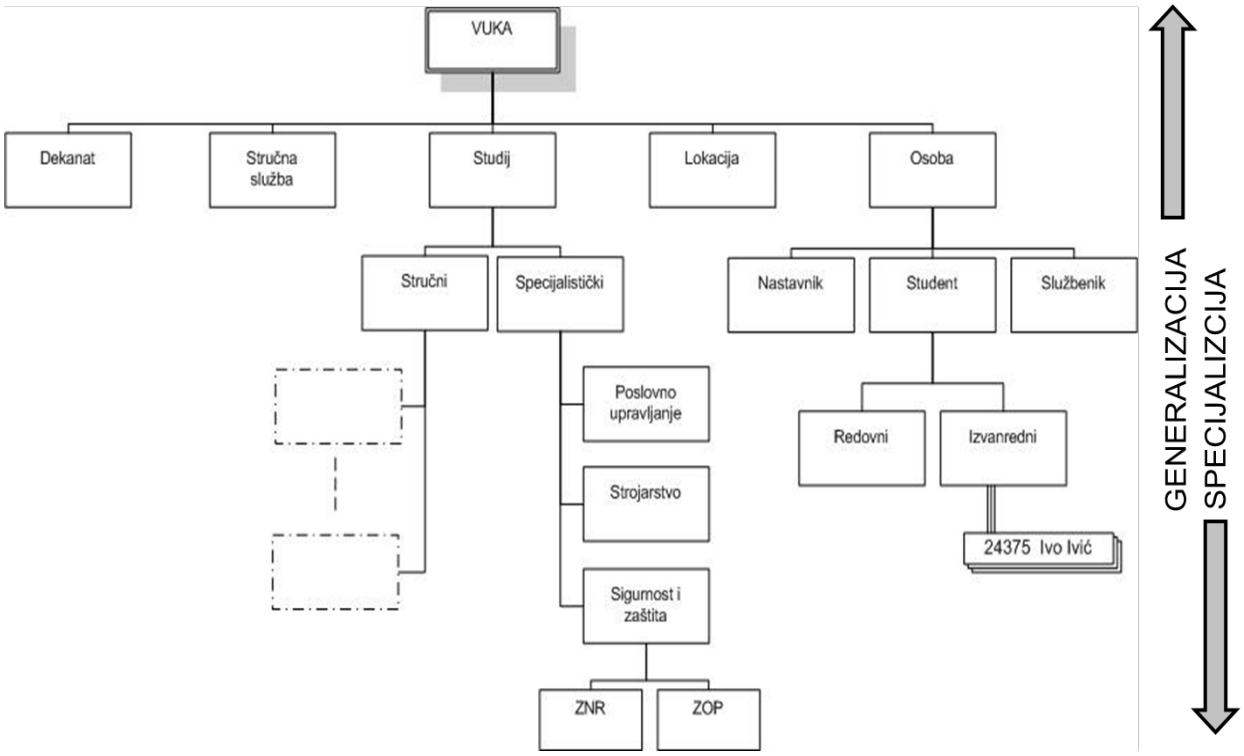

Slika 4.4. Primjer klasifikacije objekata (izvor: autor)

Tijekom modeliranja podataka često vršimo **kompoziciju**, tj. logičko združivanje različitih klasa objekata u novi objekt složene strukture (kompozitni objekt) pri čemu pojedini dijelovi glavnog objekta ne mogu postojati bez njega (drvo − lišće, tipkovnica − tipke, visoko učilište − studij i sl.). Ovisno o stvarnoj situaciji, prilikom modeliranja odredit će se do koje je razine potrebno ići sa specijalizacijom (podjelom na podklase), tj. trebat će se utvrditi jesu li dijelovi kompozicije interesantni za daljnju obradu (podklase) ili nisu (predstaviti ih samo kao dodatne atribute).

Agregacija je „labavija" veza od kompozicije, tj. obuhvaća povezivanja različitih klasa objekata koji mogu ali i ne moraju biti povezani (npr. računalo − periferija i sl.), no njihovo povezivanje dodaje dodatne elemente opisa nekog osnovnog objekta.

Postupkom apstrakcije ustanovi se postojanje ključnih klasa objekata koji se dalje reprezentiraju **entitetima** kao konkretnim pojavama koje se mogu opisati podacima.

Međusobni odnosi entiteta prikazuju se modelom entiteti − veze (EV). Ovakav prikaz entiteta i njihovih međusobnih veza predstavlja **konceptualni model** podataka unutar nekog IS-a.

Što su entiteti? Što može biti entitet?

Primjeri tipova entiteta:

- ljudi (njihove uloge):
  - OSOBA – skup svih osoba
  - DJELATNIK – skup svih zaposlenika tvrtke
  - STUDENT – skup svih studenata nekog fakulteta

- subjekti poslovanja:
    - TVRTKA – skup svih tvrtki
    - AGENCIJA – skup agencijskih tvrtki
    - POSLOVNI PARTNER – skup svih kupaca, dobavljača, agencija i sl.
    - KUPAC – skup fizičkih ili pravnih osoba koje kupuju robu.
- stvari i fizički objekti (materijalni predmeti):
    - MATERIJAL – skup materijala koji se koriste u proizvodnji
    - ZGRADA – skup zgrada u poduzeću ili tvrtki
    - REZERVNI DIO – skup rezervnih dijelova strojeva
    - STROJ – skup strojeva
    - NOSITELJ INFORMACIJA – skup dokumenata, medija za pohranu i sl.
- predmeti poslovanja:
    - PROJEKT – skup projekata neke tvrtke ili ustanove
    - USLUGA – skup usluga koje tvrtka pruža
    - PROIZVOD – skup proizvoda koje tvrtka proizvodi ili prodaje.
- apstraktni (nematerijalni) koncepti:
    - LINIJA – skup zrakoplovnih ili autobusnih linija
    - CILJ – skup ciljeva tvrtke
    - PRAVILNIK – skup primjenjivanih pravila u poslovanju ili postupanju
    - POPIS ZAKONA – skup svih primjenjivanih zakonskih odredbi.
- mjesta (geografska mjesta ili druga područja):
    - GRAD – skup gradova
    - LOKACIJA – skup lokacija objekata tvrtke ili ustanove.
- poslovni događaji (transakcije):
    - UGOVOR – skup ugovora vezanih uz poslovni proces
    - POTVRDA – skup izdanih potvrda, npr. dopusnica za rad
    - NARUDŽBA – skup narudžbi za proizvode ili usluge.

Svaki tip entiteta mora biti prepoznatljiv, tj. mora se omogućiti prepoznavanje (identifikacija) pojedinih članova (pojava) u skupu entiteta koji pripadaju istom tipu entiteta. Identifikacija entiteta postiže se pomoću atributa (obilježja, svojstva) odnosno podatka koji identificira, klasificira, kvantificira te izražava kvalitetu ili stanje entiteta.

U tom smislu atributi općenito mogu biti:

- identifikacijski – trajno pridruženi entitetu, jednoznačni i nedvosmisleni
- opisni – kvalitativna i kvantitativna svojstva koja su promjenjiva
- izvedeni – vrijednosti im se izvode aritmetičkim ili logičkim operacijama iz definiranih vrijednosti drugih atributa (formule, algoritmi i logički izrazi za izvođenje vrijednosti također su dio specifikacija modela podataka).

Vrijednosti atributa mogu biti ograničene domenom vrijednosti, npr. atribut BROJ SJEDIŠTA entiteta AUTOBUS ima domenu vrijednosti od 3 do 63 (Strahonja, Varga i Pavlić, 1992).

O entitetu možemo razmišljati kao o skupu atributa koji ga opisuju, ali kao o skupu konkretnih pojava entiteta, tzv. n-torkama, opisanih svojstvima atributa. Ova će se predodžba lakše shvatiti kada će se kasnije govoriti o relacijskim bazama podataka. U tom se kontekstu može reći da entitet ima svoju **intenziju** i **ekstenziju**. Intenzija je naziv tipa entiteta i opis tipa entiteta u obliku popisa njegovih atributa, pa tako npr. OSOBA ima tipove atributa: Matični broj, Ime i Adresu. Ekstenzija entiteta je skup pojava entiteta predstavljenih stvarnim vrijednostima atributa, tj. ekstenziju

predstavljaju sami podaci o pojavama entiteta. Slika 4.5. prikazuje opis entiteta STUDENT predočen tablicom podataka.

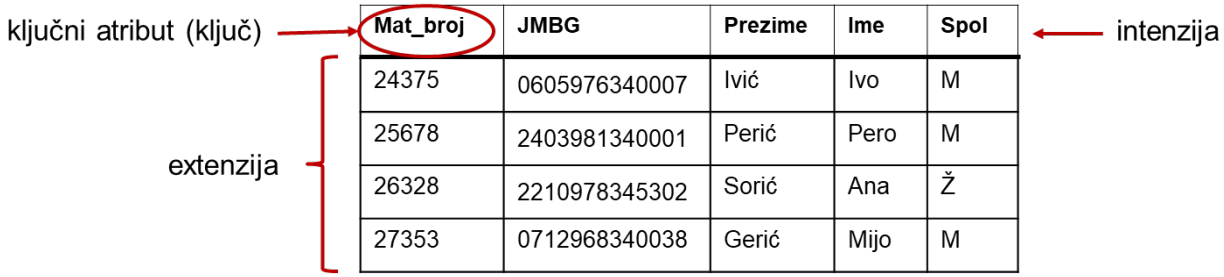

Mat_broj	JMBG	Prezime	Ime	Spol
24375	0605976340007	Ivić	Ivo	M
25678	2403981340001	Perić	Pero	M
26328	2210978345302	Sorić	Ana	Ž
27353	0712968340038	Gerić	Mijo	M

Slika 4.5. Entitet STUDENT predočen tablicom podataka (izvor: autor)

U stvarnosti su dakle entiteti predstavljeni nekim **n** brojem atributima (intenzijom) i nekim **m** brojem n-torki koje svojim svojstvima i vrijednostima opisuju entitet (ekstenzijom). Intenzija u praktičnom razvoju IS-a, odnosno baza podataka, predstavlja „kodeks atributa" ili strukturu tablice. Kodeks atributa osim naziva atributa (naziva stupaca tablice ili polja retka n-torke) sadrži i podatke o vrsti i formatu podataka (metapodatke). Slika 4.6. prikazuje kodeks atributa za entitet STUDENT predočen na slici 4.5.

Redni broj	Naziv atributa	Opis	Vrsta polja	Širina polja	Ograničenja
1	Mat_br	ID studenta	Cijeli broj	N5.0	1 - 99999
2	JMBG	MBR građana	Tekst	C13	provjera po kontrolnom broju
3	Prezime	Prezime stud.	Tekst	C25	obavezno
4	Ime	Ime studenta	Tekst	C25	obavezno
5	Spol	M - muški Ž - ženski	Tekst	C1	Obavezno M/Ž

Slika 4.6. Kodeks atributa za entitet STUDENT (izvor: autor)

4.2.1. Konceptualno modeliranje podataka

Ova razina modeliranja podataka obuhvaća prepoznavanje entiteta koji čine logičku interpretaciju stvarnih objekata (stvarnih ili apstraktnih predmeta, osoba, događaja) u stvarnom svijetu, odnosno nekom poslovnom sustavu. Kao što smo već prethodno analizirali, potrebno je odabrati neophodni (optimalni) skup atributa koji te entitete opisuju te prepoznati veze koje se između tih entiteta ostvaruju u skladu s funkcionalnim modelom IS-a. Ove veze između entiteta prikazuju se dijagramom entiteti − veze (EV). Često u praksi susrećemo i engleski naziv za ove dijagrame *entity-relationship diagram* (ERD). Postoji više standarda za oblikovanje simbola kojima se prikazuju entiteti i njihove međusobne veze. Najčešće su korišteni Chenovi i Martinovi dijagrami. Peter Chen je bio pionir u ovom području. Utemeljio je i razvio EV modeliranje i prvi put opisao ovu koncepciju modeliranja IS-a u svom radu objavljenom 1976. godine. Ovaj se standard smatra vrlo detaljnim načinom opisa entiteta i veza te se i danas često koristi. James Martin, britanski informatički konzultant, predstavio je istovremeno drugačiju notaciju entiteta i veza kao rafiniranu verziju zasnovanu na prijedlozima notacija nekih drugih teoretičara i projektanata IS-a. Osnovna razlika u ovim pristupima je ta što Chen uvodi vezu između entiteta kao poseban simbol, odnosno objekt koji po potrebi može imati svoje atribute, dok prema Martinu

veze ne mogu imati atribute, već se između dva postojeća entiteta, ako je potrebno posebno opisati svojstva veze, ubacuje novi koji opisuje ta svojstva svojim atributima. Kako bi se lakše shvatile navedene notacije, potrebno je prvo objasniti što su **funkcionalnost** veze, **obveznost** članstva i **kardinalnost** veze. Četiri vrste funkcionalnosti veza prikazane su u tablici 4.1.

Tablica 4.1. Vrste funkcionalnosti za vezu između tipova entiteta E1 i E2 (Manger, 2010)

OZNAKA	NAZIV	OPIS
1:1	Jedan-naprama-jedan	Jedan primjerak od E1 može biti povezan najviše s jednim primjerkom od E2. Isto tako, jedan primjerak od E2 može biti povezan najviše s jednim primjerkom od E1.
1:M	Jedan-naprama-mnogo	Jedan primjerak od E1 može biti povezan s više primjeraka od E2. Istovremeno, jedan primjerak od E2 može biti povezan najviše s jednim primjerkom od E1.
M:1	Mnogo-naprama-jedan	Jedan primjerak od E1 može biti povezan najviše s jednim primjerkom od E2. Istovremeno, jedan primjerak od E2 može biti povezan s više primjeraka od E1.
M:M	Mnogo-naprama-mnogo	Jedan primjerak od E1 može biti povezan s više primjeraka od E2. Isto tako, jedan primjerak od E2 može biti povezan s više primjeraka od E1.

Ako ove veze između entiteta predstavimo kao veze između elemenata skupova E1 i E2, a funkcionalnost veze kao 1 : M (jedan naprama mnogo), tada ako uvedemo pravilo da element skupa E1 mora biti povezan s minimalno jednim ili više elemenata skupa E2, govorimo o obveznom članstvu elemenata E1 u skupu E2. Ako elementi E1 ne moraju nužno biti povezani s elementima E2, članstvo nije obvezno. Svojstva funkcionalnosti i obveznosti članstva mogu se otprilike izraziti samo jednim svojstvom koje se zove kardinalnost. Dalje se promatra veza između tipova entiteta E1 i E2. Kardinalnost te veze u smjeru od E1 do E2 definira se kao broj primjeraka od E2 koji istovremeno mogu biti povezani s odabranim primjerkom od E1. Kardinalnost u smjeru od E2 do E1 definira se analogno. To znači da se za svaku vezu utvrđuju dvije kardinalnosti, i za jedan i za drugi smjer. Kako kardinalnost u općem slučaju nije moguće sasvim točno izraziti, umjesto točnog broja navodi se interval u obliku donje i gornje granice. Dvije se granice označavaju oznakama 0, 1 ili M i odvajaju se zarezom. Uobičajene oznake kardinalnosti prikazane su i opisane u tablici 4.2.

Tablica 4.2. Kardinalnost veze promatrane u smjeru od tipa entiteta E1 do tipa E2 (Manger, 2010)

OZNAKA	OPIS
0,1	Jedan primjerak od E1 može biti povezan s nijednim ili najviše s jednim primjerkom od E2.
1,1	Jedan primjerak od E1 mora biti povezan s točno jednim primjerkom od E2.
0,M	Jedan primjerak od E1 može biti povezan s nijednim, s jednim ili s više primjeraka od E2.
1,M	Jedan primjerak od E1 mora biti povezan s najmanje jednim, no možda i s više primjeraka od E2.

Kao primjer označavanja kardinalnosti uzmimo da veza označena kao „JE PROČELNIK”, promatrana u smjeru od entiteta „NASTAVNIK” prema entitetu „ODJEL”, ima kardinalnost 0,1 jer netko od nastavnika može biti pročelnik pojedinog odjela. Kardinalnost iste veze promatrane u suprotnom smjeru je 1,1 jer odjelu mora biti pridružen jedan od nastavnika u svojstvu pročelnika.

Veza „UPISAO” u smjeru od „PREDMET” do „STUDENT” ima kardinalnost 0,M jer dopuštamo da neki predmeti ostanu neupisani. No mogli bismo zahtijevati da kardinalnost iste veze u suprotnom smjeru bude 1,M čime od svakog studenta zahtijevamo da upiše bar jedan predmet. Ovaj je slučaj prikazan vezama između skupova na slici 4.7.

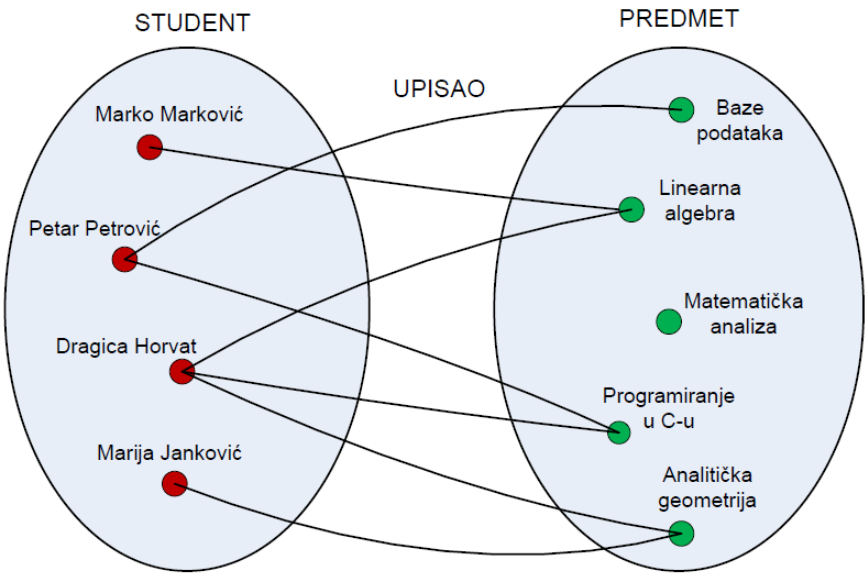

Slika 4.7. Prikaz stanja veza između skupova (entiteta) (Manger 2010)

Tablica 4.3. usporedno prikazuje oznake kardinalnosti za Chenove i Martinove EV dijagrame. Prema Martinovoj oznaci za vezu s više članova skupa (entiteta) ovi se dijagrami nazivaju „vranino stopalo” ili „ptičje stopalo” (engl. *crow's foot notation*).

Tablica 4.3. Oznake kardinalnosti za Chenove i Martinove EV dijagrame (izvor: autor)

Chen	Martin	Opis
0,M	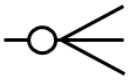	Svaki član E1 povezan je sa 0, 1 ili više članova E2
1,M	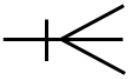	Svaki član E1 povezan je sa 1 ili više članova E2
0,1	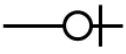	Svaki član E1 povezan je sa 0 ili 1 članom E2
1,1	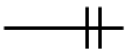	Svaki član E1 povezan je sa 1 i samo 1 članom E2

Na slici 4.8. prikazana je pod a) Chenova, a pod b) Martinova notacija EV dijagrama koja prikazuje stanje veza skupova prikazanih na slici 4.7.

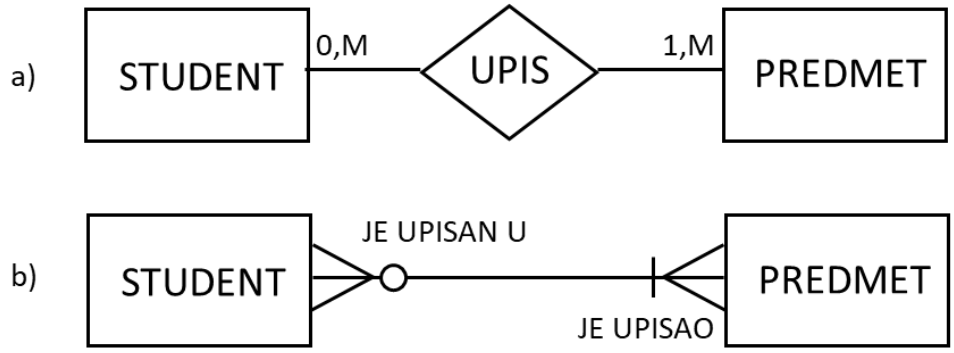

Slika 4.8. Primjeri EV dijagrama po Chenovoj (a) i Martinovoj (b) notaciji (izvor: autor)

Chenov dijagram prikazan na slici 4.8. naziva se reducirani Chenov dijagram. To je pojednostavljena vrsta izvornog Chenova dijagrama, gdje su zbog bolje preglednosti nacrtani samo pravokutnici (entiteti), rombovi (veze) i spojnice među njima, a izbačeni su tzv. „mjehurići" (atributi). Na dijagramu su prisutna imena entiteta i veza te oznake kardinalnosti veza. Nedostatak informacije o atributima na dijagramu nadomješta se tekstom uz dijagram. Slika 4.9. prikazuje izvorni Chenov dijagram. Kao grafički elementi pojavljuju se pravokutnici, rombovi i spojnice među njima, ali i „mjehurići" s nazivima atributa. U dijagram su i dalje kao tekstualni elementi ubačena imena entiteta, veza i atributa te oznake takozvanih kardinalnosti veza. Prednost takvog načina prikazivanja je ta su sve bitne informacije prikazane na dijagramu. Nedostatak je taj da dijagram može postati nepregledan i prenatrpan mjehurićima ako sadrži mnogo atributa.

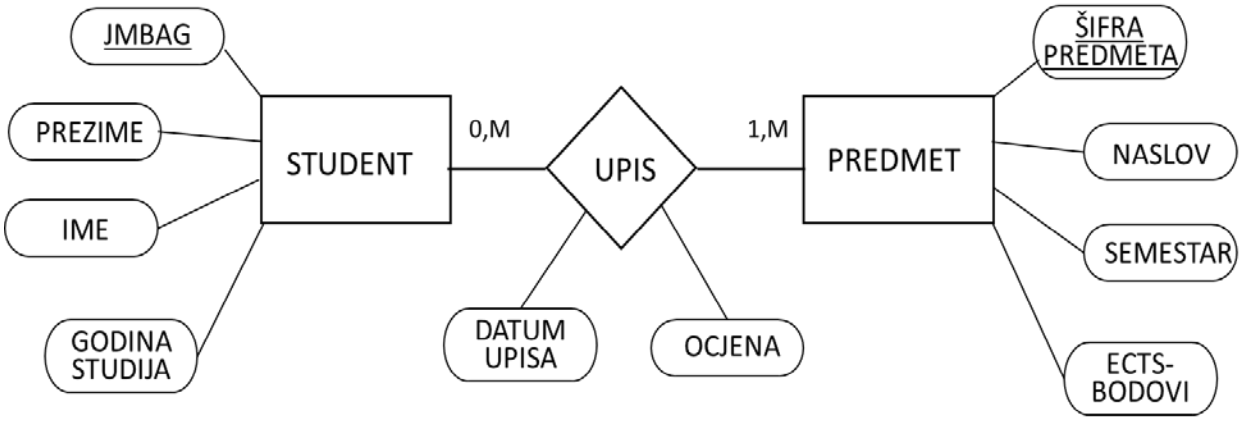

Slika 4.9. Izvorni Chenov dijagram (izvor: autor)

Pored već navedenih vrsta, odnosno notacija za EV dijagrame, primjenjuje se i UML *class*-dijagram. UML (engl. *Unified Modeling Language*) je standardizirani i danas vrlo popularan grafički jezik koji se rabi u objektno orijentiranim metodama za razvoj programske podrške. *Class*-dijagram je jedan od standardnih UML dijagrama i originalno služi za prikaz klasa objekata i veza između tih klasa. Taj dijagram možemo upotrijebiti za prikaz konceptualne sheme baze tako da entitet interpretiramo kao posebnu vrstu klase koja ima atribute, ali nema operacije. Entitet se tada crta kao pravokutnik s upisanim imenom entiteta na vrhu i upisanim imenima svih atributa u sredini. Veza (ili asocijacija po UML terminologiji) se crta kao spojnica između pravokutnika s upisanim imenom na sredini i upisanim oznakama kardinalnosti (ili multipliciteta po UML terminologiji) na krajevima. Kao što se može vidjeti na slici 4.10., dijagram sadrži sve potrebne informacije pa nema potrebe za tekstualnim nadopunama.

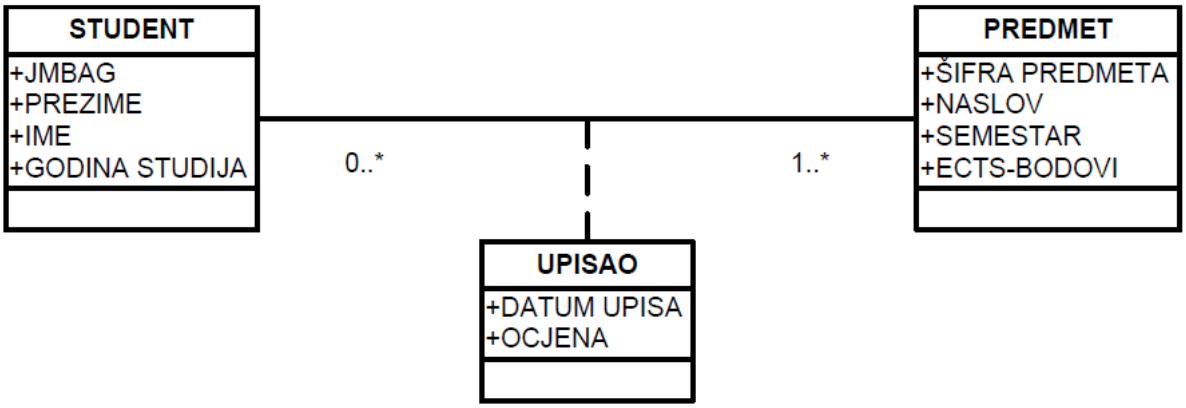

Slika 4.10. UML *class*-dijagram (izvor: autor)

S obzirom na činjenicu da nam EV dijagrami služe kao konceptualni model za oblikovanje relacijske baze podataka, na auditornim vježbama u sklopu predmeta za koji je napisan ovaj udžbenik, za konceptualno modeliranje koristit ćemo alat MS Visio i u njemu ugrađenu biblioteku predložaka za tzv. metamodeliranje u smislu grafičkog konceptualnog modeliranja relacijske baze podataka. Primjer takvog modela prikazan je na slici 4.11.

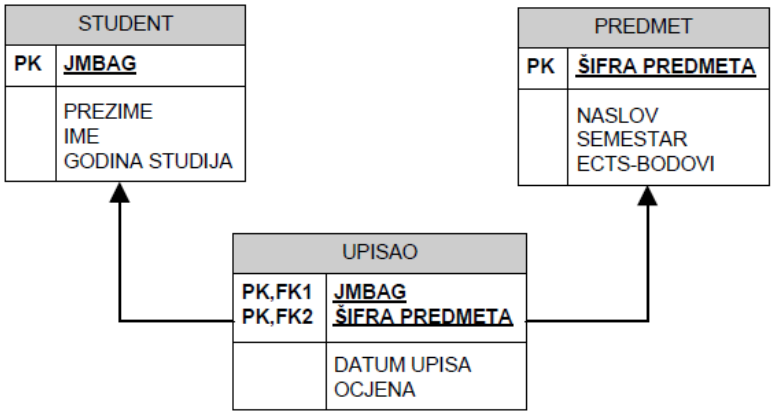

Slika 4.11. Grafički konceptualni model relacijske baze podataka (izvor: autor)

Ovaj se grafički model dopunjuje još s kodeksom atributa, odnosno s detaljnim rječnikom podataka (engl. *data dictionary*).

Na kraju priče o konceptualnom modeliranju i EV dijagramima pogledajmo još jedan primjer složenijeg reduciranog Chenovog dijagrama, kao i interpretaciju jednog specifičnog slučaja veze. Na slici 4.12. prikazan je EV dijagram koji predstavlja konceptualnu shemu baze podataka nekog veleučilišta. Izvršeno je prepoznavanje svih entiteta i njihovih atributa, opisane su njihove međusobne veze sa zadanim kardinalnostima te je prema zadanim pravilima nacrtan reducirani Chenov dijagram. Ovako izrađen dijagram potrebno je proanalizirati zajedno s korisnicima kako bi se uočili eventualni propusti i pogreške.

Slika 4.13. prikazuje primjer tzv. involuirane veze koja povezuje jedan tip entiteta s istim tipom. Njezino se stanje opisuje kao skup uređenih parova primjeraka entiteta istog tipa koji su povezani. Funkcionalnost takve veze opet može biti 1 : 1, 1 : M, odnosno M : M. Dijagram prikazuje vezu „JE PROČELNIK ZA" koja povezuje tip entiteta „NASTAVNIK" sa samim sobom. Veza prikazuje odnos nastavnika zaposlenih na odjelima veleučilišta. Bilježi se tko je kome pročelnik. Funkcionalnost je 1 : M jer jedan pročelnik može imati više podređenih nastavnika, a jedan nastavnik može imati samo jednog pročelnika. Dijagram ima ucrtanu strelicu

koja pokazuje smjer tumačenja veze (jedan je pročelnik za više nastavnika, a ne obratno). Članstvo entiteta u vezi je obavezno jer skoro svaki nastavnik ima svog pročelnika, a onaj koji nema pročelnika je pročelnik drugima.

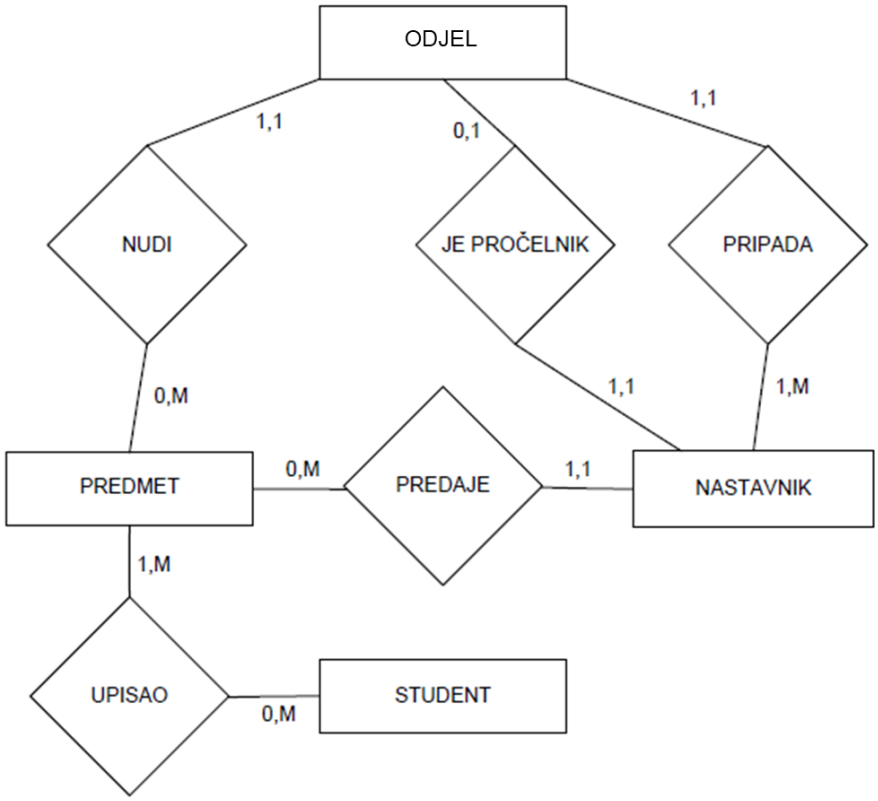

Slika 4.12. Reducirani Chenov EV dijagram za bazu podataka o veleučilištu (izvor: autor)

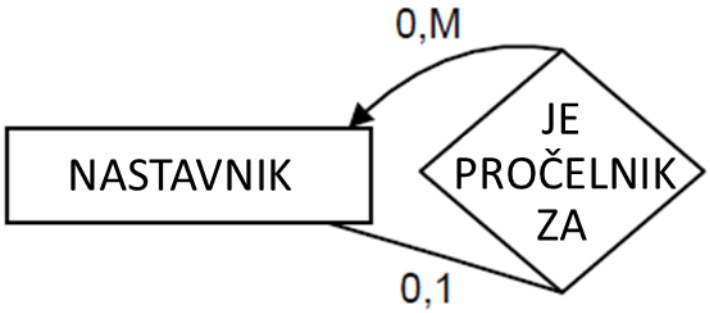

Slika 4.13. Primjer involuirane veze (izvor: autor)

4.2.2. Logičko modeliranje podataka

Logičko modeliranje podataka ili projektiranje na logičkoj razini čini u načelu drugu fazu projektiranja baze podataka. Glavni je cilj ove faze modeliranja stvoriti relacijsku shemu baze, dakle shemu koja opisuje logičku strukturu baze podataka u skladu s pravilima relacijskog modela podataka. Relacijska shema je korisnicima manje razumljiva od konceptualne jer su u njoj i entiteti i veze među entitetima pretvoreni u tzv. relacije pa je teško razlikovati jedno od drugog. Ipak, važno svojstvo relacijske sheme je da se ona može više-manje izravno implementirati pomoću današnjih sustava za upravljanje bazom podataka (engl. *Database Management System*, DBMS). Zahvaljujući današnjim programskim alatima, put od relacijske sheme do njezine konačne implementacije je vrlo kratak.

Relacijski model je teoretski zasnovan još krajem 60-tih godina 20. stoljeća u radovima Edgara Codda (Codd, 1970). Model se dugo pojavljivao samo u akademskim raspravama i knjigama, a prve realizacije na računalu bile su prespore i neučinkovite. Zahvaljujući intenzivnom istraživanju i napretku računala, učinkovitost relacijskih baza postepeno se poboljšavala. Sredinom 80-tih godina 20. stoljeća prevladao je relacijski model pa se danas velika većina DBMS-a koristi baš tim modelom.

Relacijski model zahtijeva da se baza podataka sastoji od skupa pravokutnih tablica – relacija. Svaka relacija ima svoje ime po kojem je razlikujemo od ostalih u istoj bazi. Jedan stupac relacije obično sadrži vrijednost jednog atributa (za entitet ili vezu) i zato stupac poistovjećujemo s atributom i obratno. Atribut ima svoje ime po kojem ga razlikujemo od ostalih u istoj relaciji. Dopušta se da dvije relacije imaju atribute s istim imenom, no tada se podrazumijeva da su to zapravo atributi s istim značenjem. Vrijednosti jednog atributa su podaci iste vrste. Definiran je dakle tip ili skup dopuštenih vrijednosti za atribut koji se zove domena atributa. Vrijednost atributa mora biti jednostruka i jednostavna (ne ponavlja se i ne može se rastaviti na dijelove). Pod nekim uvjetima toleriramo situaciju da vrijednost atributa nedostaje (nije upisana). Jedan redak relacije obično predstavlja jedan primjerak entiteta ili bilježi vezu između dva ili više primjeraka. Redak nazivamo n-torka (engl. *tuple*). U jednoj relaciji ne smiju postojati dvije jednake n-torke jer relaciju tumačimo kao skup n-torki. Broj atributa se zove stupanj relacije, a broj n-torki je kardinalnost relacije (Manger, 2010).

U nastavku će biti prikazani i na primjerima pojašnjeni bitni pojmovi koji definiraju relacijski model podataka:

- **Relacijska shema R** (intenzija) je imenovani skup atributa:

  $R = \{ A_1, A_2, \ldots , A_n \}$ ili

  $R = A_1, A_2, \ldots , A_n$

- **Relacija r** (ekstenzija) definirana nad relacijskom shemom R je konačan broj n-torki koji se označava sa:

  $r(R)$ ili $r(A_1, A_2, \ldots , A_n)$

  i predstavlja trenutnu vrijednost podataka opisanih relacijskom shemom.

Primjer:

U ovom su primjeru prikazana dva načina raspisivanja n-torki unutar relacije **student** opisane relacijskom shemom **STUDENT** gdje relacijsku shemu čini skup atributa {mbrStudent, prezimeStudent, imeStudent, slikaStudent}. Ono što u ovom primjeru čini odstupanje od klasične teorije relacijskih baza podataka je u tome da prikazana relacija sadrži i atribut (polje) **slikaStudent** čiji je sadržaj tzv. veliki binarni objekt, što znači da se ovdje radi o suvremenoj objektno-relacijskoj bazi podataka.

STUDENT = mbrStudent, prezimeStudent, imeStudent, slikaStudent

student(STUDENT) = { < 397798, Ivić, Ivo,  >,

< 389427, Cindrić, Jasna,  >,

< 392284, Matas, Hrvoje,  > }

student(mbrStudent, prezimeStudent, imeStudent, slikaStudent)

397798	Ivić	Ivo	
389427	Cindrić	Jasna	
392284	Matas	Hrvoje	

- Oznaka **t(A)** predstavlja vrijednost koju atribut **A** poprima u n-torki **t**, pri čemu se **t(A)** naziva **A-vrijednost n-torke t**.

Primjer:

t = < 397798, Ivić, Ivo,  >

t(prezimeStudent) = Ivić

- Neka je $X \subseteq R$ n-torka t reducirana na skup atributa X, tada **t(X)** označava **X − vrijednost n-torke t**.

Primjer:

t = < 389427, Cindrić, Jasna,  >

prezimeStudent, imeStudent ⊂ STUDENT

t(prezimeStudent, imeStudent) = < 389427, Cindrić, Jasna >

- Dvije su relacije unijski kompatibilne ako su jednakog stupnja i jednakih relacijskih shema (intenzija).

Primjer:

Usporedimo sljedeće relacije:

R_1=(Prezime,	Ime,	PostBr)		R_2=(Prezime,	Ime,	PostBr)
	Marić	Ivan	10000		Novak	Petar	10020
r_1	Senjak	Nada	10040	r_2	Kolar	Ivan	47000
	Novak	Ana	10000				

Stupanj:	d1 = 3	d2 = 3
Kardinalnost:	m1 = 3	m2 = 2

Relacije R1(r1) i R2(r2) možemo jednostavno spojiti (nadodati jednu na drugu) jer su jednakog stupnja i jednakih relacijskih shema.

- Specifične operacije provedive nad relacijama:
  - unarne:
    - projekcija − izdvajanje stupaca (atributa)
    - selekcija − izdvajanje redaka (n-torki)
  - binarne (spajanje):
    - prirodno spajanje
    - spajanje uz uvjet.

Primjer:

Projekcija relacije:

Neka je r relacija definirana na shemi R i neka je X skup atributa X⊆R. Operacija projekcije relacije r(R) na skup atributa X označava se sa $\pi_X(r) = q(x) = \{ t \mid t \in r \}$

Zadana je relacija:

popis(Osoba, Grad, Telefon)

O1	G1	T1
O2	G2	T2
O3	G3	T3

− potrebno je načiniti dvije projekcije p1 i p2 pri čemu svaka sadrži podatak o osobi:

$p1 = \pi_{Osoba,\ Grad}(popis)$

$p2 = \pi_{Osoba,\ Telefon}(popis)$

Selekcija relacije:

Neka je r relacija definirana na relacijskoj shemi R i neka je F formula primjenjiva na r. Operacija selekcije nad relacijom r uz neki uvjet selekcije F označava se sa:

$\sigma_F(r) = q(x) = \{t \mid t \in r \wedge t \text{ zadovoljava } F\}$

Za razliku od projekcije koja je vertikalno izdvajanje stupaca (atributa) iz relacijske sheme, projekcija je horizontalno odvajanje pojedinih n-torki koje zadovoljavaju neki uvjet. Pritom uvjet F može biti npr. spol gdje bismo mogli izdvojiti muške ili ženske osobe iz relacijske tablice ili npr. raspon datuma rođenja gdje bismo mogli izdvojiti skup osoba koje su rođene unutar vremenskog raspona F.

Prirodno spajanje (pridruživanje) relacija:

Neka su zadane dvije relacije p1(Osoba, Grad) i p2(Osoba, Telefon) koje je potrebno prirodno spojiti prema nekom ključnom atributu. Zajednički atribut za obje ove relacije je atribut Osoba i za njega kažemo da je ključni atribut po kojem će se spojiti ove dvije relacije u novu relaciju p3(Osoba, Grad, Telefon).

p1(Osoba, Grad)		p2(Osoba, Telefon)	
O1	G1	O1	T1
O2	G2	O2	T2
O3	G3	O3	T3

- prirodno spajanje p1 i p2 u novu relaciju p3 pišemo kao:

$$p3 = p1 \bowtie p2 \quad => \quad \text{spajanje po ključu } K = \text{Osoba}$$

* * *

Konceptualno modeliranje, tj. oblikovanje entiteta i veza među njima, ne mora nužno u potpunosti odgovarati logičkom modelu relacijske baze podataka. Naprotiv, pojedini entiteti mogu biti opisani atributima koji nisu funkcijski zavisni samo o jednom ključu, već među njima postoje neki drugi atributi o kojima je funkcijski zavisan jedan ili više atributa, odnosno postoji tranzitivna zavisnost o primarnom ključnom atributu. Logičko modeliranje nam dakle nudi mogućnost unaprjeđenja, popravka i bolje interpretacije konceptualnog modela. U nastavku će biti više riječi o postupcima optimiranja skupa relacija relacijske baze podataka u smislu logičkog modeliranja podataka.

4.2.2.1. Što je dekompozicija i zašto je vršimo?

Za primjer usporedbe jednog koncepcijskog i jednog logičkog modela uzet ćemo primjer iz vježbi. Slika 4.14. prikazuje EV model postupka upućivanja djelatnika i obavljanja sistematskih pregleda, pri čemu jedan djelatnik može jednom ili više puta biti upućen na obavljanje pregleda.

Slika 4.14. EV model upućivanja i obavljanja sistematskih pregleda (izvor: autor)

U logičkom modelu podataka ovaj bi postupak bio opisan relacijom:

$$\text{sistematski\_pregledi} = \text{djelatnici} \bowtie \text{pregledi}$$

U praktičnom smo smislu na vježbama relaciju „sistematski pregledi" oblikovali kao tablicu na radnom listu Excela prikazanu na slici 4.15.

MBR	Ime	Prezime	JMBG	Stručna sprema	Odjel	Spol	Godine	Staž	Sistematski	Datum pregleda	Klinika
1	Eva	Anić	0104965543609	VSS	Uprava	Ž	46	20	DA	2.2.2010	Nemetova
2	Ivan	Anić	1506964872343	VŠS	Uprava	M	47	20	DA	5.9.2011	Nemetova
3	Ivana	Crnković	2802977235678	VSS	Trgovina	Ž	34	9	DA	12.10.2011	Svjetlost
4	Jasna	Čapić	2007978340065	VŠS	Transport	Ž	33	6	DA	2.5.2010	Sunce
5	Filip	Čupić	1305976340129	SSS	Transport	M	35	9	DA	7.8.2010	Svjetlost
6	Mirna	Darac	0811982350480	VSS	Proizvodnja	Ž	29	2	DA	18.4.2011	Sunce
7	Jurica	Đurić	0101990124578	VŠS	Odjel MFP	M	21	1	DA	13.12.2011	Svjetlost
8	Lovro	Marojević	1905979321206	VSS	Uprava	M	32	4	NE		
9	Dražen	Matoković	0306975553322	SSS	Proizvodnja	M	36	18	DA	4.6.2011	Svjetlost
10	Mirjana	Miljac	1212970650043	SSS	Proizvodnja	Ž	41	13	DA	8.8.2011	Nemetova
11	Adam	Pecić	0112983340022	VŠS	Održavanje	M	28	4	DA	2.3.2011	Svjetlost
12	Adela	Petrić	0908975345678	VŠS	Odjel MFP	Ž	36	12	DA	2.4.2010	Sunce
13	Dubravka	Topić	0607966122100	VSS	Uprava	Ž	45	18	DA	5.7.2011	Nemetova
14	Branka	Weber	2306978987643	VŠS	Odjel kadrovskih poslova	Ž	33	10	DA	3.5.2011	Sunce
15	Boško	Weller	1212977453224	SSS	Odjel MFP	M	34	13	NE		
16	Lorna	Žerić	1005984547682	VŠS	Odjel kadrovskih poslova	Ž	27	2	DA	31.5.2011	Medikol
17	Zdenko	Gradinić	0607963128904	VSS	Uprava	M	48	21	DA	8.2.2011	Svjetlost
18	Mladen	Lončarić	2912980001203	VŠS	Proizvodnja	M	31	8	DA	12.11.2011	Medikol
19	Željko	Miljac	2804986200430	SSS	Održavanje	M	25	1	NE		
20	Zlatko	Oross	1711958802092	VŠS	Odjel MFP	M	53	30	DA	5.5.2011	Nemetova
21	Rudolf	Vučić	1711969001211	VSS	Odjel kadrovskih poslova	M	42	15	DA	23.7.2011	Sunce
22	Robert	Žerić	103971102964	VŠS	Odjel kadrovskih poslova	M	40	13	DA	9.2.2011	Sunce
1	Eva	Anić	0104965543609	VSS	Uprava	Ž	46	20	DA	6.8.2011	Sunce
4	Jasna	Čapić	2007978340065	VŠS	Transport	Ž	33	6	DA	6.8.2011	Nemetova
5	Filip	Čupić	1305976340129	SSS	Transport	M	35	9	DA	7.3.2011	Medikol
15	Boško	Weller	1212977453224	SSS	Odjel MFP	M	34	13	DA	9.12.2010	Sunce

Slika 4.15. Evidencija sistematskih pregleda sortirana kronološki (izvor: autor)

U tablici su crvenom bojom označene ponovne epizode odlazaka na pregled onih djelatnika koji su barem jedanput bili upućeni na pregled. Razlog ponovnog odlaska može biti i neprolazak na prvom pokušaju ili protek zakonskog razdoblja za ponovno upućivanje na obvezni sistematski pregled. Očito je da se ovdje javlja znatna redundancija podataka jer se svi osobni podaci djelatnika ponavljaju u svakom sljedećem zapisu o odlasku na pregled. Primarni ključ ovakve relacije, koji osigurava njezinu konzistentnost i jednoznačnost svake epizode odlaska na pregled, nije jedinstven i u načelu bi trebao biti kombinacija matičnog broja djelatnika MBR i datuma odlaska na pregled Datum_pregleda. Ono što se još može primijetiti je to da ovaj datum pregleda nije unesen u svim zapisima pa na prvi pogled nismo sigurni označava li parametar Sistematski (DA/NE) obavezu odlaska na pregled ili neprolazak na pregledu. Ako ovu evidenciju sortiramo abecedno po prezimenu i imenu kao na slici 4.16., dobit ćemo grupirane podatke za pojedinog djelatnika, ali nećemo imati precizan uvid u ukupno stanje duplikata.

MBR	Ime	Prezime	JMBG	Stručna sprema	Odjel	Spol	Godine	Staž	Sistematski	Datum pregleda	Klinika
1	Eva	Anić	0104965543609	VSS	Uprava	Ž	46	20	DA	2.2.2010	Nemetova
1	Eva	Anić	0104965543609	VSS	Uprava	Ž	46	20	DA	6.8.2011	Sunce
2	Ivan	Anić	1506964872343	VŠS	Uprava	M	47	20	DA	5.9.2011	Nemetova
3	Ivana	Crnković	2802977235678	VSS	Trgovina	Ž	34	9	DA	12.10.2011	Svjetlost
4	Jasna	Čapić	2007978340065	VŠS	Transport	Ž	33	6	DA	2.5.2010	Sunce
4	Jasna	Čapić	2007978340065	VŠS	Transport	Ž	33	6	DA	6.8.2011	Nemetova
5	Filip	Čupić	1305976340129	SSS	Transport	M	35	9	DA	7.8.2010	Svjetlost
5	Filip	Čupić	1305976340129	SSS	Transport	M	35	9	DA	7.3.2011	Medikol
6	Mirna	Darac	0811982350480	VSS	Proizvodnja	Ž	29	2	DA	18.4.2011	Sunce
7	Jurica	Đurić	0101990124578	VŠS	Odjel MFP	M	21	1	DA	13.12.2011	Svjetlost
17	Zdenko	Gradinić	0607963128904	VSS	Uprava	M	48	21	DA	8.2.2011	Svjetlost
18	Mladen	Lončarić	2912980001203	VŠS	Proizvodnja	M	31	8	DA	12.11.2011	Medikol
8	Lovro	Marojević	1905979321206	VSS	Uprava	M	32	4	NE		
9	Dražen	Matoković	0306975553322	SSS	Proizvodnja	M	36	18	DA	4.6.2011	Svjetlost
10	Mirjana	Miljac	1212970650043	SSS	Proizvodnja	Ž	41	13	DA	8.8.2011	Nemetova
19	Željko	Miljac	2804986200430	SSS	Održavanje	M	25	1	NE		
20	Zlatko	Oross	1711958802092	VŠS	Odjel MFP	M	53	30	DA	5.5.2011	Nemetova
11	Adam	Pecić	0112983340022	VŠS	Održavanje	M	28	4	DA	2.3.2011	Svjetlost
12	Adela	Petrić	0908975345678	VŠS	Odjel MFP	Ž	36	12	DA	2.4.2010	Sunce
13	Dubravka	Topić	0607966122100	VSS	Uprava	Ž	45	18	DA	5.7.2011	Nemetova
21	Rudolf	Vučić	1711969001211	VSS	Odjel kadrovsk	M	42	15	DA	23.7.2011	Sunce
14	Branka	Weber	2306978987643	VŠS	Odjel kadrovsk	Ž	33	10	DA	3.5.2011	Sunce
15	Boško	Weller	1212977453224	SSS	Odjel MFP	M	34	13	NE		
15	Boško	Weller	1212977453224	SSS	Odjel MFP	M	34	13	DA	9.12.2010	Sunce
16	Lorna	Žerić	1005984547682	VŠS	Odjel kadrovsk	Ž	27	2	DA	31.5.2011	Medikol
22	Robert	Žerić	103971102964	VŠS	Odjel kadrovsk	M	40	13	DA	9.2.2011	Sunce

Slika 4.16. Evidencija sistematskih pregleda sortirana abecedno po djelatnicima (izvor: autor)

Pogleda li se situacija prikazana na slici 4.15., može se jednostavno razlučiti što su jednoznačni podaci (crni zapisi), a što duplikati (crveni zapisi). Treba istaknuti da Excel ima ugrađenu funkciju za uklanjanje dupliciranih zapisa što znatno olakšava izdvajanja jednoznačnih podataka. U daljnjem ćemo postupku krenuti od jednostavnog kronološkog prikaza i označiti koji dio zapisa čini jednoznačni popis djelatnika, a koji dio čini ponavljajuće epizode pregleda kao što je prikazano na slici 4.17.

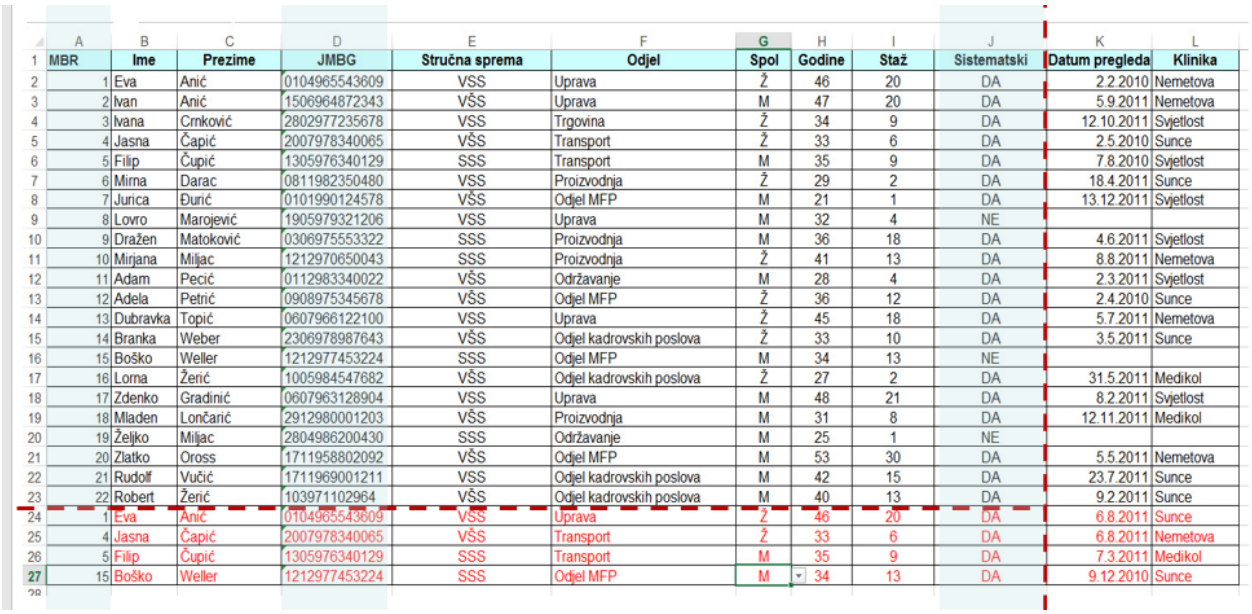

	A	B	C	D	E	F	G	H	I	J	K	L
1	MBR	Ime	Prezime	JMBG	Stručna sprema	Odjel	Spol	Godine	Staž	Sistematski	Datum pregleda	Klinika
2	1	Eva	Anić	0104965543609	VSS	Uprava	Ž	46	20	DA	2.2.2010	Nemetova
3	2	Ivan	Anić	1506964872343	VŠS	Uprava	M	47	20	DA	5.9.2011	Nemetova
4	3	Ivana	Crnković	2802977235678	VSS	Trgovina	Ž	34	9	DA	12.10.2011	Svjetlost
5	4	Jasna	Čapić	2007978340065	VŠS	Transport	Ž	33	6	DA	2.5.2010	Sunce
6	5	Filip	Čupić	1305976340129	SSS	Transport	M	35	9	DA	7.8.2010	Svjetlost
7	6	Mirna	Darac	0811982350480	VSS	Proizvodnja	Ž	29	2	DA	18.4.2011	Sunce
8	7	Jurica	Đurić	0101990124578	VŠS	Odjel MFP	M	21	1	DA	13.12.2011	Svjetlost
9	8	Lovro	Marojević	1905979321206	VSS	Uprava	M	32	4	NE		
10	9	Dražen	Matoković	0306975553322	SSS	Proizvodnja	M	36	18	DA	4.6.2011	Svjetlost
11	10	Mirjana	Miljac	1212970650043	SSS	Proizvodnja	Ž	41	13	DA	8.8.2011	Nemetova
12	11	Adam	Pecić	0112983340022	VŠS	Održavanje	M	28	4	DA	2.3.2011	Svjetlost
13	12	Adela	Petrić	0908975345678	VŠS	Odjel MFP	Ž	36	12	DA	2.4.2010	Sunce
14	13	Dubravka	Topić	0607966122100	VSS	Uprava	Ž	45	18	DA	5.7.2011	Nemetova
15	14	Branka	Weber	2306978987643	VŠS	Odjel kadrovskih poslova	Ž	33	10	DA	3.5.2011	Sunce
16	15	Boško	Weller	1212977453224	SSS	Odjel MFP	M	34	13	NE		
17	16	Lorna	Žerić	1005984547682	VŠS	Odjel kadrovskih poslova	Ž	27	2	DA	31.5.2011	Medikol
18	17	Zdenko	Gradinić	0607963128904	VSS	Uprava	M	48	21	DA	8.2.2011	Svjetlost
19	18	Mladen	Lončarić	2912980001203	VŠS	Proizvodnja	M	31	8	DA	12.11.2011	Medikol
20	19	Željko	Miljac	2804986200430	SSS	Održavanje	M	25	1	NE		
21	20	Zlatko	Oross	1711958802092	VŠS	Odjel MFP	M	53	30	DA	5.5.2011	Nemetova
22	21	Rudolf	Vučić	1711969001211	VSS	Odjel kadrovskih poslova	M	42	15	DA	23.7.2011	Sunce
23	22	Robert	Žerić	103971102964	VŠS	Odjel kadrovskih poslova	M	40	13	DA	9.2.2011	Sunce
24	1	Eva	Anić	0104965543609	VSS	Uprava	Ž	46	20	DA	6.8.2011	Sunce
25	4	Jasna	Čapić	2007978340065	VŠS	Transport	Ž	33	6	DA	6.8.2011	Nemetova
26	5	Filip	Čupić	1305976340129	SSS	Transport	M	35	9	DA	7.3.2011	Medikol
27	15	Boško	Weller	1212977453224	SSS	Odjel MFP	M	34	13	DA	9.12.2010	Sunce

Slika 4.17. Prikaz linija za razdvajanje zapisa na dvije projekcije (izvor: autor)

Dio s jednoznačnim zapisom podataka o djelatnicima kopiramo na novi radni list i nazovemo ga „Matična" jer čini tzv. matičnu tablicu evidencije djelatnika, a dio koji sadrži datume pregleda i klinika na kojima su oni obavljeni kopiramo na novi radni list koji nazovemo „Pregledi". Prikaz sadržaja ovih radnih listova dan je na slikama 4.18. i 4.19.

	A	B	C	D	E	F	G	H	I
1	MBR	Ime	Prezime	JMBG	Stručna sprema	Odjel	Spol	Godine	Staž
2	1	Eva	Anić	0104965543609	VSS	Uprava	Ž	46	20
4	2	Ivan	Anić	1506964872343	VŠS	Uprava	M	47	20
5	3	Ivana	Crnković	2802977235678	VSS	Trgovina	Ž	34	9
6	4	Jasna	Čapić	2007978340065	VŠS	Transport	Ž	33	6
7	5	Filip	Čupić	1305976340129	SSS	Transport	M	35	9
8	6	Mirna	Darac	0811982350480	VSS	Proizvodnja	Ž	29	2
9	7	Jurica	Đurić	0101990124578	VŠS	Odjel MFP	M	21	1
10	17	Zdenko	Gradinić	0607963128904	VSS	Uprava	M	48	21
11	18	Mladen	Lončarić	2912980001203	VŠS	Proizvodnja	M	31	8
12	8	Lovro	Marojević	1905979321206	VSS	Uprava	M	32	4
13	9	Dražen	Matoković	0306975553322	SSS	Proizvodnja	M	36	18
14	10	Mirjana	Miljac	1212970650043	SSS	Proizvodnja	Ž	41	13
15	19	Željko	Miljac	2804986200430	SSS	Održavanje	M	25	1
16	20	Zlatko	Oross	1711958802092	VŠS	Odjel MFP	M	53	30
17	11	Adam	Pecić	0112983340022	VŠS	Održavanje	M	28	4
18	12	Adela	Petrić	0908975345678	VŠS	Odjel MFP	Ž	36	12
19	13	Dubravka	Topić	0607966122100	VSS	Uprava	Ž	45	18
20	21	Rudolf	Vučić	1711969001211	VSS	Odjel kadrovskih poslova	M	42	15
21	14	Branka	Weber	2306978987643	VŠS	Odjel kadrovskih poslova	Ž	33	10
22	15	Boško	Weller	1212977453224	SSS	Odjel MFP	M	34	13
23	16	Lorna	Žerić	1005984547682	VŠS	Odjel kadrovskih poslova	Ž	27	2
24	22	Robert	Žerić	103971102964	VŠS	Odjel kadrovskih poslova	M	40	13

Slika 4.18. Novodobivena tablica „Matična" (izvor: autor)

	A	B	C	D	E
1	MBR	JMBG	Sistematski	Datum pregleda	Klinika
2	1	0104965543609	DA	2.2.2010	Nemetova
3	1	0104965543609	DA	6.8.2011	Sunce
4	2	1506964872343	DA	5.9.2011	Nemetova
5	3	2802977235678	DA	12.10.2011	Svjetlost
6	4	2007978340065	DA	2.5.2010	Sunce
7	4	2007978340065	DA	6.8.2011	Nemetova
8	5	1305976340129	DA	7.8.2010	Svjetlost
9	5	1305976340129	DA	7.3.2011	Medikol
10	6	0811982350480	DA	18.4.2011	Sunce
11	7	0101990124578	DA	13.12.2011	Svjetlost
12	17	0607963128904	DA	8.2.2011	Svjetlost
13	18	2912980001203	DA	12.11.2011	Medikol
14	8	1905979321206	NE		
15	9	0306975553322	DA	4.6.2011	Svjetlost
16	10	1212970650043	DA	8.8.2011	Nemetova
17	19	2804986200430	NE		
18	20	1711958802092	DA	5.5.2011	Nemetova
19	11	0112983340022	DA	2.3.2011	Svjetlost
20	12	0908975345678	DA	2.4.2010	Sunce
21	13	0607966122100	DA	5.7.2011	Nemetova
22	21	1711969001211	DA	23.7.2011	Sunce
23	14	2306978987643	DA	3.5.2011	Sunce
24	15	1212977453224	NE		
25	15	1212977453224	DA	9.12.2010	Sunce
26	16	1005984547682	DA	31.5.2011	Medikol
27	22	103971102964	DA	9.2.2011	Sunce

Slika 4.19. Novodobivena tablica „Pregledi” (izvor: autor)

Ako analiziramo sada obje tablice, možemo vidjeti pojedine nedostatke i potencijalne probleme. U tablici „Matična” uzimamo stupac (atribut) MBR kao primarni ključ, a JMBG, koji se inače više ne koristi i predstavlja alternativni primarni ključ, može u praksi biti zadržan radi eventualnog naknadnog povezivanja s nekim zapisima starijeg datuma. Osim toga, podaci o rasporedu djelatnika po organizacijskim jedinicama nisu izravno funkcijski zavisni o MBR-u. Podaci o starosti i dobi djelatnika nisu statični opisni atributi jer su izvedeni (izračunati) ovisno o trenutnom datumu pa bi bilo bolje umjesto njih koristiti datum rođenja i datum zaposlenja. Tablicu „Pregledi” je trebalo dopuniti stupcem MBR kako bismo imali informaciju kojem djelatniku pripada pojedina epizoda pregleda. Prebačen je i stupac „Sistematski” koji je upotrebljiv za indikaciju prolaz ili neprolaz, ali treba nadopuniti datume pregleda na kojima djelatnici nisu prošli pregled.

Ovim smo postupkom složenu relaciju „Sistematski_pregledi” razdvojili na dvije relacije „Matična” i „Pregledi”. Možemo reći da smo složenu relaciju sveli na tzv. prvu normalnu formu (1. NF). Ovim smo prvim postupkom **dekompozicije** samo dobili osnovnu atomizaciju, odnosno eliminirali redundanciju zapisa u polaznoj složenoj relaciji. Dobivene dvije relacije s gledišta relacijskog modela podataka i dalje imaju probleme koje bi trebalo otkloniti daljnjim postupcima dekompozicije. Do koje će se mjere primjenjivati daljnja dekompozicija ili će se dopuštati određena razina redundancije ovisi o gledištu projektanta baze podataka i zahtjevima korisnika IS-a. U općem slučaju, svaki put kada i sami krenemo u oblikovanje npr. neke naše evidencije aktivnosti, moramo razmišljati o ovim preporukama i razmotriti što bi nam od pojedinih podataka i načina oblikovanja zapisa moglo zatrebati u budućoj primjeni.

Prikazani postupak dekompozicija je samo jedan od oblika normalizacije baza podataka. Općenito u okviru relacijskog modela podataka postoje vertikalna i horizontalna normalizacija.

- Vertikalna normalizacija:
  - temelji se na operacijama projekcije i prirodnog spajanja
  - dolazi pritom do cijepanja svake n-torke polazne relacije
  - postupak mora biti reverzibilan
  - najčešće je korištena metoda

- Horizontalna normalizacija:
  - temelji se na operacijama selekcije i unije
  - relacija se rastavlja na podskupove (fragmente) n-torki koji odgovaraju određenim uvjetima
  - primjenjuje se kod distribuiranih sustava gdje relacija ne mora u potpunosti biti pohranjena na jednoj lokaciji.

Od dvije navedene vrste normalizacije, u cilju postizanja optimalnog logičkog modela, najinteresantnija je vertikalna normalizacija. Vertikalna normalizacija se dijeli na normalizaciju dekompozicijom i normalizaciju sintezom.

- Normalizacija dekompozicijom:
  - polazi od proizvoljne nenormalizirane relacijske sheme
  - izvodi se po koracima
  - svakim sljedećim korakom normalizacije relacijska shema prevodi se u višu normalnu formu
  - polazni skup atributa dijeli se na dvije nove relacije
  - svaki korak mora biti reverzibilan
  - glavna je metoda za „ručno" projektiranje baze podataka.

- Normalizacija sintezom:
  - polazi od skupa atributa i skupa zavisnosti zadanih na tom skupu atributa
  - postupak se svodi na pronalaženje najmanjeg zajedničkog pokrivača ovih skupova => relacijska shema cijele baze podataka
  - glavna je „strojna" metoda za računalno projektiranje baze podataka.

Kao što je istaknuto u svojstvima ovih dviju metoda vertikalne normalizacije, normalizacija dekompozicijom je najčešće korištena „ručna" metoda razdvajanja složenih relacija unutar nekog IS-a na elementarne skupove podataka koji bi trebali biti funkcijski zavisni samo o jednom primarnom ključu (u idealnom slučaju). Sve elementarne relacije koje se dobiju ovakvim razdvajanjem, odnosno dekompozicijom, moraju se moći ponovno prirodnim spajanjem spojiti u polaznu relaciju. Ako to nije slučaj, nismo dobro predvidjeli koji skupovi atributa predstavljaju reverzibilno spojive projekcije polazne relacije. Razlog za to najčešće su parcijalne i tranzitivne funkcijske zavisnosti o nekim drugim atributima unutar podijeljenih skupova. Kako bismo proveli ovaj postupak na ispravan i zadovoljavajući način, moramo moći okvirno predvidjeti željene funkcijske zavisnosti i potrebe za kasnijim kombinacijama (spojenim relacijama) ovih

elementarnih skupova u cilju oblikovanja željenih skupova podataka i informacija. Međutim, zbog ove potrebe za predviđanjem krajnjeg rezultata, ova metoda nije pogodna za računalnu obradu. Za potrebe „strojnog" provođenja vertikalne normalizacije primjenom računala koristi se tzv. normalizacija sintezom. Postupak polazi od objedinjavanja skupa svih mogućih funkcijskih zavisnosti (atributa o ključevima) neovisno od toga jesu li redundantni, tj. ponavljaju li se zbog prisustva istih skupova atributa u različitim podatkovnom segmentima (podsustavima) IS-a. Nakon toga se provodi postupak traženja (računanja) tzv. najmanjeg zajedničkog pokrivača ovog skupa koji sadrži sve elementarne funkcijske zavisnosti unutar IS-a koje ga čine optimalno logički modeliranim.

U kontekstu vertikalne normalizacije dekompozicijom definirano je šest normalnih formi (NF) relacijskih shema:

- prva normalna forma (1NF)
- druga normalna forma (2NF)
- treća normalna forma (3NF)
- Boyce-Coddova normalna forma (BCNF)
- četvrta normalna forma (4NF)
- peta normalna forma (5NF).

Postupak je takav da se relacijska shema prvo transformira u 1NF, zatim u 2NF i tako redom prema stvarnoj potrebi i procjeni projektanta. Što je red NF viši to su uvjeti koji se postavljaju stroži. No u praksi se najčešće ide najdalje do 3NF. Pojasnimo ukratko što znači pojedina NF i čime doprinosi logičkom modelu baze podataka. Za relaciju kažemo da je u 1NF jer su vrijednosti njezinih atributa jednostruke i nedjeljive.

Ustvari, 1NF ne predstavlja nikakav poseban zahtjev na relaciju jer je to svojstvo već ugrađeno u relacijski model i definiciju relacije. U relacijskoj bazi podataka dakle ne može postojati relacija koja ne bi već otpočetka bila u 1NF. Kao što smo vidjeli na primjeru iz vježbi, 1NF donosi samo osnovnu atomizaciju relacija, tj. uklanja redundanciju.

Relacija je u drugoj normalnoj formi (2NF) ako je svaki njezin neprimarni atribut potpuno funkcionalno zavisan o primarnom ključu. Drugim riječima, relacija je u 2NF ako u njoj nema parcijalnih zavisnosti atributa o primarnom ključu. Parcijalna zavisnost smatra se nepoželjnim svojstvom jer može uzrokovati teškoće kod manipuliranja s podacima.

Relacija je u trećoj normalnoj formi (3NF) ako je u 2NF i ako ne sadrži tranzitivne zavisnosti. Preciznije, relacija R je u 3NF ako za svaku funkcionalnu zavisnost $X \rightarrow A$ u R, takvu da A nije dio od X, vrijedi: X sadrži ključ za R ili je A primarni atribut. Slično kao i parcijalna zavisnost, i tranzitivna se zavisnost smatra nepoželjnim svojstvom jer i ona može uzrokovati slične teškoće kod manipuliranja s podacima.

Iako su za svakodnevne potrebe obično dovoljne i prve tri normalne forme, teorija normalizacije nije se zaustavila na tome. U svojim kasnijim radovima iz druge polovice 70-tih godina 20. stoljeća, Edgar Codd je definirao pojačanu varijantu 2NF i 3NF koja se zove Boyce-Coddova normalna forma. Ronald Fagin je 1977. i 1979. godine uveo četvrtu i petu normalnu formu. Kasniji autori uveli su i šestu normalnu formu. U praksi je lako naići na relacije koje odstupaju od 2NF i 3NF, no vrlo rijetko se susreću relacije u 3NF koje nisu u višim normalnim formama. Zato su te više normalne forme prvenstveno od teorijskog značaja. Ovo područje teorije i primjene prevođenja relacija iznad 3NF prelazi granice ovog udžbenika i predmet je profesionalnog izučavanja u domeni projektiranja baza podataka.

Bez obzira na razinu pristupa modeliranju podataka i oblikovanju baza podataka, normalizacija je u prvom redu potrebna zato jer se njome izbjegavaju teškoće koje bi nastupile kad

bismo radili s nenormaliziranim podacima. Normalizacija je korisna i zato jer se njome naknadno otkrivaju i ispravljaju pogreške u oblikovanju entiteta, veza i atributa. Od normalizacije možemo odustati samo u nekim rijetkim situacijama, no i tada moramo biti svjesni eventualnih loših posljedica takve odluke. Ako relacije nisu normalizirane, dolazi do teškoća kod unosa, promjene i brisanja podataka. Bez obzira o kojoj normalnoj formi je riječ, teškoće su otprilike slične. Neki od ovih problema bit će ilustrirani u nastavku s nekoliko primjera, no prije toga sažmimo ukratko razloge za provođenje postupka dekompozicije:

- smanjenje redundantnosti
- smanjenje složenosti sustava
- jednostavnije izmjene pojedinih nomenklatura bez utjecaja na konzistenciju baze podataka
- primjena te vanjsko i daljinsko održavanje normiranih nomenklatura
- povećana kombinatorika spajanja raznih tablica iz baze podataka u cilju pregledavanja, uređivanja i unosa podataka
- sprječavanje anomalije održavanja (Manger 2010; Strahonja Varga i Pavlić, 1992; Teorey 2011).

Primjeri:

1. Zadane su dvije relacije „stud" i „ispiti" kojima je opisan postupak prijave i polaganja ispita. Relacije su u 1NF jer je zapravo postignuta samo „atomizacija" relacija. Relacija „ispiti" je i u 2NF jer su svi atributi funkcijski zavisni o ključnom atributu ID, tj. nema parcijalnih i tranzitivnih zavisnosti među ostalim atributima:

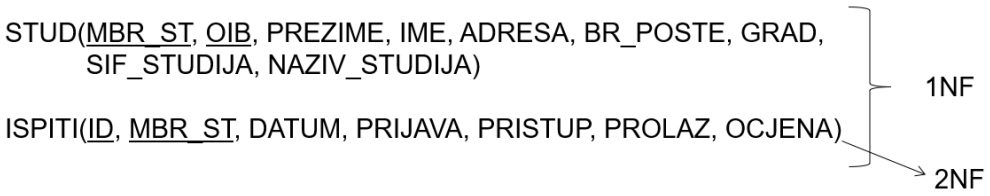

2. Kako je relacija „stud" samo u 1NF, potrebno je provesti daljnju dekompoziciju, nakon čega relacije iz Primjera 1 izgledaju ovako:

STUD(MBR_ST, OIB, SIF_STUDIJA)
OSOBA(OIB, PREZIME, IME, ADRESA, BR_POSTE)
GRADOVI(BR_POSTE, GRAD)
ISPITI(ID, MBR_ST, DATUM, PRIJAVA, PRISTUP, PROLAZ, OCJENA)

Relacije sada zadovoljavaju 2NF, pa čak i 3NF jer su neključni elementi u pojedinoj relaciji funkcionalno zavisni o jednom ključu, a nema ni tranzitivnih zavisnosti. Izbjegnute su anomalije održavanja i brisanja, tj. onemogućeno je da se npr. brisanjem podataka o studentu izgube svi njegovi podaci u bazi podataka.

3. Pretpostavimo situaciju u kojoj je jedan nastavnik zaposlen samo na jednom fakultetu i svaki fakultet se nalazi samo u jednom gradu. Svaki fakultet može imati više zaposlenih nastavnika i u svakom gradu može biti više fakulteta. Za ovu situaciju vrijedi relacijska shema:

NFG(NASTAVNIK, FAKULTET, GRAD) => 2NF

Za relaciju vrijede funkcijske zavisnosti:

NASTAVNIK → FAKULTET
FAKULTET → GRAD
NASTAVNIK → GRAD

Relacijska shema „NFG" je u 2NF, ali postoje **anomalije održavanja.** Brisanjem posljednjeg nastavnika nekog fakulteta brišu se i podaci o fakultetu i lokaciji. Podatke o gradu nije moguće upisati dok fakultet nema bar jednog nastavnika. Razlog ovih anomalija je postojanje tranzitivne zavisnosti:

NASTAVNIK → GRAD

koja proizlazi iz funkcijskih zavisnosti:

NASTAVNIK → FAKULTET i FAKULTET → GRAD

Rješenje je u dekompoziciji relacije „NFG" kojom dobivamo dvije relacije:

NF(NASTAVNIK, FAKULTET)
FG(FAKULTET, GRAD)

Ovim je završen postupak svođenja relacijske sheme „NFG" na 3NF.

4.2.3. Fizičko modeliranje podataka

Fizičko modeliranje podataka je treća faza modeliranja podataka. Glavni je cilj ove faze stvoriti fizičku shemu baze podataka, tj. opis njezine fizičke građe. Početna inačice fizičke građe baze podataka ustvari implementira sve relacije iz logičke sheme i osigurava potrebnu brzinu pristupanja podacima. U načelu, fizička shema zapravo je tekst sastavljen od naredbi u SQL-u ili nekom drugom jeziku koji razumije sustav za upravljanje bazom podataka. Izvođenjem ovih naredbi ovaj sustav stvara fizičku građu baze. U nastavku će biti opisana osnovna svojstva baza podataka, građa programskog alata MS Access kao jednostavnog i pristupačnog razvojnog alata i sustava za upravljanje relacijskom bazom podataka te drugi primjeri koji se obrađuju na vježbama iz ovog predmeta.

4.2.3.1. Baze podataka

Baza podataka je organizirani skup podataka, odnosno zbirka zapisa pohranjenih u računalu na sustavan način koja se može putem nekog računalnog programa na brz, jednostavan i efikasan način dohvatiti u cilju odgovora na neki upit. Jednostavnije rečeno, baza podataka je kolekcija trajno pohranjenih podataka, a u skladu s regulativom Europske unije, može biti i organizirani neelektronički skup podataka.

Računalni program koji podržava sve funkcionalnosti baze podataka naziva se sustav za upravljanje bazom podataka (SUBP) ili na engleskom jeziku *Database Management System* (DBMS). Ovaj sustav mora osigurati:

- zaštitu objekata baza podataka od neovlaštenog korištenja
- očuvanje integriteta podataka u bazi podataka
- obnovu podataka različitim načinima u slučaju gubitka podataka
- konkurentnost odnosno istovremeni pristup više različitih korisnika istim podacima
- identificiranje optimalne strukture za najprikladnije izvođenje manipulacija s podacima.

Prvi funkcionalni oblik baza podataka kroz 60-te i 70-te godine 20. stoljeća bile su **hijerarhijske** baze podataka. Okvirnu organizaciju hijerarhijskih baza podataka prikazuje slika 4.20.

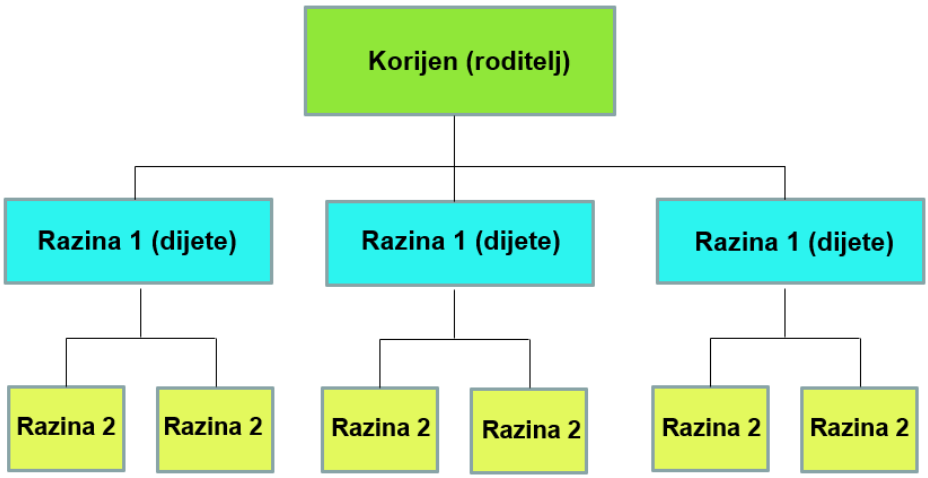

Slika 4.20. Hijerarhijski model baze podataka (izvor: autor)

Kao što je prikazano na slici , baza je uređena tako da su podaci organizirani u obliku stablaste strukture gdje je na vrhu pojam (entitet ili atribut) koji predstavlja korijen strukture, tzv. „roditelj", na kojeg se dalje veže prva razina pojmova (entiteta ili atributa), tzv. „djeca", a na svako se dijete veže druga razina pojmova. Tako na primjer korijen može biti Veleučilište, djeca u prvoj razini mogu biti Odjeli, a drugu razinu mogu činiti Studiji koje odjeli organiziraju.

Zahvaljujući rezultatima istraživanja koja je provodio E. F. Codd (1970) tijekom 70-ih godina 20. stoljeća sve više u upotrebu ulazi relacijski model podataka. Ovaj model omogućuje da bilo koja tablica podataka bude povezana s drugom tablicom preko zajedničkog atributa. Umjesto korištenja hijerarhijskih struktura za organiziranje podataka, Codd je dakle predložio prijelaz na korištenje podatkovnog modela gdje se podaci pohranjuju, a pristupa im se i povezuju ih se u tablicama bez reorganizacije tih tablica koje ih sadrže. Tablica 4.4. prikazuje svojstva odnosno prednosti i nedostatke relacijskog i hijerarhijskog modela.

Iako su se do današnjih dana razvili neki novi modeli organizacije baza podataka, relacijski model se još uvijek intenzivno koristi jer je jednostavan je za modeliranje i razumijevanje te još uvijek nudi najbrži pristup i pretraživanje podataka. Tijekom svog evolucijskog razvoja relacijske baze podataka su postale skalabilne (od jednostavnih i malih tzv. osobnih pa do velikih poslovnih baza podataka) i usvajale su određene suvremene orijentacije u pohrani i pretraživanju podataka, postajući od isključivo relacijskih baza podataka tzv. hibridne baze podataka koje podržavaju objektni i XML model podataka. U okviru vježbi koje se izvode u sklopu predmeta koje pokriva ovaj udžbenik koristi se alat za oblikovanje i obradu relacijskih baza podataka MS Access koji inicijalno sadrži osobnu (eng. *desktop*) relacijsku bazu podataka *MS Jet Database*.

Tablica 4.4. Usporedba hijerarhijskog i relacijskog modela podataka (izvor: autor)

Hijerarhijska DB	**Relacijska DB**
Jednostavnost zbog logičkog odnosa roditelj − dijete	Postojanje tablica za spremanje zapisa u tablična polja s jedinstvenim ključem za svaki zapis
Osnovna kategorija podataka naziva se „segment”	Osnovna kategorija podataka naziva se „polje”
Svako dijete (segment/čvor) nasljeđuje svojstvo svog roditelja	Nema pojma nasljeđivanja jer nema razina podataka
Segmenti su implicitno povezani (roditelj − dijete)	Tablice su izričito povezane „primarnim” i „stranim (vanjskim)” ključevima
Ne koristi ključeve, segmenti su povezani tzv. putevima kojima se dohvaćaju podaci	Ključevi daju jedinstvenu identifikaciju zapisa podataka i upućuju druge tablice tijekom procesa dohvaćanja podataka
Segmenti mogu sadržavati duplicirane podatke pa zahtijevaju puno obrade prilikom dohvaćanja podataka na zahtjev (pretraživanje i prebrojavanje duplikata uspoređivanjem naziva)	Zahvaljujući ključevima moguće je lako popisivanje podataka na zahtjev (jedinstvenost podataka) → SQL

U nastavku ćemo ukratko navesti osnovna svojstva novih i hibridnih modela organizacije suvremenih baza podataka.

Objektno-relacijske baze podataka predstavljaju kombinaciju oblikovanja jednostavnih upita i brzog pretraživanja relacijskih baza podataka kao i fleksibilnost modeliranja kompleksnih podataka objektnih baza podataka. Praktično se koristi mapiranje objektnog modela u relacijski model podataka. Polje u tablici baze podataka može sadržavati velike binarne podatke (eng. *Binary Large Object*, BLOB) kao što su programi, slike i zvuk te velike tekstualne podatke (eng. *Character Large Object*, CLOB) kao što su XML zapisi. U ovu skupinu spadaju npr. Oracle, PostgreSQL i MS SQL Server.

XML baze podataka isključivo manipuliraju strukturiranim, polustrukturiranim i nestrukturiranim XML zapisima. Hibridne ili XML-*enabled* baze podataka pohranjuju XML u CLOB ili mapiraju sadržaj u relacijske tablice. Za pretraživanje kroz XML strukturu podataka razvijeni su XPath i XQuery upitni jezici. Skupini isključivo XML baza podataka (eng. *native XML*) pripadaju npr. BaseX, eXist, Qizx i MarkLogic Server, dok su tipični primjeri za hibridne baze podataka (eng. *XML enabled*) DB2, Oracle, MS SQL Server i PostgreSQL.

Odlagališta teksta (eng. *Repository*) mogu biti sastavni dio XML baza ili hibridnih XML-relacijskih baza podataka. Odlagališta tekstualnih zapisa mogu sadržavati polustrukturirane i nestrukturirane XML zapise kao i PDF datoteke.

Skladišta podataka (eng. *Data Warehouse*) sadrže strukturirane podatke iz transakcijskih IS-a koji su prebačeni najčešće iz relacijskih baza podataka i služe kao podrška poslovnim procesima, te polustrukturirane i nestrukturirane podatke koji se prilagođavaju za kasniju obradu u analitičkim IS-ima (OLAP, *Reporting*, *Data Mining*).

Veliki podaci (eng. *Big Data*) su ukupni transakcijski podaci (kreirani, replicirani, korišteni), koji danas čine preko deset *petabytea*/god. Više od 50 % podataka su nestrukturirani podaci i interesantni su za praćenje obrazaca i ponašanja populacije, segmentiranje skupina kupaca, predviđanje tržišnih fluktuacija, balansiranje skladišnih zaliha i sl. Za analizu se koriste sustavi koji koriste umjetnu inteligenciju zasnovanu na strojnom učenju (eng. *Machine Learning*) primjenom višeslojnih neuronskih mreža (eng. *Deep Learning*). Ovako ustrojeni sustavi umjetne inteligencije koriste se općenito za prepoznavanja slika i govora, jezično prevođenje, analizu sentimenta i dr. analize društvenih mreža.

Najpoznatije baze podataka s obzirom na platformu na koju se mogu instalirati su:

- MS SQL Server [MS Windows]
- Oracle [*cross-platform*]
- MS Jet Database (Access) [MS Windows – *desktop*]
- MySQL [*cross-platform, open-source* GPL]
- PostgreSQL [*cross-platform, open-source* GPL].

Termin *cross-platform* koristi se općenito za programsku potporu koja radi pod raznim operacijskim sustavima, npr. MS Windows, UNIX, Linux i dr.

4.2.3.2. MS Access

Na auditornim vježbama u okviru predmeta koje pokriva ovaj udžbenik, za praktičan prikaz modeliranja podataka i oblikovanje relacijske baze podataka koristi se MS Access. Ovaj programski alat, koji je inače dio paketa MS Office Professional, vrlo je intuitivan, razdoblje učenja za primjenu osnovnih funkcionalnosti je vrlo kratak, a sve komponente baze podataka sadržane su u jednoj datoteci koja je na ovaj način lako prenosiva prijenosnim medijima ili računalnom mrežom. MS Access možemo opisati kao objektno orijentirani sustav za upravljanje relacijskim bazama podataka, a sastoji se od:

- Tablica (*Tables*) – spremnici podataka koji imaju neku zajedničku osobinu (odgovara npr. sadržaju jednog radnog lista Excela), sortiraju se po pojedinim poljima i mogu se staviti u odnos s poljima istog tipa u drugim tablicama, tj. mogu se postavljati relacije između tablica.
- Obrazaca (*Forms*) – grafička sučelja za jednostavniji i ugodniji unos podataka u tablice pomoću raznolikih kontrola (nazivne trake, unosna polja, kontrolni gumbi i dr.) te za kontrolu toka aplikacije (ulaz, izlaz, otvaranje i zatvaranje drugih obrazaca i sl.).
- Upita (*Queries*) – koriste se za izvlačenje i filtriranje željenih podataka iz tablica. Na jednostavan grafički način (mišem) definiraju se relacije i biraju željena polja odabranih tablica.
- Izvješća (*Reports*) – grafički dotjerani prikazi i ispisi podataka određenih upitima.
- Makroa (*Macros*) – kratki programski odsječci pisani u VBA-u (*Visual Basic for Applications*) za jednostavnije akcije kao što je izvršavanje stavki izbornika.
- Modula (*Modules*) – programski moduli pisani u VB-u (*Visual Basic*), C++, C# ili nekom drugom objektno orijentiranom programskom jeziku.

Aplikacije oblikovane u ovom razvojnom alatu pogodne su za lokalnu instalaciju, kao i za instalaciju na manjim lokalnim mrežama. Treba imati na umu da u znatnoj mjeri zagušuju mrežni promet. Osim ugrađene relacijske baze MS Jet, pridruženom relacijskom bazom smatra se i MS

SQL Server koji se instalira kao samostalna baza podataka, a aplikacije za obradu i upravljanje podacima se izrađuju kao odvojene datoteke − tzv. MS Access projekti. Na ovaj se način mogu razvijati aplikacije koje imaju prihvatljiva svojstva i u većim računalnim mrežama. Ms Access se na sličan način može koristiti i s bazama podataka drugih proizvođača korištenjem pristupa preko ODBC sučelja (*Open DataBase Connectivity*) ugrađenog u MS Windowse.

Kao primjer jednostavnosti upotrebe možemo uzeti oblikovanje baze podataka zasnovane na reduciranom Chenovom EV dijagramu prikazanom na slici 4.14. kao konceptualnom modelu podataka za postupak upućivanja djelatnika na sistematske preglede. Polazna su točka oblikovanja tablica podataka „Djelatnici" i „Pregledi". Polazi se od oblikovanja strukture tablica. Ovu strukturu možemo u logičkom smislu nazvati i kodeks atributa ili relacijska shema ili intenzija. Pri oblikovanju ove strukture navode se još i dodatni podaci o domenama i formatu prikaza podataka pa se može reći da ta struktura predstavlja jedan opsežan rječnik podataka. Svaki navedeni atribut u terminologiji relacijskih baza podataka naziva se **polje** tablice podataka. Slika 4.21. prikazuje strukturu tablice „Djelatnici".

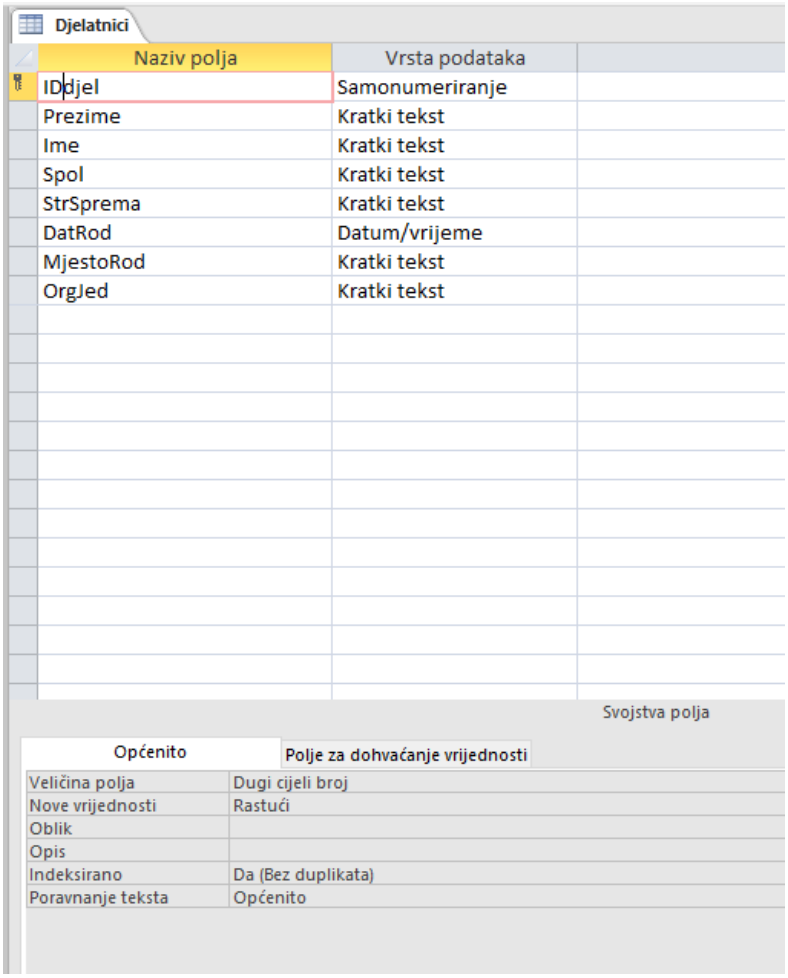

Slika 4.21. Struktura tablice „Djelatnici" (izvor: autor)

Na slici vidimo koja polja (atributi) čine tablicu „Djelatnici", a ispod popisa polja vidimo svojstva trenutno odabranog polja „IDdjel" koje predstavlja primarni ključ ove tablice. Svaki objekt unutar razvojnog okruženja MS Accessa ima dva osnovna prikaza: prikaz dizajna i funkcionalni prikaz (npr. tablice, obrasci, upiti, izvješća i sl.). Na slici 4.21. dan je prikaz dizajna tablice. Prikaz tablice prikazan je na slici 4.22.

Djelatnici

IDdjel	Prezime	Ime	Spol	StrSprema	DatRod	MjestoRod	OrgJed
1	Pecić	Adam	M	VSS	12.3.1990.	10000	Skladište
2	Petrić	Adela	Ž	VŠS	16.6.1992.	47000	Proizvodnja
3	Weller	Boško	M	SSS	3.3.1993.	44010	Proizvodnja
4	Weber	Branka	Ž	SSS	1.8.1992.	47000	Transport
5	Matoković	Dražen	M	SSS	16.1.1991.	47000	Trgovina
6	Topić	Dubravka	Ž	SSS	22.11.1990.	32238	Transport

Slika 4.22. Funkcionalni prikaz sadržaja tablice „Djelatnici” (izvor: autor)

Na sličan je način načinjena i struktura tablice „Pregledi” koja je prikazana na slici 4.23.

Pregledi

Naziv polja	Vrsta podataka
IDpreg	Samonumeriranje
IDdjel	Broj
DatPreg	Datum/vrijeme
Prolaz	Da/ne
Klinika	Kratki tekst

Općenito	Polje za dohvaćanje vrijednosti
Veličina polja	Dugi cijeli broj
Oblik	
Decimalna mjesta	Automatski
Ulazna maska	

Slika 4.23. Struktura tablice „Pregledi” (izvor: autor)

Može se uočiti da i ova tablica ima svoj primarni ključ o kojem funkcionalno zavise svi ostali atributi (polja) koji sadrži jedinstvene (bez duplikata) vrijednosti i na neki način jamči konzistentnost cijele ove tablice. Kao i u prethodnoj tablici, vrsta ovog podatka je *Samonumeriranje*, što ustvari znači da je to broj koji se automatski uvećava za jedan sa svakim novim zapisom, a kao veličina polja naveden je opis *Dugi cijeli broj*. Može se primijetiti da tablica „Pregledi” sadrži polje „IDdjel” koje je istog naziva kao i primarni ključ tablice „Djelatnici”. Ovdje je namjerno korišten isti naziv kako bismo naznačili da su to polja putem kojih će se načiniti prirodno spajanje ovih dviju relacija u jednu veću relaciju. U praksi to ne mora biti slučaj i spojna polja mogu imati različite nazive. Ono o čemu **obavezno** moramo voditi računa je da spojna polja budu istog tipa i veličine. Kao što se vidi na slikama, polje „IDdjel” u tablici „Pregledi” je oblikovano kao *Broj* veličine *Dugi cijeli broj*, kao i polje „IDdjel” u tablici „Djelatnici”. U tablici

„Pregledi" polje „IDdjel" čini tzv. vanjski ili strani ključ. Zapamtimo: **„Polje primarnog i vanjskog ključa, koja čine spojna polja za prirodno spajanje relacija, moraju biti istog tipa i veličine".**

Postupak prirodnog spajanja dviju tablica (relacija) i opis svojstava ovog spoja provodi se u MS Accessu putem alatne trake *Alati za baze podataka*, alatne skupine *Odnosi* i odabirom postupka *Odnosi*. U radno područje „Odnosi" potrebno je postaviti tablice koje želimo povezati te nakon toga klikom i držanjem tipke miša na polju primarnog ključa tablice „Djelatnici" povlačiti pokazivač miša na polje vanjskog ključa tablice „Pregledi" i pustiti tipku miša. Tada nam se iscrta spojnica između ova dva polja. Nakon toga klikom desne tipke miša otvaramo mali izbornik iz kojeg odaberemo stavku *Uređivanje odnosa*. Na slici 4.24. vidimo novopostavljenu relacijsku vezu i otvoren dijalog za uređivanje odnosa.

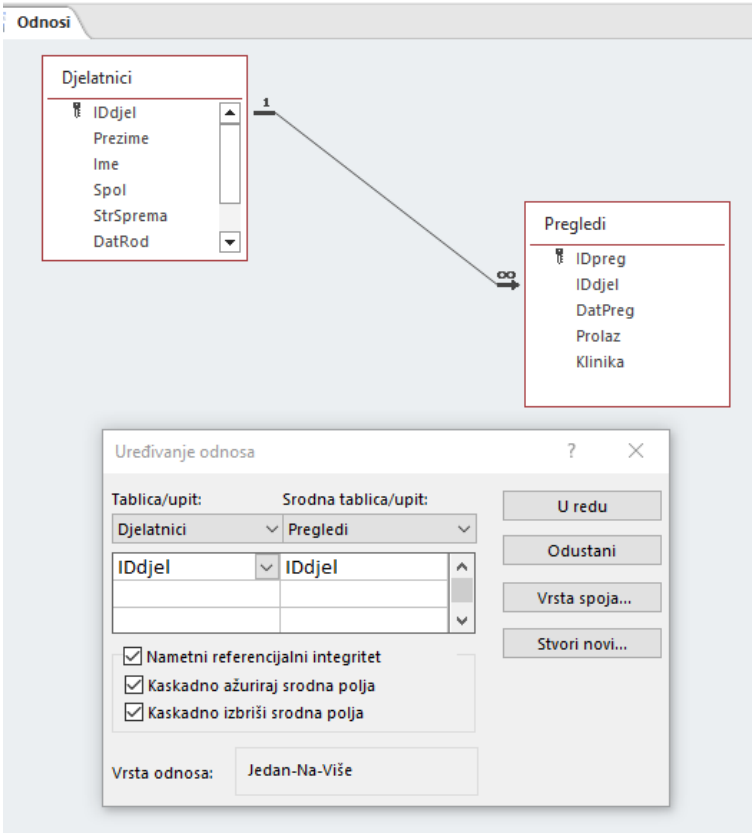

Slika 4.24. Postavljanje i uređivanje relacijskog odnosa između tablica (izvor: autor)

Sada je potrebno prvo odabrati vrstu spoja, što činimo klikom na gumb *Vrsta spoja*, nakon čega se otvara prozor s novim dijalogom prikazanim na slici 4.25.

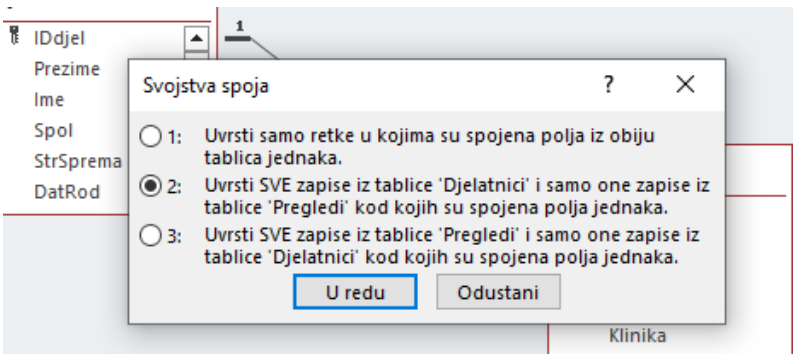

Slika 4.25. Uređivanje svojstva polja (izvor: autor)

Iz prikaza na slici 4.25. vidimo da postoje tri mogućnosti. Odabran je slučaj gdje će biti prikazani svi zapisi iz tablice „Djelatnici" i samo oni zapisi iz tablice „Pregledi" za koje su spojna polja jednaka. Klikom na gumb *U redu* vraćamo se na prikaz sa slike 4.24. gdje možemo izabrati nametanje tzv. **referencijalnog integriteta**. Referencijalni integritet je ustvari zaštita od pogrešnog unosa i čini je sustav pravila koja osiguravaju da veze između zapisa u povezanim tablicama budu važeće i da se izbjegne slučajno brisanje i izmjena podataka. Na primjer, unosom novog zapisa u tablici „Pregledi" za odabrani zapis u tablici „Djelatnici", automatski će nam se iz zapisa iz tablice „Djelatnici" prenijeti vrijednost polja „IDdjel" u zapis u tablici „Pregledi". Isto tako, pokušajem brisanja zapisa o pojedinom djelatniku u tablici „Djelatnici", sustav referencijalnog integriteta će nas upozoriti da to nije dopušteno jer postoje povezani podaci u jednoj ili više tablica. Na slici 4.24. vidimo da osim potvrdnog okvira za nametanje referencijalnog integriteta postoje još dva potvrdna okvira za uključivanje tzv. kaskadnog ažuriranja i kaskadnog brisanja srodnih polja. Kaskadno ažuriranje se odnosi na mogućnost automatskog ispravljanja vrijednosti svih spojnih polja u slučaju izmjene vrijednosti polja primarnog ključa. Kaskadno brisanje omogućava brisanje svih zapisa u povezanim tablicama u slučaju brisanja glavnog zapisa (zapisa s primarnim ključem) za jednake vrijednosti spojnih polja. Brisanjem zapisa iz tablice „Djelatnici", briše se dakle i zapis (ili više njih) iz tablice „Pregledi". Zapamtimo: „**Da bismo definirali veze između tablica i nametnuli referencijalni integritet u postupku *Odnosi*, sve tablice koje vežemo moraju biti zatvorene jer ovaj postupak zahtijeva isključiv pristup tablicama".**

Ovako definirana veza između dviju ili više tablica vrijedi apsolutno za cijelu bazu podataka. Otvaranjem sadržaj tablice „Djelatnici" možemo primijetiti oznaku + ispred prvog zapisa svakog sloga. Klikom na pojedinu oznaku + otvara se mogućnost pregleda, upisa ili brisanja pojedinog povezanog zapisa tablice „Pregledi" (slika 4.26.).

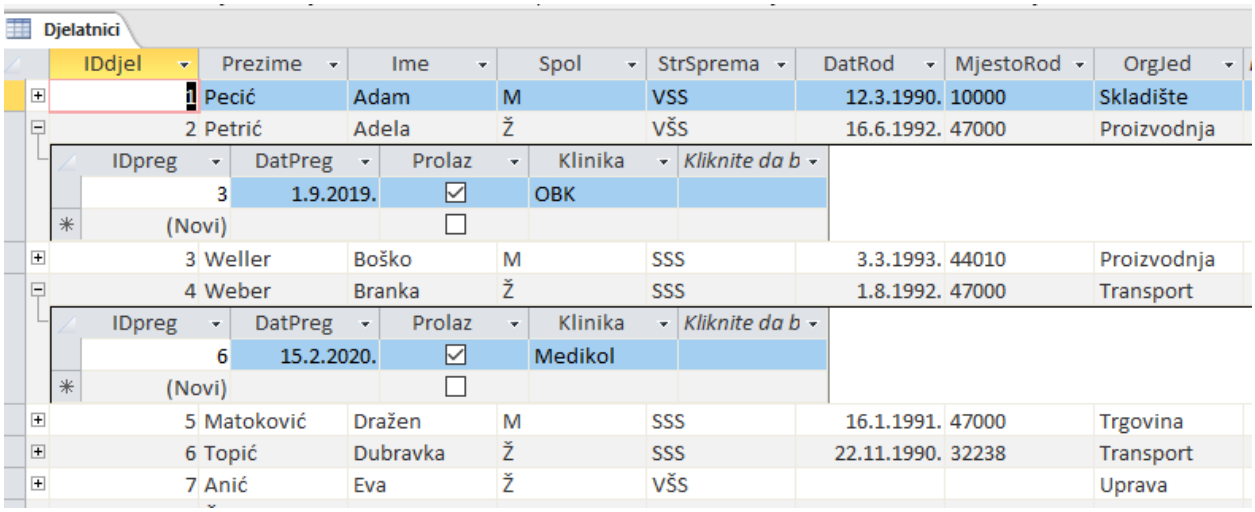

Slika 4.26. Posljedica nametanja referencijalnog integriteta relacijske veze (izvor: autor)

Kako bismo dobili tablični pregled novooblikovane relacije, potrebno je oblikovati upit (*query*). MS Access nam omogućava razvoj upita različitih razina složenosti u intuitivnom grafičkom okruženju. Izbor tablica uvelike podsjeća na postupak uređivanja odnosa u prethodno opisanom postupku *Odnosi*. S obzirom na to da smo već oblikovali apsolutno važeću relacijsku vezu, odabirom ovih dviju tablica automatski će se iscrtati ova relacijska veza sa svim zadanim svojstvima. U slučaju da nismo definirali ovakvu relacijsku vezu, u radnom području upita bismo mogli definirati relativnu, tj. lokalno važeću relacijsku vezu između odabranih tablica i definirati vrstu spoja. Međutim, u tom slučaju ne bismo mogli postaviti referencijalni integritet, a relacijska veza bi vrijedila samo dok je upit aktivan. Njegovim bi se zatvaranjem ova veza ukinula i ne bi više postojala do njegovog ponovnog aktiviranja. Pri oblikovanju upita možemo izabrati koja polja

iz obiju tablica želimo vidjeti u funkcionalnom tabličnom prikazu, možemo filtrirati zapise prema nekoj od vrijednosti obuhvaćenih polja te ih sortirati (uzlazno i silazno) prema nekoj izabranoj vrijednosti odnosno polju. Prikaz dizajna upita „Q_Sistematski" prikazan je na slici 4.27.

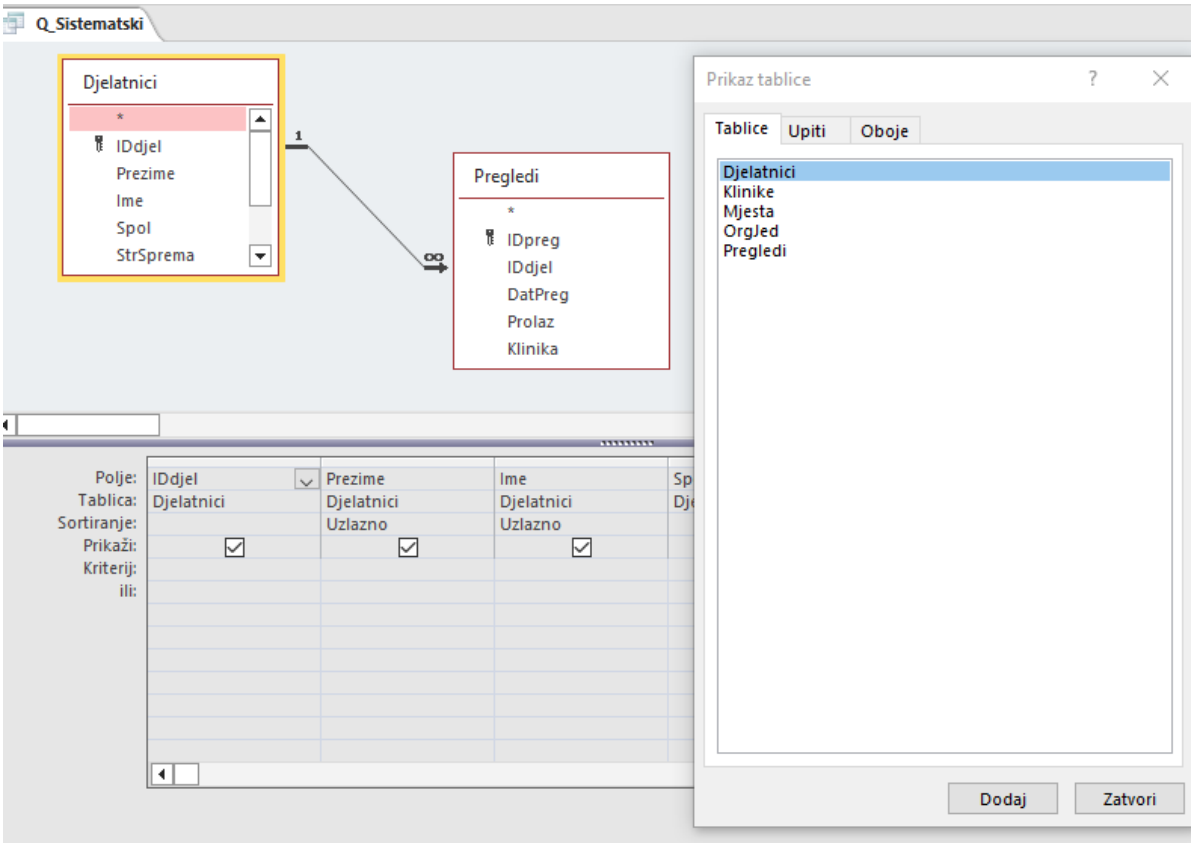

Slika 4.27. Prikaz razvoja upita „Q_Sistematski" (izvor: autor)

Q_Sistematski

IDdjel	Prezime	Ime	Spol	StrSprema	DatRod	MjestoRod	OrgJed	DatPreg	Prolaz	Klinika
7	Anić	Eva	Ž	VŠS			Uprava		☐	
9	Anić	Ivan	M	SSS			Odjel MFP		☐	
11	Čapić	Jasna	Ž	VŠS			Odjel kadrovsk		☐	
10	Crnković	Ivana	Ž	SSS			Skladište		☐	
8	Čupić	Filip	M	VSS			Odjel MFP		☐	
16	Darac	Mirna	Ž	VŠS			Proizvodnja		☐	
12	Đurić	Jurica	M	SSS			Odjel kadrovsk		☐	
23	Franović	Nebojša	M	VSS	30.8.1992.	47000	Proizvodnja	12.3.2020.	☑	OBK
20	Gradinić	Zdenko	M	VSS			Uprava		☐	
17	Lončarić	Mladen	M	SSS			Skladište		☐	
14	Marojević	Lovro	M	VŠS			Transport		☐	
5	Matoković	Dražen	M	SSS	16.1.1991.	47000	Trgovina	12.2.2020.	☑	OBK
15	Miljac	Mirjana	Ž	VŠS			Trgovina		☐	

Slika 4.28. Funkcionalni tablični prikaz pokrenutog upita (izvor: autor)

Slika 4.28. prikazuje funkcionalni tablični prikaz pokrenutog upita „Q_Sistematski" koji prikazuje odabrane podatke iz obiju povezanih tablica sortiranih prvo po prezimenu, a zatim po imenu osobe. Upit zapravo nije potpuno nova tablica koja zauzima novi memorijski prostor prepisujući iste podatke na novo mjesto, već je to samo na nov način presložen postojeći sadržaj ovih povezanih tablica. Ono što smo u prikazanom primjeru jednostavno i elegantno odradili pomoću grafičkog razvojnog sučelja ustvari je rezultat izvršavanja zapisa oblikovanog u SQL kodu. Ovaj je zapis prikazan na slici 4.29. u trećem načinu prikaza karakterističnom za upite, tj. SQL prikazu.

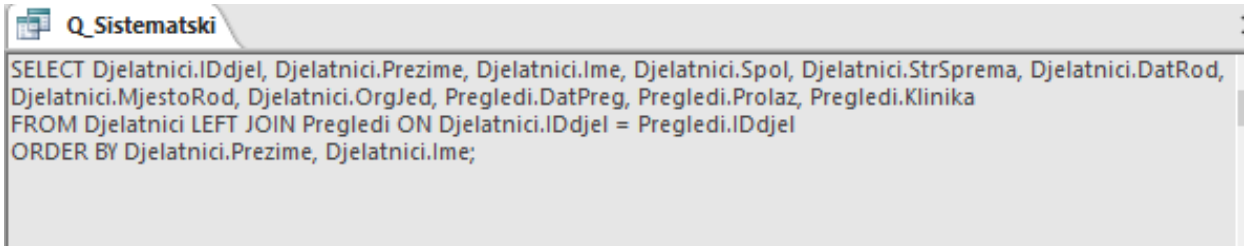

Slika 4.29. SQL prikaz upita „Q_Sistematski” (izvor: autor)

U ovom su odjeljku prikazane osnovne mogućnosti programskog alata MS Access kojima su ilustrirani i praktično pojašnjeni postupci logičkog i fizičkog modeliranja podataka primjenom jednostavnog objektno orijentiranog razvojnog sustava za oblikovanje i održavanje baza podataka primjenom grafičkog korisničkog sučelja. Detaljniji uvid u funkcionalnosti ovog sustava dobit će se svakako u okviru vježbi.

Na sadržaj

5. OSNOVNA PODJELA INFORMACIJSKIH SUSTAVA

Suvremeni poslovni informacijski sustavi se načelno dijele na transakcijske (ponekad se još nazivaju i operacijskim) IS-ove i analitičke IS-ove. Kako su suvremeni IS-ovi, za razliku od nekadašnjih tzv. monolitnih IS-ova (ograničenih na lokalne mreže), sve više potpuno mrežno koncipirani, često se označavaju skraćenicama OLTP (engl. *OnLine Transaction Processing*) i OLAP (engl. *OnLine Analytical Processing*). Odnos ovih dvaju sustava prikazan je na slici 5.1.

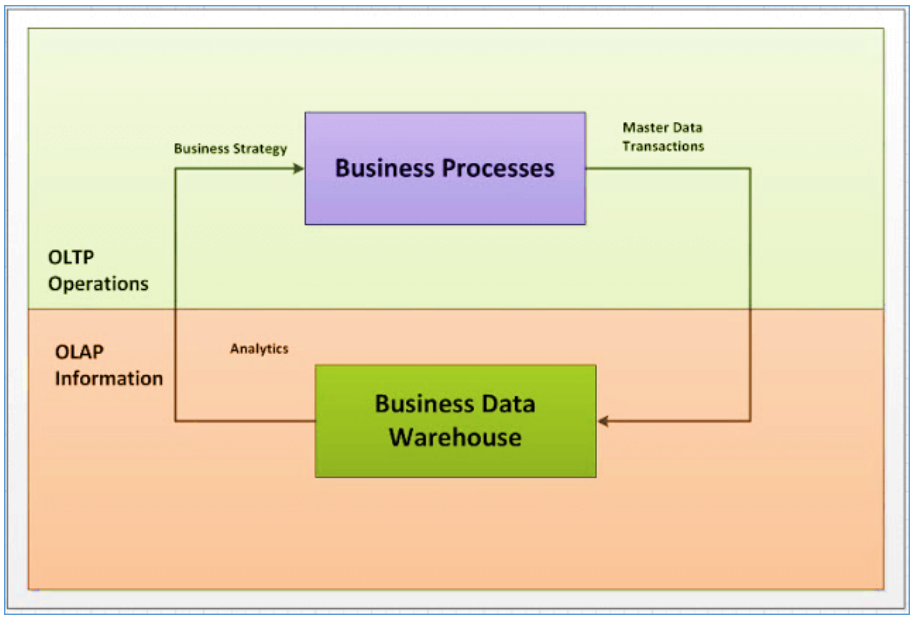

Slika 5.1. Odnos OLTP i OLAP informacijskih sustava (Taylor, 2023)

Kao što se vidi na slici, OLTP prati i opisuje pokazatelje poslovnog procesa, dok OLAP služi analizi prikupljenih pokazatelja (informacija) koje su kroz više poslovnih ciklusa prikupljani u analitičkom IS-u, gdje se najčešće pohranjuju u tzv. skladištu podataka (engl. *Data Warehouse*). Pritom skladište podataka može sadržavati i informacije prikupljane i iz drugih, vanjskih sustava, a naprednim metodama analize prikupljenih podataka i informacija mogu se oblikovati čimbenici za oblikovanje i korekciju poslovne strategije poslovnog sustava.

5.1. Transakcijski informacijski sustavi

Najčešći oblik suvremenog transakcijskog sustava prikazan je na slici 5.2. Sastoji se od tri osnovne komponente: sveobuhvatnog skupa poslovnih transakcija (engl. *Enterprise Resource Planning*, ERP), podsustava za upravljanje korisnicima usluga (engl. *Customer Relationship Management*, CRM) i podsustava za upravljanje dobavljačima (engl. *Supply Chain Management*, SCM). Svaki se podsustav sastoji se od baze podataka, aplikacijske logike i komunikacijskih slojeva prema poslovanju i korisnicima. Dok SCM i CRM čine horizontalne integracijske komponente s poslovnom okolinom, ERP čini glavnu okosnicu poslovanja. Za ERP se može reći da je jedan sveobuhvatni transakcijski IS koji obuhvaća sve segmente poslovanja (upravljanje ljudskim potencijalima, planiranje i upravljanje proizvodnjom, odnose s korisnicima, odnose s dobavljačima i dr.). Najpoznatiji proizvođač ERP sustava na svjetskoj razini je međunarodna korporacija SAP AG (*Systems, Applications and Products in Data Processing*) osnovana 1972. godine u Waldorfu u Njemačkoj koja danas ima preko 12 milijuna korisnika širom svijeta.

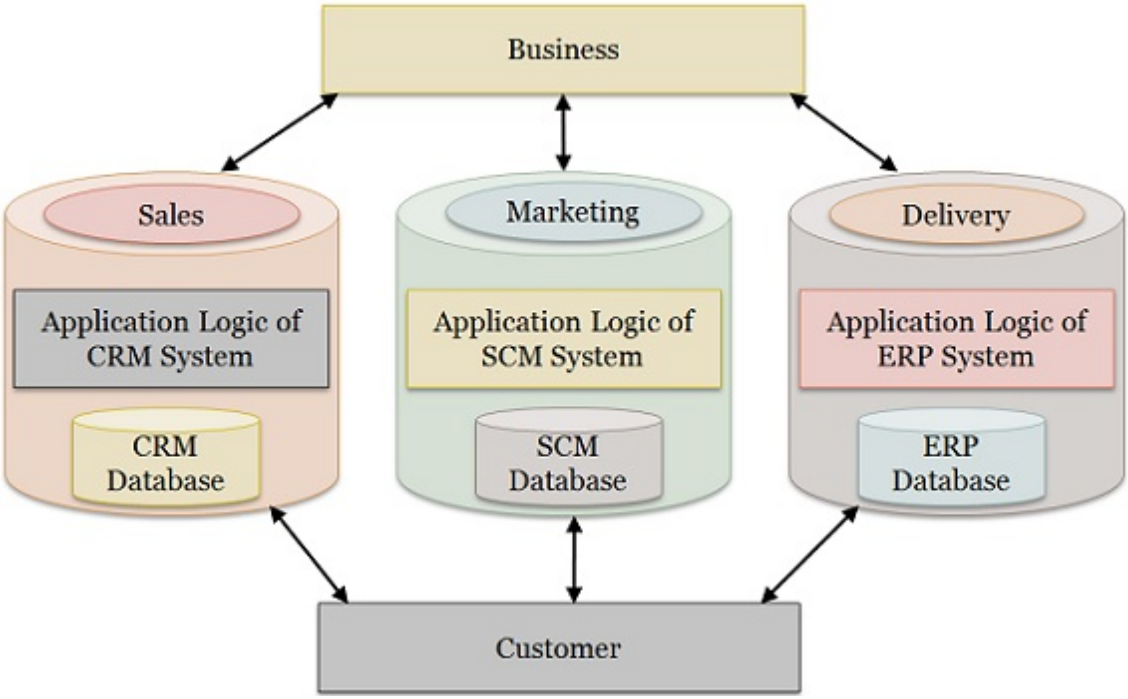

Slika 5.2. Osnovna struktura suvremenih transakcijskih sustava (Growth Stack, 2022)

U literaturi i praksi ERP sustav odnosi se na industrijski termin za visokointegrirani aplikacijski programski paket (Belak i Ušljebrka, 2014) koji podržava rad integriranoga IS-a u praksi, a oblikovan je s dva osnovna cilja:

- podržavanje poslovnih procesa u cilju postizanja veće efikasnosti obavljanja pojedinih poslovnih aktivnosti i poslovnog sustava u cjelini
- osiguravanje potrebnih informacijskih podloga za uspješno upravljanje pojedinim poslovnim sustavima.

Na temelju navedenih ciljeva može se zaključiti kako ERP podržava organizacijski sustav na operativnoj i strateškoj razini. Na operativnoj razini pomaže u koordiniranju svih poslovnih procesa kako bi se postigla što veća učinkovitost u njihovu obavljanju, dok na strateškoj razini pruža sve potrebne informacije za upravljanje sustavom i provedbu organizacijskih promjena potrebnih za opstanak i razvoj organizacije. Treba naglasiti da ono što ERP sustavu omogućava ispunjavanje ova dva osnovna cilja je njegova glavna karakteristika – integracija podataka. Integracija podataka podrazumijeva da su svi relevantni podaci i informacije dostupni svima kojima su potrebni, na bilo kojoj lokaciji i u bilo koje vrijeme, a zasniva se na postojanju jedinstvene baze podataka (Belak i Ušljebrka, 2014).

Nakon ovih razmatranja može se postaviti logično pitanje: Gdje je tu sigurnost i zaštita? Slika 5.3. prikazuje odnos podsustava sigurnosti i zaštite (SiZ) s podsustavima ERP sustava. Može se reći da je podsustav SiZ integriran s ključnim podsustavima (modulima) ERP-a. Ključni podaci iz podsustava SiZ pohranjuju se u središnjoj bazi podataka poslovnog sustava, sinkroniziraju se s podacima podsustava za upravljanje ljudskim resursima, knjiže se troškovi usluga u domeni SiZ-a u financijskim aplikacijama, bilježi se nabava i održavanje radne i zaštitne opreme (nabava, održavanje, atesti i certifikati) kroz upravljanje imovinom, prosljeđuju se informacije prema korporacijskim izvještajima, reguliraju se nadležnosti prema okruženju i dr. U načelu, kod većih poslovnih sustava često postoji i teritorijalna razvedenost, tj. svi poslovni kapaciteti nisu locirani na istom mjestu. Načelna shema organizacije takvih sustava prikazana je na slici 5.4.

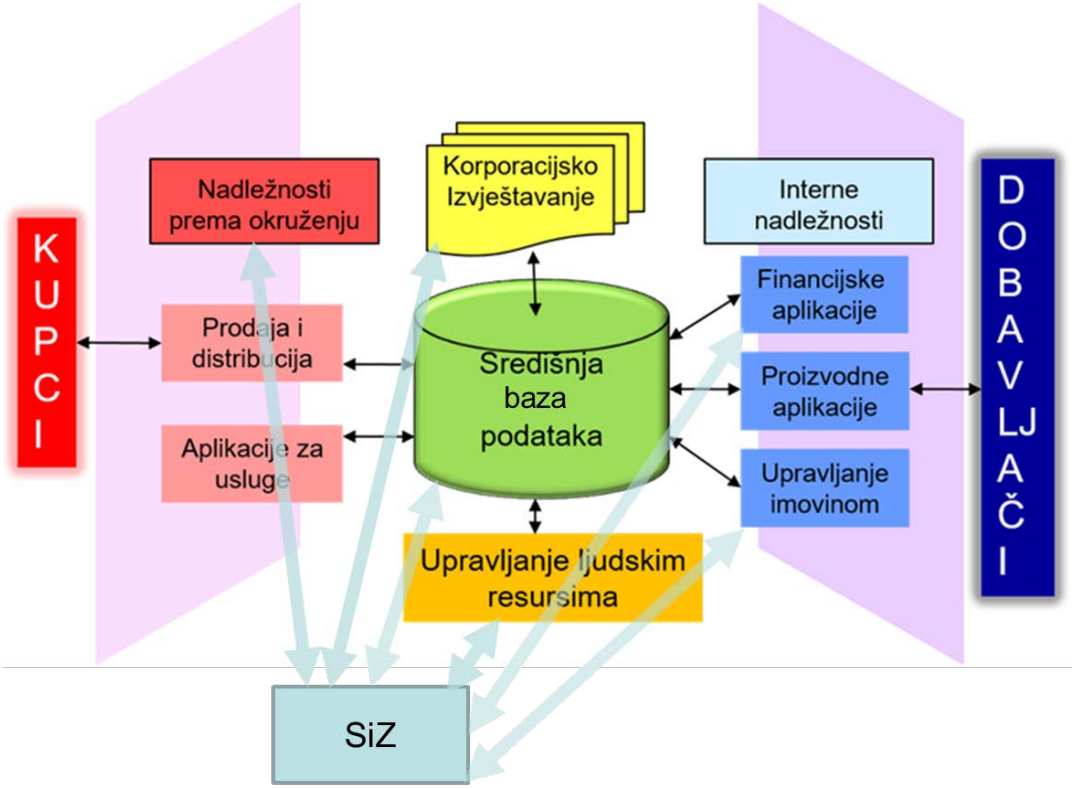

Slika 5.3. Odnos podsustava ZNR s podsustavima ERP-a (izvor: autor)

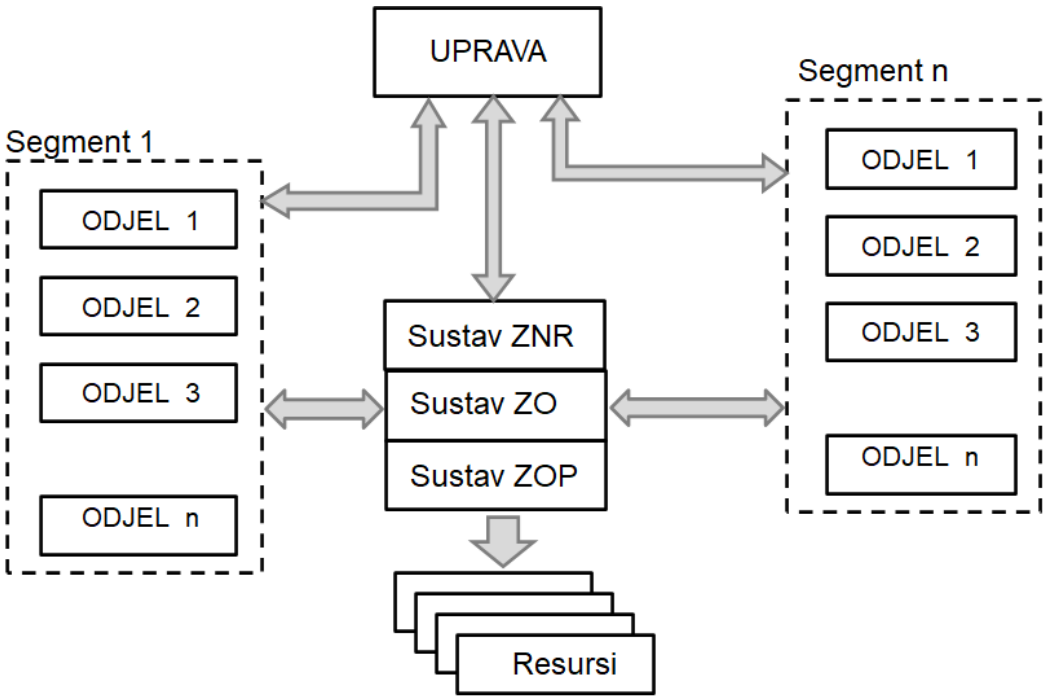

Slika 5.4. Položaj podsustava SiZ unutar složenih poslovnih sustava (izvor: autor)

U slučajevima kao što je ovaj prikazan na slici 5.4., najčešće nalazimo programska rješenja za poslove sigurnosti i zaštite, ustrojene kao jedan integrirani podsustav koji je uklopljen u cjelovito rješenje za upravljanje cjelokupnim zaštitnim aktivnostima: zaštiti na radu, zaštiti okoliša i zaštiti od požara. Takav podsustav može biti integriran u cjelokupni IS (ERP) tako da koristi jedinstvene

nomenklature raznih resursa tvrtke ili pak u slučajevima jednostavnijih IS-a tvrtke (ustanove) kao samostalno programsko rješenje uz periodičnu sinkronizaciju (automatsku ili ručnu) s ključnim evidencijama. Resurse, na kojima počiva ovakav podsustav SiZ, čine skupovi mjera, postupaka, propisa, pravila, politika, ljudstva i sredstava angažiranih u cilju provođenja sigurnosti i zaštite. U slučajevima gdje je obavezna detekcija, mjerenje i evidentiranje čimbenika koje najčešće susrećemo u domeni zaštite od požara (ZOP) i zaštite okoliša (ZO), sve je više prisutan udaljeni mrežni pristup putem interneta pri čemu svi suvremeni uređaji slijede tehnološko rješenje „interneta stvari" (engl. *Internet of Things*, IoT) gdje uređaji međusobno komuniciraju putem interneta (oblaka) bez posredovanja čovjeka. Načelna shema ovakvih sustava prikazana je na slici 5.5.

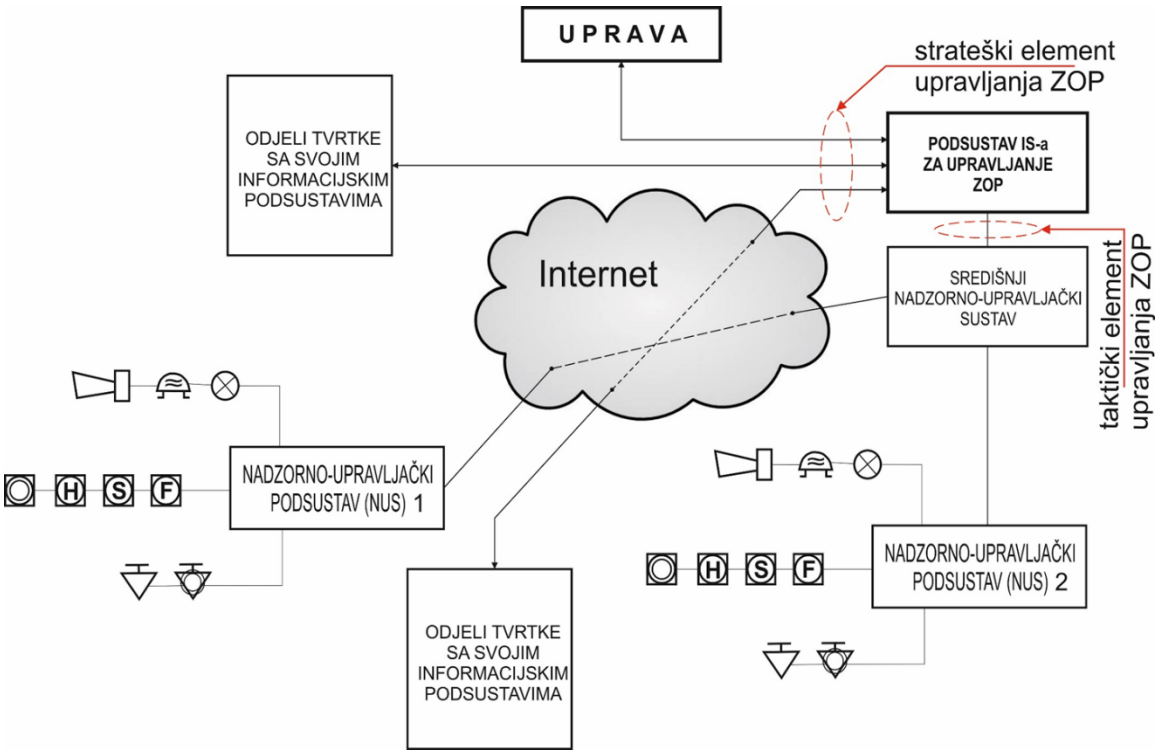

Slika 5.5. Povezivanje sustava ZOP-a putem oblaka primjenom IoT-a (izvor: autor)

Kombinirani nadzorno upravljački sustavi (NUS), koji su više taktički usmjereni, uglavnom su autonomni u odnosu na strateški usmjerene podsustave (npr. sustavi evidencije opreme, ljudstva i sl.), ali mogu biti i u određenoj mjeri integrirani u smislu korištenja zajedničkih nomenklatura i pohrane logova (dnevnika događaja). Oba navedena funkcionalna segmenta ZOP-a mogu biti u kontekstu današnjih otvorenih sustava geografski dislocirani kako međusobno tako i u odnosu na cjelokupni IS tvrtke ili ustanove. Pojedini segmenti mogu biti vezani IP vezama kao cjeline (podsustavi) ili kao pojedini IP adresabilni senzori, alarmni elementi ili aktuatori (upravljivi elementi i uređaji) za izravno gašenje požara. Slična organizacija vezanja strateški i taktički usmjerenih elementa može biti primijenjena i u specifičnim područjima ZNR-a te u području zaštite okoliša (mjerenje koncentracije štetnih plinova, mjerenje koncentracije štetnih tvari u tlu, porast intenziteta ionizirajućeg zračenja, alarmiranje o nastalom prekoračenju dozvoljenih doza i sl.).

5.2. Analitički informacijski sustavi

Analitički sustavi su programski alati ili platforme koje se koriste za prikupljanje, organiziranje, analizu i interpretaciju velikih količina podataka s ciljem donošenja kvalitetnih poslovnih odluka. Ovi se sustavi koriste u različitim područjima kao što su: poslovno upravljanje, financije, marketing, operacije, ljudski potencijali i dr. Obuhvaćaju različite tehnike i metode za analizu podataka, uključujući statističku analizu, poslovnu inteligenciju, rudarenje podataka, strojno učenje i prediktivnu analitiku. Oni omogućuju organizacijama da pretvore sirove podatke u vrijedne informacije, identificiraju trendove, donose kvalitetne odluke, optimiziraju poslovne procese i poboljšavaju ukupne performanse. Ovi sustavi obično integriraju podatke iz različitih izvora, poput internih sustava, vanjskih izvora podataka i društvenih medija i senzora kako bi stvorili cjelovitu sliku poslovanja. Korisnicima omogućavaju da vizualiziraju podatke putem grafikona, izvještaja i interaktivnih panela za upravljanje te da istražuju podatke kako bi otkrili skrivene uzorke i informacije. S poslovnog stajališta, analitički sustavi imaju ključnu ulogu u suvremenom poslovnom okruženju jer pomažu organizacijama da budu konkurentnije i da donose bolje odluke temeljene na podacima. Što se tiče razina upravljanja i njima potrebnim analizama podataka situacija je relativno složena i možemo je okvirno predočiti trokutnim modelom (presjekom piramide) prikazanim na slici 5.6.

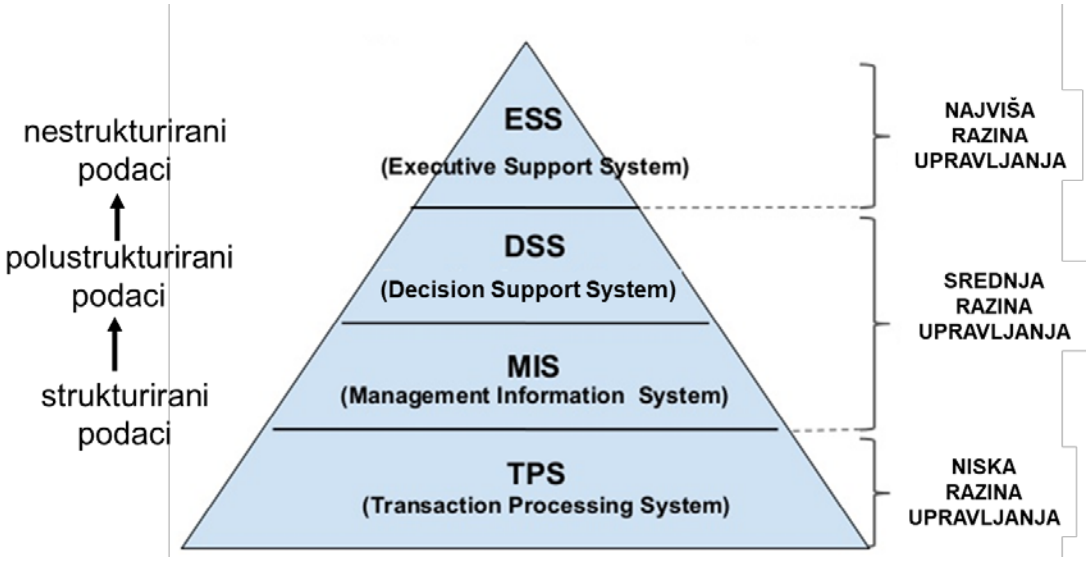

Slika 5.6. Odnos razina upravljanja, vrsta IS-a i strukture podataka (izvor: autor)

Može se primijetiti da s porastom razine upravljanja (analitike) podaci postaju sve manje strukturirani, tj. nemaju cikličku strukturu svojstvenu relacijskim bazama podataka. Na početku poglavlja navedena je osnovna podjela IS-a na OLTP i OLAP. Najniža razina upravljanja prikazana na slici 5.6. je razina transakcijskog sustava (TPS) koji je u suštini OLTP sustav. Ostale više razine predstavljaju OLAP sustave. OLAP je tehnologija koja omogućava analizu velikih količina podataka iz različitih izvora u stvarnom vremenu. Ovi izvori mogu biti jednodimenzionalni ili višedimenzionalni. Ako se analiziraju jednodimenzionalni podaci, radi se o ROLAP (engl. *Relational* OLAP) pristupu čija se analiza zasniva na relacijskim bazama podataka i SQL pristupu za izvlačenje podataka. Međutim, može se reći da se za složenije analize danas više koristi MOLAP (engl. *Multidimensional* OLAP) pristup koji koristi posebno dizajnirane multidimenzionalne baze podataka za pohranu i analizu podataka. U MOLAP pristupu podaci se prethodno agregiraju i pohranjuju u optimiziranoj strukturi koja omogućava brz pristup podacima. MOLAP sustavi često koriste tzv. kocke podataka (engl. *data cubes*) za organizaciju i manipulaciju podacima. Kocke podataka predstavljaju multidimenzionalne prikaze podataka koji

omogućavaju brze analize i rezime podataka. MOLAP pristup je obično brži od ROLAP pristupa za složene upite, ali može biti manje fleksibilan u smislu podrške za izvore podataka i promjene u strukturi podataka. Primjer osnovnih manipulacija podacima u kocki podataka prikazan je na slici 5.7.

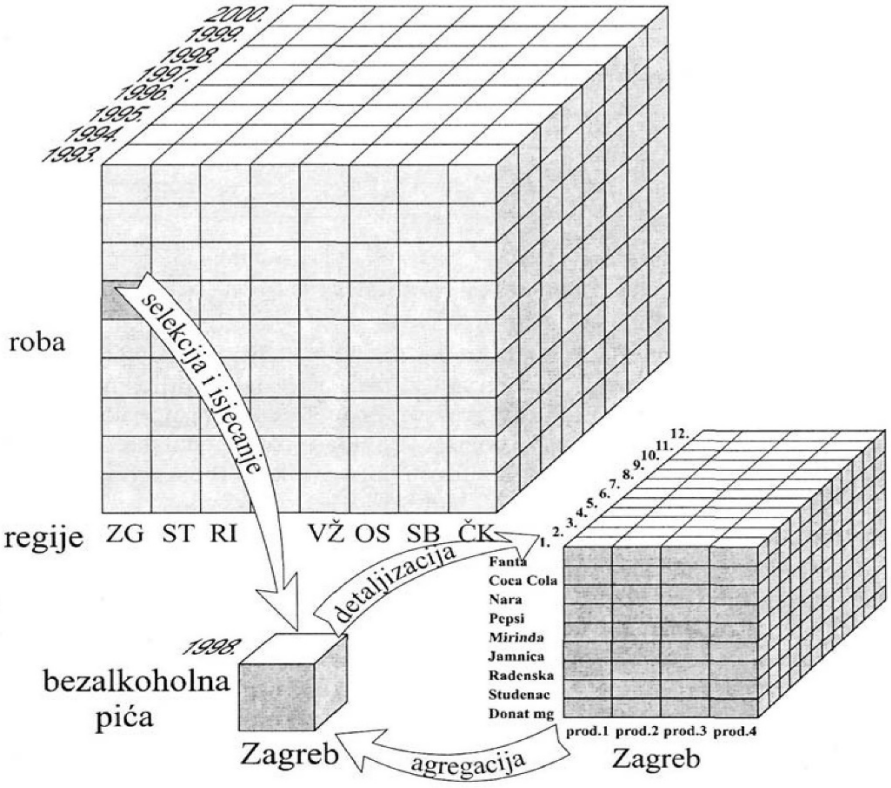

Slika 5.7. Primjer MOLAP analize unutar kocke podataka (Panian i ostali, 2010)

Međutim, kako bi se poslovnim organizacijama omogućila analiza podataka koji se prikupljaju iz različitih izvora te naknadno agregiraju radi učinkovite analize podataka i donošenje kvalitetnih poslovnih odluka, međusobno se povezuju analitički informacijski sustavi i skladišta podataka (engl. *Data Warehouse*) te se koriste zajedno kako bi organizacijama omogućili učinkovitu analizu podataka i donošenje informiranih poslovnih odluka. Nekoliko je ključnih veza između njih:

- Izvor podataka. Skladište podataka obično služi kao glavni izvor podataka za analitičke informacijske sustave. Podaci se iz različitih izvora (baza podataka, datoteka, vanjskih izvora itd.) ekstrahiraju i pohranjuju u skladištu podataka gdje se konsolidiraju i organiziraju za daljnju analizu.
- Centralizacija podataka. Skladište podataka omogućuje centralizaciju podataka iz različitih izvora. To znači da se podaci iz različitih operativnih sustava ili poslovnih jedinica mogu kombinirati i pohraniti na jednom mjestu. Ova centralizacija olakšava konzistentan pristup podacima za analitičke svrhe.
- Integracija podataka. Skladište podataka omogućuje integraciju podataka iz različitih izvora. Podaci se transformiraju, čiste i modeliraju u skladištu podataka kako bi se osigurala konzistentnost, kvaliteta i prikladnost podataka za analizu. Integracija podataka olakšava analitičkim informacijskim sustavima da pristupe i koriste te podatke za izvođenje analitičkih upita.

- Optimizacija performansi. Skladište podataka je dizajnirano i optimizirano za brz pristup i analizu velikih količina podataka. Strukturirani su indeksi, optimizirani upiti i implementirane tehnike pohrane podataka koje poboljšavaju performanse analitičkih upita. To omogućuje analitičkim informacijskim sustavima da brzo i učinkovito izvršavaju analizu podataka.
- Vizualizacija i izvješćivanje. Analitički informacijski sustavi koriste podatke iz skladišta podataka za generiranje vizualnih prikaza, izvješća, grafikona i panela za upravljanje. Podaci se prezentiraju tako da olakšavaju razumijevanje i tumačenje informacija. Ovi vizualni prikazi pomažu korisnicima u donošenju informiranih odluka zasnovanih na analizi podataka.

Ukratko, skladište podataka je temeljna infrastruktura koja podržava analitičke informacijske sustave i pruža im pouzdane, konzistentne i optimizirane podatke za analizu. Funkcionalni prikaz i organizacija jednog skladišta podataka prikazani su na slici 5.8.

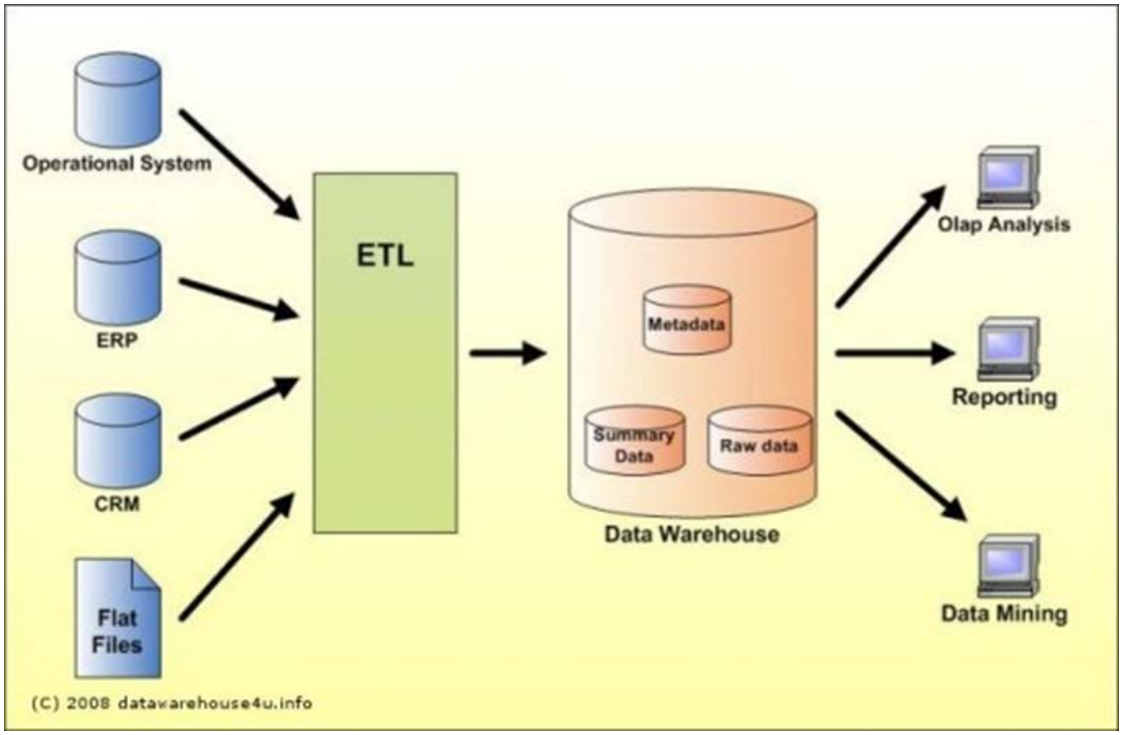

Slika 5.8. Funkcionalni prikaz i organizacija skladišta podataka (Business Intelligence, 2012)

Skraćenica ETL (engl. *Extract, Transform, Load)* definira pristup obrade i transformacije podataka koji prvo izdvaja podatke iz različitih izvora, a zatim ih preuzima u privremeno skladište (engl. *Staging Area*). Podaci se nakon izdvajanja transformiraju i čiste kako bi bili prikladni za skladištenje i analizu. Ovdje se primjenjuju različite operacije poput filtriranja, preoblikovanja, spajanja, agregacije i obogaćivanja podataka. Nakon toga slijedi učitavanje transformiranih podataka u ciljno skladište podataka. To može uključivati izgradnju tablica, indeksiranje i osiguranje integriteta podataka. Funkcionalni dijagram skladišta podataka koji opisuje slijed ovih postupaka prikazan je na slici 5.9.

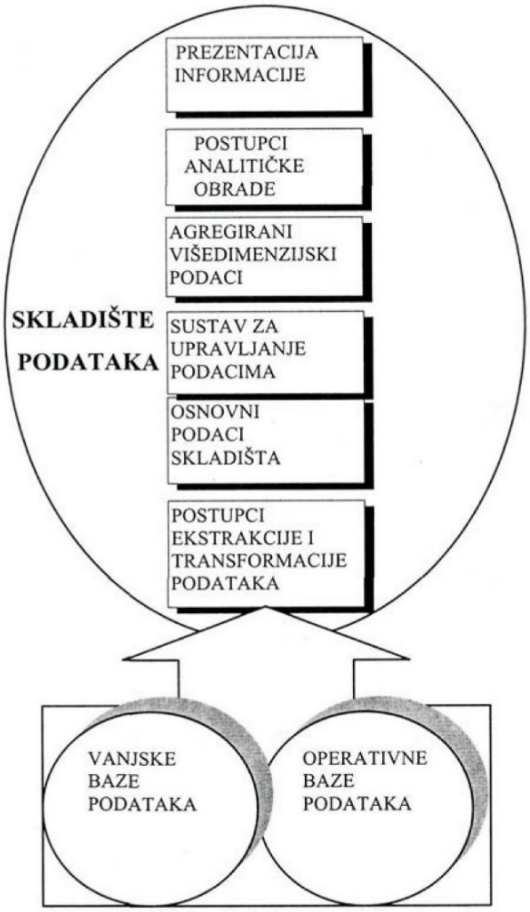

Slika 5.9. Slijed postupaka unutar skladišta podataka s ETL pristupom (Panian i ostali, 2010)

Osim opisanog ETL pristupa, u organizaciji suvremenih skladišta podataka susrećemo i ELT (engl. *Extract, Load, Transform*) pristup. Kao i kod ETL-a, podaci se izdvajaju iz različitih izvora podataka i preuzimaju u privremeno skladište. Podaci se nakon izdvajanja direktno učitavaju u ciljno skladište podataka bez prethodne transformacije. U ovom se koraku podaci samo fizički kopiraju u skladište. Kada su podaci učitani u skladište, transformacija se izvodi izravno u skladištu podataka pomoću različitih alata ili skripti. Ova se transformacija može izvesti kroz upotrebu SQL upita, skriptnih jezika ili tehnika poput spremljenih procedura. Glavna je prednost ELT pristupa ta da omogućava veću fleksibilnost u obradi podataka jer se transformacija obavlja u skladištu koje može podržavati složenije upite i analize. Isto tako, ELT može iskoristiti snagu distribuirane arhitekture skladišta podataka. S druge strane, ETL pristup je tradicionalniji i može biti koristan kada je potrebno izvršiti složene transformacije prije učitavanja podataka u skladište.

Važno je napomenuti da nema stroge podjela između ETL i ELT pristupa, a često se koriste kombinirani pristupi ovisno o zahtjevima i karakteristikama projekta skladištenja podataka (Business Intelligence, 2012; Panian i ostali, 2010).

5.3. ILOSTAT

U ovom će se potpoglavlju okvirno analizirati jedan globalni analitički sustav u domeni zaštite na radu i zaštite zdravlja radnika kojeg je utemeljila Međunarodna organizacija rada (engl. *International Labour Organization*, ILO) te je i dalje održava. ILO je jedina tripartitna agencija UN-a, a djeluje od 1919. godine. Okuplja vlade, poslodavce i radnike iz 187 država članica, a

postavila je radne standarde, razvila politike i osmislila programe koji promiču dostojanstven rad za sve žene i muškarce. Pokretačke snage za stvaranje ILO-a proizašle su iz sigurnosnih, humanitarnih, političkih i gospodarskih razloga. Utemeljitelji ILO-a prepoznali su važnost socijalne pravde u osiguravanju mira u kontekstu eksploatacije radnika u državama s brzo rastućom industrijalizacijom toga vremena. Isto tako, razlog osnutka je i u sve većem razumijevanju svjetske ekonomske međuovisnosti i potrebe za suradnjom kako bi se postigla sličnost radnih uvjeta u zemljama koje se natječu za tržišta, a postavljeni su i glavni ciljevi ILO-a kao što su: promicanje prava na radu, poticanje mogućnosti dostojnog zapošljavanja, jačanje socijalne zaštite i jačanje dijaloga o pitanjima vezanim uz rad.

ILO vodi središnju bazu podataka pod nazivom ILOSTAT (ILO, 2017). ILOSTAT je globalna baza podataka koju održava ILO, a sadrži sveobuhvatne informacije o radnoj snazi, zapošljavanju, nezaposlenosti, plaćama i drugim povezanim temama iz svih dijelova svijeta. Ova baza podataka pruža relevantne statističke podatke i indikatore koji se koriste za analizu i praćenje tržišta rada na globalnoj razini. Pomaže u razumijevanju trendova u zapošljavanju, nezaposlenosti, radnoj snazi, produktivnosti i drugim važnim aspektima vezanim za radnu ekonomiju. ILOSTAT je vrijedan izvor informacija za istraživače, političke donositelje odluka, sindikate, poslodavce i druge zainteresirane strane koje se bave radnom snagom i tržištem rada. Ova baza, odnosno skladište podataka, pruža mogućnost pretraživanja, filtriranja i preuzimanja statističkih podataka za različite zemlje i tematske oblasti. Isto tako, ILOSTAT prati i vodi evidenciju povreda na radu. ILO prikuplja podatke o radnoj nesreći i profesionalnoj bolesti iz različitih izvora kao što su nacionalne statističke agencije, administrativni zapisi, izvještaji poslodavaca i drugi relevantni izvori podataka. Ti podaci o povredama na radu koriste se za praćenje sigurnosti i zdravlja na radnom mjestu te za analizu trendova, istraživanje i razvoj politika usmjerenih na poboljšanje radnih uvjeta i prevenciju povreda i bolesti povezanih s radom. ILOSTAT, kao baza podataka Međunarodne organizacije rada, sadrži i statističke informacije o povredama na radu na globalnoj razini. Ovi podaci mogu obuhvaćati broj povreda, ozbiljnost povreda, vrste povreda, sektore i zemlje u kojima su se dogodile povrede, kao i druge relevantne informacije. Prikupljanje i analiza podataka o povredama na radu ključno je za unaprjeđenje radnih uvjeta, implementaciju odgovarajućih sigurnosnih mjera i donošenje politika koje će smanjiti rizike na radnom mjestu i zaštititi radnike. Ulazni skup podataka i njihova inicijalna obrada prikazani su na slici 5.10.

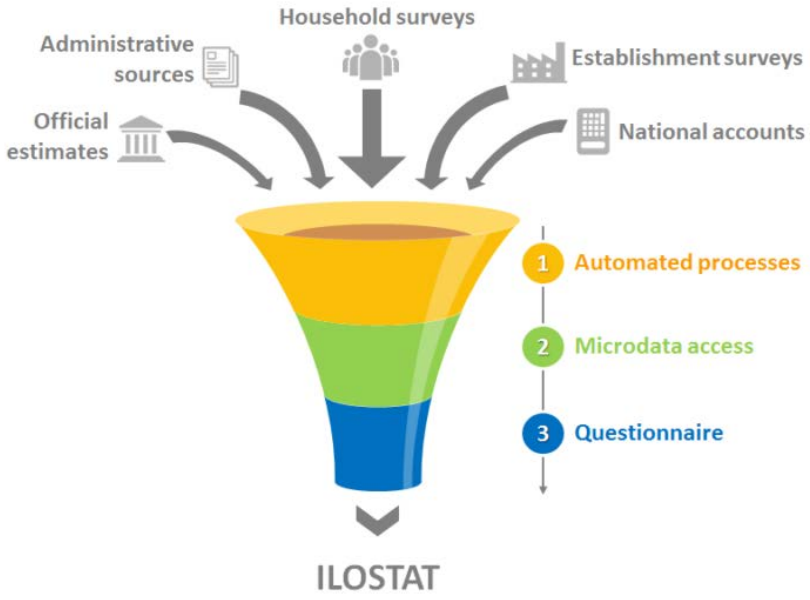

Slika 5.10. Ulazni skup podataka i inicijalna obrada za ulaz u ILOSTAT (izvor: ILO)

ILOSTAT kao sustav ne otkriva izričito informacije o arhitekturi svog skladišta podataka. Međutim, može se pretpostaviti da ILOSTAT koristi neki oblik tradicionalne arhitekture skladišta podataka koja uključuje sljedeće komponente (ILO, 2022):

- Izvore podataka. ILOSTAT prikuplja podatke iz različitih izvora kao što su nacionalne statističke agencije, ankete, istraživanja i drugi relevantni izvori podataka.
- ETL. Podaci se izvuku iz različitih izvora, transformiraju se i pripremaju za unos u skladište podataka. Ova faza uključuje čišćenje, integraciju i pretvorbu podataka kako bi se osigurala dosljednost i kvaliteta podataka.
- Skladište podataka. Podaci se pohranjuju u centraliziranu bazu podataka ili skladište podataka. Ovdje se podaci organiziraju i strukturiraju kako bi omogućili brz i učinkovit pristup podacima za analizu i izvješćivanje.
- Metapodatke. Skladište podataka uključuje metapodatke koji opisuju strukturu, semantiku i značenje podataka. Metapodaci olakšavaju razumijevanje i interpretaciju podataka te omogućavaju njihovu pravilnu upotrebu.
- Analitičke alate. Korisnici, kao što su istraživači, politički donositelji odluka i analitičari, koriste različite alate za pristup i analizu podataka u skladištu. To mogu biti poslovni inteligentni alati, statistički programski paketi ili programski jezici za analizu podataka.

Važno je napomenuti da su ovo samo pretpostavljena općenita načela arhitekture skladišta podataka, a stvarna arhitektura ILOSTAT-a može imati specifične prilagodbe i tehničke detalje prilagođene njihovim potrebama i okruženju, a čak može omogućavati i usporedno korištenje ETL i ELT pristupa. Načelna funkcionalna shema ILOSTAT sustava prikazana je na slici 5.11.

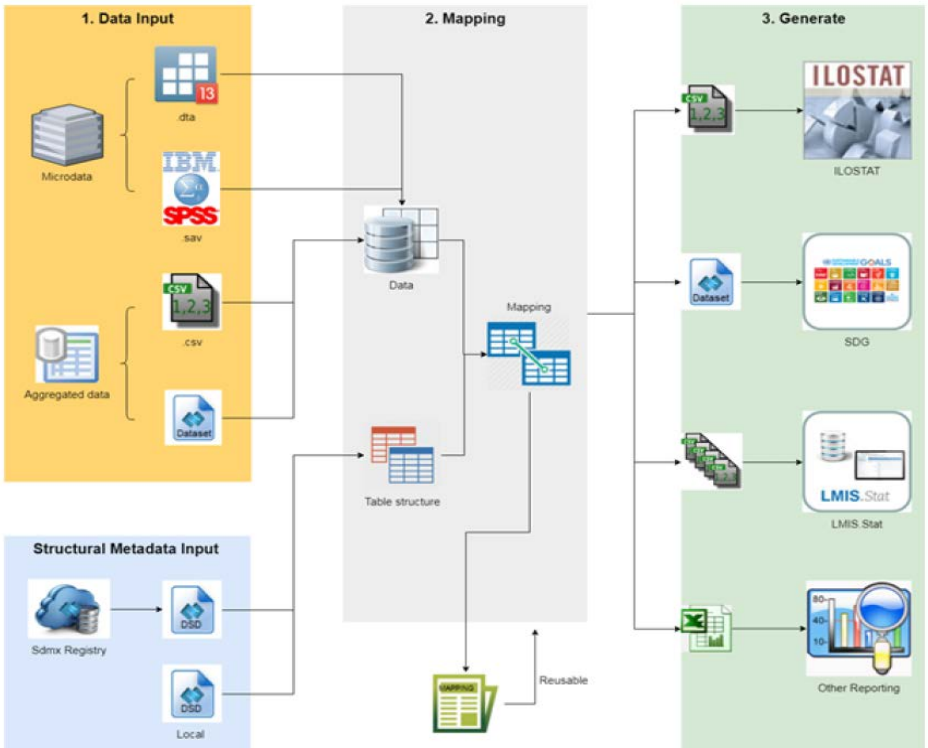

Slika 5.11. Načelna funkcionalna shema ILOSTAT sustava (izvor: ILO)

ILOSTAT koristi nekoliko standardnih formata podataka kako bi organizirao, pohranio i upravljao svojim statističkim podacima. Jedan od primarnih standarda koji se koristi je SDMX (engl. *Statistical Data and Metadata Exchange*). SDMX je međunarodni standard koji omogućava razmjenu podataka i metapodataka između različitih organizacija koje se bave statistikom. ILOSTAT koristi SDMX kako bi omogućio interoperabilnost i razmjenu podataka sa srodnim organizacijama i institucijama koje također koriste taj standard. Ovo olakšava usklađivanje i usporedbu statističkih podataka između različitih izvora. Osim SDMX-a, ILOSTAT može koristiti i druge standardne formate za razmjenu podataka kao što su CSV (engl. *Comma-Separated Values*), Excel i XML. Ovi formati omogućavaju jednostavno preuzimanje podataka iz ILOSTAT baze podataka i njihovo daljnje korištenje u analizi ili istraživanju (Ćosić, 2023).

ILO na međunarodnoj razini i Vijeće EU-a na europskoj razini potiču razvoj nacionalnih informacijskih infrastruktura u domeni zaštite na radu i zaštite zdravlja u cilju dobivanja boljeg uvida u stanje na terenu kako bi se otklonila mjesta nastajanja učestalih povreda na radu, smrtnih slučajeva i pojava profesionalnih bolesti (ILO 2022). Nažalost, u Republici Hrvatskoj još uvijek nemamo uspostavljen središnji IS u domeni zaštite na radu koji bi omogućio skladištenje i detaljnu obradu ovih podataka i tako davao pravovremene i točne informacije kao ulazne pokazatelje za analize na europskoj i svjetskoj razini. Zasad se kod nas skladište podataka primjenjuje u području praćenja i analize profesionalnih oboljenja. Njega je utemeljio Hrvatski zavod za javno zdravstvo (HZJZ), a oslanja se na Registar profesionalnih bolesti Službe za medicinu rada HZJZ-a koji je utemeljen 2006. godine. Primjena skladišta podataka i napredni analitički postupci znatna su pomoć pri unaprjeđenju dijagnosticiranja profesionalnih bolesti te preciznom izvješćivanju o njihovom aktualnom stanju.

Na sadržaj

6. OSNOVE UMREŽAVANJA

S obzirom na to da se osnove računalnih mreža obrađuju u okviru predmeta Primjena računala na prvoj godini prijediplomskog studija, ovo će poglavlje poslužiti kao sažeti repetitorij načela umrežavanja. Računalne mreže su ipak tehnološki temelj suvremenog digitalnog poslovanja.

Za suvremene mrežne računalne sustave svojstveno je umrežavanje sustava različitih generacija i arhitektura. Kao što je prikazano na načelnoj shemi na slici 6.1., uobičajena je primjena internet i intranet načela. Ove sustave odlikuje i višeslojnost sustava i aplikacija u smislu korištenja većeg broja poslužitelja specijalizirane namjene (engl. *Dedicated Servers*). U okviru lokalnih računalnih mreža (LAN) primjenjuju se uglavnom ethernet mreža po IEEE normama 802.2 i 802.3 za žične i 802.11b/g/n za bežične mreže uz primjenu TCP/IP (engl. *Transfer Control Protocol/Internet Protocol*) komunikacijskog protokola. Pristup internetu (globalnoj ili javnoj mreži) za sve mrežne korisnike LAN-a osigurava se prolaskom kroz pristupni ili tzv. PROXY poslužitelj. Načelna shema jednog takvog lokalnog mrežnog sustava povezanog na internet, odnosno javnu mrežu, prikazana je na slici 6.1. Prikazana mrežna struktura je hijerarhijski organizirana i prati organizacijsku strukturu poslovnog sustava (Kralj, 2018).

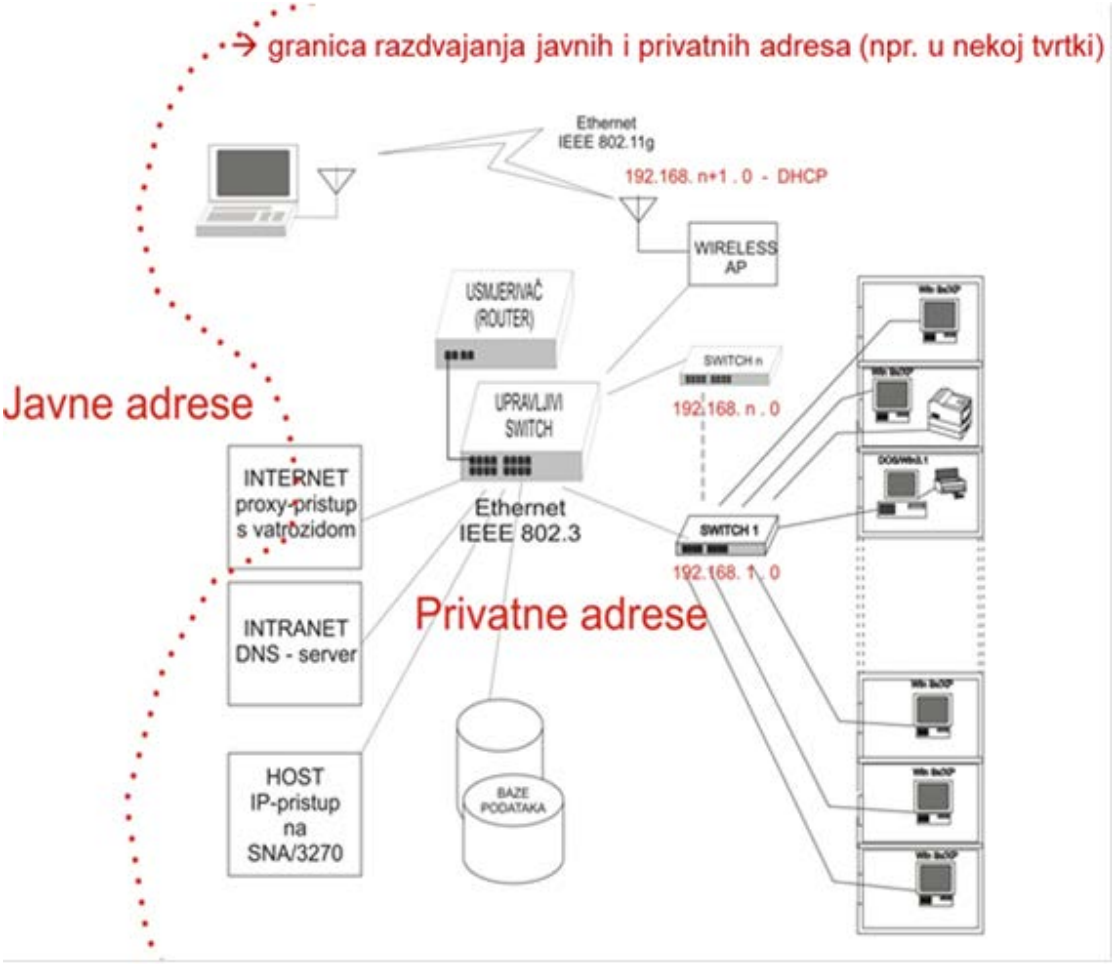

Slika 6.1. Načelna shema ustroja suvremenih otvorenih računalnih mrežnih sustava (izvor: autor)

Međunarodna organizacija za standardizaciju ISO je početkom 80-ih godina 20. stoljeća uložila znatne napore kako bi definirala skup pravila za tehničko ujednačavanje svojstava mrežnih sučelja koja su se do tada znatno razlikovala od proizvođača do proizvođača. Rezultat je bio slojni

model kojeg je ISO nazvala OSI model (engl. *Open System Interconnection*) i koji se zasniva na funkcionalnim slojevima prikazanim na slici 6.2.

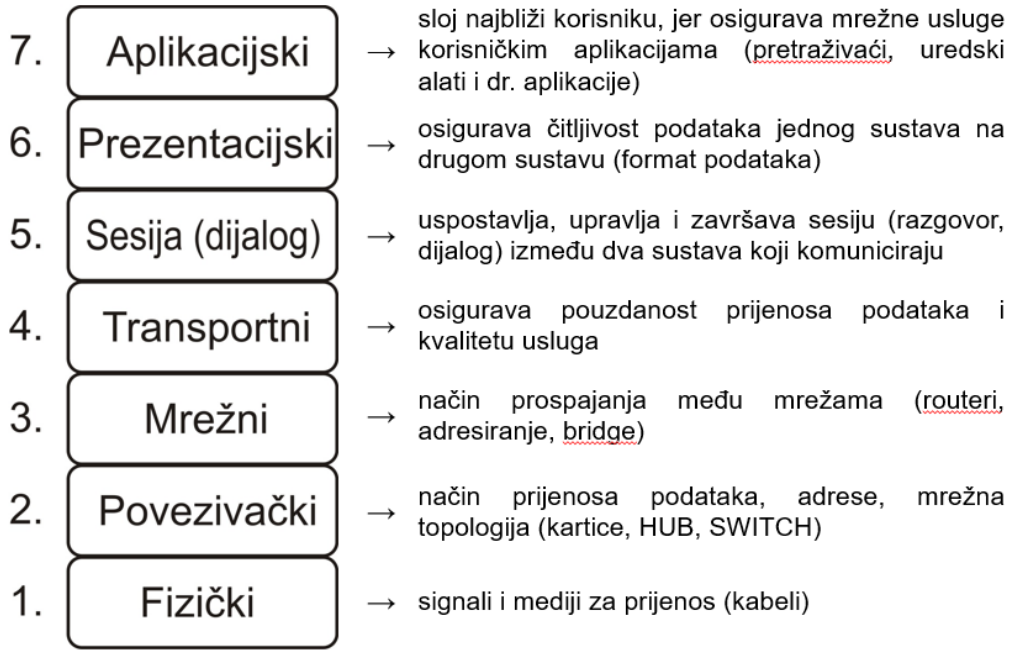

Slika 6.2. Funkcionalni slojevi OSI modela umrežavanja (izvor: autor prema ISO OSI)

Prikazani model imao je uglavnom teorijski značaj jer je okvirno definirao pojedine funkcionalne slojeve u mrežnoj komunikaciji koje je u praksi bilo teško ili nemoguće odvojiti prilikom izvedbe sklopovskih i/ili programskih modula. Kao rezultat razvoja konkretnih mrežnih sustava i praktične primjene mreža razvio se tzv. TCP/IP model. Ovaj se model ponekad naziva i DOD što je skraćeno od *Department of Defense* (hrv. Ministarstvo obrane) s obzirom na to da je razvoj interneta započela i vodila Agencija za napredna istraživanja Ministarstva obrane SAD-a − DARPA. Slika 6.3. prikazuje odnos OSI i TCP/IP modela. U praktičnoj primjeni su fizički i povezivački OSI slojevi sažeti u mrežno sučelje, mrežni sloj je ustvari internet, a slojevi sesije (dijaloga), prezentacijski i aplikacijski u praksi čine jedan aplikacijski sloj.

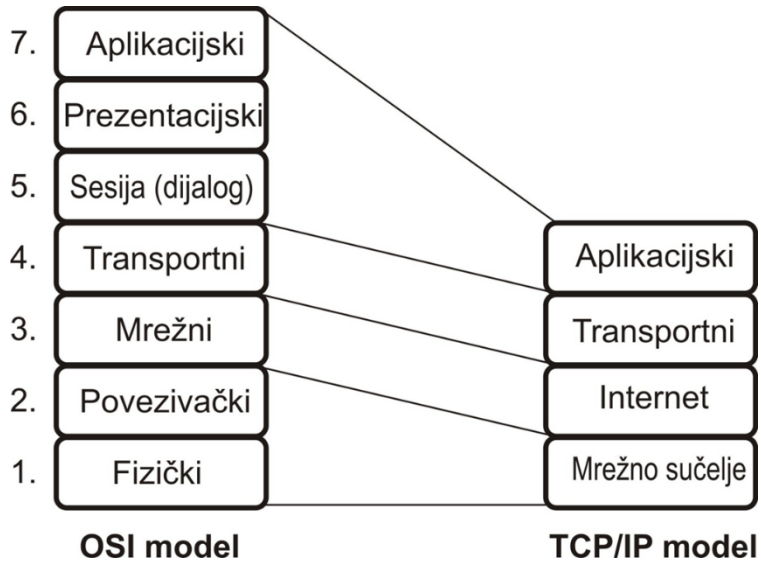

Slika 6.3. Usporedba OSI i TCP/IP mrežnog modela (izvor: autor prema DARPA)

Za početak primjene interneta kao suvremene globalne računalne mreže u gospodarstvu pojedine zemlje ključna je bila izgradnja odgovarajuće komunikacijske infrastrukture. Postojeće analogne telefonske linije i komunikacijsku opremu trebalo je postupno zamijeniti novim komunikacijskim čvorištima i vezama. Za Republiku Hrvatsku je u tom smislu prekretnica bila 1987. godina kada je u promet puštena prva javna digitalna mreža za prijenos podataka komutacijom paketa CROAPAK (u sklopu jugoslavenskog projekta tada je nosila ime YUPACK), koja je postala dijelom svjetske X.25 mreže. Naravno, radilo se samo u uspostavljanju komunikacijske infrastrukture. Pristup naprednim mrežnim uslugama za novu hrvatsku državu omogućen je tek početkom 1996. godine (za akademsku zajednicu i nešto ranije). S vremenom se broj digitalnih usluga u javnoj komunikacijskoj mreži povećavao i tako pratio stupanj svjetskog tehnološkog razvoja. Danas je već i sva analogna telefonija zamijenjena digitalnim telefonskim sustavima, odnosno, sve su to postali digitalni mrežni uređaji.

Iz perspektive prosječnog osobnog ili poslovnog korisnika, tehnološke pojedinosti izvedbe nemaju neki preveliki značaj. Stupanj razvoja suvremenih informacijsko-komunikacijskih (IK) sustava otvara nam neograničene mogućnosti prijenosa, obrade i pohrane podataka i informacija unutar nama nepoznatih ali lako dostupnih lokacija i njihovih kapaciteta. Ne razmišljamo više o tome kuda naši podaci putuju i gdje se odlažu. Kada bismo to pokušali utvrditi, naišli bismo na nepreglednu komunikacijsku strukturu koju čine komunikacijski čvorovi i privremene veze koje se stalno mijenjaju i biraju po načelu najmanjeg prometnog opterećenja, kao što je prikazano na slici 6.4.

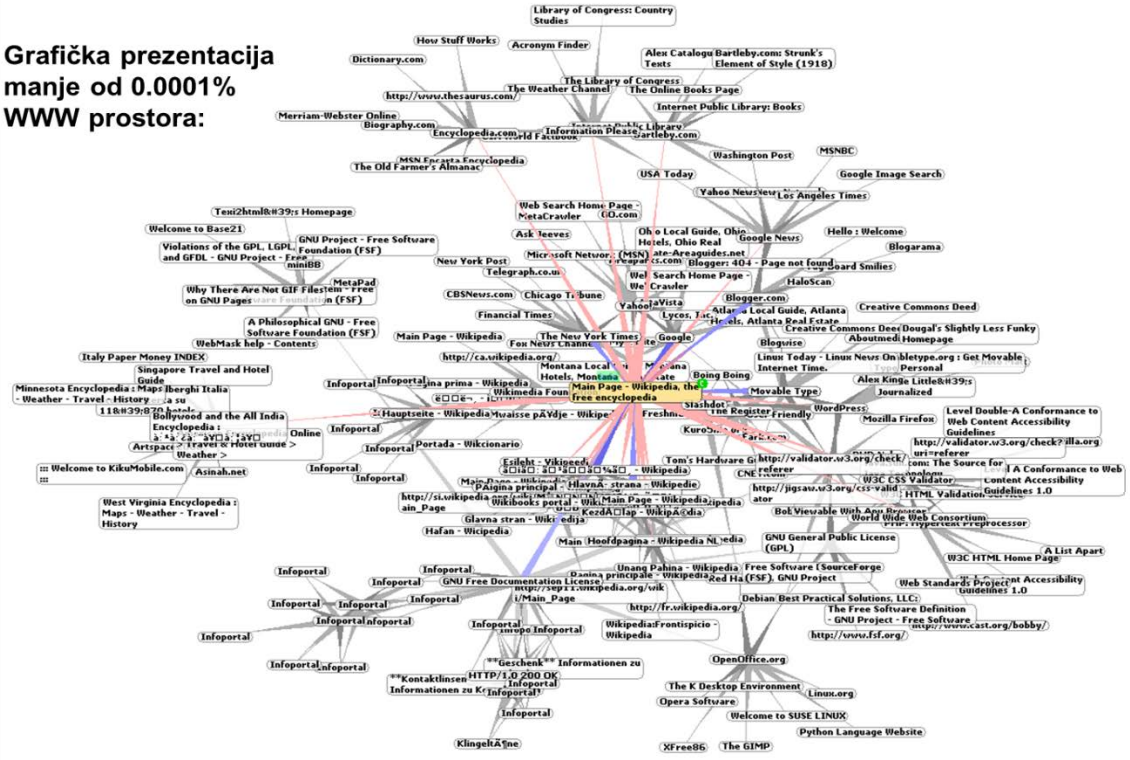

Slika 6.4. Pokušaj grafičke prezentacije jednog djelića strukture čvorova i veza (izvor: autor)

Prikazana struktura čvorova i veza samo je jedan manji dio puta između našeg korisničkog računala i ciljnog poslužitelja ili skupine poslužitelja. Na tim se odredištima potrebna računalna (obradna) snaga povećava združenim radom većeg broja pojedinačnih računala. Više računala (npr. od četiri do osam komada) slažu se u ormare s kontroliranim napajanjem i hlađenjem. Više ovakvih ormara postavlja se u termostatirane prostore koji se nazivaju farme poslužitelja (engl. *Server Farm*). Jedna ili više ovakvih farmi, ako su na istoj geografskoj poziciji, nazivaju se klaster

ili grozd (engl. *cluster*). Ako su farme poslužitelja na različitim geografskim pozicijama, pri čemu se provodi napredno balansiranje njihova opterećenja, govorimo o distribuiranim mrežnim sustavima (engl. *Data Grids*).

Zbog ovako složene i nepregledne strukture cjelokupno funkcionalno područje interneta zovemo oblak (engl. *cloud*) te ga tako i grafički prezentiramo u funkcionalnim shemama (slika 6.5.).

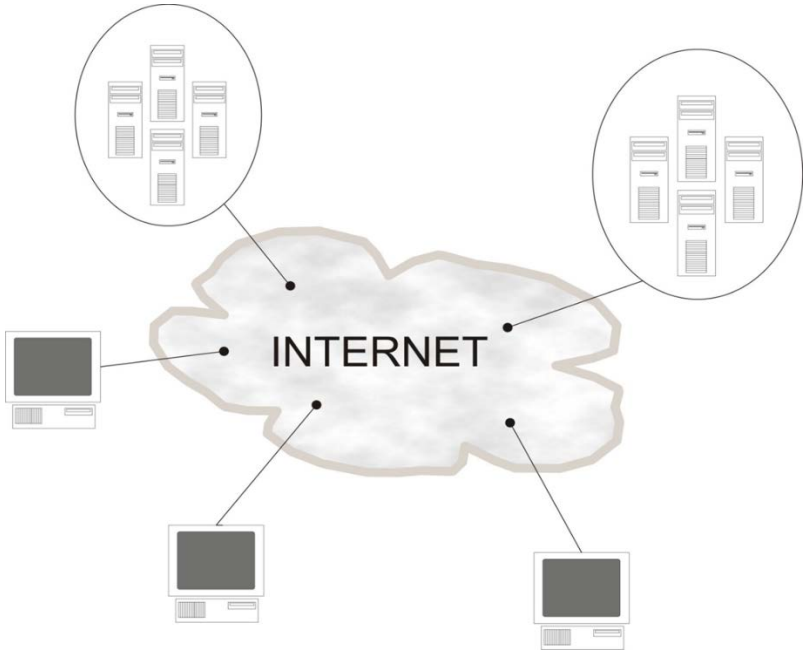

Slika 6.5. Internet kao prijenosni i obradni medij (izvor: autor)

Računala ustvari mogu predstavljati i računalne mreže pojedinih organizacija nalik onoj prikazanoj na slici 6.1., dok prikazani slogovi poslužitelja mogu biti grozdovi ili distribuirani mrežni sustavi. Ovakva organizacija i lako proširiva obradna moć omogućile su nastanak i daljnji razvoj raznih platformi za razvoj aplikacija, pohranu i distribuiranu obradu podataka, iznajmljivanje aplikacija kao usluge i razne oblike digitalne trgovine. Iz perspektive poslovnih sustava, tvrtke ne moraju više voditi računa o održavanju i proširenjima poslužiteljskih kapaciteta i aplikativne podrške jer mogu zakupiti (unajmiti) kompletnu poslužiteljsku i aplikativnu podršku od pružatelja usluga u oblaku.

Svi oblici ovakvih mrežnih usluga opisani su i sadržani u najvišem, aplikacijskom nivou slojnih mrežnih modela. Aplikacijski nivo obuhvaća i cijeli niz standarda vezanih za opis podataka (npr. XML, XSD, XSL), vizualizaciju podataka (HTML), razmjenu podataka (HTTP, SOAP, REST), kao i razvoj i primjenu aplikativne logičke podrške (Kralj 2018; Tanenbaum i Wetherall 2011).

6.1. Komunikacijski protokol

TCP/IP [*Transfer Control Protocol/Internet Protocol*] je danas najčešće korišteni protokol za mrežnu komunikaciju kako za lokalne ethernet mreže (LAN) tako i za prijenos podataka preko interneta. Sastoji se od dvije komponente:

- TCP-a koji vrši kontrolu prometa između dva povezana računala i osigurava da paketi podataka dolaze na odredište traženim redoslijedom.

- IP-a koji je odgovoran za pravilno adresiranje računala i prosljeđivanje paketa za čije dospijeće jamči TCP.

Možemo reći da TCP odgovara transportnom nivou TCP/IP mrežnog modela, a IP mrežnom, odnosno internet nivou (slika 6.3.).

Međutim, TCP nije jedini protokol nadležan za transportnu razinu komunikacijskog protokola. Drugi najčešće korišteni transportni protokol je UDP (engl. *User Datagram Protokol*). Za razliku od TCP-a, UDP protokol vrši samo funkcije multipleksiranja i provjeravanja pogreške prilikom prenošenja podataka, ali nema mogućnost provjere primitka poruke jer ne čuva informaciju o stanju veze, tj. radi na načelu pošalji i zaboravi. Zbog toga se koristi kada je bitnija brzina i efikasnost od pouzdanosti, npr. za prijenos govora u stvarnom vremenu (VoIP telefonija), ali i kada je potrebno slanje iste poruke na više odredišta (engl. *multicast*). Karikirani prikaz na slici 6.6. najbolje prikazuje usporedbu svojstava ova dva protokola na transportnoj razini OSI modela, a tablica 6.1. daje detaljnu usporedbu svojstava.

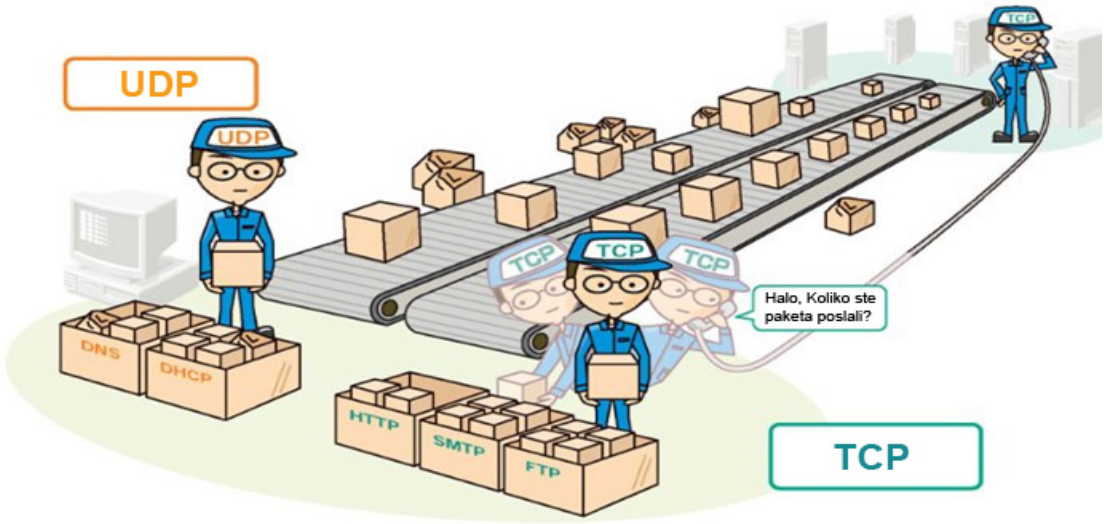

Slika 6.6. Usporedba TCP i UDP protokola (izvor: TCP vs UDP meme)

Tablica 6.1. Usporedba svojstava TCP i UDP protokola (izvor: autor)

TCP *Transfer Control Protocol*	**UDP** *User Datagram Protocol*
Pouzdan	Nepouzdan
Preliminarno testiranje prospoja između točaka koje komuniciraju (*Connection-oriented*)	Bez testiranja prospoja (*Connectionless*)
Ponovno slanje i kontrola toka pomoću veličine paketa (*windowing*)	Bez kontrole toka i ponavljanja slanja segmenta
Sekvenciranje segmenta	Bez sekvenciranja
Potvrda primitka segmenta (*Acknowledgement*)	Bez potvrde primitka
Prijenos konzistentnih podataka	Prijenos audio i videosadržaja

6.2. Adresiranje

Ethernet protokol, kao temeljni protokol za komunikaciju između mrežnih sklopovskih sučelja, zahtijeva da svako računalo, tj. njegovo mrežno sučelje ima jedinstvenu MAC (engl. *Media Access Control*) adresu koja se sastoji od šest skupina po dvije heksadekadske znamenke (ili osam bitova), npr. 01-23-45-67-89-ab ili 01:23:45:67:89:ab, pri čemu prva polovica adrese označava proizvođača mrežnog sklopa, a druga se dodjeljuje slijedno za svaki proizvedeni sklop. Ove su adrese „vidljive" unutar osnovnog segmenta neke lokalne mreže, odnosno između svih mrežnih računala spojenih na jedan mrežni preklopnik (engl. *switch*). Iza prvog mrežnog usmjernika (engl. *router*) na kojeg je preklopnik spojen, ove „fizičke" adrese više nisu vidljive.

Internet protokol (IP) zahtijeva da se svakoj „fizičkoj" adresi dodijeli jedna „logička" tzv. IP adresa koja se sastoji od četiri skupine po osam bita (4 *Byte)* zapisane u dekadskom sustavu, npr. 192.168.005.015. IP adrese mogu biti statičke i dinamičke. Ako se radi o statičkoj IP adresi, ona je trajno zadana, a upisuje ju administrator sustava prilikom konfiguriranja operacijskog sustava pojedinog računala. Dinamičke adrese dodjeljuju usmjernici prema unaprijed definiranom protokolu koji za svaku novu spojenu fizičku adresu dodjeljuje jednu logičku odnosno IP adresu unutar zadanog raspona dopuštenih IP adresa. Ovaj protokol dodjela adresa naziva se DHCP (engl. *Dynamic Host Configuration Protocol*). Mrežni usmjernici imaju u sebi pohranjene tablice mrežnih IP adresa te u skladu s njima reguliraju promet između mreža.

Osim podjele na fizičke i logičke adrese, postoje dvije vrste dodjeljivanih IP adresa mreža i računala, a to su: klasificirane (javne) i privatne. Javne adrese moraju biti jedinstvene na svjetskoj razini, dok se privatne mogu ponavljati od jedne do druge lokalne mreže. Razlog uvođenja ove podjele bila je ušteda adresa s obzirom na ograničeni raspon mogućih adresa.

Arbitražu i dodjelu IP adresa na jedinstveni način provodi agencija IANA [*Internet Assigned Numbers Authority*] koju je 1988. godine osnovala vlada SAD-a kao regulatorno tijelo za raspodjelu numeričkih i DNS [*Domain Name System*] adresa. Od 1998. godine utemeljena je neprofitna korporacija ICANN [*Internet Corporation for Assigned Names and Numbers*] kao vrhovno nadzorno tijelo, a IANA postaje njezino izvršno tijelo. Rad obje ove institucije nadzire američko Ministarstvo trgovine. Za regionalnu alokaciju adresa u svijetu IANA delegira regionalne registre RIR [*Regional Internet Registries*]. Kako bi se lakše pamtile adrese mrežnih destinacija, za numeričke IP adrese dodjeljuju se DNS adrese koje se tvore od kratkih opisnih naziva riječima, npr. umjesto IP adrese 193.198.2.4 puno je lakše zapamtiti DNS adresu www.vuka.hr, gdje krajnji desni segment „hr" označava tzv. vršnu domenu (hrvatski adresni prostor), srednji segment „vuka" označava domenu tvrtke ili institucije kojoj adresa pripada (Veleučilište u Karlovcu), dok krajnji lijevi segment označava stvarni naziv računala (tzv. *hosta*) ili se zamjenjuje skraćenicom „www", ako se radi o poslužitelju za HTTP uslugu (mrežnu stranicu), kao što je slučaj u ovom primjeru.

6.2.1. IPv4

Kao što je već prethodno navedeno IP adrese su temelj logičkog adresiranja u mrežnom prometu. Opisana struktura adresa i podjela na javne i privatne adrese obuhvaćena je standardom IPv4 donesenom 1984. godine. Prema ovom standardu IP adrese podijeljene su u četiri skupine po osam bitova dužine koje se radi lakšeg praćenja i konfiguracije prikazuju kao četiri skupine dekadskih brojeva od kojih svaka ima raspon od 0 do 255. Ove četiri skupine opisuju se velikim slovima i prikazuju kao A. B. C. i D. Teorijski moguć raspon ovako definiranih adresa je 2^{32} (ukupna dužina im je 32 bita) ili približno 4,3 milijarde adresa. Iako ovaj broj mogućih adresa izgleda velik, treba imati na umu da potreba za adresama kontinuirano raste i da se ne mogu

iskoristiti baš sve kombinacije. Prvi je korak uštede bila podjela na javne i privatne adrese. Javne adrese klasificirane su i podijeljene u tri klase vezane za veličinu potencijalnih korisnika:

- A klasa − ima 8 bitova rezerviranih za definiranje mrežnog dijela adrese. Zadanu mrežnu masku (engl. *default subnet mask*) zapisujemo kao 255.0.0.0. Ostala 24 bita rezervirana su za označavanje *hostova* (računala). Namijenjena je vladama i državnim institucijama u svijetu te izuzetno velikim korporacijama (npr. Hewlett-Packard, IBM).
- B klasa − ima 16 bitova za definiranje mrežnog dijela adrese. Mrežnu masku možemo pisati kao 255.255.0.0. Ostalih 16 bitova označavaju *hostove*. Dodjeljuje se za svjetske tvrtke srednje veličine.
- C klasa − ima 24 bita rezervirana za definiranje mrežnog dijela adrese. Mrežnu masku možemo pisati kao 255.255.255.0. Ostalih 8 bitova je rezervirano za označavanje *hostova*. Koristi se za sve ostale namjene prema zahtjevu klasa mreža unutar koje adrese dodjeljuju razni pružatelji usluga.

Treba imati u vidu i da se ne smiju za adresiranje koristiti *host* adrese 0 jer označavaju adresu cijele podmreže, i adrese 255 jer se koriste za adresiranje svih računala u podmreži tzv. *broadcasting.* Slika 6.7. prikazuje teorijski moguć raspon IPv4 adresiranja.

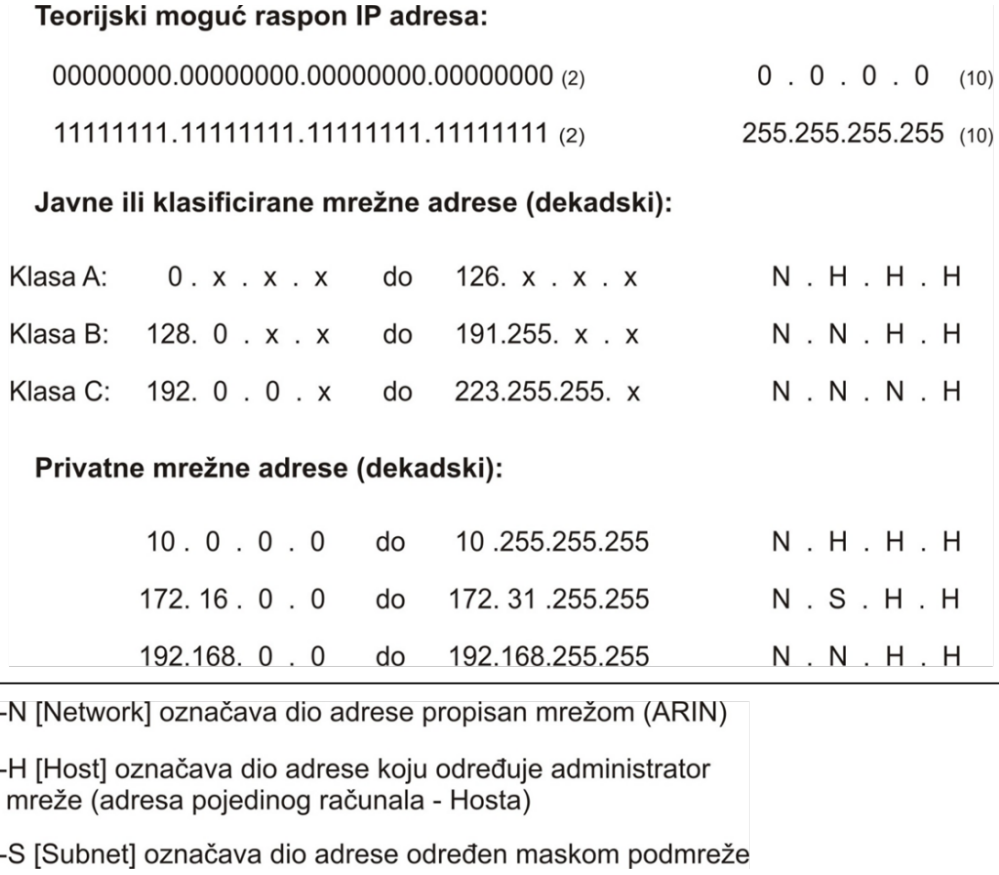

Slika 6.7. Teorijski moguć raspon adresiranja prema IPv4 standardu (Kralj, 2018)

Iz prikaza na slici 6.7. vidi se da u pojedinim klasama nisu korišteni svi rasponi vrijednosti skupina koje čine mrežni dio adrese što dodatno sužava efektivni adresni raspon. Privatne su adrese podijeljene također u tri skupine mogućih adresa, no i ti rasponi adresa su izuzeti iz raspona javnih adresa. Dodatni problem je i odnos raspoloživih prema iskorištenim mrežnim adresama. To znači

da ako za neku mrežu C klase npr. 192.165.5.0 imamo dodijeljen adresni prostor od ukupno 254 adrese (bez 0 i 255), a imamo na raspolaganju samo 32 računala, 222 adrese ostaju neiskorištene, što je vrlo veliki gubitak javnog adresnog prostora. Isprva se to nastojalo kompenzirati tzv. *subnetiranjem,* tj. modificiranjem postojećih mrežnih maski kako bi se dobio veći broj podmreža unutar zadane te tako bolje iskoristio adresni raspon. Čak su se pokušale i definirati D, E i F klase mreža.

6.2.1.1. CIDR

Bolje rješenje za povećanu iskoristivost mrežnih adresa doneseno je 1993. godine u obliku nove organizacije adresa nazvane CIDR (engl. *Classless Inter-Domain Routing*). CIDR uključuje standardnu 32-bitnu adresu zajedno s 32-bitnom informacijom koja opisuje koji dio pripada mrežnome dijelu, a koji *host* dijelu adrese. Dužina mrežne adrese može biti od 13 do 27 bita. Ostatak se odnosi na adrese *hostova*. Na ovaj se način dobije varijabilna veličina mreža (najmanja 32, a najveća preko 500 000 adresa), npr. neku adresu koja ima mrežnu masku dužine 27 bita zapisujemo kao 192.165.2.5/27. Na isti način adrese dodijeljene u okviru bivše klasne podjele adresa, umjesto zapisa mrežnih maski za klase A, B i C dobivaju dodatke /8, /16 i /24.

6.2.1.2. Portovi

Jedan od efikasnih načina uštede adresnog prostora u okviru IPv4 su i portovi. Hrvatski termin za port bio bi „priključak”. No, ovaj se engleski termin udomaćio u svakodnevnom i stručnom govoru pa ćemo ga koristiti i dalje u ovom udžbeniku. Portovi omogućavaju dodatno uslojavanje komunikacije IP protokolom, tj. čine više usluga dostupnim preko iste IP adrese. Primjer za to je pristupanje mrežnoj stranici za koju znamo da se nalazi na adresi 200.0.0.1. Upisom ove adrese u mrežni pretraživač otvara nam se željena mrežna stranica. Mrežna stranica ustvari predstavlja HTTP uslugu koja se odaziva na portu 80, ali je agencija IANA propisala da je to zadana pretpostavljena usluga te u tom slučaju nije potrebno upisivati oznaku porta, tj. zapisati adresu kao 200.0.0.1:80. Ako bismo adresu zapisali kao 200.0.0.1:21 pozvali bismo FTP uslugu (razmjena datoteka), a upisom 200.0.0.1:23 pozvali bismo Telnet (razmjena teksta) uslugu na istom poslužitelju. Za istu dakle adresu imamo raspoložive tri mrežne usluge.

Portovi su vrlo bitni za postupak prevođenja lokalnih adresa u javne i obratno ili tzv. NAT (engl. *Network Address Translation*). Općenito, u lokalnoj mreži imamo npr. nekoliko korisnika s dodijeljenim lokalnim IP adresama. Prema van, ova lokalna mreža ima dodijeljenu samo jednu javnu adresu. Ove javne adrese dodjeljuju dinamički usmjernici pružatelja TK usluga, a mijenjaju se najmanje jednom u 24 sata u cilju zaštite od mogućih zlonamjernih pristupa korisničkim računalima. U sklopu NAT postupka, pojedina lokalna adresa biva zamijenjena kombinacijom javne adrese i specifičnog dodanog porta. Prilikom zahvata sadržaja na internetu, on se vraća korisniku koji se prepoznaje na temelju dodijeljenog porta te se sadržaj usmjerava na polaznu lokalnu adresu. Kombinacija jedne IP adrese i jednog porta naziva se *socket* (hrv. utičnica). Popis nekih najčešće korištenih standardnih portova koji je propisala agencija IAN dan je u tablici 6.2.

Dio portova je zadan s unaprijed definiranom namjenom, a većina ih je dana na slobodno raspolaganje programerima u cilju višestrukog pozivanja raznih programa lociranih na istoj mrežnoj adresi. Portovi su vezani za transportnu komponentu komunikacijskog protokola pa je tako na raspolaganju 65.535 portova za TCP i isto toliko za UDP protokol.

Tablica 6.2. Neki od najčešće korištenih standardnih portova (izvor: IP With Ease)

PORT	SERVICE	DESCRIPTION
20	FTP Data	Port used by the FTP protocol to send data to a client
22	SSH	Used as secure replacment protocol for Telnet
23	Telnet	Port used by Telnet to remotely connect to a workstation or server
25	SMTP	Port used to **send** e-mail over the internet
53	DNS	Port used for DNS requests and zone transfers
80	HTTP	Protocol used for showing web pages on a browser
110	POP3	Post Office Protocol (POP3) is used to **receive/read** e-mail
143	IMAP	Internet Message Access Protocol (IMAP) is a new protocol to read e-mail
443	HTTPS	Port used for securing web traffic
3389	RDP	Port used by Remote Desktop to remotely manage a windows system

6.2.2. IPv6

IPv6 (*Internet Protocol version 6*) je standard donesen 1998. godine za mrežno adresiranje i usmjeravanje podatkovnih paketa na računalnim mrežama. IPv6 je nasljednik prethodnog standarda IPv4 koji se zasad uglavnom koristi za današnje mreže. Glavni razlog za razvoj IPv6 bio je nedostatak raspoloživih adresa u IPv4 prostoru. IPv4 koristi 32-bitne adrese, što omogućava oko 4,3 milijarde jedinstvenih adresa. S obzirom na rastući broj uređaja koji se povezuju na internet, taj prostor adresa postao je ograničavajući čimbenik. IPv6 koristi 128-bitne adrese, što rezultira u 2^{128} ili otprilike $3{,}4\times10^{38}$ potencijalnih IP adresa. Ova vrlo velika količina adresa omogućava praktički neograničen broj povezanih uređaja i podršku za buduće potrebe mreže.

Osim proširenog adresnog prostora, IPv6 donosi i druge poboljšane značajke. To uključuje bolje mehanizme automatske konfiguracije, sigurnosne značajke integrirane na protokolnom nivou, poboljšane mogućnosti kvalitete usluge (engl. *Quality of Service,* QoS), podršku za mobilne mreže i mnoge druge funkcionalnosti. IPv6 također rješava neke od ograničenja i problema koje je imao IPv4, kao što su problem NAT postupka i ograničen broj dostupnih TCP/IP portova.

IPv6 se implementira na mrežnim uređajima, operativnim sustavima, usmjernicima i drugim mrežnim infrastrukturama kako bi se osigurala kompatibilnost s novim standardom. Iako je IPv6 postao sveprisutan, IPv4 i dalje ostaje u širokoj upotrebi. Postoje mehanizmi za prijelaz između IPv4 i IPv6 mreža, što omogućava koegzistenciju oba protokola tijekom tranzicije na IPv6.

Za razliku od IPv4 adresa, IPv6 adrese imaju 128-bitnu strukturu i zapisuju se u heksadekadskom formatu. Adresa se sastoji od osam blokova odvojenih dvotočkom (:). Svaki blok je dužine 16 bita, što znači da se svaki blok može prikazati kao četiri heksadekadske znamenke. Tako naprimjer IPv6 adresa može izgledati ovako:

2001:0db8:85a3:0000:0000:8a2e:0370:7334

IPv6 adrese se često, ako je to moguće, zapisuju u skraćenom formatu kako bi se smanjila dužina. U skraćenom formatu vodeće se nule u svakom bloku mogu izostaviti, a jedan ili više uzastopnih blokova s vrijednostima 0 mogu se zamijeniti dvotočkom (::). Međutim, u adresi se može koristiti samo jedan skraćeni blok. Skraćeni oblik prethodno navedene adrese izgledao bi ovako:

2001:db8:85a3::8a2e:370:7334

Dodatno, IPv6 adrese isto mogu biti javne ili privatne. Javne IPv6 adrese su jedinstvene adrese koje se koriste za komunikaciju na javnoj mreži (internetu), a privatne IPv6 adrese se koriste unutar privatnih mreža (intraneta) i nisu izravno dostupne na internetu. Privatne adrese započinju s

adresnim blokom rezerviranim za raspon privatnih adresa. FC00::/7 je rezervirani adresni blok za privatne IPv6 adrese. Rezervirani adresni blok označava raspon adresa koji je namijenjen za privatnu upotrebu i nije dostupan za korištenje na javnom internetu. Konkretno, FC00::/7 je jedan od tri rezervirana bloka adresa za privatne IPv6 adrese. Njegov raspon adresa proteže se od FC00:: do FDFF:FFFF:FFFF:FFFF:FFFF:FFFF:FFFF:FFFF. To znači da postoji velik broj potencijalnih privatnih IPv6 adresa unutar tog bloka.

Iako NAT nije nužan u IPv6 sustavu, ne znači da ne može biti korišten. U nekim slučajevima, organizacije ili mreže mogu koristiti NAT u IPv6 mrežama iz drugih razloga kao što su poboljšanje sigurnosti, praćenje i kontrola mrežnog prometa ili slojevi privatnosti. Međutim, upotreba NAT-a u IPv6 mrežama nije tako široko rasprostranjena kao u IPv4 mrežama. Kada je riječ o adresiranju mrežnih uređaja (*hostova*), u IPv6 sustavu se može koristiti kombinacija privatnih i javnih adresa, s time da se *hostovima* mogu dodijeliti jedna privatna i jedna javna adresa. To se naziva *dual stack* pristup. Moguća je i dodjela gdje *host* ima i IPv6 i IPv4 adresu. *Dual stack* pristup omogućava *hostovima* da komuniciraju i s drugim uređajima unutar privatne mreže koristeći privatne IPv6 adrese, dok istovremeno mogu komunicirati i s uređajima na internetu koristeći javne IPv6 adrese. Osim toga, ovaj pristup olakšava prijelaz s IPv4 na IPv6 i time omogućava koegzistenciju oba protokola tijekom tranzicije adresnog prostora.

Prema statistici koja se redovito ažurira, APNIC (*Asian Pacific Network Information Centre*), kao jedno od pet regionalnih registracijskih tijela za internet adrese, prikazuje da je udio IPv6 prometa u globalnom mrežnom prometu u rujnu 2021. godine iznosio oko 33 %. Međutim, vrijednosti se mogu razlikovati između različitih regija i zemalja, a treba voditi računa i o tome da su IPv6 sustavi u kontinuiranom razvoju, tj. da postupno raste njihov udio u ukupnom mrežnom prometu (Kralj, 2018; Tanenbaum i Wetherall, 2011).

6.3. Zaštita podataka

Zaštita podataka na računalima i u mrežnom prometu je ključni aspekt informacijske sigurnosti kojoj je cilj osigurati da podaci budu sigurni od neovlaštenog pristupa, gubitka, krađe ili oštećenja. Ova zaštita obuhvaća različite tehničke, organizacijske i proceduralne mjere koje se primjenjuju kako bi se osiguralo integritet, povjerljivost i dostupnost podataka.

Na računalima, zaštita podataka uključuje sljedeće aspekte:

- Zaporke i autentikaciju. Korištenje snažnih zaporki za pristup računalu ili korisničkim računima. Isto tako, mogu se primijeniti i dodatni oblici autentikacije poput dvofaktorske autentikacije (2FA) kako bi se osigurala dodatna sigurnost.
- Kriptiranje. Upotreba kriptografskih algoritama za šifriranje osjetljivih podataka kako bi se spriječio neovlašten pristup. Kriptiranje također može osigurati sigurnu razmjenu podataka između računalnih sustava.
- Vatrozid. Korištenje vatrozida (*firewall*) za kontrolu mrežnog prometa koji ulazi i izlazi iz računala. Vatrozidi mogu filtrirati promet prema zadanim pravilima i ograničiti pristup računalnom sustavu.
- Antivirusne programe. Korištenje antivirusnih programa za otkrivanje, sprječavanje i uklanjanje zlonamjernog softvera koji može ugroziti podatke na računalu.
- Redovito ažuriranje softvera. Redovito ažuriranje operativnog sustava i ostalih softverskih komponenti na računalu kako bi se popravili poznati sigurnosni propusti i smanjio rizik od napada.

U kontekstu mrežnog prometa, zaštita podataka uključuje sljedeće mjere:

- Virtualnu privatnu mrežu (VPN). Korištenje VPN-a omogućuje sigurnu komunikaciju putem javnih mreža tako da se podaci šifriraju i prenose preko sigurnih tunela.
- Sigurnosne protokole. Korištenje sigurnosnih protokola poput SSL/TLS (*Secure Sockets Layer*/*Transport Layer Security*) za sigurnu komunikaciju na mreži (*webu*), SSH (*Secure Shell*) za sigurnu udaljenu administraciju i IPSec (*Internet Protocol Security*) za sigurnu mrežnu komunikaciju.
- IDS/IPS sustave. *Intrusion Detection Systems* (IDS) i *Intrusion Prevention Systems* (IPS) pružaju dodatnu sigurnost identificiranjem neovlaštenih pokušaja pristupa mreži ili otkrivanjem zlonamjernog prometa te mogu poduzeti mjere za njegovo zaustavljanje.
- Sigurnosnu politiku i obuku. Implementacija sigurnosne politike koja definira pravila i smjernice za sigurno korištenje mreže te obuka korisnika o sigurnosnim praksama, poput izbjegavanja sumnjivih priloga e-pošte ili „klikanja" na nepoznate veze.

Sve ove mjere zajedno doprinose zaštiti podataka na računalima i mrežnom prometu te tako osiguravaju tajnost podataka i pristup samo ovlaštenim korisnicima. U nastavku će biti detaljnije opisani ključni elementi zaštite podataka u mrežnom prometu i uslugama (CARNet, 2019).

6.3.1. Kriptiranje

Kriptiranje je postupak transformacije zapisa izvornih podataka (tzv. *plaintext*) upotrebom nekog kriptološkog algoritma u svrhu skrivanja sadržaja od nepozvanih ili neovlaštenih osoba. Primjenom određenog algoritma zapisi se prebacuju u oblik koji nije moguće pročitati bez odgovarajućih podataka (ključa). Rezultat kriptiranja je kriptirana informacija koja se naziva *ciphertext*. Pojam kriptiranja podrazumijeva i obrnuti proces kriptiranja odnosno dekriptiranje kako bi kriptirane podatke mogla pročitati ovlaštena osoba, odnosno osobe koja za to posjeduje odgovarajući ključ (Dujella i Maretić, 2007).

Danas se u praksi primjenjuju tri vrste kriptiranja:

- simetrično kriptiranje
- asimetrično kriptiranje
- hibridno kriptiranje.

Simetrično kriptiranje (slika 6.8.) je vrlo efikasan i brz postupak, ali se kao problem javlja sigurnost postupka distribucije ključa pri čemu postoji rizik da neželjena treća strana može presresti komunikaciju i doći u neovlašteni posjed ključa. Hodogram ovog postupka je sljedeći:

1. pošiljatelj formira poruku
2. pošiljatelj i primatelj dogovaraju algoritam kriptiranja i tajni ključ
3. poruka se kriptira upotrebom zajedničkog tajnog ključa i dogovorenog algoritma
4. kriptirani se tekst šalje do primatelja
5. primatelj dekriptira primljeni tekst koristeći isti tajni ključ i dogovoreni algoritam.

Slika 6.8. Postupak simetričnog kriptiranja (CARNet CERT, 2009)

Asimetrično kriptiranje (slika 6.9.) je kriptološka metoda koja koristi različite ključeve za kriptiranje i dekriptiranje podataka, odnosno javni i privatni ključ. Privatni ključ je tajan, dok se javni, kao što naziv i sugerira, distribuira javnosti. Poruka se kriptira upotrebom javnog ključa primatelja, a moguće ju je dekriptirati samo pomoću odgovarajućeg privatnog ključa primatelja.

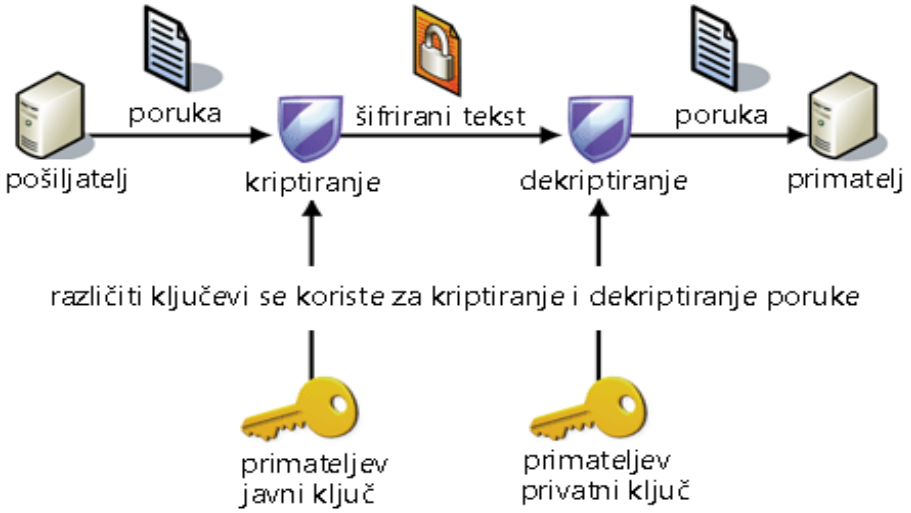

Slika 6.9. Postupak asimetričnog kriptiranja (CARNet CERT, 2009)

Hodogram ovog postupka je sljedeći:

1. pošiljatelj formira poruku
2. pošiljatelj kriptira poruku upotrebom javnog ključa primatelja i odgovarajućeg algoritma npr. RSA (Rivest-Shamir-Adleman), ECC (*Eliptic Curves Cryptosystem*)
3. mrežom se prenosi šifrirani tekst
4. primatelj dekriptira tekst pomoću svog privatnog ključa i odgovarajućeg algoritma.

Postupak asimetričnog kriptiranja je znatno sporiji (100 − 1000 puta) od simetričnog kriptiranja zbog računski znatno složenijih algoritama. Osim toga, za primjenu ovog postupka potrebno je organizirati i utemeljiti tzv. infrastrukturu javnog ključa (engl. *Public Key Infrastructure*, PKI). PKI je skupina programa, sklopovlja, ljudi, sigurnosnih politika i procedura potrebnih za kreiranje, upravljanje, pohranjivanje te povlačenje digitalnih certifikata. Povezuje javne ključeve s pojedinačnim korisnikom pomoću tzv. certifikacijskih tijela (engl. *Certificate Authority*, CA). Jedina CA u Republici Hrvatskoj je FINA. Digitalni certifikati i kriptološki ključevi su usko povezani jer se digitalni certifikati koriste za potvrdu autentičnosti kriptoloških ključeva. Kriptološki ključevi su matematički alati koji se koriste u kriptografiji za šifriranje i dešifriranje podataka. Digitalni certifikati se koriste za potvrdu autentičnosti javnih ključeva. Oni su elektronički dokumenti koji sadrže informacije o identitetu vlasnika ključa koje digitalno potpisuje pouzdana CA. Certifikat sadrži javni ključ i druge informacije, poput imena vlasnika, datuma izdavanja i isteka certifikata, serijskog broja itd. Certifikati prema namjeni mogu biti (FINA, 2023):

- **Kvalificirani certifikati za elektronički potpis** − koriste se za izradu elektroničkih potpisa. Na nedvojben su način povezani s potpisnikom te omogućavaju njegovu identifikaciju. Podatke za izradu potpisa potpisnik može koristiti pod svojom isključivom kontrolom.
- **Certifikati za autentikaciju** − koriste se za izradu elektroničkog potpisa, za jaku autentikaciju i enkripciju ključa. Prikladni su za podršku i izradu naprednog elektroničkog potpisa koji nije zasnovan na kvalificiranom certifikatu.
- **Certifikati za elektronički pečat** − koriste se za povezivanje podataka za validaciju elektroničkog pečata s pravnom osobom i potvrđuje naziv te osobe, a osiguravaju cjelovitost dokumenta. Pogodni su za ovjeru dokumenata kada nije potreban potpis fizičke osobe, pri čemu e-pečat potvrđuje da je dokument izdala određena pravna osoba.
- **Certifikati za aplikacije** − poslovni certifikati za IT opremu koji se izdaju za IT sustave, aplikacije ili servise povezane s poslovnim subjektom. Koriste se za izradu e-potpisa, za jaku autentikaciju i enkripciju ključa u poslovne svrhe.
- **Certifikati za autentikaciju mrežnih stranica (SSL certifikati)** − koriste se samo za autentikaciju mrežnih stranica, tj. za autentikaciju mrežnih poslužitelja kojima se pristupa putem TLS ili SSL protokola te povezuje mrežnu stranicu s pravnom osobom kojoj je izdan.

Uvođenjem PKI-a te zakonskim reguliranjem elektroničkog potpisa nestale su zapreke u korištenju interneta i e-poslovanja. Ovime se omogućuje potpuna eliminacija papira uz znatnu uštedu vremena u poslovnim komunikacijama. Elektroničke transakcije zaštićene primjenom PKI-a bazirane na digitalnom certifikatu i elektroničkom potpisu zadovoljavaju sljedeće osnovne zahtjeve (FINA, 2023):

- **Autentikaciju** – proces provjere korisničkog identiteta, odnosno proces kojim korisnik dokazuje da je zaista onaj za kojeg se predstavlja (prilikom prijavljivanja u neki sustav i sl.).
- **Integritet** – sigurnost da podaci u prijenosu ili obradi nisu uništeni ili promijenjeni. Elektroničkim potpisom osigurava se cjelovitost i izvornost podataka pohranjenih na određeno vrijeme ili onih koji se šalju mrežom. Jednostavnom provjerom može se utvrditi jesu li ti podaci nelegalno naknadno mijenjani.

- **Tajnost** – enkriptiranje (šifriranje) podataka, koji će biti pohranjeni ili poslani mrežom, štiti čitanje sadržaja od neovlaštenih osoba.
- **Neporecivost** – onemogućavanje poricanja (negiranja) akcije koje je osoba poduzela ili autorizirala. Ova je mogućnost realizirana kroz napredni elektronički potpis.

Iz navedenih vrsta certifikata i zahtjeva koje zadovoljava PKI proizlazi i druga glavna namjena asimetričnog kriptiranja, a to su digitalni potpisi i pečati. Slika 6.10. prikazuje postupak digitalnog potpisivanja i provjere valjanosti potpisa.

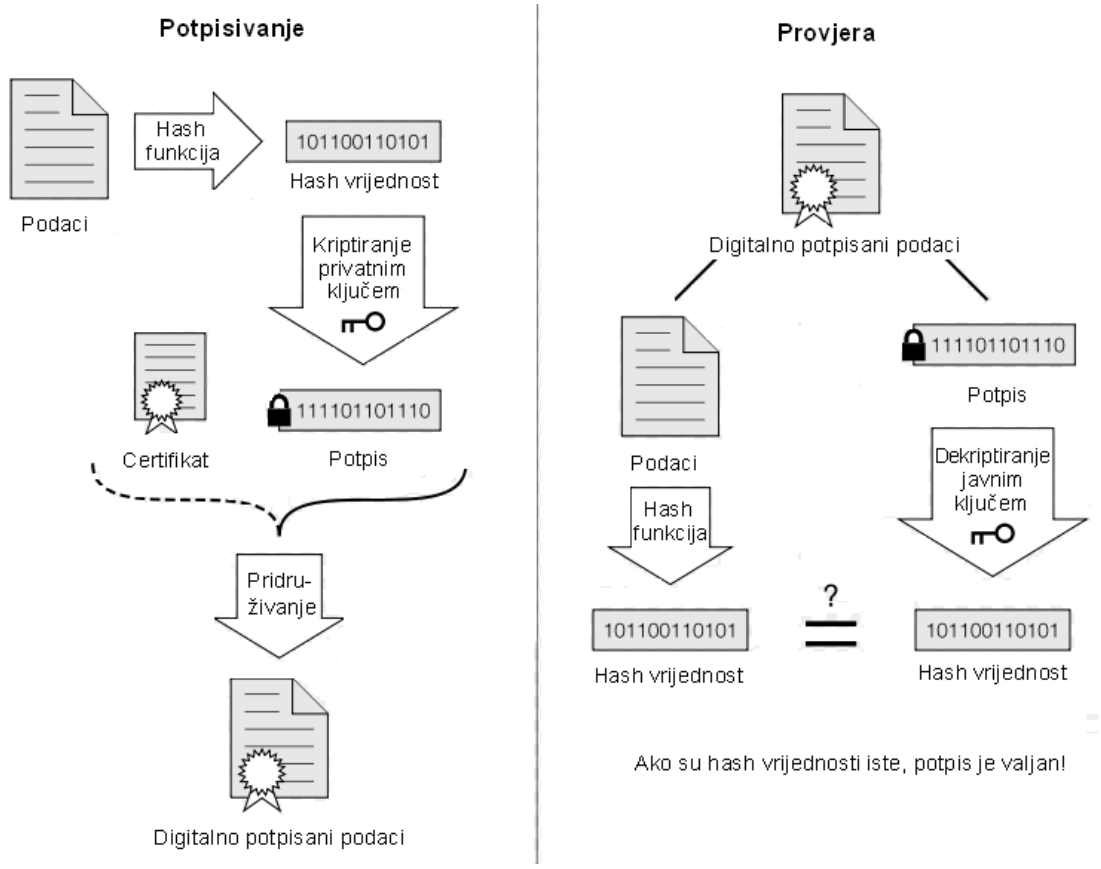

Slika 6.10. Digitalno potpisivanje i provjera valjanosti potpisa (CARNet, 2007)

Digitalni potpisi služe za potpisivanje podataka te njihovu provjeru (npr. jesu li podaci izmijenjeni u prijenosu). Potpisivanje podataka digitalnim potpisom počinje računanjem tzv. *hash* vrijednosti podataka pomoću neke *hash* funkcije, npr. primjenom *Message Digest Algorithm 5* (MD5, 128-bit) ili *Secure Hash Algorithm* (SHA-1, 160-bit). *Hash* vrijednost je numerička reprezentacija podataka dobivena primjenom odgovarajućeg algoritma za pretvorbu. Takva se vrijednost kriptira upotrebom privatnog ključa korisnika i dobije se digitalni potpis. Kada se potpisu pridruži odgovarajući certifikat podaci su digitalno potpisani.

Provjera potpisanih podataka vrši se tako da se podaci propuštaju kroz istu *hash* funkciju kako bi se ponovno dobila *hash* vrijednost. Digitalni potpis se izdvaja iz digitalno potpisanih podataka te dekriptira upotrebom javnog ključa entiteta koji je potpisao podatke. Na taj se način dobije *hash* vrijednost koju je izračunao i umetnuo entitet koji je potpisivao podatke. Ove dvije *hash* vrijednosti se međusobno usporede i ako su jednake smatra se da je digitalni potpis valjan. Slika 6.11. prikazuje postupak elektroničkog potpisivanja jednog PDF dokumenta primjenom elektroničkog certifikata kroz aplikaciju Adobe Reader. Kvalificirani certifikati za potpisivanje za

osobne potrebe nalaze se na našim elektroničkim osobnim iskaznicama (eOI), a prije upotrebe ih je potrebno aktivirati prema uputama. Kvalificirani certifikati za potpisivanje i autentikaciju pravnih osoba (organizacija) izdaju se na USB stikovima.

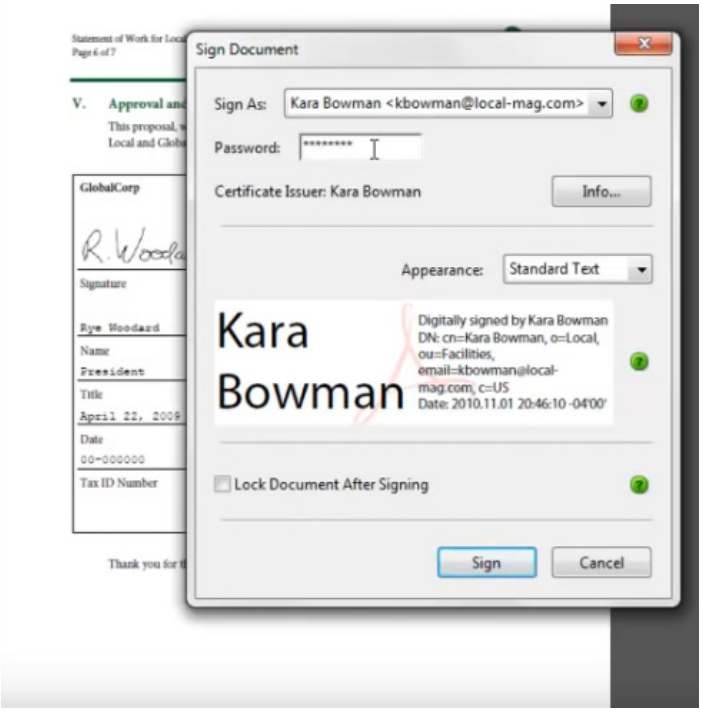

Slika 6.11. Digitalno potpisivanje digitalnim certifikatom u aplikaciji Adobe Reader (izvor: Adobe Support)

REPUBLIKA HRVATSKA MINISTARSTVO UPRAVE	Vrijeme izdavanja:	09.10.2018. 14:56
	Izdavatelj certifikata:	CN=ematicnidokumenti, L=ZAGREB, OID.2.5.4.97=HR81700550832, O=MINISTARSTVO UPRAVE, C=HR
	Serijski broj:	317272718015104797423400081040426951118
	Algoritam potpisa:	SHA256withRSA
	Broj zapisa:	2018-0001-65984
	Kontrolni broj:	827-828-921
Elektronički pečat:	ZhURst0MvYlzMpZspumb0zHXo+gSsj3xf4sFTZu6si2dEJ5xp+YDoPhGRkjvKAJLCLtXmgKKrLReA7dyYH4SmGoWPs CQa3+moCU4GQBIZWclQwDBVVtS5VEMqbBMSz3WJz4D8KycjSf71P9ya2p4tXhpvO9Gg5h5gUFKjjX+IxqhgJev97Xq ZZ9YoSPNC455ZPaRuhljahCc1youDU0CLuHiZbYnx/m+0j+bpHNuQdvfozpibQnkb2wpkUZkUii8gFeU53ABLMbOLoLrh nCMgS9V1SfEiRuQSD0/4JFtPf1Ls/LZY9rpytteYee8wsJfkyZeKOFkTgTEpQDdaRMHXIaCdlb2CqvA/d9fMl7+dQklrtET	
Informacije za provjeru dokumenta:	Elektronički zapisi se čuvaju najviše 3 mjeseca od trenutka generiranja te se u tom roku može izvršiti provjera elektroničkog zapisa uvidom u elektronički zapis kojem se pristupa putem broja zapisa i kontrolnog broja otisnutog u kontrolnom dijelu elektroničkog zapisa, putem Internet adrese https://matice.gov.hr/EDokumentiProvjera/.	
Napomena:	Elektronički pečat kreiran je certifikatom Ministarstva uprave	

Slika 6.12. Primjer digitalnog pečata javne uprave (e-Domovnica) (izvor: autor)

Hibridno kriptiranje je suvremena kriptografska tehnika u kojoj se oba prethodno spomenuta kriptološka postupka koriste paralelno kako bi se iskoristile njihove prednosti. Asimetrični algoritmi koriste se za distribuciju simetričnih ključeva na početku sjednice (samo u svrhu autentifikacije). Nakon toga, po dostavi simetričnog ključa, brži simetrični postupci mogu biti upotrijebljeni za kriptiranje (u svrhu povjerljivosti i autentičnosti). Postupak hibridnog kriptiranja prikazan je na slici 6.13. Kako bi se izračunao tajni simetrični ključ, strane koje komuniciraju koriste tzv. Diffie-Hellmanov postupak. Ovaj se postupak zasniva na matematičkim operacijama s dva javno poznata (unaprijed dogovorena) broja i privatnim ključevima sugovornika kako bi svaka strana generirala svoj javni ključ. Nakon toga sugovornici mogu razmijeniti svoje javne

ključeve putem otvorene (nesigurne) veze. Odgovarajućom matematičkom operacijom u kojoj se koriste dva prethodno spomenuta broja, dobiveni javni ključ drugog sugovornika i osobni privatni ključ, na obje se strane generira isti tajni ključ koji se dalje koristi za simetrično kriptiranje sadržaja.

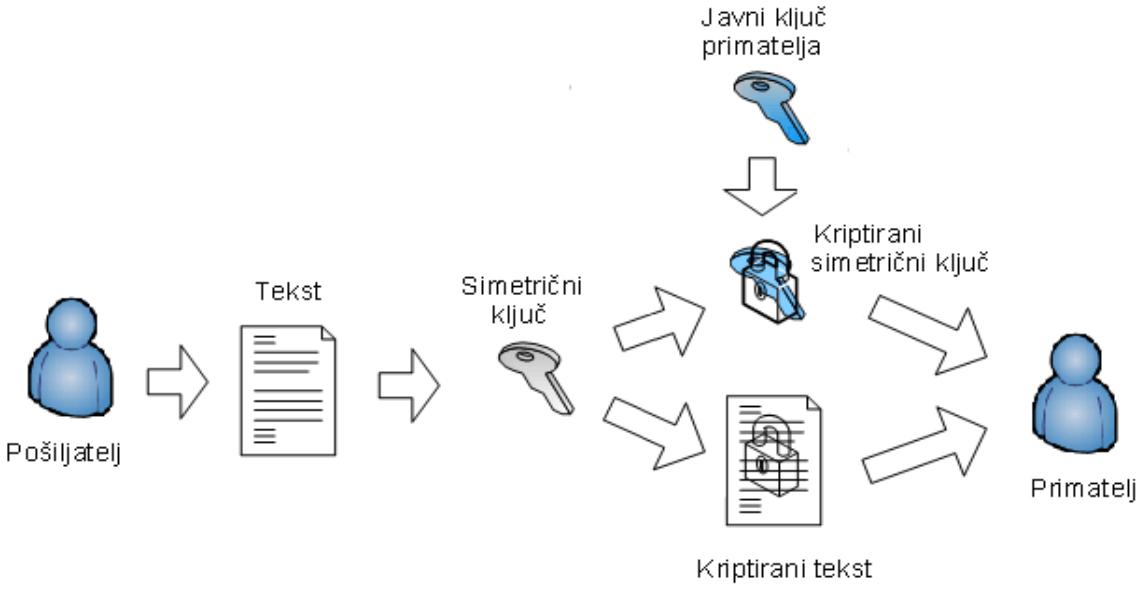

Slika 6.13. Postupak hibridnog kriptiranja (CARNet CERT, 2009)

6.3.2. VPN i sigurnosni protokoli

U današnje vrijeme velikog intenziteta mrežnog prometa, mrežne cenzure i *online* praćenja, zaštita prijenosnog puta podataka je nužnost. Prema Andrewu S. Tanenbaumu (2021) poznatom autoru knjige *Computer Networks,* zaštitu prijenosnog puta ostvarujemo primjenom virtualnih privatnih mreža (*virtual private network,*VPN) i SSL/TLS komunikacijom.

VPN je tehnologija koja omogućava stvaranje sigurne i privatne mrežne veze preko javne mreže poput interneta. Radi na mrežnom nivou i može koristiti različite protokole za sigurno povezivanje, uključujući IPsec, OpenVPN, L2TP/IPsec i dr. IPsec je jedan od najčešće korištenih protokola u VPN implementacijama i pruža sigurnosne mehanizme za šifriranje i integritet podataka koji se prenose između VPN klijenta i poslužitelja. S obzirom da ovaj način zaštite djeluje na mrežnom nivou, kaže se da ostvaruje neprobojni „tunel" prema ostalim korisnicima i procesima u mreži. Poslužitelji za pružanje VPN usluge mogu biti posebna računala, ali to može biti i jedna od funkcionalnosti suvremenih vatrozida. Primjer ostvarivanja veze VPN tunelom između korisnika, u tzv. nesigurnom okruženju, s vatrozidom zaštićenom računalnom mrežom tvrtke, prikazuje slika 6.14. Korisnik VPN tunelom prolazi najprije kroz vatrozid pa kroz VPN poslužitelj koji mu omogućuje zaštitu veze te nakon toga može pristupiti sadržajima lokalne mreže ili proći nezaštićenom vezom prema ostatku interneta.

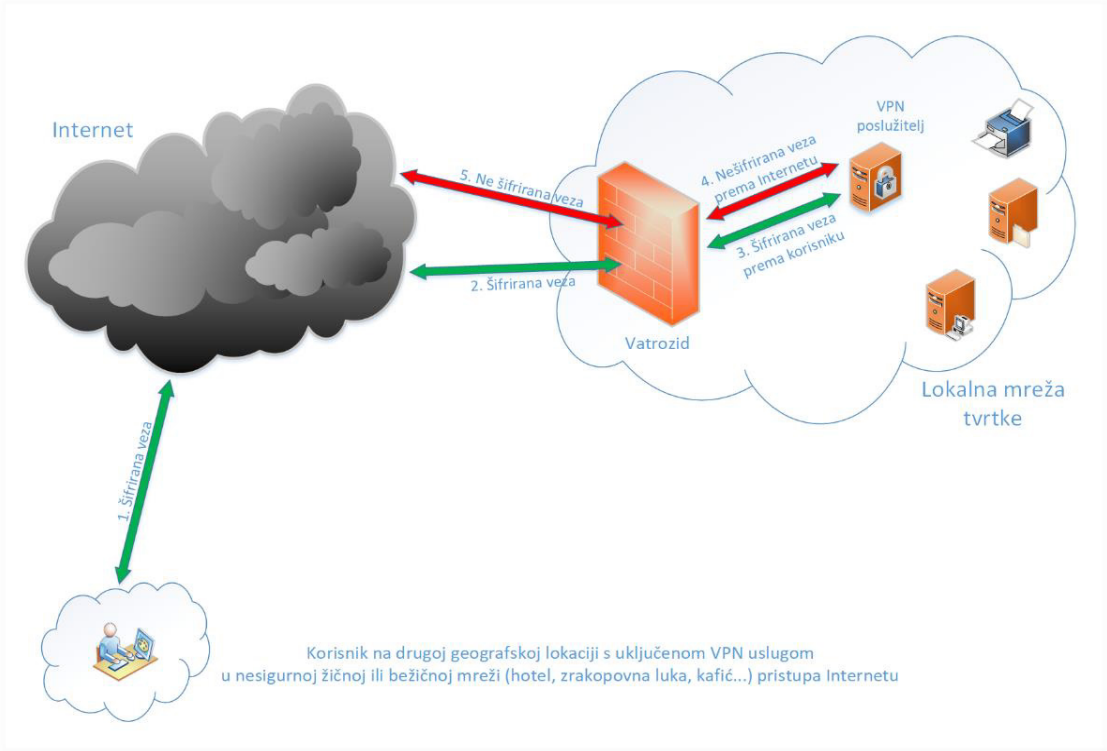

Slika 6.14. Primjer VPN pristupa kroz internet prema lokalnoj mreži tvrtke (CARNet, 2019)

SSL/TLS (*Secure Sockets Layer*/*Transport Layer Security*) zaštita prijenosnog puta odnosi se na primjenu SSL i TLS protokola za sigurnu komunikaciju koji se obično koriste na transportnom nivou, točnije iznad transportnog sloja u OSI modelu. Oni pružaju sigurnu vezu između klijenta i poslužitelja tako da šifriraju podatke i provjeravaju autentičnost poslužitelja. SSL je stariji protokol, dok je TLS njegova modernija verzija koja je danas u širokoj upotrebi. SSL/TLS se često primjenjuju u mrežnim (*web*) preglednicima kako bi se osigurala sigurna komunikacija između korisnika i mrežnih poslužitelja i omogućio HTTPS protokol. Uglavnom, skoro sve mrežne usluge koriste HTTPS pristup. U suprotnom slučaju preglednik označava mrežnu stranicu kao nesigurnu. Dakle, u širem smislu, SSL i TLS protokoli omogućuju svim aplikacijama zasnovanim na mrežnim uslugama komunikaciju preko mreže tako da se spriječi prisluškivanje, izmjena i lažiranje poruka. TLS pruža podršku za sigurniju dvosmjernu vezu od SSL-a. Oba krajnja čvora moraju znati s kim komuniciraju (obostrana autentifikacija) te svi krajnji korisnici moraju posjedovati valjane certifikate (i klijenti i poslužitelji) (CARNet, 2019, 2009b).

6.3.3. Autentikacijska i autorizacijska infrastruktura

Autentikacijska i autorizacijska infrastruktura ili sustav je uslužni sustav koji korisnicima usluga omogućava uspješan, siguran i vremenski povoljan način korištenja, pri čemu pružatelje tih e-usluga oslobađa od poslova upravljanja korisničkim računima i postupka autentifikacije.

Autentikacija se odnosi na proces provjere identiteta korisnika ili sustava. Cilj je autentikacije potvrditi da je osoba ili entitet koji pokušava dobiti pristup autentičan, odnosno da je ono što tvrdi da je. Ovisno o razini sigurnosti koja se zahtijeva, autentikacija se može temeljiti na različitim čimbenicima kao što su korisničko ime i lozinka, biometrijski podaci (npr. otisak prsta ili prepoznavanje lica), digitalni certifikati ili dodatni sigurnosni *tokeni* poput jednokratnih zaporki.

Autorizacija se, s druge strane, odnosi na proces odobravanja prava pristupa korisniku ili sustavu nakon što je autentificiran. Nakon što se korisnik ili entitet uspješno autenticiraju, autorizacija provjerava koje resurse ili funkcionalnosti ima pravo koristiti. To se obično postiže

putem pristupnih kontrolnih lista (ACL), pravila ili uloga koje su dodijeljene pojedinim korisnicima ili skupinama korisnika. Na primjer, administrator sustava ima više ovlasti i pristupa nego obični korisnik.

Ovi se sustavi zasnivaju na standardu SAML (engl. *Security Assertion Markup Language*), koji se temelji na XML standardu. Njegova je glavna svrha olakšati tzv. jedinstvenu prijavu (engl. *Single Sign-On*) između različitih sustava i aplikacija. Ukratko, kada se prijavimo samo jednom, možemo koristiti razne usluge pokrivene ovom infrastrukturom za koje imamo dopuštenje pristupa. Da bi ovakav pristup bio moguć, pored pružatelja usluga i korisnika usluga mora postojati i treća strana, a to su pružatelji identifikacijskih usluga (eng, *Identity Providers* – IdP). SAML ustvari definira način razmjene sigurnosnih tvrdnji između ove tri partnerske strane. Dva primjera ovakve infrastrukture koje gotovo svakodnevno koristimo su AAI@EduHr i NIAS (CARNet, 2009a).

AAI@EduHr (Autentikacijska i autorizacijska infrastruktura sustava znanosti i visokog obrazovanja) svim korisnicima omogućava jednostavno, sigurno i pouzdano korištenje *online* usluga u sustavu AAI@EduHr uz pomoć jedinstvenog elektroničkog identiteta dobivenog na matičnoj ustanovi te pristup velikom broju usluga izvan granica RH putem globalnog sustava eduGAIN. Korisnici ove usluge su studenti, nastavnici i djelatnici ustanova iz sustava znanosti i visokog obrazovanja, ustanove iz sustava znanosti i visokog obrazovanja, Ministarstvo znanosti i obrazovanja te druge pravne i fizičke osobe u skladu s pravilima korištenja (Srce, 2008). Ovaj sustav pruža:

- **korisnicima, pojedincima** jednostavan, siguran i pouzdan način autentikacije za dostupne resurse u sustavu AAI@EduHr uz pomoć jedinstvenog elektroničkog identiteta dobivenog na matičnoj ustanovi
- **matičnim ustanovama (davateljima elektroničkih identiteta)** sigurno, pouzdano i efikasno upravljanje elektroničkim identitetima svojih djelatnika, suradnika i studenata
- **davateljima usluga (resursa)** standardiziran proces autentikacije i autorizacije korisnika elektroničkim identitetom iz sustava AAI@EduHr (Srce, 2023).

NIAS (Nacionalni identifikacijski i autentifikacijski sustav) upravlja elektroničkim identitetima u nacionalnom sustavu autentifikacije krajnjih korisnika s e-uslugama javnog sektora. Svojim korisnicima omogućava uspješno, sigurno i vremenski povoljno korištenje javnih e-usluga, dok istodobno pružatelje e-usluga oslobađa poslova upravljanja korisničkim računima i procesa autentifikacije. NIAS razvrstava vjerodajnice za prijavu na e-Građane u tri skupine, odnosno razine sigurnosti, a to su:

- visoka razina (npr. eOsobna iskaznica, Mobile ID osobne iskaznice, RDC i Certilia certifikati)
- značajna razina (npr. *mToken*, HZZO, razni bankovni tokeni i sl.)
- niska razina (npr. ePASS, AAI@EduHr, ePošta, HT Telekom ID).

U skladu s razinom sigurnosti kojom je korisnik prijavljen bit će mu dostupne i usluge u okviru portala e-Građani (NIAS, 2023).

6.3.4. *Blokchain*

Blockchain (BC) je decentralizirana i distribuirana tehnologija koja omogućuje sigurno pohranjivanje, provjeru i upravljanje podacima putem mreže računala. Ključna značajka *blockchaina* je da omogućuje transparentnost, nepromjenjivost i pouzdanost podataka bez potrebe za povjerenjem između sudionika. Jednostavno rečeno, BC je poput digitalne knjige novčanih transakcija (engl. *ledger*) koja bilježi transakcije ili događaje u obliku blokova. Svaki blok sadrži podatke, kao što su transakcije ili druge informacije, i jedinstveni identifikator (engl. *hash*) prethodnog bloka. Kada se stvori novi blok, on se veže s prethodnim blokom putem *hash* identifikatora, čime se stvara lanac blokova. BC se u početcima najčešće koristio za upravljanje kriptovalutama kao što je Bitcoin, ali je danas njegova primjena puno šira. Umjesto da se oslanja na centralni autoritet (npr. banke ili druge posredničke agencije), BC koristi distribuiranu mrežu računala (često nazvanu čvorovi) koja sudjeluju u verifikaciji i potvrđivanju novih blokova. Ova distribuirana priroda BC-a osigurava da nema pojedinog centralnog tijela koje kontrolira i manipulira podacima.

Osnovna načela BC-a koja osiguravaju sigurnost i integritet podataka su:

- Decentralizacija. BC radi na mreži računala koja su raspoređena diljem svijeta. Nema centralnog poslužitelja koji upravlja podacima, već se podaci dijele i sinkroniziraju među svim čvorovima mreže.
- Kriptografija. Podaci na BC-u se kriptiraju kako bi se osigurala privatnost i zaštita podataka. Kriptografski algoritmi koriste se za potpisivanje i verifikaciju transakcija, kao i za osiguravanje integriteta podataka.
- Nepromjenjivost. Nakon što se podaci zabilježe u blok na BC-u, vrlo ih je teško ili gotovo nemoguće mijenjati. Svaka promjena u bloku utjecala bi na sve kasnije blokove, što bi bilo vrlo teško izvesti zbog raširene distribucije podataka.
- Konsenzus. Sudionici u mreži koriste algoritme konsenzusa kako bi se složili o valjanosti novih blokova koji se dodaju na BC. Ovi algoritmi osiguravaju da se svi sudionici slažu s novim promjenama i potvrđuju njihovu valjanost.

Kao što je već istaknuto, primjena BC tehnologije ide izvan kriptovaluta. Koristi se u raznim područjima kao što su financijske usluge, lanac opskrbe, zdravstveni sustav, glasanje, upravljanje digitalnim pravima i mnogi drugi, s ciljem osiguranja sigurnosti, transparentnosti i pouzdanosti podataka. Osim Bitcoina kao jedne od prvih BC platformi, danas postoje i druge kao što su Ethereum, Hyperledger Fabric, Corda itd. Etherum je jedna od najčešće korištenih BC platformi izvan područja kriptovaluta. Općenito gledano, BC danas nalazi svoju primjenu u područjima kao što su:

- Distribuirani i sigurni spremnik podataka. BC se može koristiti kao distribuirani spremnik podataka za pohranu i provjeru autentičnosti informacija. Podaci se pohranjuju u blokovima koji su vezani u lanac, a svaki blok sadrži digitalni potpis prethodnog bloka. Ovo osigurava da se podaci ne mogu mijenjati bez promjene svih kasnijih blokova čime se osigurava integritet podataka.
- Digitalni potpisi i verifikacija autentičnosti. BC omogućuje korištenje digitalnih potpisa za verifikaciju autentičnosti poruka. Sudionici u mreži mogu koristiti svoje privatne ključeve za digitalno potpisivanje poruka, a drugi sudionici mogu koristiti javne ključeve za verifikaciju potpisa. Ovime se osigurava da se poruke ne mogu mijenjati ili krivotvoriti tijekom prijenosa.

- Pametni ugovori. Pametni ugovori su programibilne skripte koje se izvršavaju na BC-u. Oni omogućuju automatizaciju i provođenje poslovnih logika na transparentan način. Pametni ugovori mogu biti korisni za sigurne mrežne poslovne komunikacije jer omogućuju transparentno izvršavanje i provjeru uvjeta ugovora bez potrebe za posrednicima.
- Lako praćenje i transparentnost. BC pruža transparentnost jer svi sudionici u mreži imaju uvid u transakcije i podatke koje su zabilježene na njemu. To omogućuje bolje praćenje poslovnih komunikacija i povećava povjerenje među sudionicima.
- Zaštita privatnosti. BC može pružiti sigurnost i zaštitu privatnosti kroz upotrebu kriptografskih tehnika. Identiteti sudionika mogu biti anonimizirani putem pseudonima ili jedinstvenih identifikatora, dok se osjetljivi podaci mogu kriptirati kako bi se osigurala njihova zaštita tijekom prijenosa i pohrane.

Važno je napomenuti da primjena BC tehnologije u sigurnim mrežnim poslovnim komunikacijama ovisi o konkretnim zahtjevima i kontekstu. Potrebno je pažljivo razmotriti prednosti, izazove i mogućnosti koje BC tehnologija pruža kako bi se donijela odluka o njezinoj primjeni (Arunović, 2018).

Na sadržaj

7. DIGITALNA TRANSFORMACIJA

Pojam digitalna transformacija (DT) odnosi se na intenzivnu primjenu digitalne tehnologije i resursa kako bi se ti resursi pretvorili u nove prihode, poslovne modele i načine poslovanja. Uključuje temeljitu promjenu u organizaciji i načinu tradicionalnog poslovanja korištenjem digitalnih tehnologija kao što su internet stvari (IoT), računalstvo u oblaku i inovativne digitalne platforme te primjenom novih poslovnih modela. Glavni cilj digitalne transformacije je poboljšanje performansi i brža prilagodba u okruženju koje se neprestano i ubrzano mijenja. Možemo zapravo postaviti retoričko pitanje je li s ovim poglavljem trebalo započeti ovaj udžbenik ili je baš ovo prava pozicija za ovakva razmatranja. Naime, svrha ovog udžbenika je obrazovanje novih profila stručnjaka sigurnosti i zaštite koji će kroz ove predmete steći dio potrebnih znanja i usvojiti određeni način razmišljanja kako bi se uključili u postojeći tehnološki tok DT-a i bili dio pokretačke snage za njezin daljnji napredak. S druge strane, znanje usvojeno kroz prethodna poglavlja čini tehnološki temelj za razumijevanja što je to DT i koji su njezini daljnji ciljevi.

U tehnološkom smislu, DT je treća, najnaprednija faza ukupnog toka digitalizacije. Posljedica digitalizacije su različite inovacije. Tehnološke inovacije temeljene na digitalizaciji razvijale su se u stadijima ili valovima. Prema tome, razlikuju se tri vala digitalizacije s obzirom na primjenjivane tehnologije i posljedične efekte: digitalizacija, digitalizacija i digitalna transformacija. Slika 7.1. prikazuje svojstva i doprinose svake od navedenih faza digitalizacije.

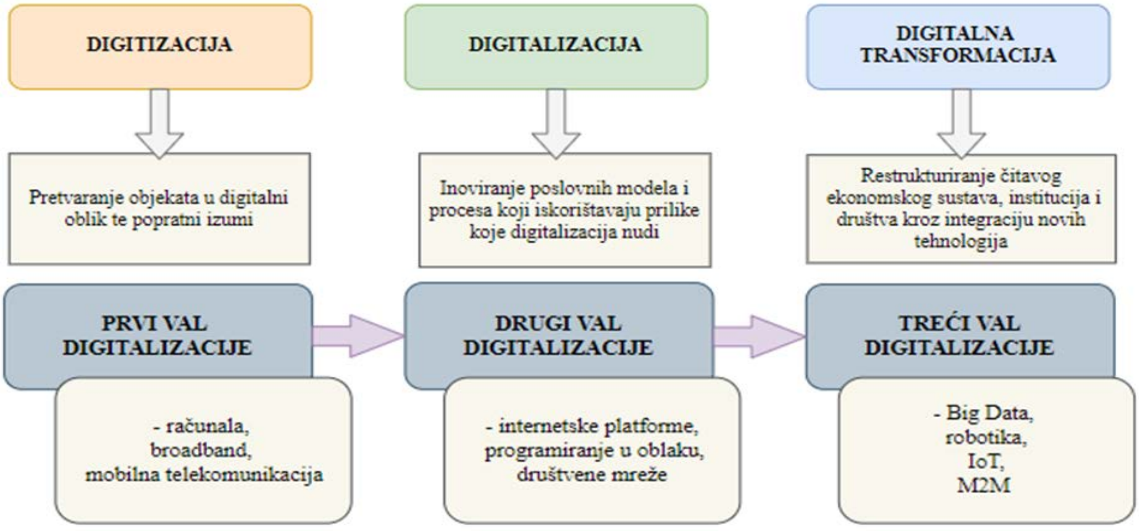

Slika 7.1. Svojstva i doprinosi tri vala digitalizacije (izvor: autor)

Digitalna transformacija oslanja se na ubrzani razvoj informacijsko-komunikacijske tehnologije, ali nužne su i promjene u ljudskom shvaćanju nužnih promjena u svim segmentima djelatnosti, kao i promjene u nastavnim programima (STEM orijentacija) koji moraju stvarati nove kadrove koji će podupirati ostvarenje i održivost ove koncepcije. Utjecaji ove koncepcije na tvrtke u osnovnim crtama su: lokalizirane i identificirane proizvodne serije koje omogućuju više saznanja o proizvodnom procesu, povezanost unutar organizacije, prilagodljivost i mogućnost optimizacije proizvodnog procesa putem kontinuiranog prikupljanja vanjskih i unutarnjih podataka, kompetitivna prednost, individualizacija proizvodnje prema zahtjevima kupca i veća povezanost s kupcima. Iz perspektive radnika utjecaji su: dodatni zahtjevi na zaposlenike, obuka (stjecanje IT znanja), veća uključenost u inovacijski proces, nova vrsta interakcije između čovjeka i stroja s

manjim prisustvom radnika unutar tvornice, podrška za pametne potpomognute sustave, decentralizirane strukture i upravljačke forme i više prostora za odlučivanje. DT je ustvari prisutna i intenzivno se razvija od 2000. godine do danas, a njezin se razvoj i dalje intenzivira. Kao što je već spomenuto, posljedice DT-a nisu prisutne samo u industriji, već i u školstvu, državnim i drugim javnim uslugama te u svakodnevnom životu. U životu svakodnevno neprimjetno usvajamo nove tehnologije koje postaju dio naših životnih navika. U školstvu je to uvođenje i naglasak na STEM predmete. U državnim i javnim uslugama izravna je posljedica uvođenje središnjeg zdravstvenog informacijskog sustava (CEZIH), čija primjena započinje 2007. godine i /nacionalnog portala za pristup javnim uslugama (e-Građani), puštenim u rad 2015. godine. No, /*/uvođenje mrežno dostupnih javnih usluga nije među građanima RH imalo znatan odjek sve do početka 2020. godine kada se zbog pandemija virusa COVID-19 uvodi zabrana izravnih kontakata (tzv. *lockdown*) što je na svjetskoj razini dovelo do intenzivne primjene isključivo mrežnih usluga i elektroničkog trgovanja s beskontaktnom dostavom na svim proizvodnim razinama. Moglo bi se reći da je npr. u RH ostvaren intenzivan razvoj DT-a unutar jedne godine za koji bismo inače trebali čekati barem jedno desetljeće.

Prema rezultatima istraživanja koja je u Republici Hrvatskoj provodila konzultantska tvrtka Apsolon, najčešći prisutni problemi i usporivači uvođenja DT-a u RH su:

- financijski razlozi (troškovi)
- preveliki naglasak na postojeće prioritete poslovanja
- nedostatak vremena za provođenje DT-a (ljudski resursi)
- nedovoljno ulaganje u obrazovanje postojećih kadrova i zapošljavanje novih vrsta stručnjaka
- nedovoljna propusnost spojnih veza na internet i premala ulaganja u širokopropusne mreže
- nerazumijevanje menadžmenta da se povećavanje digitalne spremnosti tvrtke ne može postići prebacivanjem odgovornosti na IT odjele (to je ustvari zadaća za upravu i cijelu strukturu tvrtke).

Ako gledamo iz perspektive stručnjaka SiZ-a, najveće su promjene načinjene u području industrijske proizvodnje i cjelokupnog poslovanja (Kralj i Aralica, 2022; Kralj i Mehmetaj, 2022).

7.1. Industrija 4.0

Termin i koncepcija Industrija 4.0 (I4.0), kao nova strategija razvoja njemačke industrije, predstavljena je na svjetskom sajmu *Hannover Messe* 2011. godine i najavljena kao početak nove četvrte industrijske revolucije (4.IR). Prikazana je kao sredstvo povećanja konkurentnosti njemačke proizvodne industrije kroz sve veću integraciju „kibernetičko-fizičkih sustava" (engl. *Cyber-Physical System*, CPS) u tvorničke procese (Nikolić, 2017). Između prethodne tri industrijske revolucije su prolazile stotine godina, a ova je stigla već nakon pola stoljeća. Prvu je pokrenula u 18. stoljeću energija vode i pare koja je omogućila viši stupanj mehanizacije (izgradnja prvog tkalačkog stroja pokretanog parom 1784. godine). Manja potreba za ljudskim radom i otpuštanje radnika izazvala je velike socijalne nemire, bunt radnika i uništavanje tih strojeva. U 19. stoljeću električna energija zamijenila je energiju pare čime je započela druga industrijska revolucija (izgradnja prve mehanizirane klaonice u Cincinatiju, SAD, 1870.). Treću industrijsku revoluciju obilježila je upotreba elektroničkih i informacijsko-komunikacijskih sustava, te temeljem toga i široka primjena automatizacije u proizvodnim procesima (primjena prvog

Programmable Logic Controllera ili skraćeno PLC-a). Prema nekim autorima (Roser, 2015), Industrija 4.0 i nije nova industrijska revolucija već nastavak treće industrijske revolucije zasnovan na intenzivnom suvremenom tehnološkom razvoju. Međutim, činjenica je da je ovaj razvoj zasnovan na suvremenim informacijsko-komunikacijskim rješenjima toliko snažan da zaslužuje termin 4.IR. Osim toga, svaka je industrijskih revolucija, osim povećanja intenziteta i pojeftinjenja troškova proizvodnje, donijela i novi odnos poslodavaca prema radnicima, kao i promjenu njihovog položaja u društvu. Slika 7.2., preuzeta iz brošure Hrvatske gospodarske komore (HGK) o Industriji 4.0, prikazuje vremenski tok pojave industrijskih revolucija te ukazuje na činjenicu da i HGK u svojoj studiji slučaja gleda na I4.0 kao na 4.IR.

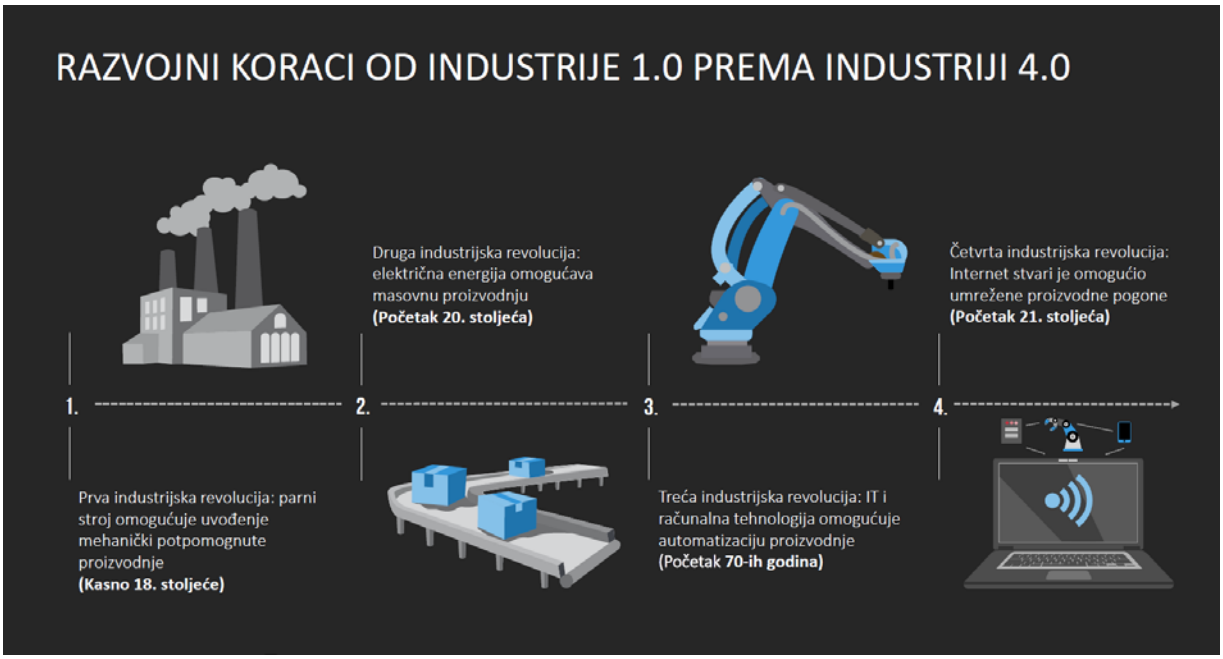

Slika 7.2. Razvojni koraci od Industrije 1.0 prema Industriji 4.0 (HGK, 2022)

Organizacijska povezanost je ključna za koncepciju I4.0 i zasniva se na vertikalnoj i horizontalnoj integraciji. Vertikalna integracija podrazumijeva umrežene proizvodne sustave koji pristupaju izmjenama u proizvodnom procesu kroz alternativne strategije. Regulatorni okvir vertikalne integracije je „Pametna tvornica" (engl. *Smart Factory*). Proizvodni blokovi neće više biti statični i predodređeni (Perić, 2022.) Definirat će se IT konfiguracijska pravila iz kojih će se kreirati specifična proizvodna struktura. Horizontalna integracija podrazumijeva optimizirani tok sirovine i informacija od različitih dobavljača u globalnom lancu vrijednosti prema krajnjim korisnicima. Povezani IT sustavi prate potrebe za sirovinama u svim koracima na globalnoj razini. Temeljem informacije mogu kreirati planove proizvodnje i na taj način proslijediti dobavljačima u realnom vremenu zahtjeve za komponentama i sirovinama za proizvodnju.

DT predstavlja put tehnološke prilagodbe do ostvarenja koncepcije I4.0. Definirano je 16 tzv. tehnoloških pokretača (engl. *enablers*) koji su temelj tog puta:

- internet stvari (engl. *Internet of Things*, IoT)
- analitika velikih skupova podataka (engl. *Big Data Analytics*)
- 3D ispisivanje (aditivne tehnologije)
- napredna robotika
- pametni senzori

- proširena stvarnost (AR)
- računalstvo u oblaku
- skladištenje energije
- umjetna inteligencija (AI)
- nanotehnologija
- sintetička biologija
- simulacija (VR, MR)
- sučelje čovjek-stroj (HMI)
- mobilni uređaji
- kibernetička sigurnost
- kvantno računanje.

Pokretači su u popisu navedeni od najvažnijih prema manje važnima, ali ti su koraci vrlo mali jer kako bismo inače objasnili da nam je kibernetička sigurnost tek na petnaestom mjestu, a težište nam je na bežičnoj komunikaciji i poslovnim procesima u oblaku. *Internet of Things,* (IoT) ima mnoštvo različitih definicija, a jedna od najkraćih je globalna mreža koja povezuje pametne stvari (*International Telecomunication Union,* 2012). IoT se smatra kolekcijom ili skupom stvari (objekata ili uređaja) kojima se može upravljati te koje daju informacije bežičnom vezom preko interneta koristeći najčešće mobilnu aplikaciju za nadzor ili upravljanje. Uz komunikaciju podrazumijeva uređaje, infrastrukturu i aplikacije. Ponuda aplikacija korisnicima odvija se pomoću softverskih platformi (IoT platforma) koje integriraju stvari i kontinuirano prikupljaju njihove podatke. U tu svrhu postoji potreba za obradom velike količine podataka (engl. *Big Data*), često u stvarnom vremenu, pa je potrebno objediniti i na jedinstveni način zapisati podatke primljene iz različitih izvora. Vodeća nova paradigma je komunikacija između strojeva (engl. *Machine to Machine,* M2M), i to ne samo između strojeva u tvornici, već i komunikacija između svih postojećih uređaja i sustava. Smatra se da industrija ima više razloga za uvođenje umreženog softvera u strojeve i proizvode u klasičnoj industrijskoj podjeli dizajna, proizvodnje i podrške proizvodima i uslugama. Umjetna inteligencija i robotika sastavni su dio trenutnih i nadolazećih promjena. Danas je industrija bez primjene robotike nezamisliva. Roboti su se u nekadašnjim primjenama obično nalazili u kavezima ili iza ograda radnih stanica. Promjena njihovog položaja i uloge temeljna je ideja nadolazećih promjena, odnosno smatra se da bi inteligentni strojevi koji samostalno uče, koji su prilagodljivi i mogu uzeti u obzir svoju okolinu, trebali prirodno surađivati s ljudima. Prema viziji 4.IR, roboti i ljudi bi zajedno trebali surađivati i izvršavati zadatke. Valja naglasiti da iako se daje veća uloga robotima, središnja je ideja da se oni prilagođavaju ljudima, a ne obratno. Od robota se očekuje mogućnost lociranja i navigacije, računalni vid, prilagodljivo planiranje i multiagentske strategije. Veći robotski sustavi imaju važnu ulogu u brojnim industrijskim djelatnostima, od automobilske industrije do biotehnološkog sektora. Još jedna promjena koju nosi DT je način prikupljanja podataka. Dugi niz godina poduzeća su donosila odluke na temelju podataka koje su preuzimali iz skupa tradicionalnih izvora poput izvještaja o proizvodnji, internih izvještaja, izvještaja o istraživanju tržišta i slično. Danas je mnogo više dostupnih izvora podataka, uključujući podatke koje su generirali senzori u pametnim proizvodima, kao i podatke s internetskih tražilica ili društvenih medija. Analiza velike količine podataka (engl. *Big Data Analytics*) pruža nove mogućnosti poduzećima u obliku oglašavanja, praćenja suvremenih trendova i prilika na međunarodnim tržištima bez ulaganja značajnih resursa u lokalni marketing te u obliku učinkovitije optimizacije nabave, proizvodnje i distribucije aktivnosti. Upravo je mogućnost obrade i analize tih prikupljenih podataka za daljnju upotrebu to što ovu tehnologiju čini vrlo vrijednom. Međutim, treba naglasiti da je preduvjet za funkcioniranje

ovih sustava dobra pokrivenost širokopojasnom internetskom vezom čija nedostupnost predstavlja glavnu kočnicu za DT u slabije razvijenim zemljama. Trodimenzionalni (3D) ispis promijenio je iz korijena način proizvodnje i dostave. Tradicionalni načini proizvodnje su subtraktivni, što znači da se primjenom odgovarajućih alata uklanja materijal iz obrađivanog komada čime se oblikuje zadani objekt. Završni objekt dobiva se slaganjem dijelova i komponenti. Nasuprot tome, 3D ispis je aditivni proces kojim se objekt dobiva tako da se uzastopno polažu različiti slojevi materijala. Proizvodi se mogu bolje prilagoditi potrebama krajnjih korisnika budući da 3D ispis omogućuje proizvodnju malih količina u mnogo kraćem vremenu uz optimizaciju potrošnje materijala i bez otpada (Franc i Dužević, 2020; Kralj i Mehmetaj, 2022; Perić, 2022). Istina je da i ova industrijska revolucija stvara viškove radne snage unutar pojedinih zanimanja, no s druge strane otvara nova radna mjesta u strukama koje obuhvaćaju razvoj, upravljanje i primjenu pametnih sustava. U tu je svrhu bilo potrebno prilagoditi i obrazovanje koje je intenzivno usmjereno na STEM (engl. *science, technology, engineering i mathematics*) područja počevši od osnovnog školstva. U području visokog školstva inzistira se na inovativnim projektima sveučilišnih subjekata koji se moraju dovesti do prototipa spremnog za korištenje u gospodarstvu ili stvaranje novih *start-up* tvrtki (Nikolić, 2017).

7.2. Industrija 5.0

Dok je taj proces razvoja I4.0 postajao sve intenzivniji, 2015. godine pojavio se novi pojam Industrija 5.0 (I5.0).

Prije svega treba istaknuti da se razvoj I.0 ili 5.IR i dalje zasniva na intenzivnom tehnološkom razvoju i unaprjeđenju informacijsko-komunikacijskih sustava definiranom u koncepciji I4.0. Međutim, umjesto da se nova tehnologija uzme kao polazište i ispita njezin potencijal za povećanje učinkovitosti, pristup u industriji usmjeren na čovjeka (engl. *human-centric approach*) stavlja temeljne ljudske potrebe i interese u srce proizvodnog procesa. Umjesto da pitamo što možemo učiniti s novom tehnologijom, pitamo se što tehnologija može učiniti za nas. Umjesto da tražimo od radnika u industriji da svoje vještine prilagode potrebama tehnologije koja se brzo razvija, želimo koristiti tehnologiju za prilagodbu proizvodnog procesa potrebama radnika, npr. da ga/nju vodi i obučava. To također znači da treba osigurati da korištenje novih tehnologija ne ugrožava temeljna prava radnika, kao što su pravo na privatnost, autonomiju i ljudsko dostojanstvo. Radnik za tvrtku nije više „trošak" već „investicija". To podrazumijeva da je poslodavac zainteresiran za ulaganje u vještine, sposobnosti i dobrobit svojih zaposlenika kako bi oni ostvarili svoje ciljeve. Gube se jasne granice između tzv. bijelih i plavih ovratnika. Pored usmjerenosti čovjeku, Industrija 5.0 mora poštivati koncepcije održivosti i otpornosti. Održivost znači poštivanje planetarnih granica, tj. smanjenje potrošnje energije i emisije stakleničkih plinova kako bi se izbjeglo iscrpljivanje i degradacija prirodnih resursa te osigurale potrebe današnjih generacija bez ugrožavanja potreba budućih generacija. Primjena umjetne inteligencije i aditivna proizvodnja u tome igraju veliku ulogu jer optimiziraju učinkovitost resursa i minimiziraju otpad u proizvodnji. Otpornost se odnosi na postizanje višeg stupnja robusnosti u industrijskoj proizvodnji, tj. prevenciju poremećaja te osiguravanje podrške kritičnoj infrastrukturi u vrijeme krize. Krize, poput pandemije COVID-19, istakle su krhkost našeg trenutačnog pristupa globaliziranoj proizvodnji. Ovaj bi pristup trebalo uravnotežiti razvojem dovoljno otpornih strateških lanaca vrijednosti, prilagodljivih proizvodnih kapaciteta i fleksibilnih poslovnih procesa, posebno tamo gdje lanci vrijednosti služe osnovnim ljudskim potrebama, kao što su zdravstvena skrb ili sigurnost. Tri su dakle ključna čimbenika Industrije 5.0: humanocentrički pristup, održivost i otpornost (European Commission, 2021; Nikolić, 2017).

Što se tiče radnika u proizvodnji, dio kritičara koncepcije I4.0 smatra da će i onaj mali broj radnika koji ostane u industriji nakon njene reorganizacije prema konceptu I4.0 raditi poput

strojeva. Slažu se da čovjeka treba vratiti u industrijsku proizvodnju uz korištenje novih tehnika kao što su suradnički roboti (engl. *Collaborative robots, cobots*) odnosno „koboti" (Østergaard 2016; Rada 2018). Ističu da je I5.0 po svojoj koncepciji više „antiindustrijska" nego industrijska jer je to povratak na vrijeme prije industrijalizacije, povratak u vrijeme kada su se cijenile vještine i zanati i kada je svaki proizvod bio unikat prema želji kupca. S vremenom se ustalio stav da je I5.0 novi oblik suradnje čovjeka i robota kako bi se iskoristile mogućnosti strojeva i ljudi. U I4.0 postignuto je da se roba prodaje poznatom kupcu prije same proizvodnje, a I5.0 donosi mogućnost specifičnosti izrade po narudžbi. Strojevi su precizniji i s većom snagom, a radnici posjeduju vještine te kognitivna i kritička razmišljanja. Takav je način rada prikladan za poslove koji su između potpuno ručne montaže i potpuno automatiziranih proizvodnih linija. Rad s kobotima omogućava tvrtkama bilo koje veličine implementaciju automatizacije i na mjestima gdje je ona neisplativa ili ju je teško realizirati. Tome na ruku ide i sve veća želja kupaca za personificiranim proizvodima prema njihovim željama i potrebama. Ovaj prodor u procese proizvodnje suradnjom kobota i čovjeka pojedini autori nazivaju i revolucijom „ljudskog dodira" (engl. *human touch*). Smatra se da je to ponovni povratak radnika u proizvodni proces pri čemu se koriste prednosti automatizacije i kognitivne sposobnosti ljudi. Pojava kobota se ne može smatrati revolucionarnim izumom, već je to logičan evolucijski korak u razvoju robota. Oni dobivaju sve više senzora da mogu percipirati okolinu, prepoznavati predmete i njihov položaj u prostoru, a ugrađeni viši stupanj umjetne inteligencije omogućuje im donošenje adekvatnih odluka. Koncepcija I5.0 odrazila se i u promjeni edukacijskog pristupa. Njegova se svrha eksplicitno odnosi na specifične ishode koje ljudi trebaju postići kao rezultat određenog iskustva učenja. Ne radi se o tome da svakom učeniku treba omogućiti prijenosno računalo ili tablet. Ne radi se o poboljšanju infrastrukture i povezanosti. Ne radi se o razvoju digitalnih alata i platformi. Umjesto toga, radi se o pripremi intelektualno, socijalno i emocionalno jakih pojedinaca, brizi za njihovo zdravlje i osobni razvoj, kao i općoj motivaciji, kreativnosti i vraćanju radosti učenja natrag učenicima. Digitalna oprema, infrastruktura i platforme i dalje mogu ovdje biti presudni, međutim, oni su pokretači, a ne sama svrha. U obzir se ne uzima samo potreba tržišta/tvrtke (zapošljivost), već i potreba društva i učenika. Nudi se „obrazovanje s velikom slikom", imajući na umu širu sliku o tome kako se obrazovna ponuda uklapa u cjelokupnu putanju učenja, tržište rada i razvoje u svijetu, a učenici se smatraju nositeljima promjena koji se aktivno uključuju u razvoj i provedbu kurikuluma (Dervojeda, 2021; InfinityQS, 2018).

7.3. Utjecaj digitalne transformacije na SiZ

U okviru definicije I4.0 navedeno je da su CPS (kibernetičko-fizički sustavi) temelj njezine proizvodne koncepcije. Odnos između radnika rukovatelja (engl. *Operator*) industrijskim proizvodnim sredstvima (strojevima, alatima) kroz povijest proizvodnje opisana je kategorijama od Operator 1.0 do Operator 4.0. Tipologija Operator 4.0 prikazuje kako će tehnologije 4.IR pomoći u radu rukovatelja. Operater 1.0 definiran je kao čovjek koji obavlja ručni rad. Operator 2.0 generacije predstavlja ljudski entitet čiji posao podržavaju alati, npr. računalno numeričko upravljanje (CNC) alatnih strojeva. U trećoj generaciji Operator 3.0 ljudi su uključeni u kooperativni rad s robotima i računalnim alatima. Ova suradnja čovjeka i robota u industrijskom okruženju je fascinantno polje s posebnim fokusom na fizičku i kognitivnu interakciju. Međutim, novi skup rješenja temelji se na još intenzivnijoj suradnji rukovatelja i proizvodnih sustava. Ova nova koncepcija nazvana Operator 4.0 predstavlja budućnost radnih mjesta. Rukovatelji proizvodnim sredstvima pojavljuju se u raznim vidovima. Analitički rukovatelji koriste analitiku velikih podataka za prikupljanje, organiziranje i analizu velikih skupova podataka. Proširena stvarnost (engl. *Augmented Reality*, AR) može se smatrati ključnom tehnologijom koja omogućuje poboljšanje prijenosa informacija iz digitalnog u fizički svijet pametnog rukovatelja.

Kolaborativni rukovatelj radi zajedno s kolaborativnim robotima (kobotima). Rukovatelji zdravstvenih parametara (engl. *healthy operator*) mjere i pohranjuju aktivnost vježbanja, stres, broj otkucaja srca i druge metrike povezane sa zdravljem, kao i GPS lokaciju i druge osobne podatke. Pametniji rukovatelji (engl. s*marter operators*) komuniciraju sa strojevima, računalima, bazama podataka i drugim informacijskim sustavima te primaju korisne informacije za podršku svom radu. Društveni rukovatelji koriste mobilne i društvene suradničke metode za povezivanje s resursima pametne tvornice. Supersnažni rukovatelji povećavaju snagu ljudskih rukovatelja kako bi mogli obavljati ručne zadatke bez napora koristeći nosive egzoskelete, dok virtualni rukovatelji komuniciraju s računalnim mapiranjem dizajna, montaže ili proizvodnih okruženja. Iako na prvi pogled ovaj opis aktivnosti Operatera 4.0 zvuči zbunjujuće, više je nego očito da se zasniva na suradnji čovjeka i CPS-a. Čovjek kao rukovatelj se u postupku proizvodnje susreće i komunicira s novim oblicima naprednih strojnih sučelja. Osnovna podjela CPS-a dana je na slici 7.3.

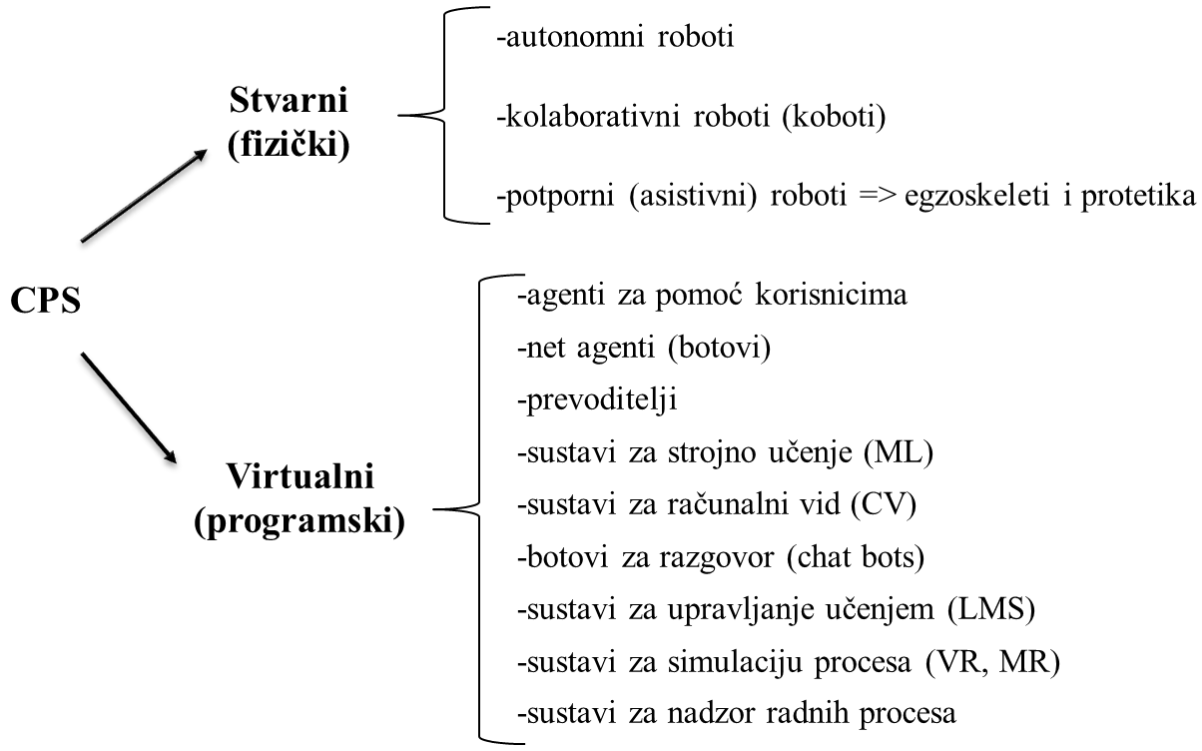

Slika 7.3. Osnovna podjela kibernetičko-fizičkih sustava (izvor: autor)

Model upravljanja pametnom tvornicom unutar koncepcije Operator 4.0 definiran je pojmom i modelom „Inteligentnog prostora" (engl. *Intelligent Space*, iSpace) čiji funkcionalni prikaz možemo vidjeti na slici 7.4.

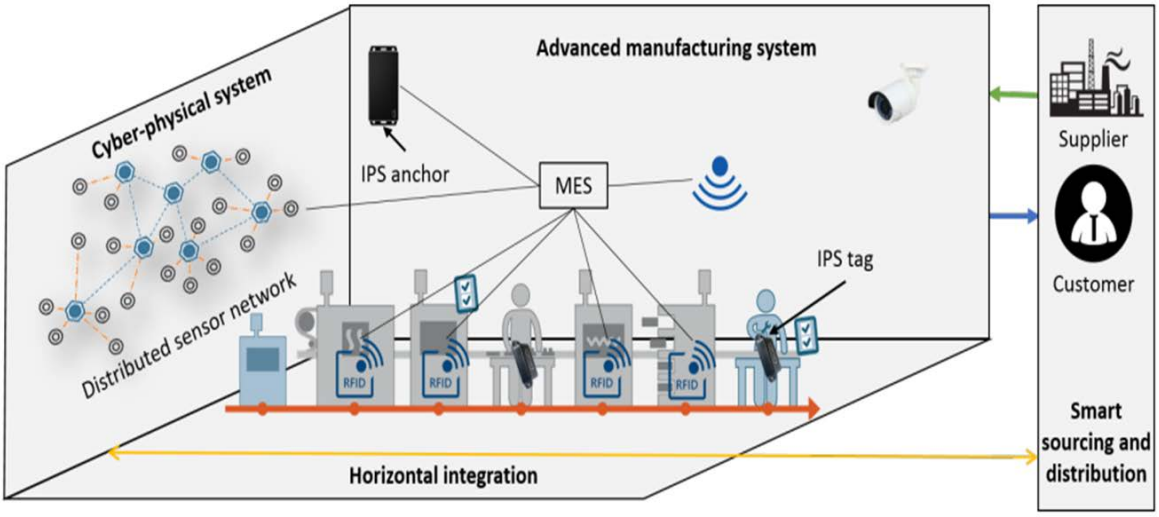

Slika 7.4. Funkcionalni prikaz modela upravljanja iSpace (Ruppert i ostali, 2018)

Integrirani signali raspodijeljeni unutar mreže naprednih senzora mogu se koristiti za praćenje rada rukovatelja, predviđanje njihovog ponašanja, sinkronizaciju aktivnosti i pružanje informacija zavisnih o radnom kontekstu. Svim aktivnostima upravlja izvršni proizvodni sustav (MES) koji prati pozicije svih rukovatelja putem unutrašnjeg pozicijskog sustava (IPS). Na ovaj je način ostvarena vertikalna integracija proizvodnog procesa. Kroz iSpace ostvaruje se i horizontalna integracija koja međusobno povezuje druge slične raspodijeljene proizvodne blokove, kupce, dobavljače te upravlja sustavom pametne nabave i dostave (Ruppert i ostali, 2018).

7.3.1. Osnovne vrste i primjene robota

Kao što je prikazano na slici 7.3., CPS dijeli fizičke robote u tri okvirne skupine, a to su:

- autonomni roboti
- kolaborativni roboti (koboti)
- potporni roboti (asistivni roboti).

Današnji autonomni roboti nastavak su primjene industrijskih robota koja je započela još 70-ih i 80-ih godina 20. stoljeća, najčešće u autoindustriji, samo što današnje generacije imaju sofisticiranije sustave za programiranje, kao i naprednije zaštitne senzore. Uglavnom se radi o sustavima koji u masovnoj proizvodnji zamjenjuju čovjeka na radnim mjestima na kojima se pojedine radne operacije neprekidno ponavljaju. Primjer takvog robotiziranog pogona u automobilskoj industriji prikazan je na slici 7.5.

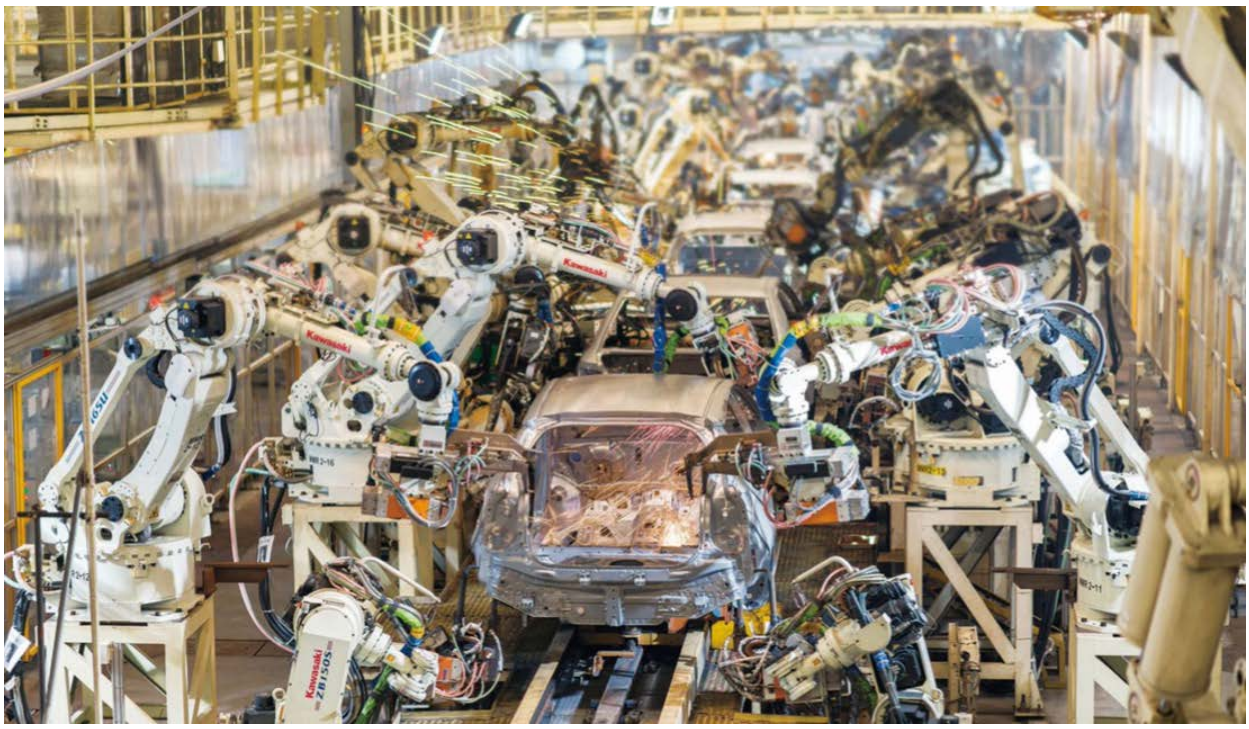

Slika 7.5. Primjer suvremenog robotiziranog pogona u autoindustriji (izvor: Toyota Motor Corporation)

Kolaborativni roboti ili koboti rade zajedno s čovjekom (rukovateljem) pri čemu se njihove radne sekvence mogu obavljati naizmjenično (čovjek odradi svoj dio posla pa pusti ili aktivira robota da odradi svoju sekvencu ili njihove radne sekvence mogu biti naizmjenične pri čemu napredna senzorika prati obavljanje čovjekove radne sekvence pa nakon toga pušta da robot odradi svoj dio). Napredni senzorski sustavi i upravljačka logika pritom mogu spriječiti potencijalne nezgode koje mogu nastati uslijed nekontroliranih pokreta čovjeka rukovatelja. Koboti mogu biti vođeni računalom ili ručno. Osnovna svojstva i sigurnosni kriteriji kod računalom vođenih kobota su:

- ograničena snaga
- nema oštrih rubova i otvorenih pokretnih mehanizama
- postojanje naprednih senzora za detekciju okoline
- mogućnost ručnog programiranja pokreta.

Prva tri kriterija usmjerena su na prevenciju od slučajnih povreda rukovatelja, što bi u suprotnom vodilo k radnom mjestu s vrlo visokim radnim rizikom. Mogućnost ručnog programiranja pokreta odnosi se na mogućnost da rukovatelj za potrebe korekcije postojeće i nove radne sekvence svojom rukom vodi robotsku pri čemu sustav upravljanja robotom pamti ove pokrete i povezuje ih u novi program za automatsko izvođenje. Slika 7.6. prikazuje primjer kolaboracije čovjeka i računalom vođenog kobota.

Slika 7.6. Primjer kolaboracije između robota i čovjeka (izvor: Universal Robots)

Svojstva ručno vođenih kobota svode se na:

- ručno upravljanje čovjeka
- haptička sučelja
- povećanje snage, preciznosti i sigurnosti ljudskog rada.

Način ručnog upravljanja može biti putem komandi (poluga i okidača) ili putem računalnog sučelja. Kod posebno oblikovanih ručnih komandi u nekim područjima primjene vrlo je važna tzv. haptička (grč. *Haptesthai,* hrv. dodirnuti) povratna veza. Haptička sučelja dijele se na kinestetička i taktilna. Kinestetička sučelja djeluju na naše udove i daju nam osjećaj sila koje na njih djeluju i osjećaj položaja u prostoru. Taktilna sučelja daju nam dodirne podražaje kojima možemo definirati sam dodir s nekom površinom kao i njezinu hrapavost, tvrdoću i, do određene granice, osjećaj topline. U slučajevima kada je radno okruženje zbog svojih utjecaja opasno po život i zdravlje korisnika (zračenje, utjecaj otrova, pirotehnički zahvati i sl.). ručno upravljani koboti nude mogućnost obavljanja poslova iz sigurnog okruženja. Tamo gdje snaga čovjeka nije dovoljna za obavljanje nekog posla, ovi će koboti osigurati potrebne sile djelovanja. U slučajevima kada se zahtijeva preciznost u obavljanju nekog posla, koboti će biti računalom precizno navođeni pri čemu neće patiti od mogućeg zamora ili tremora kao što bi to mogao biti slučaj kod čovjeka. Na sljedećim slikama možemo vidjeti nekoliko primjera navedenih vrsta kobota. Slika 7.7. prikazuje daljinski upravljan robot za razminiranje EOD-3 kojom se pirotehničar stavlja u poziciju izvan eventualnog smrtonosnog djelovanja eksplozivne naprave. Slika 7.8. prikazuje tzv. UAS (engl. *Unmanned Aircraft System*), tj. vatrogasni sustav koji se koristi za upravljanje dronovima za vatrogasna izviđanja i ograničena gašenja požara primjenom praha.

Slika 7.7. Robot za razminiranje EOD-3 (izvor: Nex Robotics Pvt Ltd.)

Slika 7.8. Dron za izviđanje i gašenje upravljan UAS-om (izvor: DronetechNZ)

U medicini se koboti danas sve više koriste u endoskopskim kirurškim intervencijama, ali i za uvježbavanje ovakvih zahvata primjenom haptičkih sučelja i virtualne stvarnosti (VR). Slika 7.9. prikazuje jedan takav trenažni sustav gdje liječnik u virtualnom okruženju provodi simuliranu endoskopsku operaciju putem komandi koje se koriste i pri stvarnim operacijama. Sličan postupak bi bio i pri telemedicinskoj operaciji gdje bi liječnik na jednoj geografskoj lokaciji upravljao kobotom koji fizički izvršava daljinski upravljane operativne postupke na drugoj lokaciji.

Slika 7.9. Primjena kobota u trenaži i telemedicinskim operacijama: prikaz područja operacije (lijevo) i konzola rukovatelja (desno) (izvor: Kun Qian – VR Based Surgery Simulation)

Sličnu primjenu kolaboracije čovjeka i robota nalazimo i u Hrvatskoj, i to u sve češćoj robotskoj operaciji prostate (slika 7.10.). Ovakve su operacije minimalno invazivne, zahtijevaju kratko razdoblje opravka te omogućavaju da se pacijenti vrlo brzo vrate svojim redovnim radnim aktivnostima.

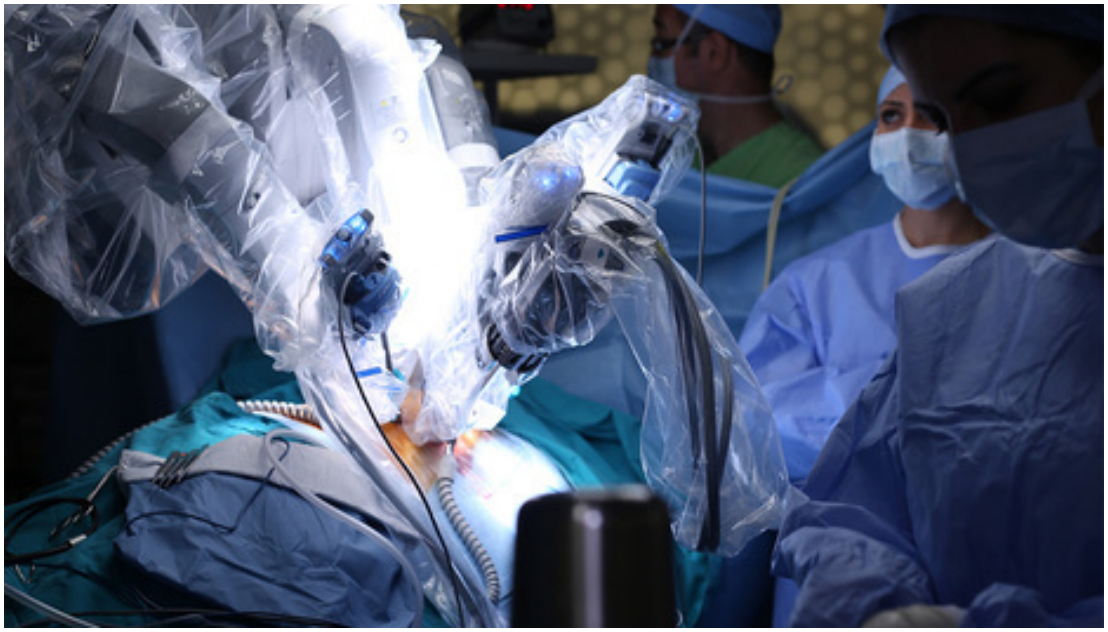

Slika 7.10. Izvođenje robotske operacija prostate (izvor: www.plivazdravlje.hr)

Jedna primjena računalom vođenih kolaboracijskih robota u medicini prikazana je na slici 7.11.

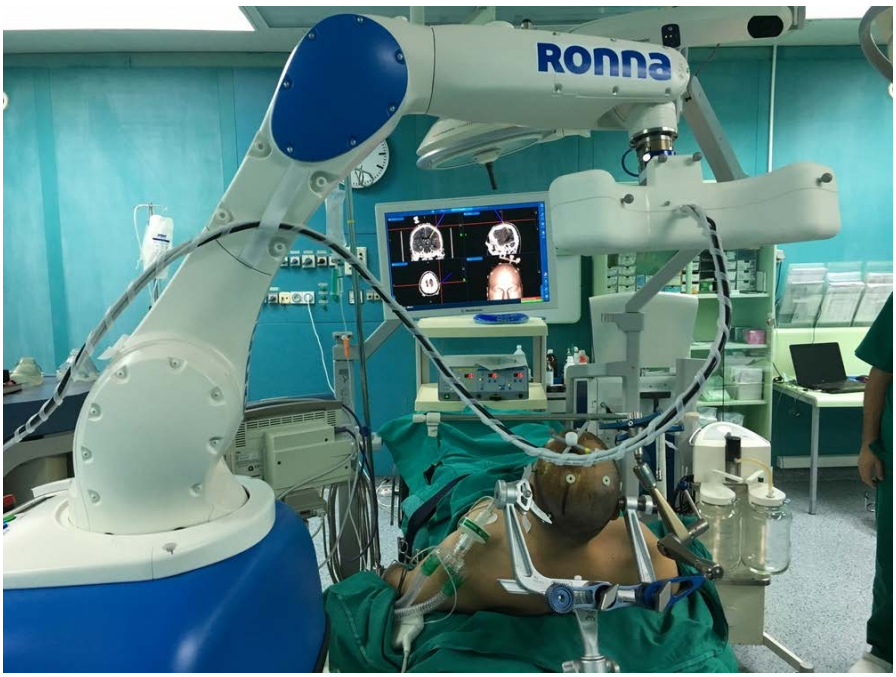

Slika 7.11. Robotizirani sustava za operacije u neurokirurgiji (izvor: FSB)

Prikazani robotizirani sustav za stereotaktičku navigaciju s primjenom u neurokirurgiji razvijen je u sklopu istraživanja u projektu *RONNA* (Robotska neuronavigacija). Razvoj je proveden u suradnji Fakulteta strojarstva i brodogradnje Sveučilišta u Zagrebu (FSB) i Kliničke bolnice Dubrava. Ovdje do izražaja dolaze preciznost i „mirna ruka" (bez tremora) robota prilikom pristupa npr. ciljanom području unutar mozga.

Na slici 7.12. prikazana je jedna industrijska primjena računalom vođenog kobota u postupku zavarivanja. Ovdje također dolazi do izražaja operativna preciznost robota i kreativni pristup čovjeka koji pritom može biti na poziciji zaštićenoj od izravnog djelovanja UV zračenja.

Slika 7.12. Primjena računalom vođenih kobota u industriji (izvor: PopTok)

Poseban slučaj kolaboracije čine potporni (asistivni) koboti u koje ubrajamo agzoskelete i naprednu protetiku. Aktivni agzoskeleti svojom osnovnom konstrukcijom pružaju vanjsku potporu ljudskom tijelu, a ugrađenim aktuatorima (elektromotornim, pneumatskim, hidrauličkim i dr.) povećavaju snagu djelovanja ljudskih udova, odnosno smanjuju napor i povećavaju fizičke

mogućnosti radnika. Na slici 7.13. prikazane su dvije vrste aktivnih egzoskeleta. Lijevo je prikazan egzoskelet tvrtke Daewoo koji omogućava radniku-rukovatelju prijenos teških tereta pružajući potporu cijelom tijelu. Desno je prikaz egzoskeleta tvrtke Panasonic, model AWN-03, koji pruža potporu tijelu radnika prilikom podizanja teških tereta. Ovaj egzoskelet pruža potporu i rasterećenje donjeg dijela leđa i kukova uz povećanje snage podizanja. Ovi su sustavi opremljeni senzorima i naprednom računalnom logikom koja detektira i prati pokrete radnika pružajući potporu u pravom smjeru i u trenutku kada je to potrebno. Sustavi su potpuno autonomni s baterijskim napajanjem.

Slika 7.13. Egzoskeleti za manipulaciju teretom (izvor: Daewoo, Panasonic)

Pored ovih industrijskih egzoskeleta razvijeni su i egzoskeleti za primjenu u fizikalnoj terapiji koji pomažu osobama pri savladavanju pokreta u rehabilitaciji, kao i egzoskeleti koji paraliziranim osobama pružaju mogućnost kretanja. Posebnu kategoriju čine vojne primjene koje omogućavaju vojnicima veću snagu i preciznost djelovanja, kao i veću brzinu kretanja bojištem. Slične su primjene u eksperimentalnoj fazi i u vatrogastvu.

Napredna protetika je također jedno od područja kolaboracije čovjeka i robotskih sustava koje intenzivno napreduje. Ove proteze možemo podijeliti u dvije osnovne skupine: proteze koje nadomještaju dio nekog uda (npr. šaku, podlakticu, potkoljenicu) i proteze koje nadomještaju cijeli ud (npr. nogu, ruku). Kod protetike dijela uda, gdje postoji batrljak, za upravljanje protezom koriste se uglavnom elektromiografski (EMG) signali postojećih živčanih završetaka, dok se kod nadomještanja nepostojećih udova i u slučajevima kada se želi postići prijenos taktilnog doživljaja (dodira), koriste elektroencefalografski (EEG) signali što često zahtijeva invazivnu ugradnju elektroda u korteks. Primjer jedne napredne nadomjesne proteze prikazan je na slici 7.14.

Slika 7.14. Primjer napredne nadomjesne protetike (izvor: CWRU, Functional Neural Interface LAB)

7.3.2. Nadzor sigurnosti i zaštite na radu

Sustavi videonadzora i drugih naprednih senzora omogućuju kroz iSpace koncepciju znatno povećanje sigurnosti rada praćenjem korištenja zaštitne opreme te praćenjem ponašanja i putanja kretanja radnika u proizvodnom okruženju. Od ključnog je značaja primjena umjetne inteligencije (AI) i tzv. računalnog vida (CV). Slike 7.15., 7.16. i 7.17. prikazuju primjere ovakvih nadzornih aktivnosti putem sustava kojeg je razvila turska tvrtka Intenseye.

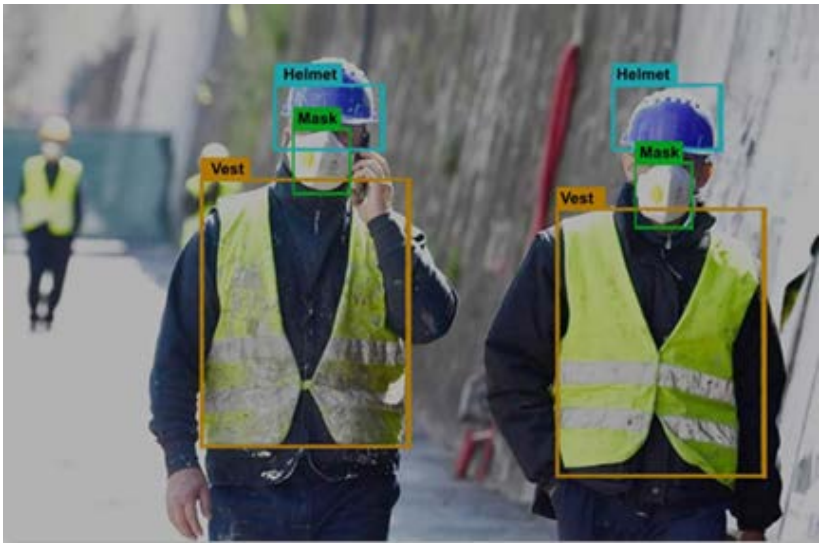

Slika 7.15. Nadzor opremljenosti radnika zaštitnom opremom (izvor: Intenseye)

Slika 7.16. Nadzor primjene zaštitne opreme pri rukovanju strojevima (izvor: Intenseye)

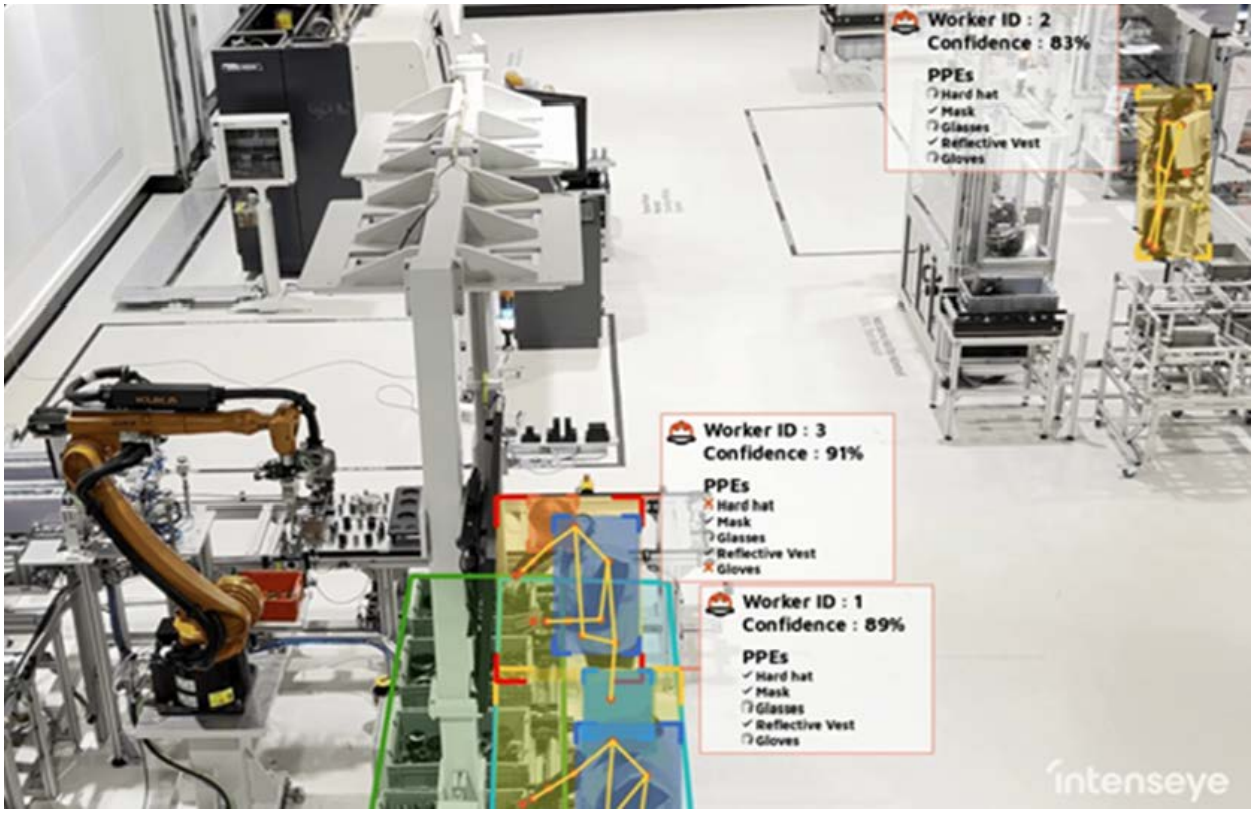

Slika 7.17. Nadzor opremljenosti zaštitnim sredstvima u kolaborativnom okruženju (izvor. Intenseye)

Na slici 7.15. prikazana je kontrola opremljenosti osobnim zaštitnim sredstvima (OZS) prilikom ulaska na radilište, dok slika 7.16. prikazuje nadzor opremljenosti OZS-a prilikom pristupanja radnim operacijama na stroju, pri čemu se za opomenu radnika koristi postojeći sustav svjetlosnog i zvučnog upozorenja, kao i zasloni radne opreme. Ovisno o sustavu, strojevi mogu biti blokirani za daljnji rad dok radnik (rukovatelj) nema kompletnu zaštitnu opremu. Slika 7.17. prikazuje udaljeni nadzor opremljenosti radnika unutar kolaborativnog radnog okruženja, pri čemu se koristi proširena stvarnost (AR) u cilju izvješćivanja nadležnih stručnjaka ZNR-a o stanju

opremljenosti pojedinog rukovatelja. Može se primijetiti da u svakom izvještajnom okviru sustav daje podatak o pouzdanosti (engl. *confidence*) s kojom je utvrdio prikazano stanje. Naime, sustavi zasnovani na AI i CV rade na načelu uspoređivanja promatranih objekata (slika) s pohranjenim (naučenim) uzorcima. Kako se radi o objektima u pokretu, ne može se očekivati da prepoznavanje bude sa stopostotnom preciznošću, no i ovdje prikazani postotci mogu se smatrati visoko pouzdanim.

Jedna od vrlo praktičnih aplikacija za nadzor opasnosti na otvorenom ili zatvorenom prostoru je aplikacija *Safety Compass* koju proizvodi tvrtka Pyxis Group Pty Ltd. *Safety Compass* koristi intuitivnu proširenu stvarnost i interaktivno mapiranje za prenošenje informacija o opasnostima korisnicima na terenu. Instalira se jednostavno na pametnim telefonima ili tabletima i omogućava korisnicima povlačenje mrežom razne dokumente i upute o pojedinim točkama interesa u radnom okruženju. Na otvorenom aplikacija koristi geolokaciju putem GPS-a, dok u zatvorenom prostoru može koristiti interne sustave za pozicioniranje (engl. *beacons*) s kojima komunicira putem *bluetooth* protokola. Pristupom fizičkoj lokaciji radnika, aplikacija predstavlja vitalne informacije o trenutnim opasnostima izravno na telefon radnika i tako izbjegava potrebu za glomaznim sigurnosnim priručnicima za lociranje i upravljanje rizikom. Slika 7.18. prikazuje neke od mogućih unutarnjih i vanjskih funkcionalnih scenarija i zaslonskih prikaza u aplikaciji *Safety Compass.*

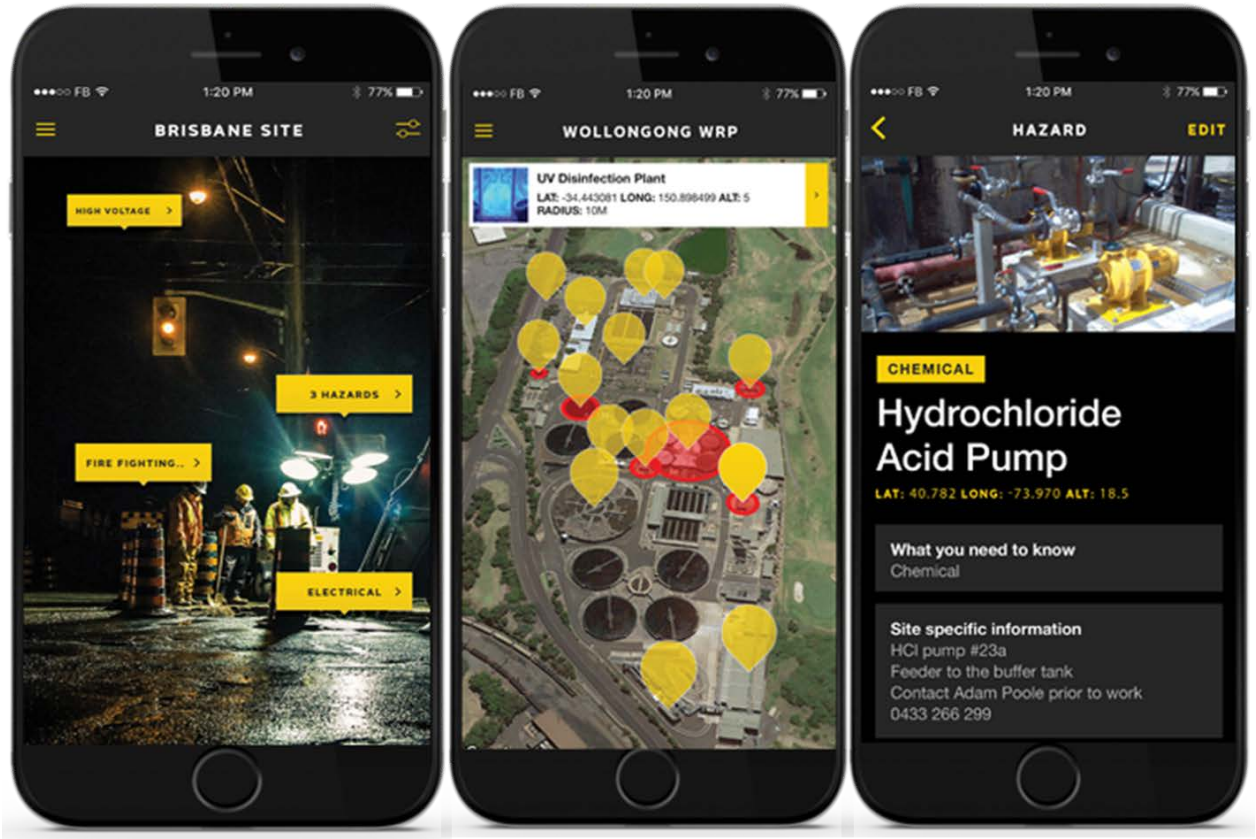

Slika 7.18. Neki od nadzornih scenarija i prikaza aplikacije *Safety Compass* (izvor: Pyxis Group Pty Ltd)

7.3.3. Sažeto o doprinosima digitalne transformacije

Nakon ovih detaljnih razmatranja učinaka digitalne transformacije i posljedičnih promjena u proizvodnji koje su se pojavile u obliku paradigmi I4.0 i I5.0 možemo zaključiti da digitalna transformacija i robotika mogu unaprijediti sigurnost i zaštitu zdravlja na radu na više načina:

- **Automatizacijom.** Uvođenje robotike i automatizacije u proizvodnju može smanjiti izloženost radnika opasnim materijalima i uvjetima rada što značajno poboljšava sigurnost i zaštitu zdravlja na radu.
- **Upotrebom senzora i loT-a.** Senzori i loT tehnologija mogu se koristiti za prikupljanje podataka o radnom okruženju kao što su temperatura, vlažnost, kvaliteta zraka i druge varijable. Ovi se podaci mogu koristiti za nadzor uvjeta rada i poboljšanje sigurnosti na radnom mjestu.
- **Analizom podataka.** Analiza podataka može se koristiti za identificiranje rizika i poboljšanje sigurnosti i zaštite zdravlja na radu. Primjerice, korištenje strojnog učenja i analitičkih alata za prepoznavanje uzoraka u podacima o sigurnosti može pomoći u otkrivanju rizičnih situacija i identificiranju mjera za sprječavanje nesreća.
- **Nadzorom na daljinu.** Daljinski nadzor može se koristiti za nadgledanje radnika na udaljenim ili opasnim mjestima. Primjerice, upotreba dronova za inspekciju i nadzor na visokim nadmorskim visinama ili drugim teško dostupnim područjima može smanjiti rizik od nesreća.
- **E-učenjem.** Digitalna transformacija omogućuje uvođenje *e-learning* platformi i drugih digitalnih alata za obuku i osposobljavanje radnika za sigurno i zdravo radno okruženje.

Ukratko, digitalna transformacija i robotika mogu unaprijediti sigurnost i zaštitu zdravlja na radu primjenom novih tehnologija koje mogu smanjiti rizik od nesreća, poboljšati nadzor i analizu podataka te pružiti obuku radnicima na siguran i učinkovit način.

Na sadržaj

8. INFORMATIZACIJA U DOMENI SIGURNOSTI I ZAŠTITE U RH

Kroz prizmu elementarnih znanja stečenih kroz prethodna poglavlja o informacijskim sustavima, njihovim sastavnicama, kao i o razvoju suvremene informacijsko-komunikacijske tehnologije fokusirane kroz paradigmu digitalne transformacije, u ovom će se poglavlju analizirati razvoj informatizacije ili, možda bolje rečeno, izgradnja informacijske infrastrukture u domeni sigurnosti i zaštite na području Republike Hrvatske. Posebno će biti prikazane dosadašnje ideje i projekti u domeni ZNR-a, a posebno u ZOP-u i vatrogastvu, iako u načelu postoje određena preklapanja između aktivnosti unutar ovih područja.

Zaštita na radu odnosi se na skup mjera i aktivnosti koje se poduzimaju kako bi se osigurala sigurnost i zaštita zaposlenika na radnom mjestu. Cilj je smanjiti rizike od nesreća, ozljeda na radu i profesionalnih bolesti. Doneseni su zakoni i propisi koji reguliraju zaštitu na radu, a poslodavci su obvezni osigurati sigurno radno okruženje za svoje zaposlenike. Ovo uključuje pravilno održavanje opreme, obuku o sigurnom radu, osiguravanje zaštitne opreme i procjenu rizika kako bi se identificirali potencijalni problemi i spriječile nesreće. Zaštita od požara je skup mjera i postupaka usmjerenih na sprječavanje požara, kao i na zaštitu ljudi, imovine i okoliša u slučaju izbijanja požara. Ovo uključuje postavljanje i održavanje protupožarnih sustava, kao što su sustavi detekcije požara, protupožarni aparati i sustavi, alarmni sustavi te planiranje evakuacijskih ruta i izradu evakuacijskih planova. Cilj je minimizirati štetu koja može nastati uslijed požara te osigurati siguran izlaz i evakuaciju ljudi u slučaju opasnosti. Vatrogastvo je struka koja se bavi gašenjem požara i spašavanjem ljudi i imovine u slučaju požara ili drugih hitnih situacija. Vatrogasci su obučeni profesionalci koji koriste različitu opremu i tehnike kako bi kontrolirali i ugasili požar te pružili hitnu pomoć u različitim situacijama. Često surađuju s drugim službama hitne pomoći i agencijama za zaštitu od katastrofa kako bi pružili učinkovitu reakciju u slučaju velikih nesreća ili prirodnih katastrofa.

Zaštita na radu i zaštita od požara se preklapaju budući da su obje usmjerene na sprječavanje nesreća i osiguranje sigurnog radnog okoliša. Primjerice, postavljanje protupožarnih aparata i obuka zaposlenika o protupožarnim mjerama može biti dio zaštite na radu, ali istovremeno pomaže u sprječavanju i suzbijanju požara. Zaštita na radu također može uključivati procjenu opasnosti na radnom mjestu i provođenje preventivnih mjera kako bi se smanjio rizik od požara. Iako je vatrogastvo posebna grana koja se bavi aktivnim gašenjem požara i spašavanjem ljudi i imovine u slučaju požara ili drugih hitnih situacija, može se reći da vatrogastvo čini operativni dio zaštite od požara, dok zaštita od požara uključuje i preventivne mjere, kao i organizacijske procedure koje se primjenjuju kako bi se spriječili požari i osigurala brza i sigurna evakuacija u slučaju požara.

8.1. Informatizacija u domeni zaštite na radu

8.1.1. Ideje i projekti za oblikovanje informacijske infrastrukture

ILO je povodom Međunarodnog dana sigurnosti i zdravlja na radu održanog 28. travnja 2017. godine, predstavila ideju prikupljanja i obrade podataka vezanih uz ZNR na međunarodnom planu. Prema njihovim procjenama tada je bilo 313 milijuna ozljeda na radu, a one smanjuju BDP za 4 % (Franović i Kralj, 2021). Vrlo je važno da zemlje povećaju svoje kapacitete za prikupljanje i analizu podataka o ZNR-u u svrhu prevencije. Podaci su neophodni za određivanje prioriteta i mjerenje napretka kako na razini tvrtke tako i na nacionalnoj razini. Nadležno tijelo može biti ministarstvo rada koje je ovlašteno izdavati propise ili naloge koji imaju zakonsku snagu u odnosu na sustav. Nadležno ministarstvo u suradnji s reprezentativnom organizacijom poslodavaca i radnika treba osigurati uspostavu i primjenu sljedećih postupaka:

- izvješćivanje o ozljedama na radu i profesionalnim bolestima
- izvješćivanje u ozljedama na putu da posla
- istrage nesreća koje uzrokuju ozljede
- izrade godišnjih statistika o ozljedama na radu, bolestima i smrtnim slučajevima
- izvješćivanje o slučajevima pojava opasnih profesionalnih bolesti.

U kontekstu EU-a, Republika Hrvatska je kroz projekte IPA2007 i IPA 2012 (Uredbe Vijeća EU: 1085/2006, 718/2007) dobila zadaću oblikovanja nacionalne informacijske infrastrukture u domeni ZNR-a. Ova se ideja predstavlja i kroz Strateški okvir o zaštiti zdravlja i sigurnosti na radu za razdoblje od 2014. do 2020. godine (Franović i Kralj, 2021). Ovaj je dokument donesen u cilju bolje zaštite radnika u EU od nezgoda na radu i profesionalnih bolesti. U njemu su navedeni najveći izazovi i strateški ciljevi u području zaštite zdravlja i sigurnosti na radu te su predstavljene glavne mjere i instrumenti za njihovo ostvarenje. Ne propisuje se izravno primjena IKT rješenja, ali se težište stavlja na pravovremena izvješćivanja, povezanost i koordinaciju između svih čimbenika u ovom području, što je s tehničko-tehnološkog gledišta izvedivo primjenom IKT rješenja.

Zavod za unaprjeđenje zaštite na radu (ZUZNR), prije nego je postao jedna od uprava Ministarstva rada i mirovinskog sustava (MRMS), predstavio je u siječnju 2016. godine program pomoću kojega bi unaprijedio ZNR, zdravlje i produktivnost radnika u Republici Hrvatskoj. Njihova je vizija bila razvijati kulturu prevencije i unaprjeđivanja ZNR-a radi osiguranja sigurnih i zdravih radnih mjesta koja pridonose dobrobiti radnika i poslodavca, rastu produktivnosti, konkurentnosti i gospodarskom rastu. Edukacijom u području ZNR-a podizala bi se razina svijesti i informiranosti. Osim edukacije uvedene u školskoj dobi, kao glavni projekt naglašena je sveobuhvatna baza podataka pod nazivom Središnji informacijski sustav ZNR (SNIS ZNR) ili *Data Collector* ZNR shematski prikazan na slici 8.1.

Slika 8.1. Shematski prikaza ideje sustava *Data Collector* ZNR (ZUZNR, 2016)

Prije definiranja projektnog zadatka bilo je potrebno provesti detaljnu analizu postojećeg stanja (analizu raspoloživih potencijala, procesa, ciljeva i potreba) te nakon toga definirati sve potrebne sastavnice i pripremiti natječajnu dokumentaciju. Nakon provedenog natječaja uslijedile bi faze izrade, testiranja i implementacije informacijskog sustava te edukacija sudionika (budućih

konzumenata informacijskog sustava). Održivost projekta je važan parametar koji treba zadovoljiti kako bi realizacija projekta bila opravdana.

U osnovi je zamišljeno da bi sljedeće skupine korisnika trebale ažurirati odgovarajuće podatke u ovom informacijskom sustavu:

- **Porezna uprava.** Pristup podacima o pravnim i fizičkim osobama na temelju OIB-a.
- **Ministarstvo gospodarstva**. Integracija podataka iz obrtnog registra.
- **MRMS**. Prijava i odjava radnika te evidencija ovlaštenja za pravne i fizičke osobe i unos podataka izravno u aplikaciju.
- **Državni zavod za statistiku**. Integracija klasifikacijskih podataka.
- **HZZO i HZJZ.** Unos podataka o ozljedama na radu i profesionalnim bolestima izravno u bazu ili učitavanjem iz postojeće internet baze podataka.
- **Inspektorat rada.** Unos podataka o nepravilnostima nakon provedenih inspekcijskih nadzora.
- **Poslodavci.** Omogućen unos podataka preko mrežne stranice (tzv. *web*-sučelja) i učitavanje podataka iz postojećih baza propisano Zakonom o ZNR i pravilnicima.
- **Ovlaštene osobe (pravne i fizičke).** Omogućen unos podataka preko *web*-sučelja.

S druge strane, izlaz iz sustava omogućavao bi generiranje normiranih izvješća na zahtjev te pristup javnosti preko *web*-sučelja.

Ovaj ambiciozno zamišljen sustav nikada nije zaživio zbog različitih objektivnih razloga. Ukidanjem ZUZNR-a i restrukturiranjem, MRMS se okrenulo postupnom modularnom razvoju podsustava u domeni ZNR-a. Ove su aktivnosti obuhvaćene i kasnije predstavljenim prijedlogom dokumenta Nacionalni plan zaštite na radu za razdoblje 2021. − 2027. godine (MRMS, 23. studenoga 2020. godine). Do svog ukidanja ZUZNR kao tadašnje izvršno tijelo investitora u gradnji sustava, uspio je implementirati samo dio funkcionalnosti, i to kroz aplikativno rješenje IS ZNR-a. U sadašnjoj funkcionalnoj fazi, IS ZNR sadržava podatke o ovlaštenim osobama za obavljanje poslova zaštite na radu i njihovom obavljanju poslova zaštite na radu za poslodavce te različite podatke koje svi poslodavci prema ZZNR-u i drugim važećim propisima imaju obvezu redovno dostavljati MRMS-u. Ovi će se podaci koristiti za stručni nadzor i reviziju poslovanja ovlaštenih osoba za obavljanje poslova ZNR-a u odnosu na dobivena ovlaštenja, praćenje stanja, izradu stručnih mišljenja za različite subjekte, provođenje statističkih istraživanja, izrađivanje programa, vodiča, metoda i modela ZNR-a, utvrđivanje kriterija i postupaka u vezi s organizacijom rada, pružanje pomoći udruženjima poslodavaca, sindikatima, ovlaštenim osobama za poslove ZNR-a te tijelima uprave, provođenje akcija s pojedinih područja ZNR-a i zaštite zdravlja na radu te za unaprjeđivanje ukupnog stanja ZNR-a. U prvoj fazi punjenja baze podataka utkani su podaci iz evidencija kontrolnih kuća, a slijedi i faza uvezivanja aplikacija za vođenje evidencija po ZNR-u u tvrtkama koje dobivaju dodatne module za izravnu razmjenu podataka s IS ZNR-om. Kroz portalski način rada, osim same prijave u IS ZNR, kroz mrežnu stranicu MRMS-a omogućen je i jednostavan unos podataka o osobama koje je poslodavac odredio za obavljanje poslova zaštite na radu.

Ako se IS ZNR gleda kao polazna točka, daljnji razvoj i njegova transformacija u sustav očekivane veličine i složenosti zahtijeva vrlo velika financijska ulaganja. Osim financijskih problema, postoje pravni i tehnički problemi. Tehnički problem IS ZNR-a zasada leži u generacijskom usklađenju programske platforme kako bi se sustav integrirao s NIAS-om, tj. povezao s portalom e-Građani. S pravnog stajališta, IS ZNR treba u potpunosti uskladiti sa Zakonom o državnoj informacijskoj infrastrukturi, tj. ovaj registar treba uskladiti u cilju koordinacije s ostalim projektima državne informacijske infrastrukture. Investitori i izvođači

projekta IS ZNR-a trebali bi obavezno poštivati planove i strategije koje je donijela Vlada, pogotovo o pitanju sigurnosti IS-a koji bi trebao biti usklađen s Nacionalnom strategijom kibernetičke sigurnosti i Akcijskim planom za provedbu nacionalne strategije kibernetičke sigurnosti. Morao bi biti implementiran sustav nadzora transparentnog pristupa podacima koji će biti dostupan kako korisnicima tako i svim obveznicima dostave podataka koji su navedeni u funkcionalnom opisu sustava. Prema nekim tumačenjima, to je i jedan od zahtjeva GDPR-a. Kako bi se IS ZNR uskladio s akcijskim planom Vlade RH o smanjenju administrativnog opterećenja poslodavaca, sve operacije koje je poslodavac već obavio putem drugih informacijskih sustava ne smiju biti ponovljene. Novozaposleni radnik npr. mora se automatski pojaviti na listi aktualnih zaposlenika ako je prijavljen putem MRMS-a. Stranica prijave u IS ZNR prikazana je na slici 8.2., a sučelje za unos podataka u evidenciju osoba koje obavljaju poslove ZNR-a prikazano je na slici 8.3.

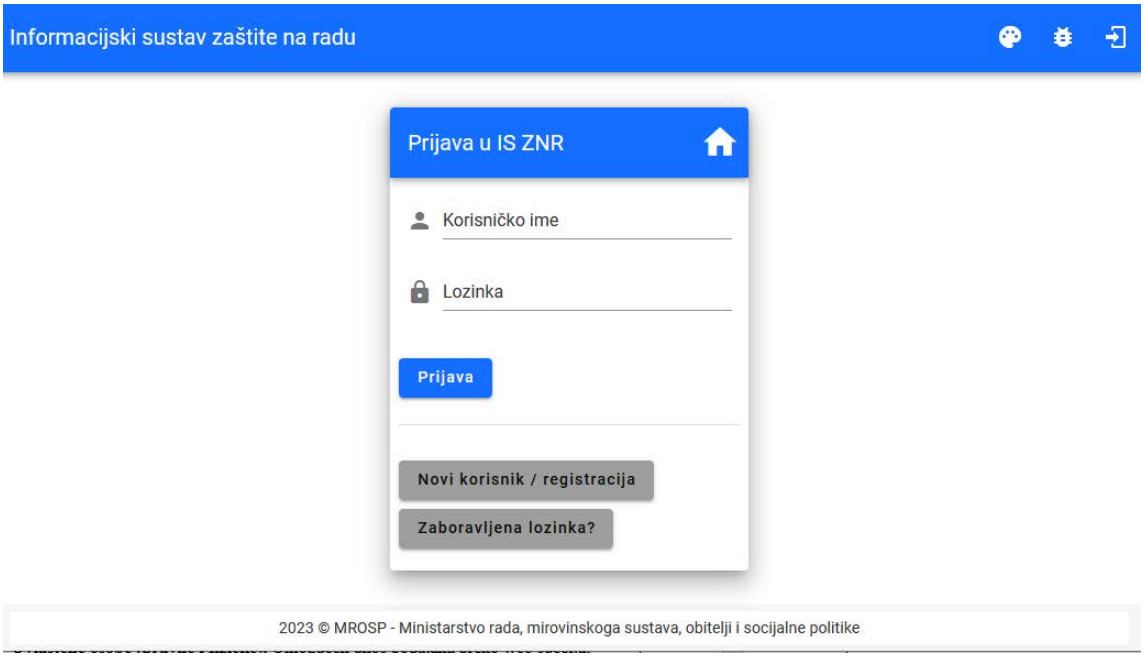

Slika 8.2. Stranica prijave ovlaštenih korisnika za pregled podataka u IS ZNR-u (izvor: MROSP)

Slika 8.3. Sučelje za unos podataka u evidenciju osoba koje obavljaju poslove ZNR-a (izvor: MROSP)

Očekuju se dakle bitne regulatorne i tehničke promjene kako bi ova evidencija OKOPZNR prerasla u e-Registar osposobljavanja i usavršavanja iz zaštite na radu i obavljanja poslova zaštite na radu. Početak ovih aktivnosti očekuje se u rujnu 2023. godine.

8.1.2. Korisničke aplikacije za vođenje evidencija ZNR-a

Jedna od prvih tržišno dostupnih aplikacija za vođenje evidencija u ZNR-u, a dijelom i evidencija u ZOP-u, bio je program **EVIZ** tvrtke Zitel, d. o. o. iz Zagreba (ZITEL, 1992). EVIZ je program koji omogućuje upravljanje sigurnošću i zaštitom pomoću propisanih i evidentiranih podataka. U potpunosti je prilagođen vođenju evidencija iz područja zaštite na radu i zaštite od požara, a u dijelu obrade ozljeda na radu usklađen je s evidencijama koje vodi EU (ESAW). Radi isključivo pod operativnim sustavom MS Windows, a izrađen je u programskom alatu Visual Basic. Za njegov rad ne postoje posebni sklopovski zahtjevi. Primarno je izrađen za instalaciju i višekorisnički pristup na jednom računalu, ali se može instalirati i za mrežni pristup unutar manje lokalne mreže. Osnova za izradu programa bio je Zakon o zaštiti na radu i Pravilnik o evidenciji, ispravama, izvještajima i knjizi nadzora iz područja zaštite na radu. Rad samog programa bazira se na prethodno unesenim podacima i nomenklaturama. Iako inicijalni unos podataka zahtijeva prilično velik napor i utrošak vremena, unos matičnih podataka koncepcijski se odvija preko jednostavnih obrazaca grupiranih po usko specijaliziranim područjima. Na taj je način zaobiđeno veliko grupiranje podataka na jednom mjestu, a sam unos je dinamičan i jednostavniji. Slika 8.4. prikazuje organizaciju izbornika na polaznom zaslonskom obrascu.

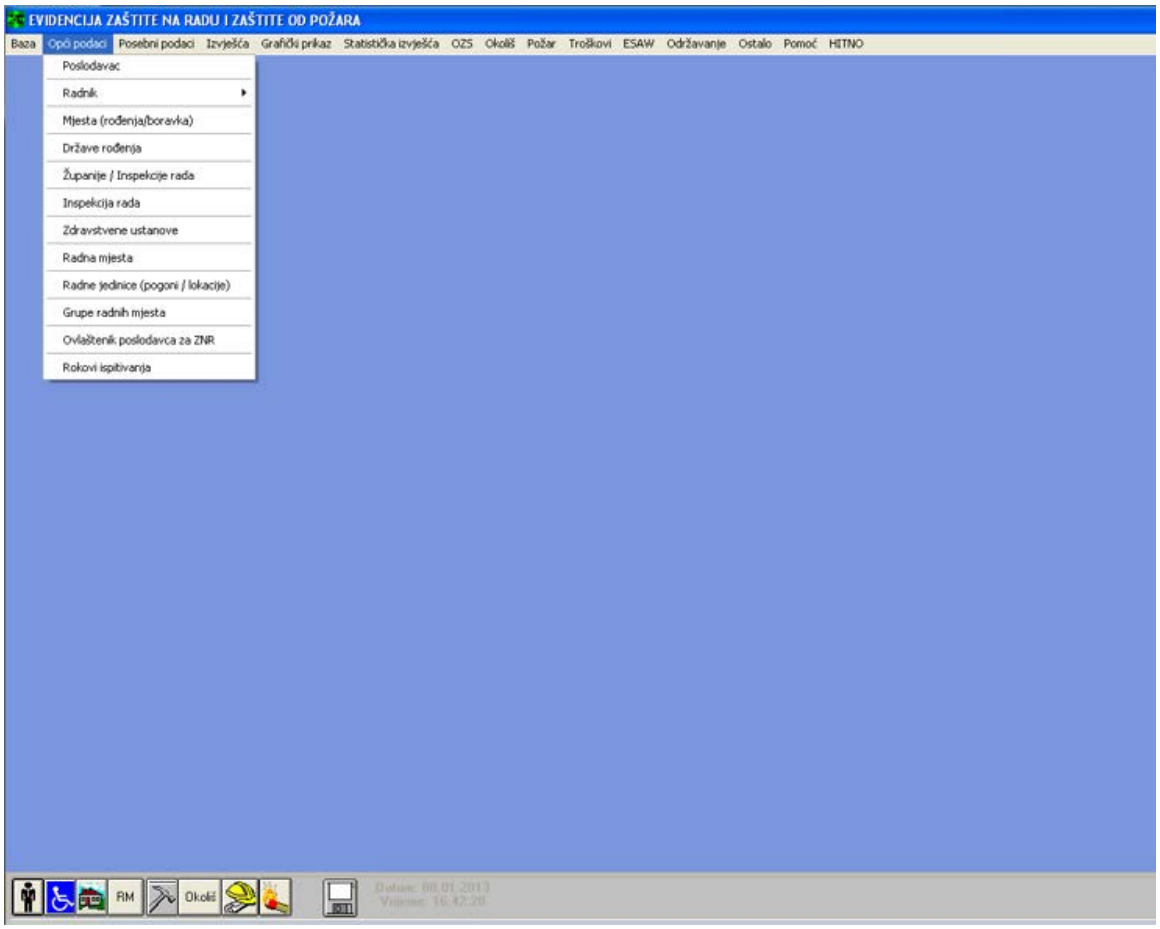

Slika 8.4. Polazni zaslonski obrazac aplikacije EVIZ (ZITEL 2016)

Iako je ovaj program logički vrlo dobro pratio postupke u domeni ZNR-a i ZOP-a, zbog svojih tehničko-tehnoloških ograničenja te suvremenih zahtjeva mrežnog poslovanja i mrežne sigurnosti ipak pripada povijesti informatizacije domene ZNR i ZOP u RH.

Danas postoji otprilike desetak korisničkih programskih rješenja za upravljanje ZNR-om i ZOP-om u tvrtkama raznih veličina i zahtjeva. Prema posljednjim analizama tržišta i primjene u praksi (Jajetić i Kralj, 2021), izdvojit ćemo tri u praksi šire korištena programska rješenja.

Sinarm je programsko rješenje tvrtke Web IT iz Osijeka. Omogućava vođenje evidencija iz zaštite na radu, zaštite od požara i zaštite od okoliša. Program sadrži uređenu bazu podataka za upravljanje rokovima iz područja ZNR, ZOP i ZO. Nudi centralizaciju dokumenata, odnosno svi kreirani ili priloženi dokumenti pohranjeni su na jednom mjestu što ih čini lakše dostupnima i bolje organiziranima. Omogućava generiranje svih potrebnih izvještaja i propisane dokumentacije, precizno definiranje korisničkih ovlasti, integraciju vanjskih podataka te mogućnost vođenja evidencija za više tvrtki. Iako proizvođač tvrdi da je njihova aplikacija *cloud* aplikacija, to nije u potpunosti točno jer se u načelu radi samo o udaljenom pristupu virtualnom MS Windows poslužitelju (engl. *Remote Desktop Connection*, RDC) na kojem se nalazi mrežna instalacija aplikacije. Na slici 8.5. prikazan je inicijalni zaslonski obrazac, koji sadrži kalendar/planer svih paniranih aktivnosti i obavijesti o isteku raznih rokova. Ovo je inače obilježje suvremenih aplikacija za upravljanje ZNR-om i ZOP-om.

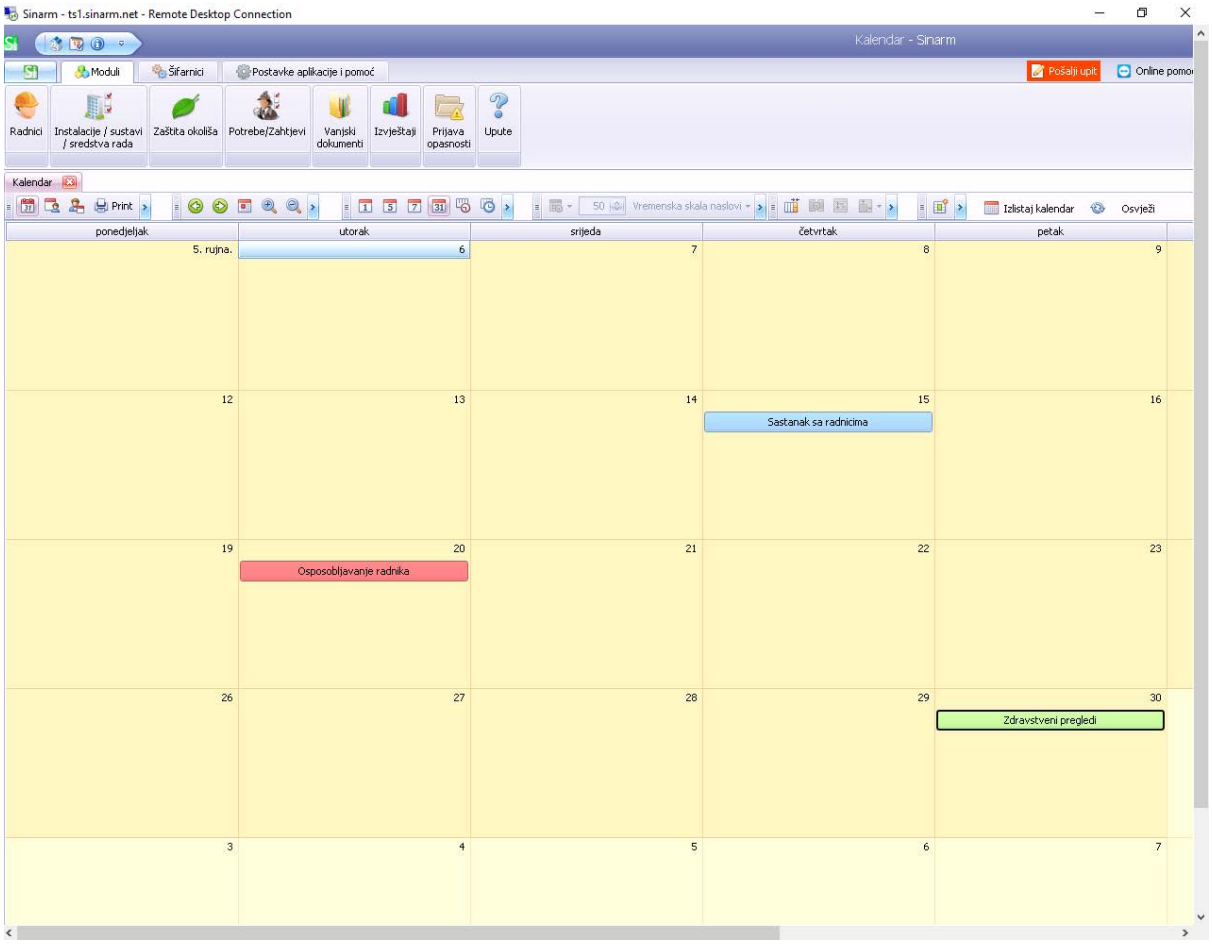

Slika 8.5. Kalendar/planer na inicijalnom zaslonu aplikacije Sinarm (Sinarm, 2021)

Slika 8.6. prikazuje glavni izbornik aplikacije kroz kojeg se može pristupati svim potrebnim evidencijama i izvješćima vezanim za upravljanje radnicima, zaštitnim sredstvima, radnom opremom te stvaranjem svih ključnih izvješća i uputnica.

Slika 8.6. Glavni izbornik aplikacije Sinarm (Sinarm, 2021)

STpro je aplikacija za upravljanje ZNR-om, ZOP-om i ZO-om, a proizvod je tvrtke Humas d. o. o. iz Zagreba. Njezini su autori nastojali napraviti aplikaciju koja se u potpunosti oslanja na računarstvo u oblaku te svojim sučeljem podsjeća na okruženje u mobilnom operacijskom sustavu Android. Slika 8.7. prikazuje inicijalni obrazac zaslona u aplikaciji STpro.

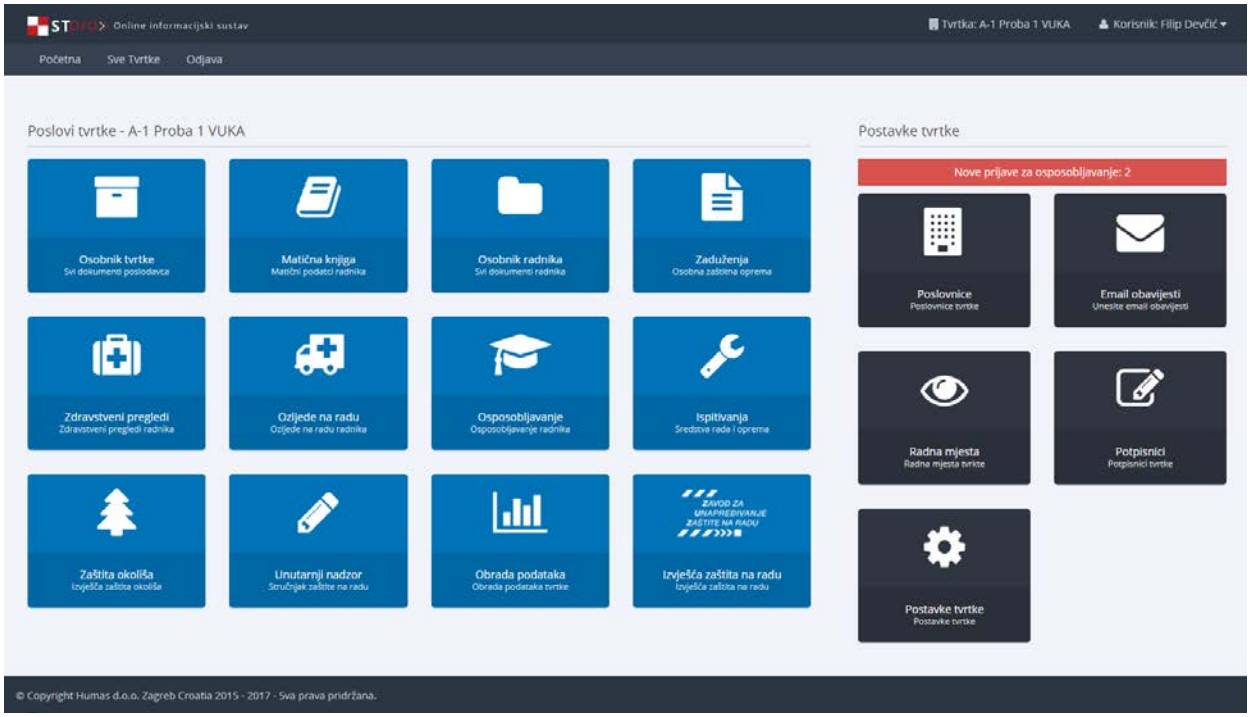

Slika 8.7. Inicijalni zaslon aplikacije STpro (STpro, 2022)

Iz ovog jednostavnog tzv. *flat*-sučelja vidljivi su svi moduli i funkcionalnosti ove programske podrške. Razvijena je u Laravel PHP Frameworku i koristi MySQL relacijsku bazu podataka. Pokreće se upisom poveznice https://www.stpro.hr/ u mrežnom pretraživaču, nakon čega se otvara mrežni obrazac za unos korisničkog imena i zaporke. Po uspješnoj identifikaciji korisnika otvara se mrežna stranica s inicijalnim obrascem. Za razliku od Sinarma, ova aplikacija nema vizualnu organizaciju u obliku kalendara/planera, ali precizno prati kronologiju svih događaja i omogućava generiranje svih potrebnih izvještaja i propisane dokumentacije, precizno definiranje korisničkih ovlasti, integraciju vanjskih podataka te mogućnost vođenja evidencija za više tvrtki.

Aplikacija automatski na zadanu korisničku elektroničku poštu (koji je upisan u modulu „E-mail obavijesti") šalje obavijesti o mjesečnom planu neizvršenih obaveza i isteka pojedinih

rokova. Obavijesti elektroničke pošte su one koje korisnika obavještavaju o određenim obavezama unutar tvrtke/poslovnice kao što su: osposobljavanje, stabilni sustavi, instalacije, radna oprema, radni okoliš, vatrogasni aparati, održavanja/servisi, zdravstveni pregledi i dr.

WebZNR je aplikacija za upravljanje ZNR-om i ZOP-om koju je proizvela i već više od 15 godina na tržištu nudi tvrtka Linija koda d. o. o. iz Zagreba (WebZNR, 2023). Aplikacija je razvijena u oblaku na MS Azure razvojnoj platformi i u potpunosti koristi potencijale računarstva u oblaku. Slično kao kod Sinarma, WebZNR na inicijalnom zaslonu (slika 8.8.) ima prikazan kalendar/planer na kojem su istaknute nadolazeće obaveze. Sučelje je *flat* tipa, s glavnim izbornikom funkcionalnih modula iznad planera te s modulom za brzo pretraživanje promjena po svim bitnim kategorijama unutar posljednjih 30 dana koji je pozicioniran u podnožju zaslona.

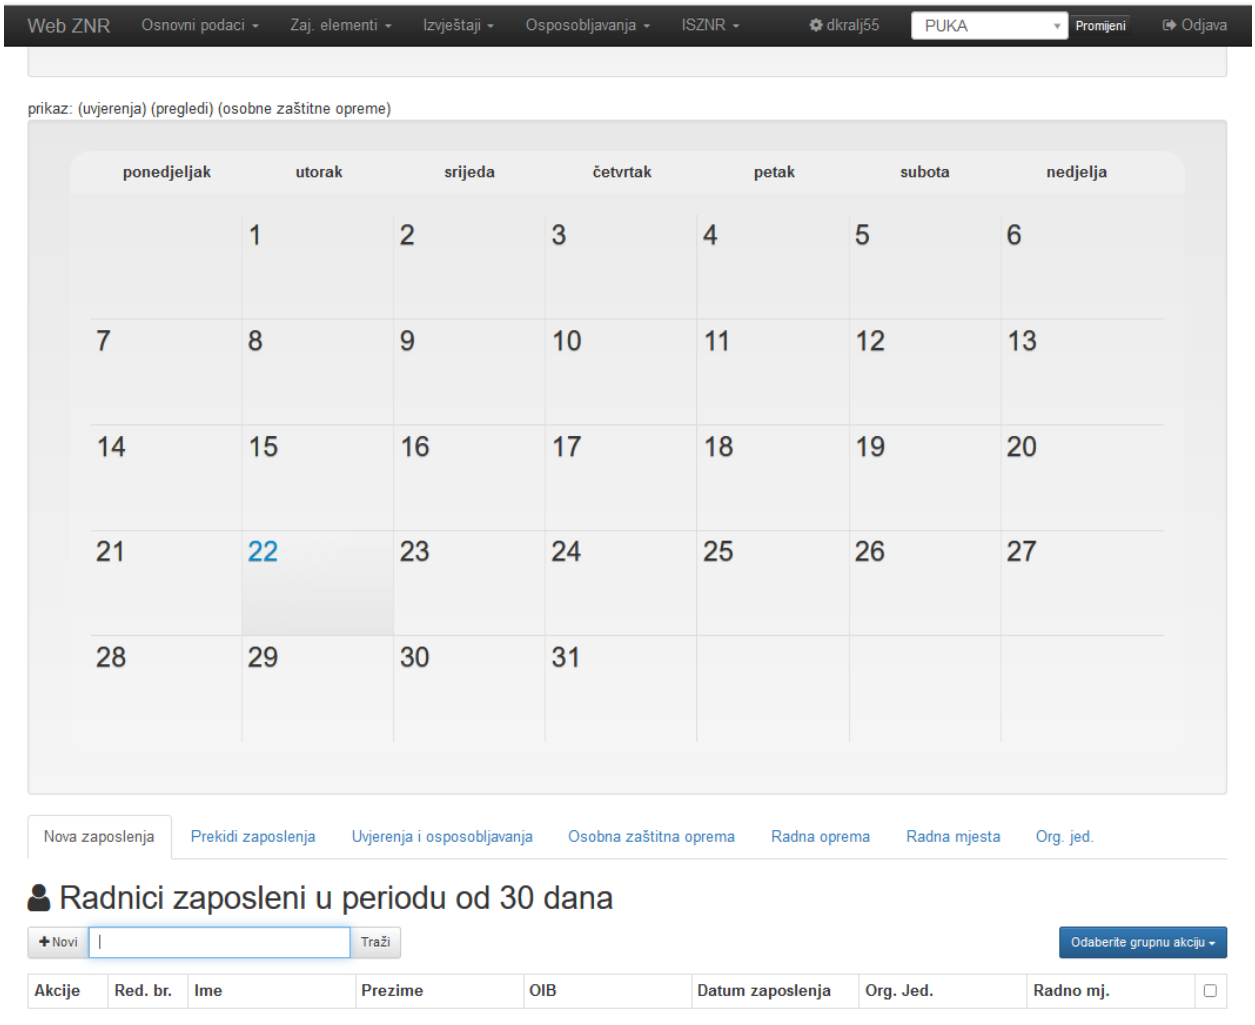

Slika 8.8. Inicijalni zaslonski obrazac aplikacije WebZNR (izvor: autor)

Pored svih važnih funkcionalnosti koje nalazimo i u aplikaciji STpro, WebZNR nudi i sljedeće važne funkcionalnosti:

- Ažurno i jednostavno praćenja rokova. Bilo da se radi o liječničkom pregledu djelatnika, ispitivanju stroja, ispitivanju vatrogasnog aparata ili izdavanju zaštitnog sredstva, aplikacija će se pobrinuti da nijedan jedan rok ne prođe nezamijećen, tj. aplikacija će putem kalendara i obavijesti elektroničke pošte na vrijeme obavijestiti o nadolazećim obavezama što omogućava planiranje djelovanja na vrijeme i spremno dočekivanje isteka nekog roka.

- Jednostavno popunjavanje obrazaca. S obzirom na to da je najveći gubitak vremena ponovno upisivanje podataka o zaposleniku ili uređaju u sve potrebne obrasce, aplikacija WebZNR omogućava da liječničke uputnice RA-1, MA-1, RO-1, RO-2, NR-1, prijava ozljede na radu OR i EK-3, prijave profesionalne bolesti PB, obavijesti o događaju koji je izazvao smrt, težu ozljedu dvaju ili više zaposlenika OIR-1, godišnji izvještaj o ozljedama na radu i dr. budu automatski popunjene podacima koji su već uneseni u aplikaciju (poput osobnih podataka zaposlenika i sl.). Na korisniku je jedino da popuni dijelove obrazaca koji traže ekspertizu stručnjaka te da ih snimi ili ispiše.
- Pojednostavljen postupak upravljanja. Postupak upravljanja ZNR-a i ZOP-a je pojednostavljen mogućnošću pristupa aplikaciji s bilo kojeg stacionarnog i mobilnog uređaja čime se omogućava ažuriranje i pregled svih podataka na licu mjesta u pogonu ili na terenu.
- Generiranje evidencijskih kartona i liječničkih uputnica. Na temelju evidentiranih podataka omogućena je izrada evidencijskih kartona EK-1, EK-2, EK-4, EK-5, liječničkih uputnica te već spomenutih izvještaja. Evidencijski kartoni i liječničke uputnice pritom imaju zakonom propisanu formu i u samoj aplikaciji kako bi snalaženje u njima bilo što jednostavnije za korisnika aplikacije. Njihov je ispis također u skladu sa zakonom propisanim formama s mogućnošću ispisa na A4 i A3 papir i snimanje u velikom broju formata datoteka.
- Kontrola pristupa zaposlenika. Aplikacija WebZNR omogućava zaposlenicima tvrtke ili vanjskih suradnicima kontrolu pristupa podacima u samoj aplikaciji (kontrolne kuće i sl.). Unutar same aplikacije jednostavno se može kontrolirati pristup pojedinim dijelovima aplikacije s pravima čitanja ili uređivanja. Na ovaj način npr. kontrolne kuće mogu same unositi rezultate ispitivanja uređaja u aplikaciju korisničke tvrtke, a da pritom ne mogu vidjeti ni uređivati podatke za koje to tvrtka ne želi.
- Osposobljavanje zaposlenika. Aplikacija omogućava da kroz nju tvrtke, koje to žele, mogu same izvršavati teorijsko i praktično osposobljavanje svojih zaposlenika. Kroz aplikaciju stručnjaci SiZ-a mogu sami pratiti osposobljavanje te na kraju i izdavati uvjerenja o osposobljavanju koja više nisu zakonski obavezna, ali predstavljaju svojevrsnu potvrdu zaposleniku da je osposobljen. Iz ove se evidencije generira matična knjiga osposobljavanja.
- Praćenje i planiranje troškova. Aplikacija omogućava praćenje i planiranje troškova. U samoj aplikaciji omogućen je unos cijene za pojedino ispitivanje, liječnički pregled ili ispitivanje uređaja. Na temelju tog podatka i rasporeda potrebnih radnji u pojedinom vremenskom razdoblju, moguće je izraditi troškovnike, budžete za naredno razdoblje, procjene troškova i sl.
- Kreiranje digitalne arhive. Aplikacija omogućava da se svi dokumenti koje tvrtka inače posjeduje na različitim mjestima (registratori, Excel datoteke i sl.) stave na jedno mjesto u obliku digitalne arhive. Aplikacija također omogućava da se uz zaposlenika priloži skenirana osobna iskaznica, uz uređaj uvjerenje o ispitivanju ili možda uz organizacijsku jedinicu evakuacijski plan. Svi ti dokumenti će tako postati uvijek dostupni i na raspolaganju korisnicima bez obzira gdje se nalazili u tom trenutku.
- Prebacivanje podataka i postojećih baza podataka. U aplikaciji je omogućen jednostavan uvoz podataka iz postojećih baza (najčešće su to razne aplikacije kadrovske službe). Kreiranjem jednostavne CSV datoteke moguć je uvoz podataka o zaposlenicima čime se značajno olakšava prijelaz na novu aplikaciju. Za veće sustave, gdje je fluktuacija zaposlenika veća i gdje je potrebna automatska sinkronizacija,

stručnjaci Linije koda d. o. o. napravit će sinkronizacijske aplikacije koje će podatke automatski sinkronizirati.

- Procjena rizika. Od početka 2016. godine WebZNR sadrži i modul procjene rizika koji omogućava generiranje Word dokumenta na temelju upisanih podataka nakon čega korisnici mogu nastaviti obradu dokumenta prema svojim željama. Ovaj je modul u produženoj evaluacijskoj fazi i očekuje se od korisnika da daju svoje ocjene, mišljenja i preporuke za unaprjeđenje.
- Korisnički portal. Putem korisničkog portala stručnjak zaštite na radu može dozvoliti kontrolirani pristup podacima iz evidencije. Korisnički portal djeluje kao interna stranica za ZNR i ZOP što omogućava svim zaposlenicima pristup informacijama o nekom stroju, radnom mjestu ili organizacijskoj jedinici, a da pritom stručnjak zaštite na radu cijelo vrijeme ima potpunu kontrolu nad time koji se podaci prikazuju na korisničkom portalu.
- ISZNR modul. Početkom 2020. godine objavljen je novi ISZNR modul aplikacije WebZNR. Pomoću modula ISZNR ovlaštene osobe (kontrolne kuće i sl.) mogu kroz aplikaciju kreirati svoje upitnike čijim se popunjavanjem automatski popunjavaju zapisnici o ispitivanjima uređaja i objekata. Modul podržava sve vrste zapisnika o ispitivanju, uvjerenja o osposobljavanju te je kroz isti modul moguće kreirati radni nalog. Šifriranje dokumenata je također moguće prilagoditi svakom tipu dokumenta (WebZNR, 2023).

Može se reći da su navedene funkcionalnosti odlike jedne suvremene aplikacije za upravljanje sigurnošću i zaštitom, tehnološki načinjene ukorak sa zahtjevima digitalne transformacije. Ono što u funkcionalnom smislu izdvaja ovu aplikaciju u odnosu na prethodno prikazane jesu mogućnosti praćenja troškova po SiZ-u, posvudašnja dostupnost, oblikovanje dokumenta procjene rizika iz već unesenih podataka i modul koji povezuje WebZNR i ISZNR u cilju izbjegavanja višestrukog unosa istih podataka u više sustava. Interesantna je i mogućnost označavanja radne opreme QR kodovima kojima su u aplikaciji pridruženi razni dokumenti (upute, atesti, jamstva i dr.). Slikanjem QR koda pametnim telefonom ili tabletom putem pridružene mrežne poveznice omogućen je pristup pripadajućim dokumentima.

Tržište korisničkih aplikacija za upravljanje ZNR-om prilagođavat će se budućem razvoju središnjeg sustava upravljanja koji će morati definirati potrebne uvjete koje će ove aplikacije morati zadovoljiti s obzirom na sigurnost i funkcionalnost.

8.1.3. Dodatna programska podrška za unaprjeđenje upravljanja ZNR-om

Pored dosad analiziranih ideja i pokušaja razvoja središnjeg IS-a u domeni ZNR-a te korisničkih aplikacija za upravljanje ZNR-om, ali i ostalih segmenata SiZ-a, u postupku upravljanja ZNR-om od velike koristi mogu biti dvije skupine programske podrške. Prvu skupinu čine programi za računalnu grafiku (engl. *Computer-aided Design*, CAD), a drugu programi za grafičko oblikovanje, animaciju i proračunavanje parametara opterećenja radnih mjesta i radnih procesa.

Iz prve ćemo skupine istaknuti programe MS Visio i AutoCAD. MS Visio je po svojoj namjeni grafički programski alat koji prije svega omogućava oblikovanje raznih organizacijskih dijagrama, procesnih dijagrama, tehničkih shema i tehničkih skica. Ovaj se programski alat koristi i u sklopu vježbi u okviru nastavnih predmeta koje pokriva ovaj udžbenik, i to za izradu organizacijskih dijagrama poslovnih sustava, konceptualnih modela IS-a te evakuacijskih dijagrama koji su jedan od ključnih elemenata upravljanja SiZ-om (koriste se i u ZNR-u i u ZOP-u). Slika 8.9. prikazuje jedan evakuacijski plan izrađen u alatu MS Visio.

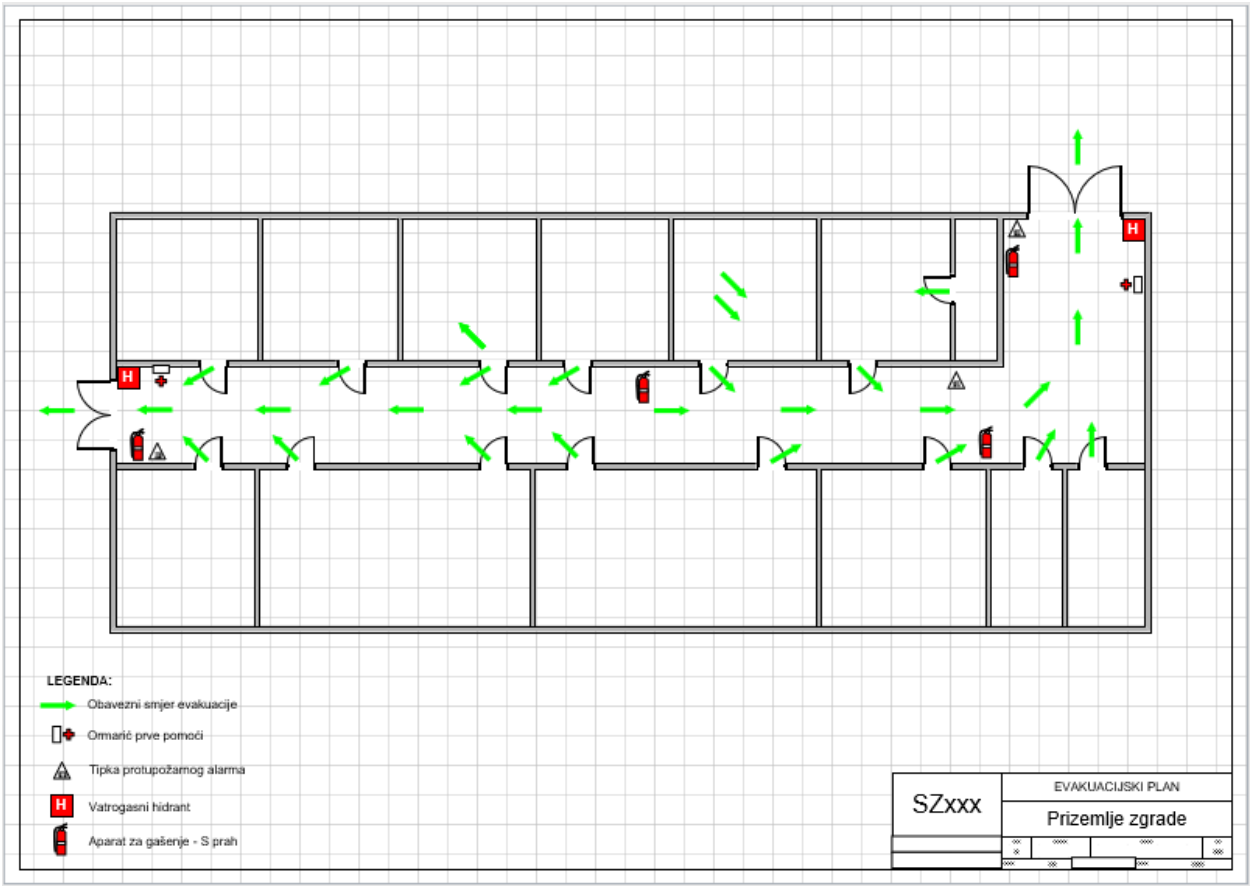

Slika 8.9. Primjer jednog evakuacijskog plana izrađenog u MS Visiju (izvor: autor)

MS Visio je po cijeni pristupačan višenamjenski grafički alat koji sadrži velik broj tematskih predložaka i biblioteka grafičkih objekata, a dopušta izradu i pohranu vlastitih grafičkih oblika. Omogućava crtanje u više nivoa i uvoz grafičkih podloga u standardnim grafičkim formatima (preferiran je BMP). Možemo npr. skenirati tlocrt neke zgrade, uvesti ga u jedan od nivoa kao podlogu te u drugim nivoima iscrtavati razne elemente i simbole evakuacijskog plana.

Međutim, u praksi kontrolnih kuća uglavnom dominira **AutoCAD** koji pripada kategoriji profesionalnih CAD alata za izradu projekata u raznim tehničkim područjima. Jedan od razloga ovoj praksi je vjerojatno i činjenica da je većina arhitektonskih i građevinskih projekata izrađena u ovom ili u njemu kompatibilnim alatima te se na lak način učitavaju već postojeći tlocrti i dodaju se novi slojevi s elementima evakuacijskih planova. Primjer postupka izrade evakuacijskog plana u programu AutoCAD prikazan je na slici 8.10. Prikazano je radno područje crtanja plana te unaprijed pripremljeni grafički oblici i sastavnica (desno od plana). Treba naglasiti da je AutoCAD profesionalni alat i znatno je skuplji od alata MS Visio, ima znatno veće mogućnosti, ali i zahtijeva puno više vremena i napora da bi se njime ovladalo. Za oba ova programska alata postoji relativno ograničena mogućnost razmjene crteža i grafičkih elementa u nekim od standardnih grafičkih formata datoteka.

U drugoj skupini dodatne programske podrške upravljanju ZNR-om, na tržištu je dostupno otprilike desetak proizvoda različitih svjetskih proizvođača. U načelu su ovi programski alati vrlo važni za unaprjeđenje područja primijenjene ergonomije, no kako i kontinuirano unaprjeđenje postupaka u okviru radnih mjesta ulazi u domenu upravljanja ZNR-om, ukratko ćemo opisati dva predstavnika ove skupine.

Slika 8.10. Prikaz izrade evakuacijskog plana u programu AutoCAD (Škrbec, 2022)

HumanCAD (NexGen Ergonomics, 2023) je programsko rješenje za modeliranje ljudi u virtualnom okruženju i proizvod je tvrtke NexGen Ergonomics. Stvara digitalne prikaze ljudi u trodimenzionalnom okruženju u kojem se mogu izvesti različite analize ergonomije i ljudskog čimbenika. HumanCAD pomaže korisnicima u dizajnu proizvoda i radnih mjesta određujući što ljudi različitih veličina mogu vidjeti, dosegnuti ili podići. Primjer digitaliziranog prikaza radnog mjesta unutar radnog područja programa HumanCAD prikazan je na slici 8.11.

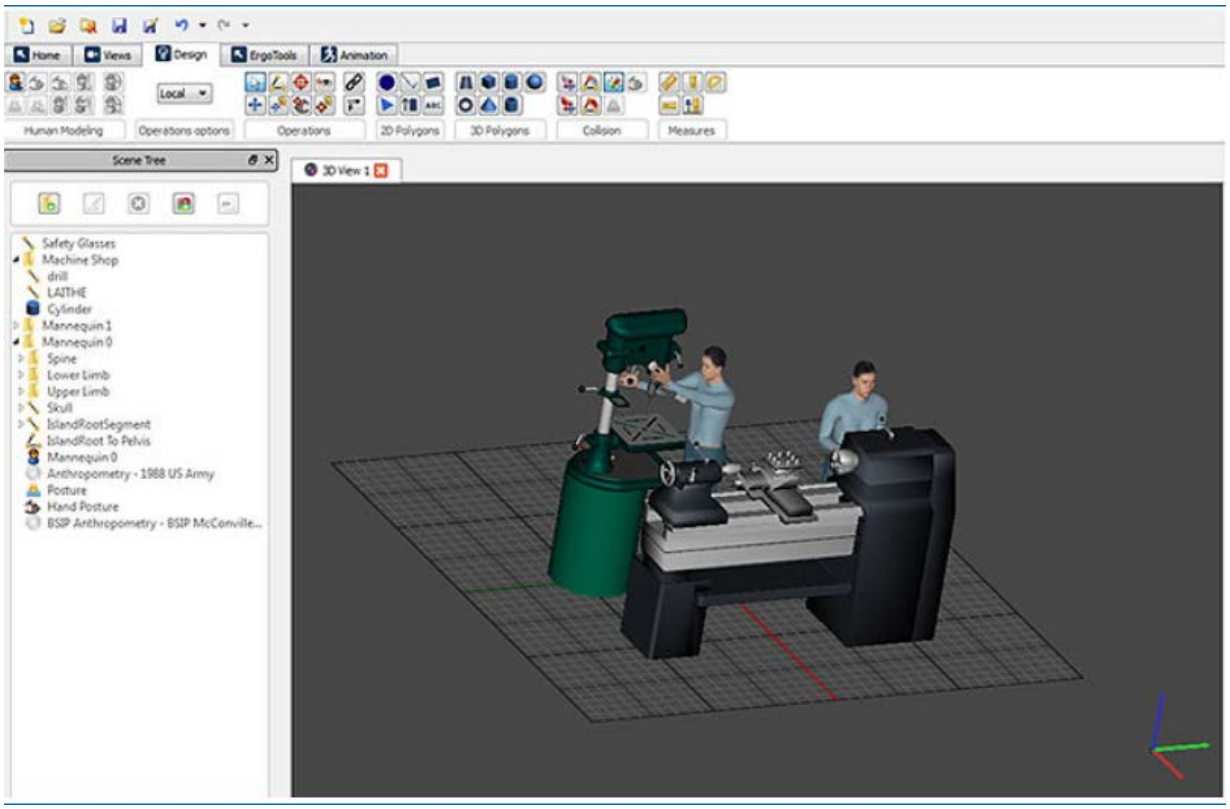

Slika 8.11. Prikaz radnog područja programa HumanCAD (izvor: NexGen Ergonomics)

Tehnologija digitalnog ljudskog modeliranja važan je alat u određivanju prilagođenosti proizvoda i radnih mjesta ljudima prije nego što se izgrade. To uključuje traženje zona udobnosti za određene zadatke (slika 8.12.).

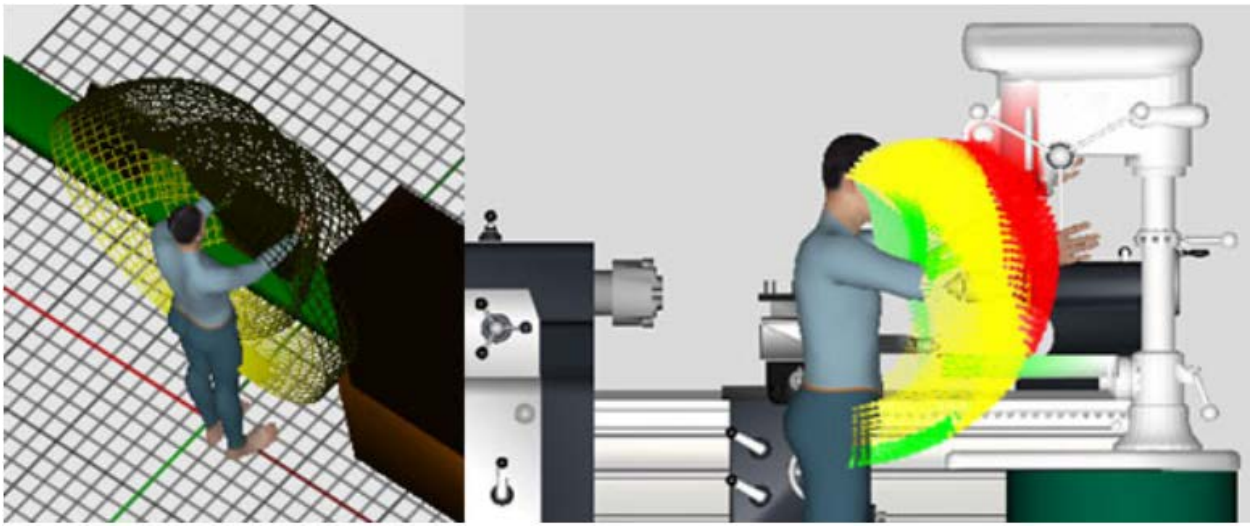

Slika 8.12. Analiza zona dosega i udobnosti radnika na radnom mjestu (izvor: NexGen Ergonomics)

HumanCAD ima modularnu arhitekturu koja korisnicima omogućuje kupnju modula koji su im potrebni. U sve konfiguracije uključena je inverzna i prednja kinematika, digitalna ljudska kreacija korištenjem raznih biblioteka i baza podataka, analiza vizije i dosega i slično. Svoje prilagođene položaje ili antropometrije korisnik može spremiti u ove biblioteke za ponovnu upotrebu. HumanCAD-ovi ergonomski alati za procjenu pružaju podatke o potencijalnom riziku od ozljeda i posturalnu analizu. Ostali alati za analizu ljudskog čimbenika pomažu u određivanju zahtjeva za dosegom, vidom, udobnošću i prilagodbom. Elementi radnog mjesta mogu biti oblikovani u drugim CAD alatima i uvezeni u HumanCAD. NexGen Ergonomics nudi široku lepezu instrumenata za ergonomska i biomehanička mjerenja te analizu, istraživanje i dizajn proizvoda. U ponudi su mjerači sile ili dinamometri, ali i sofisticiraniji proizvodi kao što su rješenja za fiziološka mjerenja, mapiranje tlaka ili napredni sustavi za analizu kretanja. U ponudi su i specijalizirani instrumenti za mjerenje razine zvuka, senzori temperature i senzori za analizu vibracija, kao i linija magnetskih, optičkih i inercijalnih uređaja za praćenje pokreta te opcionalna programska podrška koja s navedenim sustavima čini cjelovita rješenja za snimanje i analizu pokreta.

Drugi predstavnik iz ove skupine je skup programskih rješenja pod nazivom **NAWO Solutions** francuskog proizvođača HRV Simulation, a čine ga programski alati NAWO Live, NAWO Smart i NAWO Studio. NAWO Live je alat za procjenu rizika od mišićno-koštanih poremećaja (MSD) koji koristi princip ergosimulacije. Ergosimulacija (slika 8.13.) reproducira ljudski pokret na virtualnoj lutki (tzv. manekenu) koji ustvari predstavlja avatara stvarnog radnika. Ovaj avatar obogaćen je ergonomskim i biomehaničkim pokazateljima koji omogućuju procjenu posturalnih ograničenja, napora i vremena izloženosti povezanih s profesionalnom aktivnošću. Cilj je ovog programskog alata:

- identificirati rizike povezane s MSD-om
- kvantificirati poteškoće profesionalnih aktivnosti
- izraditi objektivne i standardizirane ergonomske procjene radilišta.

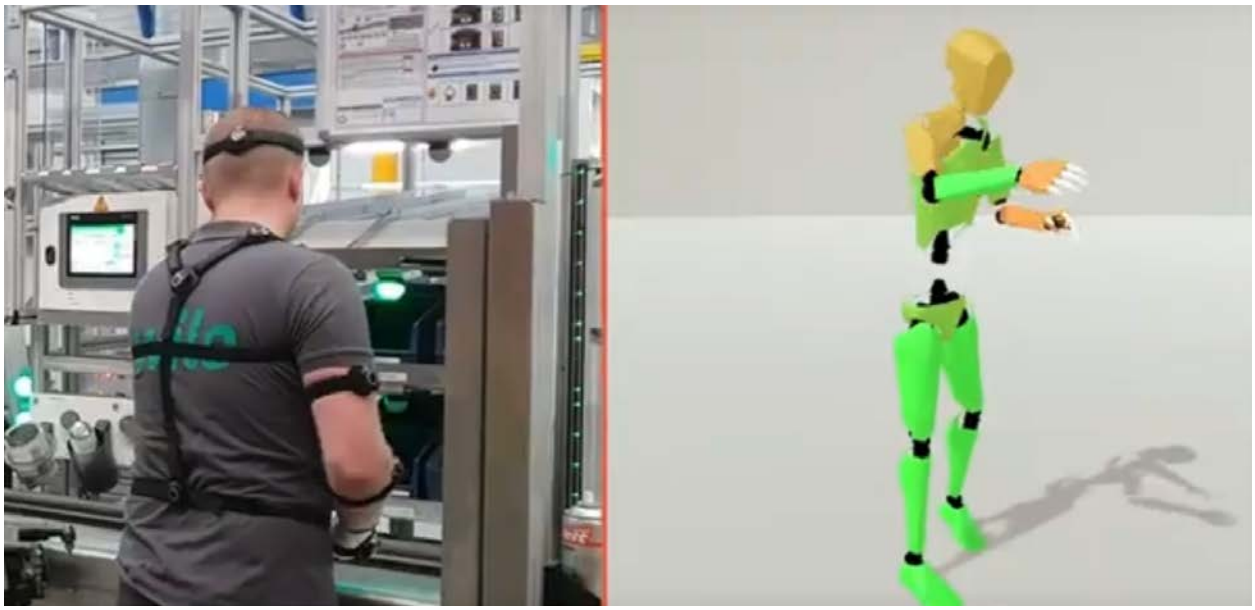

Slika 8.13. Prikupljanje podataka putem senzora i ergosimulacija (izvor: HRV Simulation)

Programski alat NAWO Smart je besplatni program za mobilne uređaje putem kojeg možemo snimati radnu sekvencu u cilju kreiranja ergosimulacije. S tehnologijom snimanja pokreta koju koristi NAWO Smart, aktivnost se reproducira i bilježi na virtualnoj lutki obogaćenoj ergonomskim i biomehaničkim indikatorima za prepoznavanje rizika od razvoja MSD-a. Ova je aplikacija ustvari džepni alat za mjerenje kojim svi zaposlenici mogu mjeriti rizike povezane s tjelesnom aktivnošću svojim pametnim telefonom i igrati aktivnu ulogu u prevenciji rizika. Snimljene sekvence prebacuju se na računalo i obrađuju u alatu NAWO Live u kojem se mogu automatski procijeniti svi biomehanički čimbenici rizika uz pomoć referentne metode (RULA, REBA, NIOSH itd.).

NAWO Studio je programsko rješenje za pregled ergonomije i dizajna koji koristi virtualnu stvarnost te omogućuje integraciju ergonomije radnih mjesta od faze dizajna. Ergonomija dizajna uzima se u obzir odmah od primarnih faza dizajna alata ili radnog mjesta kako bi se smanjio broj nesreća i nastajanje profesionalnih bolesti kao što su poremećaji mišićno-koštanog sustava. Ovaj pristup smanjuje izravne i neizravne troškove. Ukratko, primjenom ovog programskog rješenja postiže se:

- dizajniranje ili transformiranje industrijskog radnog mjesta uzimajući u obzir ergonomski čimbenik
- ograničavanje slučajeva profesionalnih bolesti i nedostataka u dizajnu, izvora nelagode i dodatnih troškova za tvrtku
- podizanje višeg stupnja odgovornosti u pogledu zaštite zdravlja zaposlenika.

(Nawo Solution, 2023)

8.2. Informatizacija u domeni zaštite od požara i vatrogastvu

8.2.1. Projekt e-HVZ

Projekt informatizacije hrvatskog vatrogastva i njegov začetak zasnivaju se na dva temeljna dokumenta: Strategiji informatizacije Hrvatske vatrogasne zajednice 2015. − 2020. (Strategija razvoja i primjene informacijsko-komunikacijske tehnologije u vatrogastvu Republike Hrvatske za razdoblje od 2015. do 2020. godine) i Nacionalnoj strategiji zaštite od požara za razdoblje od 2013. do 2022. godine (NN 68/2013). Strategija informatizacije zasnovana je na postavljenoj viziji i predviđenoj misiji za njeno provođenje:

- Vizija. Razvoj i primjena suvremenih informacijsko-komunikacijskih tehnologija omogućiti će kvalitetno upravljanje informacijama značajnima za zaštitu od požara stanovništva, imovine i okoliša te bitno unaprijediti sustav vatrogastva Republike Hrvatske.
- Misija. Primjenom najsuvremenijih informatičkih i telekomunikacijskih tehnologija razvijat će vlastite operativne alate i dati ih na korištenje cijeloj vatrogasnoj organizaciji za obavljanje svakodnevnih aktivnosti. Standardizacijom opreme i postupaka omogućit će povezivanje i koordinaciju svih elemenata zaštite od požara i spašavanja ljudi i imovine. Na svim razinama osposobljavat će vatrogasce za korištenje razvijenih alata kako bi se omogućilo učinkovitije upravljanje vatrogasnom službom.

Navedena vizija i predviđena misija zapravo su prihvaćanje i provođenje digitalne transformacije u domeni ZOP-a i vatrogasne prakse. Intenzivni razvoj informacijskih tehnologija i metoda djelovanja vatrogastva otvorili su mogućnosti za pokrivanje potreba za uvođenjem informatizacije u procese vatrogasne djelatnosti. Pojam „informatizacija" može se definirati kao uvođenje programskih alata koji olakšavaju protok, spremanje i pristup informacijama čime se omogućuje tako dobar pregled podataka potrebnih za donošenje odluka, a time i povećanje uspješnosti djelovanja. Ključni uvjeti za uspješno korištenje ovih alata su, osim samih aplikacija i odgovarajuće infrastrukture, standardizacija poslovnih procesa u vatrogastvu, dobra educiranost korisnika te kvalitetna korisnička podrška. Hrvatska vatrogasna zajednica ulaže velike napore kako bi se ovi uvjeti osigurali vatrogasnim organizacijama diljem Republike Hrvatske, a razvoj ovih alata pokazao se ujedno i kao prilika za uređivanje nekih vatrogasnih procesa i postizanje suradnje s drugim državnim i znanstveno-istraživačkim institucijama. Ciljeve ovog postupka informatizacije možemo sažeti u sljedeće četiri aktivnosti:

- stvaranje jedinstvenog integriranog informatičko-komunikacijskog sustava koji će modularno povezati sve dosadašnje i buduće sustave te objediniti skupljeno znanje i iskustvo
- bolja potpora odlučivanju kod svih radnih procesa u vatrogasnom sustavu
- stvaranje platforme za edukaciju vatrogasnih kadrova, pučanstva te polaznika određenih obrazovnih institucija
- bolje vodoravno i okomito povezivanje te jedinstveno djelovanje svih vatrogasnih službi i tijela.

Sve su ovo odrednice koje definiraju i primjenu digitalne transformacije u provođenju Industrije 4.0. Projekt informatizacije, nazvan e-HVZ (e-HVZ, 2014), provodi se kao EU projekt zasnovan na iskustvima najčešće i najjače opožarenih područja RH (uglavnom primorske županije). Aplikacije koje sačinjavaju ovaj sustav su:

- **VATROnet** − središnja baza podataka Hrvatske vatrogasne zajednice u koju se pohranjuju podaci o vatrogasnim organizacijama, njihovim članovima, zaposlenicima, opremi, vozilima i aktivnostima.
- **Sustav za praćenje vozila** − sustav koji omogućuje operaterima uvid u trenutne pozicije vatrogasnih vozila i osoba na GIS karti. Omogućava i generiranje izvještaje, povijest kretanja te rekonstrukciju intervencija.
- **HAZMAT** – interaktivna baza opasnih tvari. To je aplikacija koja je rađena kao mrežni portal koji služi javnosti/građanstvu kao izvor općih informacija o opasnim tvarima (osnovne opasnosti, koliko koje tvari smiju skladištiti itd.) i hitnim službama kao pomoć pri rukovanju opasnim tvarima na intervencijama.
- **Sustav za uzbunjivanje** − aplikacija koja je namijenjena za uzbunjivanje vatrogasaca za vatrogasne intervencije te obavještavanja vatrogasaca o raznim drugim aktivnostima. Uzbunjivanje se radi putem glasovne poruke ili SMS-a. Grupe za uzbunjivanje, zajedno s ostalim podacima, uređuju se u aplikaciji VATROnet.
- **UVI** – (Upravljanje vatrogasnim intervencijama) zajednički je projekt Hrvatske vatrogasne zajednice i Državne uprave za zaštitu i spašavanje kojim se za vatrogasne intervencije želi postići standardizacija radnih procesa, izraditi jedinstveni sustav pohrane, obrade i distribucije informacija, veća efikasnost izvješćivanja te ekonomičnost u održavanju programskih rješenja, uređaja i opreme.
- **SPIS – HVZ** − Središnji portal internet-stranica (SPIS) je sustav putem kojeg bilo koja vatrogasna postrojba ili zajednica u Hrvatskoj može besplatno dobiti vlastitu internet-stranicu i administracijske ovlasti za njezino uređivanje. Sve su stranice smještene na domeni spis.hvz.hr, a adresa pojedine mrežne stranice ovisi o nazivu vatrogasne organizacije, u pravilu: http://naziv-organizacije.spis.hvz.hr.

Struktura ovog informacijskog sustava prikazana je na slici 8.14. Sastoji se od pet modula koji su povezani sa središnjim dijelom e-HVZ sustava.

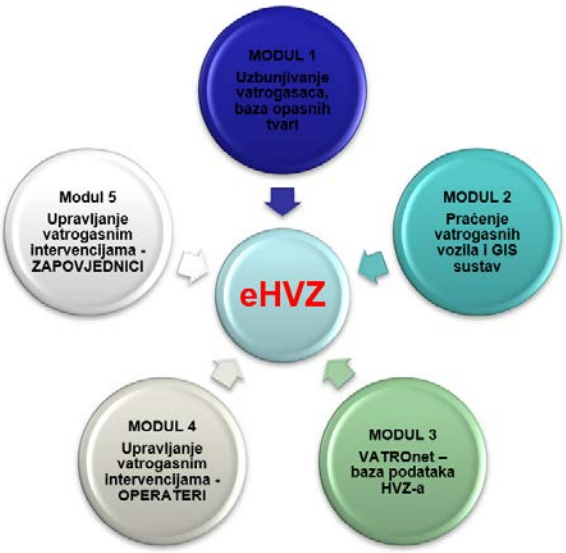

Slika 8.14. Modularna struktura e-HVZ sustava (izvor: HVZ)

Modul 1 čine aplikacije Sustav za uzbunjivanje i HAZMAT. Uzbunjivanje se radi putem glasovne poruke/poziva ili SMS-a. Nakon pokretanja uzbunjivanja, svaki uzbunjeni vatrogasac

dobiva poziv putem kojeg odgovara dolazi li ili ne dolazi na intervenciju te paralelno uz poziv dobiva SMS poruku s detaljima. Na ovakav se način uzbunjivanje može raditi na bilo kojem telefonskom uređaju jer ne zahtijeva neku aplikaciju na telefonu. Aplikacija se koristi kao podmodul aplikacije Upravljanje vatrogasnim intervencijama (UVI) te je u praksi možemo smatrati njezinim sastavnim dijelom. Tijekom uzbunjivanja, operater odmah dobiva povratnu informaciju od uzbunjenih osoba koje su potvrdile dolazak, a nakon intervencije moguće je generirati razne izvještaje i statističke podatke. Aplikacija HAZMAT načinjena je kao mrežni portal koji služi javnosti/građanstvu kao izvor općih informacija o opasnim tvarima (osnovne opasnosti, koliko koje tvari smiju skladištiti itd.) i hitnim službama kao pomoć pri rukovanju opasnim tvarima na intervencijama. Ideja aplikacije je da na jednom mjestu budu objedinjene sve informacije, pravilnici, zakoni i iskustva o opasnim tvarima i njihovim sigurnim rukovanjem, ERI kartice, evidencija opreme za opasne tvari itd. Sastoji se od javnog dijela dostupnog svima te dijela koji je dostupan samo korisnicima koji imaju pristupne podatke. Ti su korisnici administratori aplikacije te hitne službe i ostale zainteresirane organizacije. Aplikacija je višejezična te podržava i međunarodne korisnike, a prihvaćena je i od Komisije za opasne tvari − CTIF-a.

Modul 2 čine Sustav za praćenje vozila i dodatni GIS alati za označavanje značajki i prikupljanje podataka s terena.

Modul 3 je aplikacija VATROnet koja čini sveobuhvatnu logističku bazu podataka na koju se oslanjaju svi ostali dijelovi sustava jer svi potencijali moraju biti prvo upisani i opisani u ovoj bazi podataka kako bi se njihovi podaci mogli koristiti u ostalim dijelovima sustava e-HVZ. Ovaj je odnos prikazan funkcionalnim dijagramom na slici 8.15.

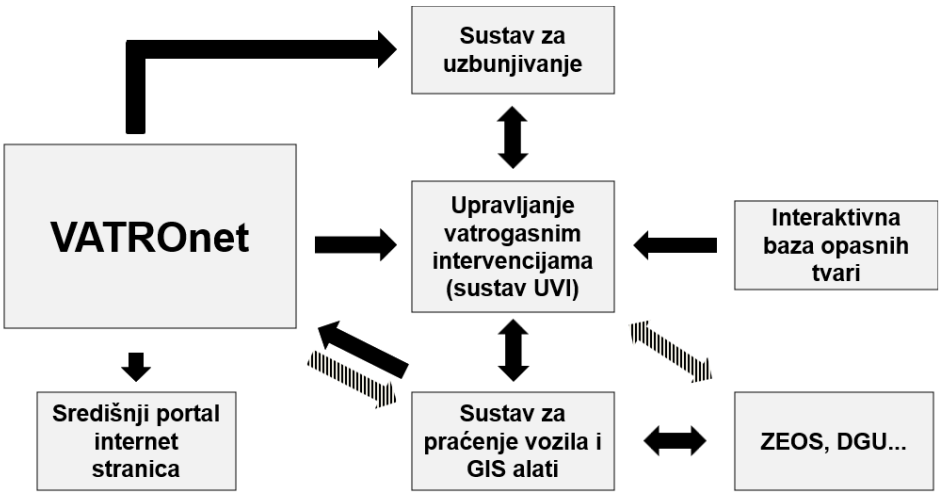

Slika 8.15. Povezanost VATROnet-a s ostalim modulima e-HVZ-a (Barić, 2023)

Modul 4 (operateri) i modul 5 (zapovjednici) su dio podsustava Upravljanje vatrogasnim intervencijama (UVI) i može se reći da su od najvećeg operativnog značaja jer obuhvaćaju organizacijsko-taktičke aktivnosti od samog uzbunjivanja vatrogasaca i njihovo upućivanje na lokaciju, vođenje operacija posredstvom Vatrogasnog operativnog centra (VOC) koji po dojavi nesreće pokreće uzbunjivanje i prati sva događanja na terenu te osigurava neprekidni zapovjedni komunikacijski kanal. Po završenim intervencijama kroz analitičko izvještajni sustav generiraju se potrebna operativna i statistička izvješća.

8.2.2. Sustavi za otkrivanje, praćenje i predviđanje širenja požara

S obzirom na to da je rano otkrivanje požara vrlo važno za smanjenje požarne štete, ulažu se veliki napori kako bi se požar otkrio što ranije. Rano otkrivanje požara otvorenog prostora tradicionalno se temelji na ljudskom nadzoru šumskih požara koji se ostvaruje 24-satnim promatranjem ljudskih promatrača koji se nalaze na odabranim motrilačkim mjestima. Protupožarni nadzor u Hrvatskoj uglavnom organiziraju Hrvatske šume – državna tvrtka odgovorna za zaštitu i iskorištavanje šuma u državnom vlasništvu. Ljudski promatrači obično su opremljeni samo standardnim dalekozorima i komunikacijskom opremom, a njihovo promatračko područje je samo područje koje pokriva njihov vid. Noviji, tehnički napredniji pristup ljudskom nadzoru požara raslinja je sustav temeljen na daljinski upravljanim videokamerama kojima upravlja ljudski promatrač iz centra za promatranje. Takav se sustav može koristiti ne samo za rano otkrivanje požara već i za daljinsku videoprisutnost na lokaciji požara. Ovakav način ranog otkrivanja i nadzora požara ima mnoge prednosti u usporedbi s izravnim ljudskim motrenjem s motrilačkih mjesta. Neke od tih prednosti su:

- može se pokriti šire područje jer jedan ljudski promatrač može pratiti nekoliko terenskih jedinica videonadzora
- kamere su obično opremljene velikim zumom pa promatrač može detaljno pregledati sumnjiva područja.

Međutim, glavno ograničenje ljudskog nadzora temeljenog na videokamerama je što otkrivanje požara u potpunosti ovisi o ljudskom promatranju. Promatrač se nalazi u ugodnijem okruženju, centru za promatranje, ali mora pažljivo promatrati više monitora računala u isto vrijeme pa se mogu pojaviti problemi poput umora, dosade i gubitka koncentracije. To je i glavni razlog za uvođenje različitih oblika naprednih sustava za automatsko otkrivanje, nadzor i praćenje požara.

Jedan od prvih istraživačkih i razvojnih projekata u području razvoja i primjene ovakvih naprednih sustava započeo je 2003. godine na području Splitsko-dalmatinske županije koje su pokrenuli istraživači Fakulteta elektrotehnike, strojarstva i brodogradnje u Splitu (FESB).
Konačni rezultat je bio sustav IPNAS (Inteligentni protupožarni nadzorni sustav) koji je u to vrijeme pripadao posljednjoj generaciji naprednih automatskih sustava za nadzor i praćenje šumskih požara i uključivao puno inovativnih i naprednih značajki. IPNAS je bio zamišljen kao integriran i inteligentan sustav za nadzor i praćenje požara raslinja temeljen na analizi slika s videokamera. Požari raslinja se otkrivaju u početnoj fazi pomoću postupaka napredne obrade i analize slika s videokamera. Inteligentni algoritmi za prepoznavanje požara automatski analiziraju slike i pokušavaju pronaći vizualne znakove požara raslinja, osobito dima tijekom dana i plamena tijekom noći. Ako se pronađe nešto sumnjivo, generira se preliminarni alarm i vidljivo se označavaju odgovarajući dijelovi slike. Operater pregledava sumnjive dijelove slike i odlučuje radi li se stvarno o požaru ili ne.

Tijekom rada na projektu instalirane su tri motrilačke jedinice na splitskom Marjanu, na Vidovoj gori na Braču i na zgradi FESB-a na kojima su tijekom projekta testirana i ispravljane početne ideje. Nakon istraživačkog razdoblja do 2006. godine nastavljen je intenzivni rad na uobličavanju IPNAS-a u radni sustav koji je sposoban efikasno raditi neprekidno 24 sata 7 dana u tjednu. Put od prototipa do radnog proizvoda koji mora u prirodnim uvjetima raditi 24/7 često je i zahtjevniji od samog razvoja prototipa jer zahtijeva rješavanje brojnih problema, od efikasne i pouzdane komunikacije do zaštite od grmljavinskih izboja. Nakon 2006. godine radni sustavi su instalirani u brojnim hrvatskim nacionalnim parkovima i parkovima prirode (NP Paklenica, NP Mljet, PP Telašica, PP Vrana i PP Biokovo).

Sljedeći korak u razvoju dogodio se 2015. godine kroz projekt *HOLISTIC* kada su sustavom IPNAS probno pokrivene i sve četiri dalmatinske županije. Pozitivna iskustva projekta *HOLISTIC* potaknula su i širu primjenu sustava. Tijekom 2015. godine pokrenut je projekt u suradnji Hrvatskih šuma kao investitora, Odašiljača i veza kao nositelja komunikacijske i računalne infrastruktura i FESB-a kao nositelja programske podrške. Sustav IPNAS je potpuno prerađen u unaprijeđenu verziju tada radnog naziva STRIBOR, a danas komercijalnog naziva *OiV Fire Detect* AI (OIV, 2023). Sustavno je pokriveno skoro cijelo područje dalmatinskih županija s 86 motrilačkih kamera na 43 motrilačke lokacije, a uspostavljena su i 4 motrilačka županijska centra. Slika 8.16. prikazuje jednu motrilačku jedinicu i izgled prikaza na nadzornom zaslonu, a slika 8.17. izgled motrilačkog centra Split.

Slika 8.16. Prikaz jedne motrilačke jedinice i prikaz na zaslonu aplikacije *OIV Fire Detect AI* (Stipaničev, 2021)

Slika 8.17. Motrilački centar Split (Stipaničev, 2021)

Ovaj se sustav stalno nadograđuje i unaprjeđuje, a integriran je i s GIS-om te sustavima za procjenu požarnog rizika i simulaciju širenja požara. Procjena mikrolokacijskog požarnog rizika drugi je važan korak u okviru projekta *HOLISTIC*. Požarni rizik se definira kao „vjerojatnost izbijanja požara i mogući gubitak koji može požarom nastati". Vjerojatnost izbijanja požara određuje se na temelju:

- klimatoloških i meteoroloških parametara
- karakteristika terena
- karakteristika vegetacije
- sociooloških parametara.

Rizik se iskazuje jednom od pet kategorija: vrlo mali, mali, umjereni, veliki i vrlo veliki. Prva varijanta proračuna požarnog rizika za područje Splitsko-dalmatinske županije nazvanog MIRIP (Proračun mikrolokacijskog indeksa rizika od požara) dovršena je 2008. godine u suradnji sa Splitsko-dalmatinskom županijom i Državnim hidrometeorološkim zavodom (DHMZ). Posebnost MIRIP-a je bila u tome što je požarni rizik računat na razini mikrolokacije pa su karte požarnog rizika puno detaljnije od dotad uobičajenog okvirnog načina iskazivanja požarnog rizika za šire područje, kao na primjer: „Na području srednje Dalmacije veliki indeks opasnosti od požara raslinja.". Slika 8.18. daje usporedni prikaz karti mikrolokacijskog indeksa požarnog rizika za dan malog i velikog rizika na području Splitsko-dalmatinske županije.

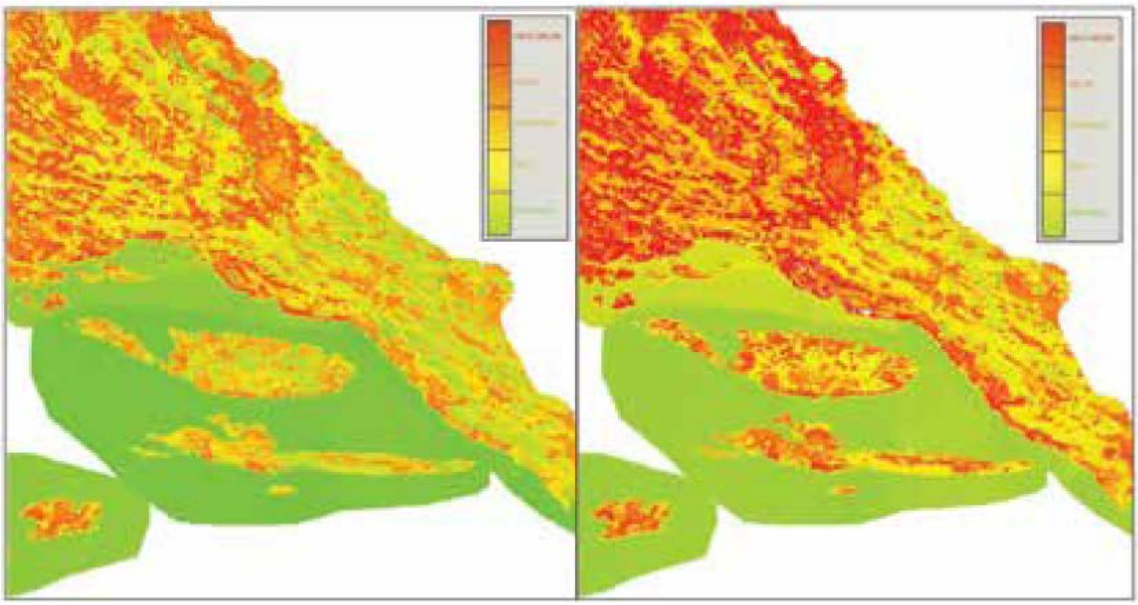

Slika 8.18. Prikaz požarnog rizika za dan malog (lijevo) i velikog (desno) rizika (Stipaničev, 2021)

Ovaj je sustav za proračun indeksa požarnog rizika kasnije u okviru projekta *HOLISTIC* proširen na cijelo područje jadranske regije i nazvan je *AdriaFireRisk*.

Modeliranje širenja požara samo je jedan od dijelova kompleksnijeg modela ponašanja požara. Modeliranje ponašanja požara osim modela širenja uključuje i modeliranje zapaljenja požara i modeliranje intenziteta požara. Modeliranje ponašanja požara je dosta kompleksnije i uključuje interakciju požara s dinamikom atmosfere te modelira primjerice i problem nastajanja i širenja dima. Međutim, po praktičnim iskustvima EU projekata koji su se proteklih deset godina bavili ovom problematikom, za operativni rad vezan za požarnu preventivu i upravljanje gašenjem požara dovoljno je modeliranje širenja požara. Prva istraživanja vezana uz modeliranje širenja

požara raslinja također su počela 2003. godine, ali su se posebno intenzivirala 2007. i 2008. godine tijekom rada na projektu za Splitsko-dalmatinsku županiju. Konačni rezultat ovih istraživanja je bio prototip simulatora širenja požara otvorenog prostora radno nazvan MOPP (Modeliranje propagacije požara). Sljedeći korak u razvoju simulatora širenja požara bilo je njegovo unaprjeđenje i integracija u naš napredni sustav za rano otkrivanje i praćenje požara raslinja *OIV Fire Detect AI* (OIV, 2023). Slika 8.19. prikazuje način integracije simulatora. Integracija se odvija na više razina. Korisnik na slici klikne na mjesto gdje je otkrio požar u nastajanju. Kako je korištenjem elemenata proširene stvarnosti (engl. *Augmented Reality*, AR) slika povezana s GIS sustavom, na karti se prikazuje i odabrana lokacija. Korisnik sada za tu lokaciju može pokrenuti simulator te za trenutne meteorološke podatke dobiti prikaz mogućeg širenja požara tijekom sljedećih nekoliko sati. Na unaprjeđenju simulatora se radi i dalje. Slika 8.20. prikazuje integrirani prikaz simulatora širenja požara unutar zaslonskog prikaza aplikacije *OIV Fire Detect AI.*

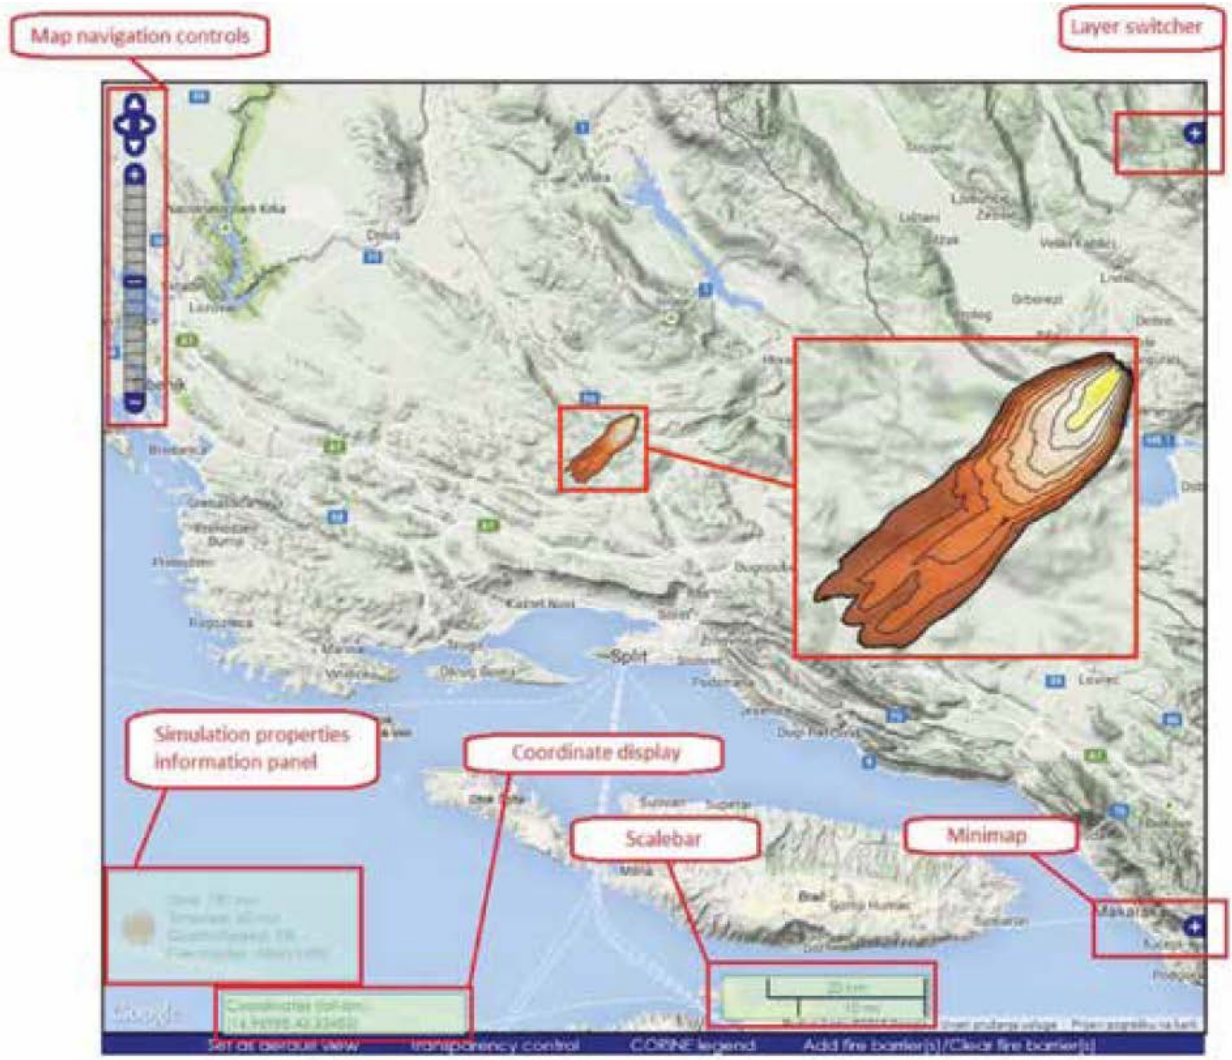

Slika 8.19. Prikaz modela širenja požara na sučelju *Adria Fire Propagatora* (Stipaničev, 2021)

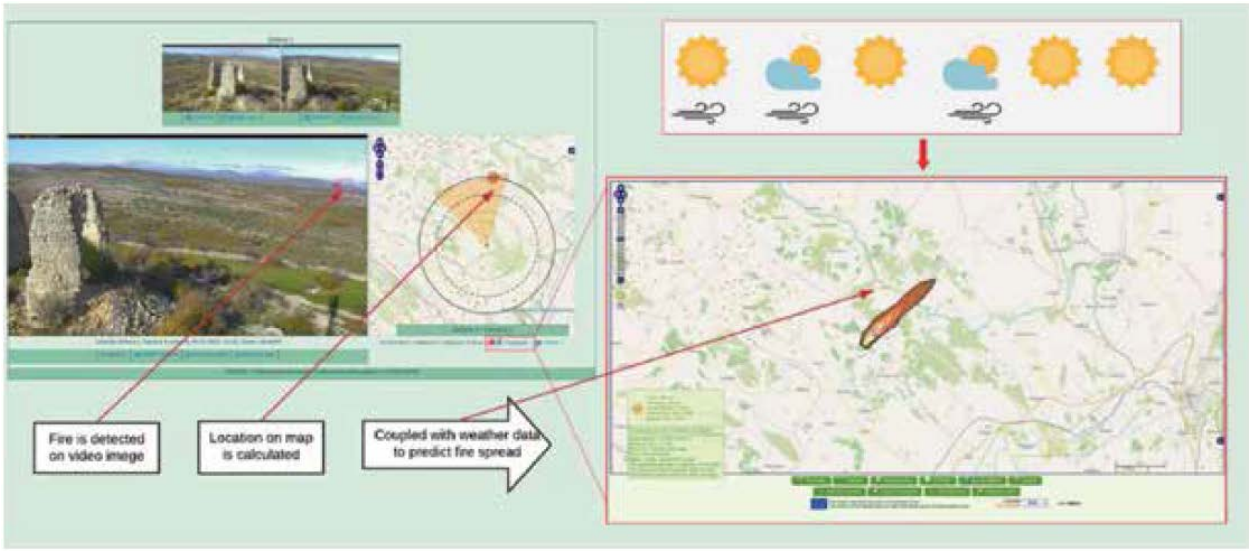

Slika 8.20. Integracija simulatora širenja požara u *OIV Fire Detect AI* (Stipaničev, 2021)

8.3. Predviđanje i sprječavanje industrijskih nezgoda sa štetnim posljedicama na okoliš i ljudsko zdravlje

U ovom će se potpoglavlju ukratko analizirati programska podrška za predviđanje nastanka nezgoda u domeni naftne, petrokemijske i drugih grana kemijske industrije čije sirovine i završni proizvodi mogu izazvati teške posljedice za okoliš, kao i za život i zdravlje ljudi koji žive i rade unutar dosega potencijalnih nezgoda. Za ove se aplikacije može reći da pokrivaju cijeli segment SiZ-a jer se bave analizom i procjenom rizika za okoliš, sigurnošću i zaštitom radnika na radnim mjestima unutar industrije te prevencijom nastanka i smanjenjem posljedica požara, s obzirom na to da su često tvari u kemijskoj industriji, osim što su otrovne, zapaljive i eksplozivne. Za primjer ove programske podrške uzete su aplikacije američkog proizvođača Safer Systems (*Safer Systems*, 2013). Konkretan primjer mjesta primjene u praksi u RH je petrokemijska industrija Petrokemija d. d. u Kutini.

Primijenjena programska podrška sastoji se od dvije aplikacije: *Safer TRACE* i *Safer Real-time*. *Safer TRACE* (skraćenica od engl. *Toxic Release Analysis of Chemical Emissions*) je aplikacija za analizu toksičnih kemijskih emisija koja je na tržištu prisutna od 1986. godine i otad je najkvalitetniji sustav za utvrđivanje i procjenu rizika koji analizira učinke toksičnih, zapaljivih i eksplozivnih kemikalija ispuštenih u atmosferu. TRACE aplikacija omogućava izradu temeljite i stručne analize, a prikaz dobivenih rezultata moguće je prilagoditi potrebama korisnika. Za analizu stanja od običnih propuštanja, preko pogrešaka u sprječavanju širenja sve do eksplozija, aplikacija TRACE osigurava potrebno znanje za učinkovito postupanje u opasnim situacijama i u donošenju odluka vezanih za složenu problematiku sigurnosti i zaštite.

TRACE simulira ispuštanje toksičnih kemikalija koristeći grupe sofisticiranih algoritama za modeliranje oštećenja spremnika, propuštanja cjevovoda, fizičkih pojava na izvoru ispuštanja, modeliranje gustoće plinova i Gaussovog raspršenja. Dodatno, algoritmi za modeliranje požara i eksplozije mogu prikazati zone utjecaja (udara) toplinskog isijavanja i nadtlaka eksplozije. TRACE algoritmi daju nekoliko opcija za grafički prikaz rezultata u kontekstu uz vrlo velik broj detalja. Zone utjecaja (udara) mogu biti prikazane na „mreži" ili na prilagođenim grafičkim kartama. Primljeni podaci te podaci o populaciji i evakuaciji mogu se iskoristiti za izradu plana djelovanja u slučaju opasnosti. Ovakav je sustav vrlo važan za Petrokemiju d. d. jer ona proizvodi i u svojoj proizvodnji koristi opasne kemijske tvari i spojeve, a smještena je u blizini naselja. Taj

nam sustav pomaže predvidjeti i spriječiti nezgode ili u slučaju nezgode predvidjeti posljedice i na vrijeme reagirati te zaštititi radnike i građane koji se mogu naći u opasnosti.

Unosi u TRACE modele uključuju kemijska svojstva, scenarije propuštanja, meteorološke podatke, nivoe djelovanja (utjecaja) na receptore (primatelje), populacijske podatke i karte. TRACE, kao sustav za pomoć pri odlučivanju, pruža stručnu pomoć tijekom unosa ulaznih podataka kako bi osigurao njihovu točnost. Baza podataka kemikalija sadrži fizičke konstante i druge podatke potrebne za kalkuliranje modela za više od 700 kemikalija. Dostupno je nekoliko konfiguracija scenarija ispuštanja kako bi se korisniku pomoglo okarakterizirati konkretnu jedinstvenu situaciju uz primjere scenarija. Receptori se mogu definirati s mnogo atributa tako da mogu biti korišteni za proučavanje djelovanja udara. Karte se mogu integrirati tako da pruže kontekst za rezultate modela. Raspodjela populacije može se prikazati grafički, uz pojašnjenje kompliciranih podataka, a može se i vizualno prikazati jesu li podaci pravilno uneseni. Jednom kada se razvije tzv. „Ulazna Studija Događaja", pokrene se u okviru odgovarajućeg predloženog modelu. Tada se transformira u „Izlaznu Studiju Događaja". U pregledu „Izlazne Studije Događaja" postoji mnoštvo opcija za vizualizaciju rezultata analize. To uključuje izvještaje karakteristike izvora, profile, utjecaj na receptore, utjecaj na populaciju (radnici, stanovništvo) te analize rubnih područja. Grafički se prikaz može prilagoditi odabirom boja, formatom iscrtavanja, određivanjem interesnog područja i podešavanja osi. Dodatno pripadajući podaci za iscrtavanje mogu se jednostavno transformirati u Word, Excel ili Powerpoint format datoteke. Funkcionalni moduli koje ova aplikacija pokriva su:

- modeliranje slučajnog ispuštanja
- identifikacija opasnosti
- planiranje upravljanja rizicima
- planiranje hitnih intervencija
- modeliranje ljudskih reakcija
- modeliranje regulativnih potreba
- kvantitativna procjena rizika
- procjena sustava za „ublaživanje"
- procjena izloženosti populacije
- studija „najgoreg slučaja" i alternativnog scenarija.

Safer Real-Time je aplikacija napravljena za jednostavnu upotrebu, fokusirana na upravljanje ishodom u slučajevima već nastale nesreće, brzi prikaz rezultata i dokumentiranje događaja. Odličan je alat i za vježbe, „što − ako" analize i vrednovanje planova za slučajeve nesreća. Prilagođena je području tvrtke i definira njezinu specifičnu problematiku. Objedinjuje snažne alate za modeliranje i specifične informacije područja za izradu prilagođenog okruženja u cilju shvaćanja posljedica ispuštanja otrovnih kemikalija u tvrtki. Kombinira meteorološke podatke u stvarnom vremenu s predprogramiranim scenarijima ispuštanja tako što trenutno odredi utjecaj oblaka otrovnih para u nekoj hitnoj situaciji. Isto tako, postoji način rada za planiranje koji pruža potpunu kontrolu nad svim ulaznim podacima modela i meteorološkim parametrima. Osnovni model procjene opasnosti uključuje parametre količine/brzine za:

- ispuštanje plinova
- ispuštanje tekućina
- ispuštanje tekućina i plinova

- emisije iz dimnjaka
- emisije pri zemlji i s povišenih mjesta.

Dodatni moduli daju sposobnosti za dodatna napredna modeliranja:

- curenje cjevovoda
- oštećenja spremnika i cjevovoda koji vode od spremnika
- višekomponentno modeliranje tekućina i plinova
- napredna povratna kalkulacija – procjena brzine i količine istjecanja
- modeliranje požara – toplinsko isijavanje
- modeliranje eksplozija – efekt nadtlaka
- modeliranje infiltracije – vrednovanje efekta sigurnosti
- modeliranje eksfiltracije – ispuštanje unutar građevine.

Treba naglasiti da *Safer Real-Time* u modele integrira aktualne vrijednosti različitih senzora (tlaka, protoka, temperature, koncentracije tvari i dr.) raspoređenih na bližem i širem području tvrtke, kao i aktualne meteorološke podatke iz lokalnih meteoroloških stanica na području djelovanja.

Temelj procjene i predviđanja je dinamička analiza i grafički prikaz tzv. perjanice (oblaka) koja prikazuje područja koncentracija raspršenja kemikalija. Prikaz perjanice daje informacije koje su ključne za odgovor na događaj. Putanja i zahvaćeno područje su vizualno konstantni i razumljivi sami po sebi. Posljedice utjecaja perjanice na obližnje stanovništvo nisu baš tako očite. Svaka boja oblaka predstavlja informaciju o tome što se može dogoditi pri različitim nivoima koncentracija. Nivoi koncentracija uvijek su definirani kao dio na milijun (ppm). Tipičan oblak (slika 8.21.) je prikazan u tri boje: žutoj, crvenoj i ljubičastoj. Tvrtka za svoje područje definira značenje za sva tri nivoa, npr. žuta boja predstavlja detekciju kemikalije koja nema kratkotrajne ni dugotrajne posljedice za zdravlje, a crvena i ljubičasta mogu predstavljati ozbiljnije posljedice u slučaju izloženosti tim nivoima.

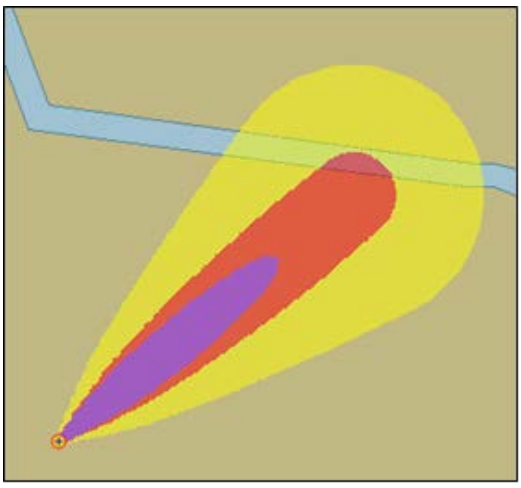

Slika 8.21. Tipični prikaz perjanice oblaka u tri boje (izvor: *Safer Trace* priručnik)

Granice kontura koncentracija mogu se različito definirati ovisno o vrsti opasnosti pridruženoj kemikaliji, a to su: toksičnost, zapaljivost ili oboje. Nivoi zapaljivosti su obično: Donja granica

eksplozivnosti (DGE) i Gornja granica eksplozivnosti (GGE). Dinamička analiza perjanice nam kroz prikaz modela simulacije treba dati prije svega odgovor na dva ključna pitanja:

- Gdje će biti oblak u vremenu?
- Kolika je koncentracija u bilo kojem području interesa?

Po završetku unosa parametara događaja i pokretanja izračuna otvara se obrazac prikaza rezultata, nalik prikazanom na slici 8.22.

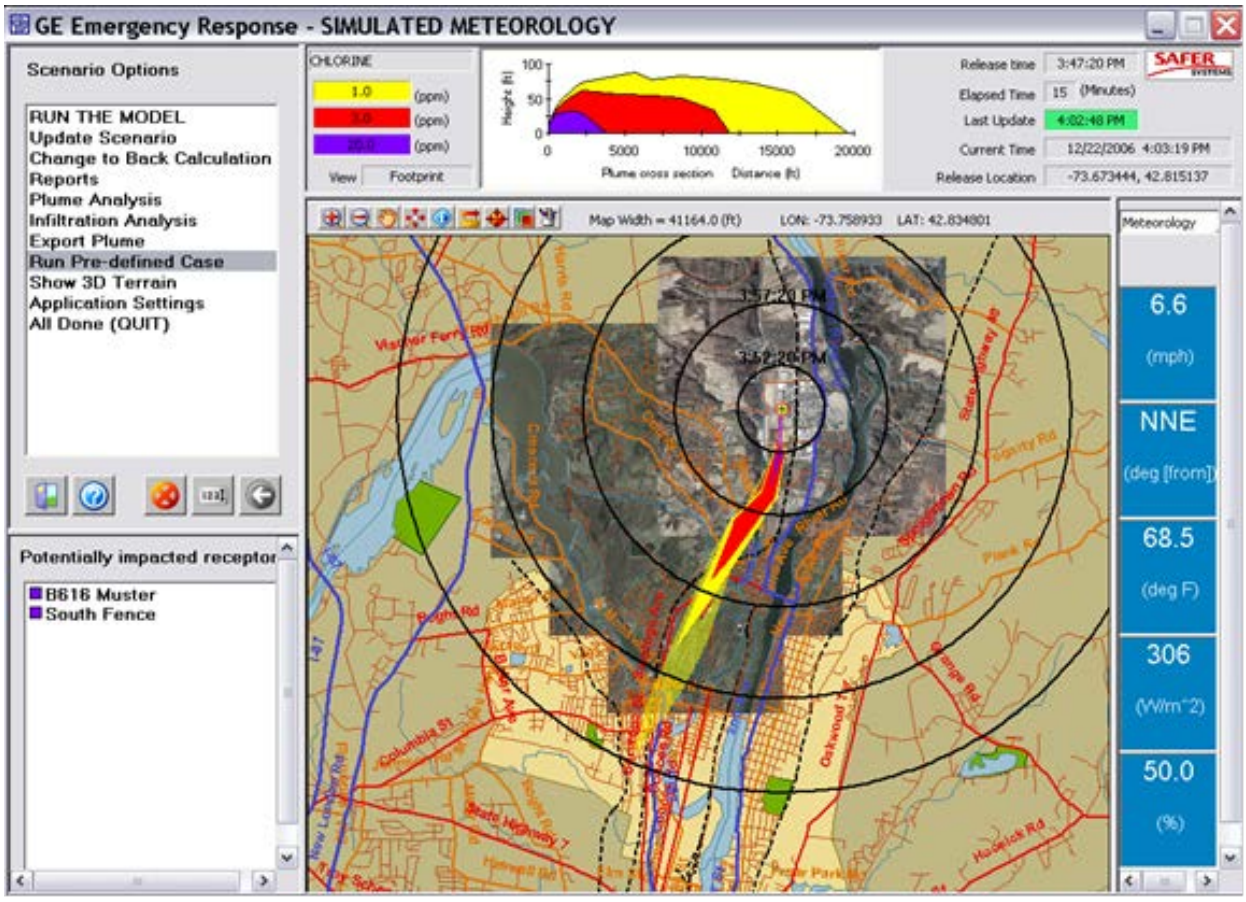

Slika 8.22. Prikaz specifičnih informacija za scenarij (izvor: *Safer Trace* priručnik)

Dostupne informacije su:

- modelirana kemikalija
- konture granica koncentracija
- trenutni prikaz koji može biti Trag, Snimak, Nadtlak ili Toplinsko isijavanje
- vertikalni profil koji prikazuje vertikalno raspršenje naspram horizontalne udaljenosti za svaki od koncentracijskih nivoa
- vremenska ljestvica događaja:
  - vrijeme početka događaja – vrijeme ispuštanja
  - proteklo vrijeme – koliko dugo događaj traje
  - vrijeme zadnjeg ažuriranja prikaza – zadnje ažuriranje
  - aktualni datum i vrijeme.

Lokacije ispuštanja prikazane su u kartografskim jedinicama, uglavnom kao zemljopisna dužina i širina.

Koristeći način rada „Snimka" možemo vidjeti kako će oblak izgledati u budućnosti. Na primjer, u grafičkom prikazu gledamo snimak perjanice u dvadesetoj minuti od početka istjecanja iako je „Proteklo vrijeme" događaja samo 17 minuta. U tom je slučaju ispuštanje zaustavljeno, a oblak se kreće niz vjetar. Primjer korištenja snimke i traga u grafičkoj analizi perjanice prikazan je na slici 8.23.

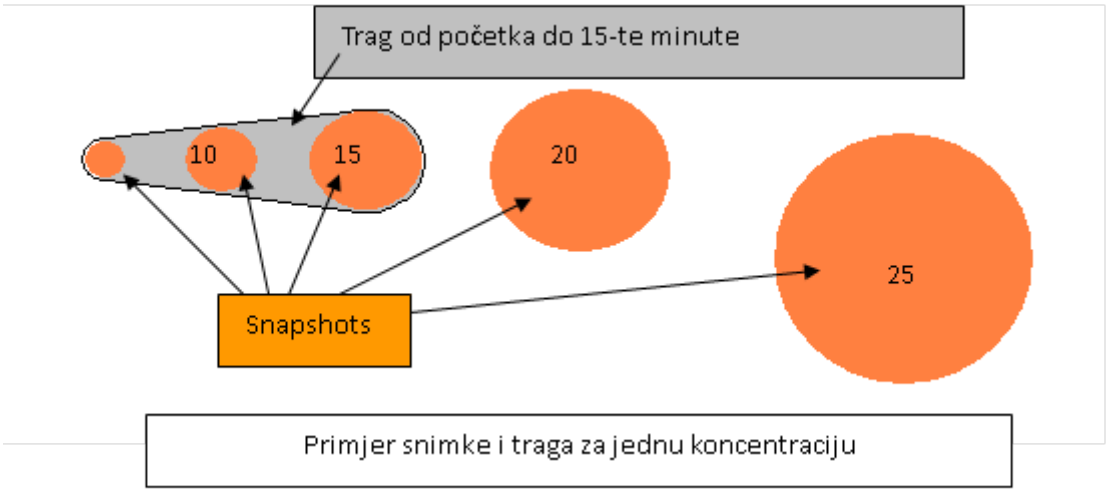

Slika 8.23. Grafički prikaz analize perjanice (izvor: *Safer Trace* priručnik)

Smatra se da je događaj završen kada se dosegne najniži nivo granice koncentracija. U toj točki kemikalija još uvijek postoji, ali se nalazi ispod prepoznatljivih ili štetnih nivoa. Sustav uvijek treba raditi i ažurirati ulazna stanja dok se ne dosegne taj nivo. Ne može se znati kako će vremenski uvjeti modificirati putanju oblaka pa je važno nastaviti analizu i ažuriranje dok se ne uvjerimo da je kemikalija dosegla prihvatljive koncentracije.

Tijekom kompletnog izvršavanja pojedinog hitnog slučaja program sprema informacije o ispuštanju i meteorološke podatke. Po završetku izrade simulacije događaja program zatvara datoteku u kojoj je sadržan taj događaj.

* * *

Na kraju ovog udžbenika nužno je istaknuti da je prikazana i opisana programska podrška predmet stalnog razvoja i usavršavanja. Aktualno stanje razvoja informacijsko-komunikacijske infrastrukture u Republici Hrvatskoj također se mijenja i napreduje. Funkcionalnosti središnjeg dijela informacijskih sustava u domeni sigurnosti i zaštite mijenjaju se u skladu s aktualnom zakonskom i podzakonskom regulativom. U skladu s ovim promjenama mijenjat će se i funkcionalnosti korisničke programske podrške. Prikazane metode analize poslovnih sustava i razvoja informacijskih sustava su jedna relativno stabilna osnova kroz koju trebamo naučiti razmišljati o načinima digitalizacije stvarnog svijeta, njezinoj nužnosti i aktualnim ograničenjima. Naravno, granice ograničenja se kontinuirano pomiču unaprijed stalnim tehnološkim razvojem. Ovaj udžbenik zato predstavlja osnovu za praćenje predavanja i vježbi na predmetima Upravljanje zaštitom na radu primjenom računala i Upravljanje zaštitom od požara primjenom računala, ali prije svega, jednu dobru osnovu za ulazak u svijet digitalne transformacije i njezin daljnji razvoj u domeni sigurnosti i zaštite.

Na sadržaj

9. LITERATURA

1. Arunović, Denis. 2018. „Što je u stvari blockchain i kako radi? − Tehnologije @ Bug.hr". https://www.bug.hr/tehnologije/sto-je-u-stvari-blockchain-i-kako-radi-3011 (4. 9. 2023.).

2. ATLASSIAN. 2023. Agile manifesto. *Software Development*. https://www.atlassian.com/agile/manifesto (13. 7. 2023.).

3. Averweg, Udo Richard Franz. 2012. *Decision-Making Support Systems: Theory and Practice*. South Africa: Udo Richard Franz Averweg.

4. Barić, Marko. 2023. „Upravljanje vatrogasnim intervencijama". Veleučilište u Karlovcu. https://urn.nsk.hr/urn:nbn:hr:128:197675 (9. 5. 2023.).

5. Beck, Kent, i Cynthia Andres. 2012. *Extreme Programming Explained: Embrace Change*. 2. ed., 11. print. Boston: Addison-Wesley.

6. Belak, Stipe, i Ivana Ušljebrka. 2014. „Uloga ERP sustava u promjeni poslovnih procesa". *Oeconomica Jadertina* (2): 33–52. https://hrcak.srce.hr/136745 (13. 7. 2023.).

7. Bourgeois, David. 2014. *Information Systems for Business and Beyond*. Saylor Foundation. http://www.saylor.org/courses/bus206 (5. 12. 2023.).

8. Business Intelligence. 2012. „Skladišta podataka i poslovna inteligencija – prvi dio". *Business Intelligence*. https://sqlbicro.wordpress.com/2012/10/19/skladista-podataka-i-poslovna-inteligencija-prvi-dio/ (7. 5. 2023.).

9. CARNet. 2007. *Digitalni potpis*. CARNet. https://www.cert.hr/digitalni-potpis/ccert-pubdoc-2007-02-182/ (13. 3. 2023.).

10. CARNet. 2019. *VPN usluge – što su, kako funkcioniraju i kada su korisne*. https://www.cert.hr/wp-content/uploads/2019/07/VPN_usluge.pdf (16. 3. 2023.).

11. CARNet. 2009a. *SAML - Security Assertion Markup Language*. CARNet. https://www.cis.hr/www.edicija/LinkedDocuments/CCERT-PUBDOC-2009-10-279.pdf (13. 3. 2023.).

12. CARNet. 2009b. *TLS protokol*. CARNet. https://www.cis.hr/www.edicija/LinkedDocuments/CCERT-PUBDOC-2009-03-257.pdf (13. 3. 2023.).

13. CARNet CERT. 2009. *Nedostaci PKI infrastrukture*. CARNet.

14. Codd, Edgar. 1970. „A Relational Model of Data for Large Shared Data Banks". *Communications of the ACM* 13(6).

15. Ćosić, Nikolina. 2023. „Primjena skladišta podataka u upravljanju zaštitom na radu". Veleučilište u Karlovcu. https://urn.nsk.hr/urn:nbn:hr:128:309562.

16. Daintith, John i Edmund Wright, ur. 2008. *A dictionary of computing*. 6th ed. Oxford ; New York: Oxford University Press.

17. DeMarco, Tom. 1978. *Structured analysis and system specification*. New York: Yourdon.

18. Dervojeda, Kristina. 2021. „Education 5.0: Rehumanising Education in the Age of Machines". *LinkedIn*. https://www.linkedin.com/pulse/education-50-rehumanising-age-machines-kristina-dervojeda/ (4. 9. 2023.).

19. Deželić, Gjuro. 2009. „Što je medicinska informatika?" U *Medicinska informatika*, ur. Josipa Kern i Mladen Petrovečki. Zagreb: Medicinska naklada, 1–21.

20. Dujella, Andrej, i Marcel Maretić. 2007. *Kriptografija*. Zagreb: Element.

21. Eckel, Bruce. 1989. *Using C++: Covers C++ Version 2.0*. Berkeley: Osborne McGraw-Hill.

22. e-HVZ. 2014. „Hrvatska vatrogasna zajednica − EU projekt e-HVZ". https://hvz.gov.hr/istaknute-teme/eu-projekti/eu-projekt-e-hvz/162 (5. 9. 2023.).

23. Embley, David, Barry, Kurtz, i Scott Woodfield. 1992. *Object-oriented systems analysis: a model-driven approach*. Englewood Cliffs, N.J: Yourdon Press.

24. European Commission. 2021. *Industry 5.0: Towards a sustainable, human-centric and resilient European industry,*. Publications Office of the European Union. https://research-and-innovation.ec.europa.eu/news/all-research-and-innovation-news/industry-50-towards-more-sustainable-resilient-and-human-centric-industry-2021-01-07_en (15. 5. 2023.).

25. Fertalj, Krešimir, i Damir Kalpić. 2006. „Projektiranje informacijskih sustava". Predstavljeno na FER, ZPR, Sveučilište u Zagrebu.

26. Franc, Sanja, i Ines Dužević. 2020. *Digitalna transformacija i trgovina*. Zagreb: Ekonomski fakultet Sveučilišta u Zagrebu.

27. Franović, Kristina, i Damir Kralj. 2021. „Mogućnosti daljnjeg razvoja nacionalne informacijske infrastrukture u području zaštite na radu". 63(4): 405–17.

28. Growth Stack. 2022. „Difference: ERP, CRM and SCM". *Groeth Stack*. https://www.growthstack.gs/difference-between-erp-crm-and-scm/ (15. 7. 2023.).

29. IBM. 1978. *Business Systems Planning: Information Systems Planning Guide (GE20-0527-4)*. Second Edition. IBM Corporation.

30. ILO. 2017. „Data Sources for Optimizing the Collection and Use of OSH data". U Ankara: ILO. https://www.ilo.org/ankara/news/WCMS_551802/lang--en/index.htm (5. 12. 2023.).

31. ILO. 2022. „ILOSTAT Data collection and production". https://ilostat.ilo.org/about/data-collection-and-production/ (5. 12. 2023.).

32. InfinityQS. 2018. „InfinityQS: Inside the Next Factory of the Future: Industry 5.0". *Advantive*. https://www.infinityqs.com/blog/april-2017/inside-the-next-factory-of-the-future-industry-5 (4. 9. 2023.).

33. Jajetić, Tomislav, i Damir Kralj. 2021. „Okvirni model mjerenja kvalitete programske potpore vođenju evidencija zaštite na radu". *Sigurnost* 63(3): 259–71. https://hrcak.srce.hr/263124 (5. 9. 2023.).

34. Kern, Josipa, i Mladen Petrovečki, ur. 2009. *Medicinska informatika*. Zagreb: Medicinska naklada.

35. Khoja, Shariq i ostali. 2007. „E-Health Readiness Assessment Tools for Healthcare Institutions in Developing Countries". *Telemedicine and e-Health* 13(4): 425–32. https://www.liebertpub.com/doi/10.1089/tmj.2006.0064 (31. 8. 2023.).

36. Kralj, Damir. 2018. *Primjena računala*. Veleučilište u Karlovcu.

37. Kralj, Damir, i Karlo Aralica. 2022. „Industry 5.0 from the perspective of safety at work". U *Proceedings of 8th International Professional and Scientific Conference Occupational Safety and Health*, Zadar: Veleučilište u Karlovcu, 114–20.

38. Kralj, Damir, i Dominik Mehmetaj. 2022. „The Impact of The Covid 19 Pandemic on the Dynamics of Digital Transformation − Croatian Perspective". https://zenodo.org/record/5818060 (4. 9. 2023.).

39. Kukhnavets, Pavel. 2019. „How to run Scrum efficiently in 2019? Quick guide for beginners". *Hygger*. https://habr.com/en/companies/hygger/articles/455022/ (13. 7. 2023.).

40. Lewin, Kurt. 1976. *Field Theory in Social Science: Selected Theoretical Papers*. Chicago: University of Chicago Press.

41. Lundeberg, Mats, Göran Goldkuhl, i Anders Nilsson. 1981. *Information Systems Development: A Systematic Approach*. Englewood Cliffs, N.J: Prentice Hall.

42. Mall, Rajib. 2015. *Fundamentals of Software Engineering*. Fourth edition, eastern economy edition. Delhi [India]: PHI Learning Private Limited.

43. Manger, Robert. 2010. *Osnove projektiranja baza podataka : D310 : priručnik za polaznike*. Zagreb: Sveučilište u Zagrebu. http://library.foi.hr/lib/knjiga.php?B=422&sqlx=13004&H=.

44. Nawo Solution. 2023. „Ergonomic analysis solution to indentify MSDs − Nawo Solution". https://nawo-solution.com/home/ (5. 9. 2023.).

45. NexGen Ergonomics. 2023. „NexGen Ergonomics − Welcome". http://www.nexgenergo.com/ (5. 9. 2023.).

46. NIAS. 2023. „NIAS". https://nias.gov.hr/ (4. 9. 2023.).

47. Nikolić, Gojko. 2017. „Industrija i obrazovanje". *Andragoški glasnik* 21(1–2): 37–48.

48. Østergaard, Esben. 2016. „Industry 5.0 – Return of the human touch". *UNIVERSAL ROBOTS*. https://www.universal-robots.com/fi/blogi/industry-50-return-of-the-human-touch/ (15. 5. 2022.).

49. Panian, Željko i ostali. 2010. *Poslovni informacijski sustavi*. Element.

50. Pavlić, Mile. 1996. *Razvoj informacijskih sustava − projektiranje, praktična iskustva, metodologija*. Znak.

51. Perić, Emil. 2022. Industrija 4.0. https://www.hgk.hr/documents/hgk-industrija-4058d8c59722f1e.pdf (10. l0. 2022.).

52. Pilar, Mario. 2020. „Šta je zona komfora i zašto je važno da POD HITNO iz nje izađete?" *Menadžment i liderstvo*. https://mariopilar.com/zona-komfora/ (5. 12. 2023.).

53. Prochaska, James, Carlo DiClemente, i John Norcross. 1993. „In Search of How People Change: Applications to Addictive Behaviors". *Journal of Addictions Nursing* 5(1): 2–16. https://journals.lww.com/00060867-199305010-00002 (31.8. 2023.).

54. Rada, Michael. 2018. „Industry 5.0 − Human Industry". *LinkedIN*. https://www.linkedin.com/pulse/industry-50-human-michael-rada (15. 5. 2022.).

55. Roser, Christopf. 2015. „A Critical Look on Industry 4.0 | AllAboutLean.Com". *AllAboutLean*. https://www.allaboutlean.com/industry-4-0/ (4. 9. 2023.).

56. Ross, Charles. 1991. *Computer systems for occupational safety and health management*. 2nd ed., rev. expanded. New York: M. Dekker.

57. Ruppert, Tamás, Szilárd Jaskó, Tibor Holczinger, i János Abonyi. 2018. „Enabling Technologies for Operator 4.0: A Survey". *Applied Sciences* 8(9): 1650. http://www.mdpi.com/2076-3417/8/9/1650 (4. 9. 2023.).

58. Safer Systems. 2013. „SAFER One | Dynamic Plume Modeling Software | Industrial Scientific". https://www.indsci.com/en/safer-one (5. 9. 2023.).

59. Sinarm. 2021. „Računalni program Sinarm – vođenje evidencija iz područja ZNR, ZOP i ZO". http://www.sinarm.net/ (5. 9. 2023.).

60. Srce. 2023. „Upute za korištenje jedinstvenog korisničkog web-sučelja za matične ustanove i partnere u sustavu AAI@EduHr | AAI@EduHr". https://www.aaiedu.hr/ (4. 9. 2023.).

61. Stipaničev, Darko. 2021. „Centar za istraživanje požara otvorenog prostora Split". *Godišnjak Akademije tehničke znanosti Hrvatske* 2021(1): 321–37. https://hrcak.srce.hr/279250 (28. 8. 2023.).

62. STpro. 2022. „Program za zaštitu na radu − STpro". https://www.stpro.hr/ (05. 9. 2023.).

63. Strahonja, Vjeran, Mladen Varga, i Mile Pavlić. 1992. *Projektiranje informacijskih sustava*. Zavod za informatičku djelatnost Hrvatske : INA-info.

64. Škrbec, Maja. 2022. „Izrada evakuacijskih planova primjenom programskog alata Autocad". Veleučilište u Karlovcu. https://urn.nsk.hr/urn:nbn:hr:128:751115 (9. 5. 2023.).

65. Tanenbaum, Andrew i David Wetherall. 2011. *Computer networks*. 5th ed. Boston: Pearson Prentice Hall.

66. Taylor, David. 2023. „OLTP vs OLAP: What's the Difference". *Guru99*. https://www.guru99.com/oltp-vs-olap.html (15. 7. 2023.).

67. Teorey, Toby, ur. 2011. *Database modeling and design: logical design*. 5th ed. Amsterdam : Burlington, MA: Elsevier ; Morgan Kaufmann.

68. WebZNR. 2023. „Vodeće rješenje za evidenciju zaštite na radu − WebZNR". https://www.zastitanaradu.hr/ (5. 9. 2023.).

69. Wiener, Norbert. 2007. *Cybernetics or Control and Communication in the Animal and the Machine*. 2. ed., reprint. Cambridge, MA, USA: MIT Press.

70. ZITEL. 2016. „EVIZ – Zitel d. o. o." https://zitel.hr/racunalni-programi/eviz/ (5. 9. 2023.).

71. ZUZNR. 2016. „Nadležnost Zavoda za unapređivanje zaštite na radu kao javne ustanove". https://uznr.mrms.hr/ (5. 1. 2018.).

Na sadržaj

10. PRILOZI

10.1. Popis slika

10.2. Popis tablica

10.3. Kazalo pojmova

Na sadržaj