Identifikacija utjecajnih faktora na povlačenje sredstava za znanost, istraživanje i inovacije iz fondova Europske unije primjenom poslovne inteligencije

Babić, Neva

Professional thesis / Završni specijalistički

2022

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University North / Sveučilište Sjever**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:122:846821

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

Repository / Repozitorij:

University North Digital Repository

Sveučilište Sjever

Specijalistički poslijediplomski rad br. 14/PiEUf/2022

Identifikacija utjecajnih faktora na povlačenje sredstava za znanost, istraživanje i inovacije iz fondova Europske unije primjenom poslovne inteligencije

Neva Babić, 0066172884

Varaždin, srpanj 2022. godine

Sveučilište Sjever

Odjel za ekonomiju

Specijalistički poslijediplomski rad br. 14/PiEUf/2022

Identifikacija utjecajnih faktora na povlačenje sredstava za znanost, istraživanje i inovacije iz fondova Europske unije primjenom poslovne inteligencije

Student

Neva Babić, 0064172887

Mentor

Izv. prof. dr. sc. Ljerka Luić

Varaždin, srpanj 2022. godine

Sveučilište Sjever
Sveučilišni centar Varaždin
104. brigade 3, HR-42000 Varaždin

Prijava specijalističkog poslijediplomskog rada

Definiranje teme specijalističkog poslijediplomskog rada i povjerenstva

ODJEL Odjel za ekonomiju

STUDIJ poslijediplomski specijalistički studij Poduzetništvo i EU fondovi

PRISTUPNIK Neva Babić | MATIČNI BROJ 0066172887

DATUM 10. 6. 2022. | KOLEGIJ Business intelligence u poduzetništvu

NASLOV RADA Identifikacija utjecajnih faktora na povlačenje sredstava za znanost, istraživanje i inovacije iz fondova Europske unije primjenom poslovne inteligencije

NASLOV RADA NA ENGL. JEZIKU Identification of influence factors on the absorption of funds for science, research and innovation from European Union funds by application of business intelligence

MENTOR izv. prof. dr. sc. Ljerka Luić | ZVANJE doktor znanosti

ČLANOVI POVJERENSTVA

1. prof. dr. sc. Ante Rončević, predsjednik
2. prof. dr. sc. Ljubo Jurčić, član
3. izv. prof. dr. sc. Ljerka Luić, mentor
4. prof. dr. sc. Danijel Radošević, zamjenski član
5. doc. dr. sc. Petar Mišević, zamjenski član

Zadatak specijalističkog poslijediplomskog rada

BROJ 14/PIEUf/2022

OPIS

Suočavanje s globalnim izazovima i njihova analiza rezultirali su UN-ovim ciljevima održivog razvoja i, posljedično, zajedničkom strategijom djelovanja Europske unije nazvanom Europa 2030, a koja sadrži skupove faktora koji bi trebali biti glavni pokretači promjena.

Jedan od tih skupova, nazvanih horizontalnim čimbenicima za prijelaz na održivost, čine obrazovanje, znanost, tehnologija, istraživanje, inovacije i digitalizacija, koje se smatra preduvjetom za ostvarivanje EU održivog gospodarstva. Na razini Europske unije, u tom se kontekstu ističe važnost okvirnih programa za istraživanje i inovacije kao katalizatora održive konkurentnosti, rasta i ulaganja, a jedna od vodećih EU inicijativa za potporu istraživanjima i inovacijama je program Obzor Europa kojim se nastoji povezati istraživanja i inovacije. U svakom programskom razdoblju Europska unija, među ostalim stavlja naglasak na istraživačke, razvojne i inovacijske aktivnosti kao glavnog pokretača razvoja organizacije, ali i društva u cjelini, i na njima se inzistira, ponajviše u vidu udjela ulaganja poduzeća u istraživanje i razvoj, kao osnovne pretpostavke za povećanje broja inovacija.

Kako pritom koristiti BI koncepte i BI alate zadatak je ovog specijalističkog poslijediplomskog rada.

Sveučilište Sjever
Sveučilišni centar Varaždin
104. brigade 3, HR-42000 Varaždin

Zadatak specijalističkog poslijediplomskog rada (nastavak)

OPIS

U uvodnom dijelu rada potrebno je elaborirati teorijski okvir problematike kojom se rad bavi, obrazložiti cilj i predmet istraživanja, izvore podataka, metode i metodologiju istraživanja, potom je potrebno dati prikaz strukture rada kroz kratki opis sadržaja rada te navesti istraživačko pitanje i hipoteze.

U poglavljima koja slijede potrebno je: (1) Dati određenje ključnih pojmova vezanih uz temu rada te na osnovu pregleda znanstvene literature iznijeti spoznaje dosadašnjih istraživanja poslovne inteligencije (Business Intelligence, BI) sagledane iz povijesnog, organizacijskog i tehnološkog aspekta; potom je u nastavku potrebno (2) Elaborirati preduvjete održivog gospodarstva Europske unije i (3) Sistematično prikazati instrumente Europske unije za znanost, istraživanje i inovacije. Pritom je važno razradu teme fokusirati na istraživačko pitanje: "Kako je moguće primjenom poslovne inteligencije utvrditi potencijal zemlje za povlačenje sredstava za znanost, istraživanje i inovacije iz fondova Europske unije?" svrha kojega je identificirati utjecajne faktore na povlačenje sredstava za znanost, istraživanje i inovacije. U drugom dijelu rada potrebno je (4) Opisati materijal i metodologiju istraživanja, potom (5) Deskriptivno i vizualno prikazati rezultate istraživanja provedenog primjenom BI alata, a u nastavku u okviru diskusije (6) Elaborirati postavljene hipoteze i kroz odgovor na istraživačko pitanje sistematizirati zaključke do kojih se došlo te ocijeniti ostvarenje cilja istraživanja, a u završnom dijelu rada (7) Iznijeti aplikativni doprinos rada za povlačenje sredstava za znanost, istraživanje i inovacije iz fondova Europske unije.

Glavne spoznaje do kojih se došlo proučavanjem literature i primjenom BI alata potrebno je iznijeti u zaključku na kraju rada, kvaliteti kojeg će doprinijeti prijedlog daljnjih istraživanja, cilj kojih je kreiranje nacionalnih smjernica i politika vezanih za povlačenje sredstava za znanost, istraživanje i inovacije.

U svim europskim strateškim dokumentima, uključujući programski okvir Obzor Europa, nastoji se povezati istraživanja i inovacije te razraditi trokut znanja između visokog obrazovanja, istraživanja i inovacija, a što bi trebalo predstavljati temelj za postizanje sinergijskih učinaka ulaganja u znanost i inovacije iz nacionalnih, regionalnih i međunarodnih fondova. Takva vrsta ulaganja trebala bi omogućiti povezivanje gospodarskog i znanstveno-istraživačkog sektora kako bi unutar države dala aktivan doprinos u postizanju međunarodne kompetitivnosti, odnosno, stvaranje nove znanstvene, društvene, kulturne i gospodarske vrijednosti. Nova znanja i ideje, procesi, proizvodi i usluge kao i novo poduzetništvo sastavnice su istraživačkog stvaralaštva koje su međusobno čvrsto povezane.

Zbog svega navedenog, očekuje se da ovaj specijalistički rad, kroz pregled problematike primjene poslovne inteligencije, BI koncepte i BI alate, potakne poslodavce i poduzetnike da se više uključe u izdvajanje za istraživanje i inovacije, a znanstveno-istraživačku zajednicu da identificirane utjecajne faktore i upotrijebi ih za učinkovitije povlačenje sredstava iz programa Obzor Europa.

ZADATAK UREUČEN 08.07.2022. | POTPIS MENTORA

SVEUČILIŠTE SJEVER

Zahvala

„Naša žuta i crvena svjetla u životu s vremenom se pretvaraju u zelena.“ (M.M.)

Početak ove zahvale dugujem svojoj šefici, prof. dr. sc. Anici Hunjet, koja me motivirala da upišem ovaj poslijediplomski studij te je uvijek bila na raspolaganju za savjet, vjetar u leđa i podršku bilo kakvog tipa.

Velika hvala i prof. dr. sc. Anti Rončeviću što je bio uz nas studente na našem početku, kraju i u svakoj sredini, nedoumici, formalnom učenju, ali i neformalnom razgovoru. Hvala za znanje, poticaje, savjete, angažman i interes koji su nas tjerali da budemo još bolji, da istražujemo više i da se pronađemo u vlastitim interesima i idejama. Hvala i na duhovitosti i smijehu kada je to bilo najpotrebnije.

Listajući vlastite bilješke s predavanja, jedna je iskočila, podcrtana i nekoliko puta zaokružena kao najvažnija. Čitajući ju, uvidjela sam da ista nije vezana uz lekciju sa studija, već uz onu životnu. „Dobro je učiti i dobro je činiti dobro.“, rekao je jednom prilikom dr. sc. Ljubo Jurčić, prof. emer. komentirajući svoje najvažnije spoznaje o životu, i time uvelike odredio daljnju motivaciju za izvući najbolje iz ovog iskustva i pri tome, ako je moguće, biti na pomoći i raspolaganju kome zatreba.

Hvala i Domagoju Topiću, univ. spec. oec., pred. na vrijednim savjetima, konstruktivnim raspravama i velikoj podršci kod pisanja ovog specijalističkog rada.

Za kraj, najveću zahvalu dugujem svojoj mentorici, izv. prof. dr. sc. Ljerki Luić. Teško je riječima izraziti količinu zahvalnosti koju osjećam za svaki odgovoreni poziv, svaki akademski i životni savjet, svaku podršku i vjetar u leđa, svaku poruku i e-mail koji su stigli u pravo vrijeme, svaki poticaj da izvlačim i želim još više i bolje od same sebe. Malo je reći da je upravo takva podrška odredila smjer završetka studija, ali i daljnjeg interesa, ambicije i želje za novim znanjima, novim istraživanjima i novim suradnjama.

Hvala mojoj obitelji, hvala mami koja je strpljivo uskočila kad god je zatrebalo i nikad se nije požalila da joj je teško ili naporno, hvala tati koji se tiho ponosio mojim malim koracima i uspjesima i s interesom slušao moje dojmove odslušanih predavanja, hvala Juri na čuvanju, obavljanju stvari umjesto mene i malim porukama ohrabrenja, hvala teti Jasni jer nikad ne zaboravi reći koliko vjeruje u mene, i teti Sanji koja uvijek pusti onu baš tada potrebnu suzu ponosa i ohrabrenja, hvala onima koji se vesele zajedno sa mnom i koji pitaju.

Hvala mojoj Ledi, najvažnijoj osobi u mojem životu jer je upravo ona glavni razlog, početak i kraj svega, ona kojoj sam vlastitim primjerom željela dokazati da se može – unatoč svemu. Može se kad to želimo, može se kad smo ponekad i sami u svemu, može se i kad se čini nemogućim.

S one osobne strane i najveće emotivne podrške, još jednu veliku zahvalu dugujem svojoj mentorici izv. prof. dr. sc. Luić jer me, prilikom naših dugih dnevnih i noćnih razgovora koji su često prerasli akademsku razinu i postali izmjena osobnih, životnih iskustava, emocija, radosti i tuga, želja, strahova i nadanja, uvijek podsjećala da mogu kad sam sama najmanje vjerovala u to, hvala jer me upravo kroz takve razgovore podsjetila o nekim životnim pravcima, promišljanjima i prioritetima po kojima i sama živim ili bih barem to željela i tome težim. Hvala još jednom i mojoj Ledi, neka ostane ovdje jednom kad bude znala pročitati, da nikad ne zaboravi koliko je mama zahvalna za nikad izgovorenu ali toliko puta osjećanu podršku u obliku razumijevanja i zagrljaja i poljubaca kad je najteže. („*Mi smo super žene i jednako smo važne.*“).

Hvala Vam svima na pomoći da se moja žuta i crvena svjetla počnu pretvarati u zelena.

Sažetak

Znanost, tehnologija, istraživanje, razvoj, inovacije i digitalizacija danas se promatraju kao jedni od glavnih čimbenika održivog gospodarskog razvoja i dio su svih strateških smjernica koje se tiču gospodarskog oporavka. U tu svrhu, Europska unija omogućava korištenje instrumenata kojima se direktno financiraju procesi istraživanja i razvoja u međunarodnom okruženju zajedničkim korištenjem resursa, kao i povezivanje akademske zajednice sa poslovnim sektorom s ciljem razvoja društvenih inovacija i inovacijskih ekosustava. Sve to bilo bi nemoguće bez digitalizacije, digitalne tehnologije i koncepta i alata poslovne inteligencije koji omogućavaju lakši pristup informacijama, kao i njihovu selekciju temeljem važnosti i međusobne povezanosti. Svrha ovog rada primjena je BI alata i koncepata u detektiranju utjecajnih faktora na povlačenje sredstava za znanost, istraživanje i inovacije. Cilj rada je identificirati utjecajne faktore promatrajući skup tzv. horizontalnih čimbenika gospodarskog razvoj unutar kategorije znanosti, tehnologije, istraživanja, razvoja i inovacija, uključujući pritom i dimenziju digitalizacije koja se, uz zelenu tranziciju, spominje kao jedna od okosnica i osnovnih faktora razvoja društva u cjelini. Efikasnost neke zemlje kod povlačenja takve vrste sredstava može odrediti intenzitet i brzinu njezinog budućeg gospodarskog razvoja. Istraživanje je provedeno *desk*-metodom. Za uzorak istraživanja odabrane su statističke baze podataka koje sadrže relevantne pokazatelje za procjenu utjecaja horizontalnih čimbenika na povlačenje sredstava za znanost, istraživanje i inovacije. Na osnovu rezultata identificirani su neki od čimbenika koji utječu na povlačenje sredstava iz programa Obzor te su u tom dijelu stvoreni osnovni preduvjeti za kreiranje nacionalnih smjernica i politika vezanih za povlačenje sredstava za znanost, istraživanje i inovacije te učinkovitije iskorištavanje takvih instrumenata i fondova. U tom smislu ovaj rad daje sveobuhvatan pristup analizi faktora koji utječu na korištenje instrumenata Europske unije za istraživanje i inovacije korištenjem koncepata i alata poslovne inteligencije, a čijim se dodatnim analizama uključivanjem indikatora iz drugih kategorija čimbenika pomoću alata može kreirati model za uspješno povlačenje sredstava kod takve vrste fondova.

Ključne riječi: poslovna inteligencija, znanost, istraživanje, inovacije, Obzor 2020

Abstract

Science, technology, research, development, innovation and digitalization are today seen as some of main factors of sustainable economic development and are part of all strategic guidelines concerning economic recovery. For this purpose, European Union enables the use of instruments that directly finance research and development processes in the international environment through the joint use of resources, as well as connecting the academic community with the business sector with the aim of developing social innovations and innovation ecosystems. All of this would be impossible without digitalization, digital technology, and business intelligence concepts and tools that enable easier access to information, as well as their selection based on importance and mutual connection. The purpose of this paper is the application of BI tools and concepts in the detection of influential factors on the absorption of funds for science, research and innovation. The aim of the paper is to identify the influencing factors by observing a set of horizontal factors of economic development within the category of science, technology, research, development and innovation, including the dimension of digitalization which, along with the green transition, is mentioned as one of the backbones and basic factors of the development of society as a whole. The efficiency of a country in absorbing this type of funds can determine the intensity and pace of its future economic development. The research was conducted using the *desk*-method. Statistical databases containing relevant indicators for assessing the impact of horizontal factors on the absorption of funds for science, research and innovation were selected for the research sample. Based on the results, some of the factors affecting the absorption of funds from the Horizon program were identified, and in that part, the basic preconditions are made for the creation of national guidelines and policies related to the withdrawal of funds for science, research and innovation, and the effective use of such instruments and funds. In this sense, this thesis provides a comprehensive approach to the analysis of factors that influence the use of European Union instruments for research and innovation by using business intelligence concepts and tools, and with the additional analysis of which, by including indicators from other categories of factors using the tool, a model can be created for successful funding from of such types of funds.

Keywords: business intelligence, science, research, innovation, Horizon 2020

Popis korištenih kratica

ABI	Analitika i poslovna inteligencija *(eng. Analytics and Business Intelligence)*
AI	Umjetna inteligencija *(eng. Artificial Intelligence)*
BA	Poslovna analitika (*eng. business analytics*)
BERD	Ulaganja poduzeća u istraživanje i razvoj *(eng. Business enterprise expenditure on R&D)*
BI	Poslovna inteligencija *(eng. business intelligence)*
BPM	Menadžment poslovnih procesa (*eng. Business process management*)
BSC	Tablica uravnoteženih rezultata *(eng. Balanced Scorecard)*
CIS	Ankete o inovacijama u zajednici *(eng. Community Innovation Survey)*
CNP	Cloud-Native platforme *(eng. Cloud-Native Platforms)*
DESI	Indeks digitalnog gospodarstva i društva *(eng. Digital Economy and Society Indeks)*
DQ	Digitalna inteligencija *(eng. Digital Intelligence)*
DSI	Indikator digitalnih vještina *(eng. Digital Skills Indicator)*
DSS	Sustav podrške odlučivanju *(eng. decision support system)*
EIS	Europska ljestvica uspjeha u inoviranju *(eng. European Innovation Scoreboard)*
EIT	Europski institut za inovacije i tehnologiju *(eng. European Institute of Innovation & Technology)*
EQ	Emocionalna inteligencija *(eng. Emotional Intelligence)*
ERA	Europski istraživački prostor (*eng. European research area*)
ERP	Planiranje resursa poduzeća *(eng. Enteprise Resource Planning)*
ESIF	Europski strukturni i investicijski fondovi (e*ng. European Structural and Investment Funds)*
ETL	Izdvajanje, transformiranje i učitavanje *(eng. extract, transform, load)*
EU	Europska unija *(eng. European Union)*
GDPR	Opća uredba o zaštiti podataka *(eng. General Data Protection Regulation)*
GERD	Bruto domaći rashodi za istraživanja i razvoj *(eng. Gross domestic expenditure on R&D)*
HRST	Ljudski resursi u znanosti i tehnologiji *(eng. Human resources in science and technology)*
IKT	Informacijsko-komunikacijska tehnologija
IQ	Kvocijent intelligence *(eng. Intelligence Quotient)*
IT	Informatička tehnologija *(eng. Information Technology)*
OECD	Organizacija za ekonomsku suradnju i razvoj *(eng. Organisation for Economic Co-operation and Development)*
OLAP	Online analitička obrada *(eng. online analytical processing)*
PEC	Računanje koje poboljšava privatnost *(eng. Privacy-Enhancing Computation)*
PM2.5	Čestične materije koje imaju prečnik manji od 2.5 mikrometara *(eng. particulate matter)*
R&D	Istraživanje i razvoj *(eng. Research and Development)*
STEM	Znanost, tehnologija, inženjerstvo, matematika *(eng. science, technology, engineering i mathematics)*
STI	Znanost, tehnologija i inovacije *(eng. Science, Technology, Innovation)*
TOE	Okvir tehnologija-organizacija-okoliš (*eng. technology–organization–environment framework*)
TX	Ukupno iskustvo *(eng. Total experience)*

Sadržaj

1. Uvod 1

1.1. Predmet i cilj rada 2
1.2. Izvori podataka i metode prikupljanja 2
1.3. Istraživačko pitanje i hipoteze rada 3
1.4. Struktura rada 3

2. Poslovna inteligencija 5

2.1. Definicija pojma poslovna inteligencija 5
2.1.1. Poslovna inteligencija i upravljanje znanjem 7
2.1.2. Model poslovne inteligencije 8
2.2. Povijesni razvoja poslovne inteligencije 10
2.3. Poslovna inteligencija u organizacijskom kontekstu 16
2.3.1. Metodologija 16
2.3.2. Rezultati 19
2.3.3. Diskusija rezultata 23
2.3.4. Zaključak poglavlja 24
2.4. Poslovna inteligencija u tehnološkom kontekstu 25
2.4.1. Trendovi među alatima poslovne inteligencije 25
2.4.2. Gartnerov Hype Cycle 29
2.4.3. Glavni strateški tehnološki trendovi za 2022. godinu prema Gartneru 31

3. Preduvjeti održivog gospodarstva Europske unije 35

3.1. Znanost i tehnologija 36
3.2. Istraživanje, razvoj i inovacije 39
3.3. Digitalna transformacija i digitalne vještine 42
3.4. Europska ljestvica uspjeha u inoviranju 45
3.4.1. Okvir za mjerenje inovacijskog indeksa 46

4. Instrumenti Europske unije za znanost, istraživanje i inovacije 51

4.1. Obzor Europa 52

5. Materijali i metodologija 56

5.1. Istraživački materijal 56
5.2. Metodologija 56
5.3. Metodologija provedbe istraživanja 57
5.4. Metode obrade podataka 59

6. Rezultati 60

6.1. Predmet i cilj istraživanja 60
6.2. Istraživačko pitanje i hipoteze 60
6.3. Opis rezultata istraživanja 61
6.3.1. Obzor 2020 61
6.3.2. Digitalne vještine 68
6.3.3. Digitalne vještine i Obzor 71
6.3.4. Ulaganja u istraživanje i razvoj 74
6.3.5. Ulaganja u istraživanje i razvoj i Obzor 79
6.3.6. Europska ljestvica uspjeha u inoviranju 82
6.3.7. Inovacijske aktivnosti i dimenzije i program Obzor 83

7. Diskusija 89

7.1. Elaboracija istraživačkog pitanja 89

7.2. Elaboracija hipoteza 92
7.3. Primjena rezultata i preporuke 97
8. Zaključak 99
Literatura 100
Popis slika 110
Popis vizuala 111
Popis tablica 113
Prilog 1 114

1. Uvod

Europska unija svojim se strategijama i planovima za 2030. godinu primarno usmjerila na održivost. Održivost se promatra u okviru okretanja digitalizaciji i zelenim ciljevima i prioritetima. Takve su strategije usmjerene na sve razine i sektore, ali i pojedince koje se nastoji uključiti u aktivno kreiranje inovativnih ideja i smjernica s ciljem rješavanja društvenih problema. Globalni ciljevi održivog razvoja Ujedinjenih naroda polaze od pretpostavke kako je u ovom vremenu globalizacije ključna suradnja među državama s ciljem rješavanja društvenih izazova i na taj su način ciljevi svrstani u kategorije najvećih izazova današnjice. Potiče se na mir i suradnju, upozorava na probleme u kojem se svijet zatekao, kao i nejednakosti koje iz toga proizlaze, stavlja se naglasak na važnost klimatskih promjena i očuvanje okoliša te se nastoji pronaći održiviji način funkcioniranja u promatranim uvjetima. Svaki takav cilj znači i sagledavanje prilika i potencijalnih prijetnji kao i snaga i slabosti unutar zemlje te pronalaženje načina kako snage i prilike pretvoriti u konkurentske prednosti i s njima raditi na eliminaciji slabosti i potencijalnih prijetnji. Sve to nije moguće bez znanosti i znanstvenih činjenica koje istražuju uzroke nekih pojava i problema i daju smjernice za njihovo rješavanje, suradnje s gospodarstvom u realizaciji istraživačkih saznanja i rezultata u obliku stvaranja inovacija koje bi služile kao odgovor na društvene izazove. Suradnja s gospodarstvom moguća je ukoliko postoji interes obje strane za takvu suradnju. S jedne strane, znanstvene zajednice koja je spremna istražiti određena društvena pitanja i probleme u znanstvenom kontekstu i s druge strane, poduzeća koja se bave istraživanjem i razvojem ili barem razumiju njegovu važnost kako bi svoj praktičnim saznanjima doprinijela stvaranju novih znanstvenih spoznaja. I Europska unija to je prepoznala kao prioritet i osnovne čimbenike održivog gospodarskog razvoja te upravo svojim instrumentima potiče i omogućava da se takve suradnje i ciljevi realiziraju. Jedan od najvažniji instrumenata Europske unije za istraživanje i inovacije u čijem se kontekstu povezuje i spominje znanstvena zajednica je upravo program Obzor koji se bazira na kompetitivnom projektom financiranju, a uspješnost pozitivne ocjene projekta ne ovisi samo o kvaliteti projektne ideje, već i o kvaliteti istraživačkog tima i njihovom znanstvenom kapacitetu, kao i o uspostavljanju suradnje kroz međunarodna partnerstva s ciljem što boljeg iskorištavanja prednosti svakog međunarodnog partnera kako bi se postigli relevantni i kvalitetni istraživački rezultati i omogućila njihova praktična primjena. Ulaganje u istraživanje i razvoj također je jedan od prioriteta u kontekstu promatranog, pri čemu je cilj Europske unije povećati izdvajanja za istraživanje i razvoj na 3% BDP-a. Kako se razvojem država i društva te povećanom dostupnosti informacija povećava količina sadržaja koji je dostupan, postalo je gotovo nemoguće utvrditi smjer i načine kako ostvariti postavljene ciljeve. Tome služi današnja tehnologija koja omogućava brže pronalaženje informacija i identifikaciju onih najrelevantnijih za promatranu

problematiku. Jedan od načina na koji je lakše grupirati informacije i utvrditi njihove odnose i stvoriti širu sliku je upravo poslovna inteligencija. Koncept i ideja poslovne inteligencije primjenjivi su na sve sektore i industrije, a glavni im je cilj korištenjem alata poslovne inteligencije prikupiti podatke i stvoriti ih u znanja potrebna organizaciji za daljnje planove i predviđanja.

1.1. Predmet i cilj rada

Predmet ovoga rada je povlačenje sredstava iz fondova Europske unije za znanost, istraživanje i inovacije. Radom se želi ukazati na ključne pokazatelje, odnosno čimbenike uspješnosti prijavitelja koji su realizirali projekte u okviru financijskih instrumenata za istraživanje i razvoj.

Cilj rada je identificirati utjecajne faktore promatrajući skup tzv. horizontalnih čimbenika gospodarskog razvoj unutar kategorije znanosti, tehnologije, istraživanja, razvoja i inovacija, uključujući pritom i dimenziju digitalizacije koja se, uz zelenu tranziciju, spominje kao jedna od okosnica i osnovnih faktora razvoja društva u cjelini.

1.2. Izvori podataka i metode prikupljanja

Za potrebe istraživačkog rada korištene su dvije vrste izvora:

- **Sekundarni izvori**, putem kojih su analizirani pojmovi i procesi unutar teme i predmeta istraživanja
- **Baze i *online* alati poslovne inteligencije**, a koji su sagledavani su okviru povlačenja sredstava za Obzor projekte, Digitalnih vještina, Ulaganja poduzeća u istraživanje i razvoj te inovacijskog uspjeha koji obuhvaća 12 dimenzija s različitim skupovima ranije spomenutih faktora svrstanih u određene kategorije.

Rad se sastoji od dva dijela: teorijskog, kroz koji su obrađeni osnovni pojmovi i saznanja vezani uz proučavanu temu, i empirijskog dijela u okviru kojeg je provedeno istraživanje.

Metode korištene u ovom radu su:

- **Metoda analize** kojom se raščlanjivanjem određenih tvrdnji pokušala stječi jasnija slika o proučavanim objektima
- **Metoda sinteze** kojom su pojedine jednostavne tvrdnje nastojale biti povezane u one složenije i općenitije kako bi se objekti koje se analiziraju i istražuju mogli detaljnije proučiti
- **Metoda indukcije i dedukcije** koje su primarno služile za izvođenje zaključaka u teorijskom i empirijskom dijelu istraživanja kratkom elaboracijom svakog poglavlja

- **Metoda generalizacije** s ciljem uopćavanja pojmova, od posebnih do općenitijih
- **Metoda deskripcije** koja je korištena prilikom opisivanja pojmova, okvira, grafičkih vizuala, primjera i relevantnih politika
- **Metoda komparacije** kojom se nastojalo usporediti slične činjenične procese.

1.3. Istraživačko pitanje i hipoteze rada

Istraživačko pitanje koje je postavljeno kada se pristupilo kreiranju okvira u kojima će se rad kretati je: Kako je moguće primjenom poslovne inteligencije utvrditi potencijal zemlje za povlačenje sredstava za znanost, istraživanje i inovacije iz fondova Europske unije? te su temeljem navedenog pitanja postavljene sljedeće hipoteze:

H1: Povlačenje sredstava iz programa Obzor ovisi o razini digitalnih vještina stanovništva zemlje

H2: Ulaganja poslovnog sektora u istraživanje i razvoj utječu na povlačenje sredstava iz programa Obzor

H3: Alatima poslovne inteligencije moguće je identificirati koje inovacijske dimenzije utječu na povlačenje sredstava iz programa Obzor.

1.4. Struktura rada

U prvom dijelu rada, koji se sastoji od 4 različita segmenta, analiziran je pojam poslovne inteligencije i promatran u kontekstu pojma upravljanje znanjem te u kontekstu modela poslovne inteligencije, opisan je i objašnjen povijesni razvoj poslovne inteligencije te je potom poslovna inteligencija prikazana iz dva aspekta – organizacijskog i tehnološkog, pri čemu je u okviru organizacijskog konteksta dan pregled novije literature iz relevantnih znanstvenih baza, dok je tehnološki koncept analiziran kroz osnovne modele, zaključke i preporuke tvrtke *Gartner Inc*. koja se bavi tehnološkim istraživanjem i savjetovanjem.

U drugom dijelu rada pojedinačno su analizirani preduvjeti održivog gospodarstva Europske unije s orijentacijom na skup horizontalnih pokazatelja održivog razvoja, a u koje ulaze znanost i tehnologija te istraživanje, razvoj i inovacije, a posljedično i digitalna transformacija i digitalne vještine koje su imperativ u svim segmentima održivog razvoja. Na kraju poglavlja prikazana je Europska ljestvica uspjeha u inoviranju koja mjeri inovacijski indeks pojedinih država uzimajući u obzir širok skup indikatora koji obuhvaćaju razne kategorije u okviru znanosti, tehnologije, istraživanja, razvoja, inovacija i digitalizacije.

U trećem dijelu rada dan je osvrt na osnovne instrumente Europske unije za znanost, istraživanje i inovacije te je detaljnije opisan i analiziran program Obzor Europa i njegov prethodnik Obzor 2020, kao glavni instrumenti Europske unije za znanost, istraživanje i inovacije.

Peti dio rada, koji je ujedno i uvod u empirijski dio, detaljno opisuje istraživački proces kroz prikaz istraživačkog materijala, metodologije, postupka provedbe istraživanja te metode obrade podataka.

U šestom dijelu rada definiraju se predmet i cilj istraživanja te istraživačka pitanja i hipoteze te se vizualiziraju istraživački rezultati.

Sedmi dio rada donosi diskusiju rezultata kroz elaboraciju istraživačkog pitanja i hipoteza i kritički osvrt, primjenu rezultata i preporuke daljnjih istraživanja.

Osmi, a ujedno i posljednji dio rada, donosi finalan zaključak teorijskog i empirijskog dijela.

2. Poslovna inteligencija

Prikupljanje i obrada podataka metode su kojima se dolazi do relevantnih informacija, donose odluke i usmjerava poslovanje različitih subjekata i organizacija. Znanje i pojam upravljanja znanjem s vremenom su evoluirali u poslovnu inteligenciju, ponajviše s razvojem informacijsko-komunikacijskih tehnologija. One su omogućile prikupljane većih količina podataka, a kasnije i obradu istih u željene svrhe. U današnje je vrijeme postalo gotovo nemoguće razvijati se i biti konkurentan ukoliko ne postoji organiziran sustav prikupljanja i obrade podataka za donošenje poslovnih odluka. Upravo je zbog navedenog poslovna inteligencija široko rasprostranjen koncept i obrađivan pojam čiji razvoj sustavno prati razvoj informacijsko-komunikacijskih tehnologija koje omogućavaju sve veću iskoristivost informacija i upravljanje istima.

2.1. Definicija pojma poslovna inteligencija

Pojam poslovne inteligencije (eng. *Business Intelligence, BI*) sveprisutan je i vrlo zastupljen koncept koji se može promatrati s različitih aspekata i samim time ne postoji njegova jedinstvena definicija.

Osnovno polazište od kojeg sve kreće je analiza pojma inteligencije i zašto se ista našla u pojmu poslovna inteligencija. Pojam inteligencije sagledan kroz *dictionary.com* podrazumijeva:

- Sposobnost saznavanja ili razumijevanja; spremnost shvaćanja
- Znanje preneseno ili stečeno učenjem, istraživanjem ili iskustvom
- Postupak ili stanje saznavanja; aktivnost razumijevanja.

Sukladno navedenom, jasno je vidljivo zašto neko poslovanje mora biti inteligentno i koje to preduvjete mora zadovoljiti da bi poslovanje odgovaralo ovom konceptu. Nekad je to bilo jednostavnije jer se baziralo na razgovoru nadređenog sa zaposlenicima kroz koji su se mogle saznavati sve važne stvari i činjenice i vrlo lako donositi odluke. No, pojavom Interneta, takav je način i koncept postalo nemoguće slijediti. Rast poduzeća i procesa, a samim time i količine informacija i činjenica, donio je vođama organizacija nove izazove u smislu obrade tih informacija i njihovog uspješnog upravljanja u svrhu donošenja strateških odluka i poboljšanja poslovnih procesa. Upravo zato, pred organizacije se postavio novi imperativ-postati inteligentne, a što je primarno značilo donositi kvalitetnije odluke i biti u tome brže od svoje konkurencije. U tu svrhu, a pomoću podataka preoblikovanih u informacije te izvođenjem tih informacija u inteligenciju, danas je moguće stvoriti kolektivnu organizacijsku inteligenciju koja omogućava uvide u određene poslovne procese i izvođenje zaključaka temeljem kojih se donose daljnje poslovne odluke. (Liautaud, Hammond, 2006:3)

Prema Panianu i Klepcu (2003:21), ovaj se izraz može promatrati s najmanje dva aspekta:

- **Makroaspekta**, prema kojem je poslovna inteligencija „*složena, agregirana kategorija koje se stvara (gradi) sustavnim, ali unaprijed (a priori) neciljanim prikupljanjem podataka o makroekonomskim kretanjima u određenoj geopolitičkoj sredini, njihovim organiziranim i strukturiranim bilježenjem (evidentiranjem) odnosno pohranjivanjem (arhiviranjem, memoriranjem), pretraživanjem, te logičkom i/ili računskom obradom radi otkrivanja makroekonomskih trendova ili tendencija, te predviđanja i prognoziranja procesa i događaja i makroekonomskim sustavim i njihovih budućih stanja.“ (Panian, Klepac, 2003:21)*
- **Mikroaspekta,** a u kojem se slučaju taj pojam odnosi na *„otkrivanje prikrivenih znanja iz poslovnih podataka koje neka organizacija prikuplja rutinski, obavljajući svoje svakodnevne poslovne transakcije.“ (Panian, Klepac, 2003:21)*

Prema Bilandžiću et al. (2012), *„Business intelligence podrazumijeva proces prikupljanja podataka i informacija iz unutarnje i vanjske poslovne okoline te njihovo pretvaranje u poslovna znanja na temelju kojih se donose poslovne odluke. To je strateški menadžerski resurs i presudan čimbenik za formuliranje kvalitetnih poslovnih strategija.“*

Kad se na poslovnu inteligenciju gleda s aspekta metodologija i alata koji se u tu svrhu koriste, koncept se određuje kao *„pojam koji objedinjuje skup metodologija (Data Warehousing, Data Mining, OLAP) i softverskih alata kojima se omogućuje korištenje podataka iz različitih skladišta podataka (Data Warehouse) i njihovo pretvaranje u informaciju potrebnu za donošenje poslovnih odluka.“* (mitSOFTWARE)

Prema Savić i Luić (2016:231) Business Intelligence je „*vrlo velik skup aplikacija i tehnologija koje se koriste za prikupljanje, pohranu, analizu i omogućavanje odgovarajućeg pristupa podacima kako bi se pomoglo korisnicima u donošenju boljih i bržih poslovnih odluka.“*

Danas pojam poslovne inteligencije igra vrlo važnu ulogu u procesu kreiranje informacija za proces operativnog i strateškog odlučivanja u poslovnim organizacijama. Iako se poslovne odluke donose na dnevnim razinama, kod potrebe sagledavanja više aspekata i usporedbe s konkurencijom, upotreba sustava poslovne inteligencije čini se kao logično rješenje. Pri tome je najvažnije voditi računa o unapređenju informacijskog procesa kako bi se omogućio jedinstven pristup potrebnim informacijama kao i njihova integracija u svrhu što boljeg razumijevanja cjelokupnog načina funkcioniranja organizacije i samim time sagledavanja njezinih snaga i slabosti. (Popovič, Turk, Jaklič, 2010)

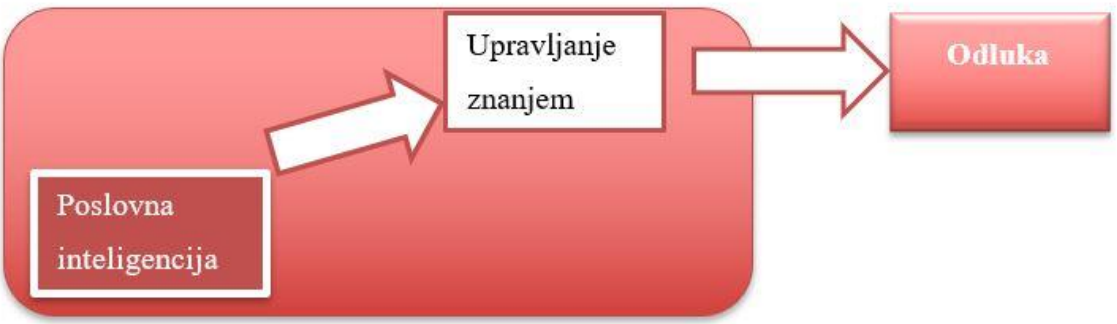
Danas se na poslovnu inteligenciju gleda kao na *„tehnološki vođen proces za analizu podataka i isporuku djelotvornih informacija koji pomažu rukovoditeljima, menadžerima i radnicima da*

donose informirane poslovne odluke". Pri tome važnu ulogu igraju interni i eksterni sustavi iz kojih organizacija prikuplja podatke te ih priprema za analizu i iz njih izvodi određene vizualizacije kako bi se takvim analitičkim rezultatima poslovnim korisnicima omogućilo lakše donošenje odluka u procesu operativnih radnji, ali i strateškog planiranja. Kako bi taj proces bio uspješan, nije dovoljno imati samo dobar BI softver, već je važno prikupiti dovoljnu količinu relevantnih podataka u sustavu, uključujući one povijesne ali i trenutne podatke u realnom vremenu koji zajedno doprinose strateškom i taktičkom procesu donošenja odluka. (Stedman, 2020)

2.1.1. Poslovna inteligencija i upravljanje znanjem

Uz pojam poslovne inteligencije najčešće se veže pojam upravljanja znanjem. Međuovisnost i međusobna isprepletenost ta dva pojma najviše se ogleda u činjenici da su se kroz faze razvoja poslovne inteligencije vodile polemike oko definicije i razlike ta dva pojma. Prema *Gartneru*, poslovna inteligencija definira se primarno kao set tehnologija koje prikupljaju i analiziraju podatke kako bi doprinijele procesu odlučivanja, dok je upravljanje znanjem definirano kao proces pronalaska, odabira, pročišćavanja i predstavljanja informacija na način da se poboljšava znanje i razumijevanje zaposlenika za neko specifično područje interesa. Iz navedenog je razvidno kako poslovna inteligencija proučava skrivene i relevantne kontekste u velikom skupu poslovnih i ekonomskih podataka, dok upravljanje znanjem omogućava organizacijama da uče i razumiju temeljem njihovih vlastitih iskustava. (Ravlić, 2015)

Kod procesa organizacijskog odlučivanja, poslovna inteligencija omogućava pronalazak vrijednih informacija i otkrivanje skrivenih obrazaca u unutarnjim i vanjskim izvorima podataka s glavnim ciljem poboljšavanja znanja o informacijama potrebnih za donošenje odluka kojima se postižu organizacijski ciljevi. Pri tome, većina organizacijskog znanja nalazi se u nestrukturiranom obliku ili kod samih zaposlenika. Tako upravljanje znanjem, obuhvaćajući i prešutno i eksplicitno znanje unutar organizacija, povećava provođenje odluka u djelo pružanjem kooperativnih alata za stvaranje, stjecanje i doprinos znanju unutar organizacije. Poslovna inteligencija i upravljanje znanjem služe organizaciji kao glavni alati za stvaranje okruženja u kojem korisnici dobivaju željene i pouzdane te pravovremene informacije ili znanja. Zaključak je kako organizacije trebaju koristiti oboje, poslovnu inteligenciju i upravljanje znanjem, kao integrirani sustav za dobivanje vrijednosti iz eksplicitnog i implicitnog znanja. (Muhammad et al., 2014, prema Khan i Quadri, 2012).

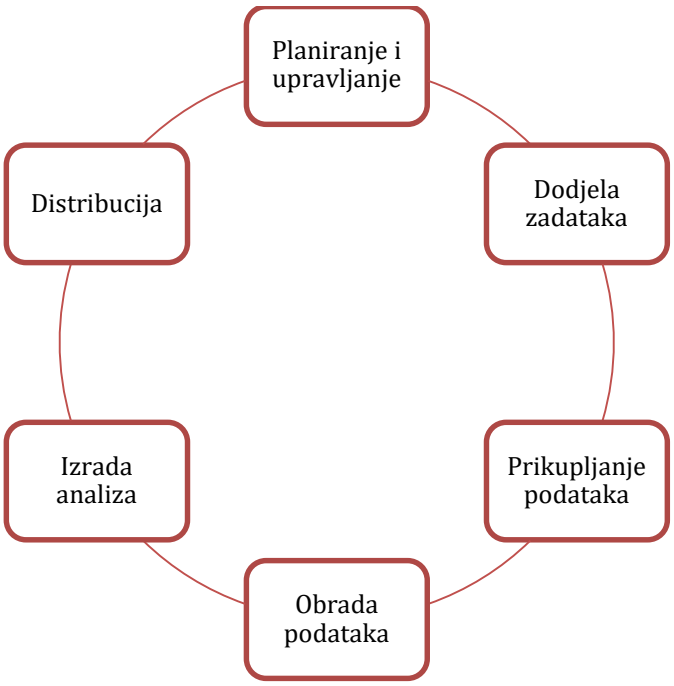


Slika 1. Prikaz odnosa poslovne inteligencije i upravljanja znanjem kod procesa donošenja odluka (Izvor: izrada autora prema Muhammad et al., 2014)

S obzirom na navedene definicije i razlike u pristupima i načinima određivanja pojma poslovne inteligencije različitih autora, uzorak koji je zajednički svima i način na koji bi se poslovna inteligencija prema definiciji mogla jedinstveno odrediti je kao proces prikupljanja i obrade podataka i informacija koji služi za donošenje odluka. Taj se proces mijenjao i nadopunjavao kako su potrebe rasle, a tehnologije sazrijevale, ali srž iza koje stoji ideja poslovne inteligencije ostala je jednaka i nepromijenjena. Usko vezan pojam uz poslovnu inteligenciju je i upravljanje znanjem čija međusobna sinergija i povezanost doprinose lakšem i jednostavnijem donošenju odluka.

2.1.2. Model poslovne inteligencije

Proces događaja u poslovnoj se inteligenciji ne ostvaruje sam od sebe, već isti zahtijeva pažljivu pripremu i plan, a potom i sustavno provedenu aktivnost. Kao rezultat, stvaraju se rana poslovno-obavještajna izvješća koji se u rukama menadžera pretvaraju u poslovno znanje i potpora su procesu donošenja odluka. Tu je posebno izražena interakcija i povezanost s konceptom upravljanja znanjem, gdje znanje podrazumijeva ostale čimbenike koje menadžeri uzimaju u obzir kada analiziraju poslovno-obavještajna izvješća kako bi stekli što dublji, potpuniji i točniji uvid u okolinu u kojoj donose odluke. Poslovna inteligencija čini kružnu aktivnost, s ciklusom koji ima nekoliko temeljnih faza. (Javorović, Bilandžić, 2007:206)



Slika 2. Prikaz modela poslovne inteligencije

(Izvor: izrada autora prema Nolan, 2000.)

Model poslovne inteligencije uključuje sljedeće faze (Javorović, Bilandžić, 2007:207):

a) **Planiranje i upravljanje ciklusom poslovne inteligencije (*eng. planning and direction*),** a koji se usmjerava na sustav i njegovu predodžbu u količini i vrsti podataka koje želi prikupiti. Nakon definiranja cilja i izražavanja interesa, unutar poslovnog subjekta najčešće se događa planiranje kako bi se taj interes i cilj ostvarili u smislu dodjele zadataka i uspostave mehanizma prikupljanja podataka.

b) **Prikupljanje podataka *(eng. collection),*** koja razlikuje dvije razine pristupa, a to su opći i konkretni. Kod općeg pristupa uz zaposlenike u sustavu poslovne inteligencije mogu sudjelovati svi zaposlenici organizacije, dok se kod konkretnog pristupa zahtijeva vrlo detaljna definicija potreba te u istom sudjeluju samo stručnjaci za poslovnu inteligenciju. Kod prikupljanja podataka, najvažnije je poznavati zone, odnosno kategorije prikupljanja podataka, a koje se određuju kao bijela zona kod koje se koriste zakonita i etična sredstva kod prikupljanja podataka, siva zona koja podrazumijeva neetična ali zakonita sredstva te crna zona gdje se koriste nezakonita i neetična sredstva. Svako prikupljanje podrazumijeva nabavu sirovog materijala i to najčešće iz otvorenih, javnih, odnosno svima dostupnih izvora.

c) **Analiza podataka *(eng. processing and analysis)*** faza je koja podrazumijeva raščlambu i vrednovanje prikupljenih podataka, a prethodi analizi podataka i

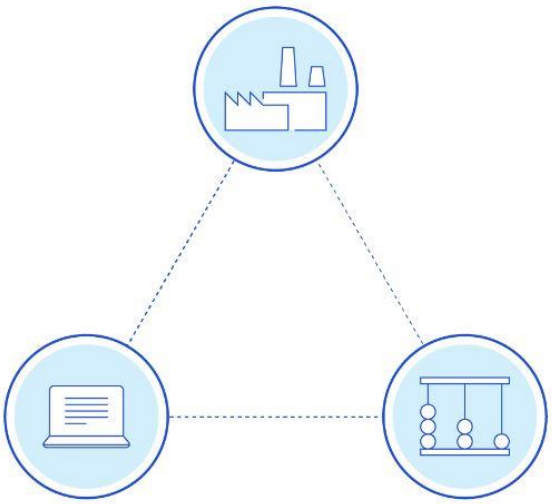
podrazumijeva uporabu različitih metoda kako bi se od prikupljenih podataka formirala slika.

d) **Distribucija analiza *(eng. dissemination),*** a koja kao posljednja faza uključuje predstavljanje obavještajnog proizvoda krajnjem korisniku. Analiza završava tek kad su svi utvrđeni nedostaci uklonjeni. Završetak ove faze ujedno može značiti i početak sljedećeg obavještajnog ciklusa ukoliko se temeljem dostavljenih rezultata odluče poduzeti određene akcije ili strategije.

Model poslovne inteligencije kao i pojedine faze modela usmjeravaju organizaciju koja koristi poslovnu inteligenciju da se lakše kreće među fazama i određuje prioritete i ciljeve svake faze kako bi bio ispunjen finalni cilj svakog takvog procesa, a to je dobivanje potrebnih informacija za donošenje odluka.

2.2. Povijesni razvoj poslovne inteligencije

Unatoč činjenici da se tek u posljednje vrijeme pojam poslovne inteligencije intenzivno izučava u znanstvenom i praktičnom kontekstu, njegova povijest i začeci vežu se uz godine tokom kojih se bilježi i postepen razvoj informacijsko-komunikacijske tehnologije (IKT). Naime, tek je IKT omogućio obradu većih količina podataka i njihovo postepeno stavljanje u kontekst poslovnog odlučivanja. U nastavku je dan povijesni prikaz razvoja pojma poslovne inteligencije, kao i ilustrativni pregled razvojnog konteksta predmetnog pojma, a sljedeći predloženi okvir razvoja poslovne inteligencija po određenim razdobljima i fazama Justina Heinza (2014).



Slika 3. Ilustrativni prikaz utjecaja razvoja IKT-a na razvoj BI-a
(Izvor: Limp, 2020)

a) Nastanak i razvoj do 1958. godine

Godine 1865. pojavila se prva inačica opisa i određenja pojma poslovne inteligencije, kreirana od strane Richarda Millara Devensa te primjerena tadašnjem shvaćanju. Naime, Devens je u svjetlu današnjeg tumačenja principa funkcioniranja poslovne inteligencije opisao strategiju bankara Henryja Furnesea za ostvarivanje profita. On je uspio steći prednost nad svojim konkurentima prikupljanjem, proučavanjem i djelovanjem na temelju nekih podataka koji su se odnosili na politička pitanja i na tržište koje ga okružuje. To mu je dalo rano razumijevanje ovih okolnosti prije njegovih ostalih konkurenata, a što mu je onda dalo prednost nad njima. (Ahmed, 2020)

Pojam poslovna inteligencija *(eng. Business Intelligence)* prvi je u svom članku upotrijebio Hans Peter Luhn, tadašnji IBM-ov istraživač, koji pojam poslovne inteligencije opisuje kao „*sposobnost razumijevanja međusobnih veza prikazanih činjenica na način da usmjeravaju djelovanje prema željenom cilju*“. (Cebotarean, 2011)

Procvat industrijskih, vladinih i znanstvenih sektora nakon Drugog svjetskog rata, zahtijevalo je odgovarajuću organizaciju, pojednostavljenje i prikladan način organiziranja tih sektora koji su obilovali tehnološkim i znanstvenim spoznajama i informacijama. S tim u vezi, Hans Peter Luhn u svom članku “Sustav poslovne inteligencije” opisuje poslovnu inteligenciju kao “*automatski sustav... razvijen za širenje informacija različitim dijelovima bilo koje industrijske, znanstvene ili vladine organizacije*”. Luhn je tom prilikom i prvi citirao definiciju same inteligencije kao "*sposobnosti razumijevanja međuodnosa prezentiranih činjenica na takav način da usmjerava akciju prema željenom cilju*." Te su definicije zadržane sve do danas i označavaju srž onog što BI i danas predstavlja, a to je primarno način koji omogućava brzo i jednostavno razumijevanje ogromnih količina informacija kako bi se mogle donositi najbolje odluke. Luhnov rad uveo je i prepoznao mogućnosti BI koncepta, a njegovo je istraživanje uspostavilo metode koje su izgrađene za stvaranje nekih od IBM-ovih analitičkih sustava, zato je i zaslužio titulu „oca poslovne inteligencija“. (Heinze, 2014)

Sukladno navedenom, kod pokušaja određivanja evolucije i razvoja pojma poslovne inteligencije, može se reći da njeni počeci sežu već u 1960-e godine kada se, s pojavom računala treće tehnološke generacije počelo prikupljati velike količine podataka za koje je brzo postalo jasno da predstavljaju temelj za donošenje poslovnih odluka ukoliko se iste pretvore u korisne informacije. (Panian, Klepac, 2003:53)

b) Napredak i evolucija do kasnih 1980-ih

U 1970-im godinama, tvrtke IBM i Siebel počeli su eksperimentirati s prvim inačicama BI koncepta i raditi prve korake prema modernom BI-u kakav je zastupljen u današnje vrijeme. U to

se vrijeme poslovna inteligencija naglašavala kao nezaobilazni dio poslovanja, dok je do tad ona samo činila jednu od prednosti. (Ahmed, 2020)

Alternativa pohranama na papiru pojavila se zajedno s pojavom računala u poslovnom svijetu. Važan događaj u tom kontekstu bio je IBM-ov izum tvrdog diska 1956., koji je uveo svojevrsnu revoluciju kad se govori o pohrani podataka, a svi ti alati kao što su diskete, laserski diskovi i druge tehnologije za pohranu značili su mogućnost pohrane većih količina podataka koji su se neprestano stvarali i čija je količina brzo rasla. To je dovelo i do stvaranja prvih sustava za upravljanje bazama podataka, koji se zajednički nazivaju sustavi za podršku odlučivanju (DSS), a do 1970-ih zabilježena je i nekolicina BI dobavljača koji su osmislili alate za pristup i organiziranje pohranjenih podataka, no to je bilo u samim začecima i samim time nije odisalo praktičnošću i jednostavnošću, kao ni lakoćom korištenja. Kao odgovor na novonastale probleme, organizirana je međunarodna konferencija 1988. godine, čiji je cilj bio pojednostaviti procese obrade podataka te je konzorcij *Multiway Data Analysis*, održan u Rimu, označio i obilježio novo razdoblje, ono koje se bavilo pojednostavljenjem BI analiza. (Heinze, 2014)

c) Prekretnice 1980-ih i 1990-ih godina

Svako doba novih razvoja informacijsko-komunikacijskih tehnologija slijedio je i razvoj poslovne inteligencije čiji se službeni začeci smatraju 1990-te godine razvojem ideje o sustavima za podršku odlučivanju. (Panian, Klepac, 2003:53)

Konačno, definiciju i sam naziv pojmu poslovne inteligencije najbližu današnjem konceptu i razumijevanju iste dao je 1989. godine Howard Dresner, glavni analitičar američke konzultantske kuće *GartnerGroup Inc*, koji je predložio da se pojam *Business Intelligence* koristi za „*koncepte i metode za poboljšanje poslovnog odlučivanja korištenjem sustava podrške utemeljenih na činjenicama.“* (Cebotarean, 2011)

Howard Dresner pojam je poslovne inteligencije upotrebljavao kao zajednički pojam kojim je pokrivao sustave za pohranu analizu podataka, poput DSS-a i izvršnog informacijskog sustava. Konkurencija više dobavljača na terenu dovela je do napretka prema skladištima podataka. Taj je alat poboljšao protok podataka s operativnih sustava na podršku odlučivanju. Skladištenje podataka drastično je skratilo vrijeme potrebno za pristup podacima, a podaci koji su tradicionalno bili pohranjeni na više mjesta bili su na jednom mjestu. Također, a zajedno s ovim razvojem, pojavili su se i razvili i dodatni aspekti skladištenja podataka koji su danas glavni dio BI-ja, uključujući alate za izdvajanje, transformiranje i učitavanje (ETL) i softver za online analitičku obradu (OLAP). U kasnijim godinama, ova faza razvoja postala je poznata kao poslovna inteligencija 1.0. (Heinze, 2014)

d) Poslovna inteligencija 1.0

Poslovna inteligencija postala je široko prepoznata fraza kasnih 1990-ih i početkom 2000-ih godina, a na tržište su izašli deseci novih dobavljača. Tijekom tog razdoblja BI je imao dvije osnovne funkcije: proizvodnja podataka i izvješća te njihovo organiziranje i vizualizacija. No složenost i vrijeme bili su problematični faktori razvoja BI-a i kočili su napredak istog. Najveći problem bio je što se BI orijentirao na IT odjele i samo su ti odjeli mogli njime upravljati, nije bio dostupan i iskoristiv ostalim korisnicima. Za razumijevanje načina funkcioniranja alata bila je potrebna opsežna obuka za analitiku jer je on bio razvijen samo s IT stručnjacima. Također, budući da su podaci bili odvojeni, bilo je potrebno i više vremena za formuliranje i dostavu izvješća donositeljima odluka. Samo tehnički stručnjaci mogli su koristiti napredni softver za analizu podataka i to je polako detektiralo novi problem i prekretnicu u razvoju BI-a, a to je razvoj alata prilagođenog svim korisnicima. (Heinze, 2014)

Faza naziva poslovna inteligencija 1.0 bilo je razdoblje kada su ERP sustavi postali popularni, i to kao ogromne softverske platforme za upravljanje koje integriraju aplikacije za upravljanje i automatizaciju aspekata poslovanja. Oni su osigurali strukturiranje podataka za skladišta podataka i u narednim godinama postaju ključni za sve velike svjetske kompanije. Također, kao kraj ovog razdoblja i prelazak u novo, godine 1995. Microsoft je izdao Windows 95, prvi operativni sustav prilagođen korisniku i računala su time postala široko dostupna za uporabu u kućanstvu, što je obilježilo i ostavilo utjecaj na način na koji su ljudi proizvodili i konzumirali podatke u sljedećim desetljećima, pa sve do danas. (Limp, 2020)

Smatra se, prema *Gartneru* kako je, od sveukupno 13 karakteristika koje se smatraju ključnima za BI sustave, u fazi poslovna inteligencija 1.0 bilo razvijeno njih devet, i to redom: izvješćivanje, nadzorne ploče, *ad hoc* upit, BI pretraživanje baze, OLAP, interaktivne vizualizacije, tablice rezultata, prediktivno modeliranje, rudarenje podataka. (Chen, Chiang, Storey, 2012)

e) Poslovna inteligencija 2.0

Početak 21. stoljeća i razvoj tehnologije označio je i novu prekretnicu u razvoju BI-a razvojem tehnologija za rješavanje problema složenosti i brzine. Pojavili su se i računalni softveri u oblaku koji su proširili i pojednostavili doseg BI platformi. Faza poslovna inteligencija 2.0 uključivala je niz različitih tehnologija kao što je obrada u stvarnom vremenu, koja je prikupljala informacije iz skladišta podataka omogućavajući tako donošenje odluka temeljem najnovijih i najsvježijih informacija. Pojavile su se i tehnologije koje su služile kao samoposlužni pristup za korisnike koji nisu bili iz IT odjela, a to je omogućilo sudjelovanje većeg broja zaposlenika u korištenju BI alata. Rast Interneta i pojava alata za društveno umrežavanje kao što su *Facebook*, *Twitter* i blogovi omogućili su korisnicima da brže dijele ideje i razmišljanja, pregledaju metode i softver, te šire

razumijevanje različitih upotreba poslovne inteligencije. Do 2005. godine sve veća međupovezanost poslovnog svijeta značila je sve veću potrebu prikupljana podataka u stvarnom vremenu kako bi tvrtke mogle razumjeti konkurenciju i potrošače i slijediti njihova razmišljanja te raditi na poboljšanjima. To je ujedno i vrijeme u kojem je BI postao imperativ za tvrtke koje žele ostati konkurentne na tržištu. (Heinze, 2014)

U razdoblju poslovne inteligencije 2.0 uveden je i *Google Analytics*, koji korisnicima pruža besplatan način analize podataka svojih web stranica. Roger Magoulas, iz O'Reilly Media, prvi je put upotrijebio izraz *big data* za "*veliki skup podataka kojima je gotovo nemoguće upravljati i obraditi pomoću tradicionalnih alata poslovne inteligencije*". Porastom količine podataka, rasla je i potreba za njihovom sve većom pohranom. S obzirom da tadašnji sustavi nisu zadovoljavali tu potrebu, tvrtke su u pronalaženju alternativnih rješenja doskočile tome na način korištenja nekoliko strojeva odjednom, što je ustvari i svojevrsni početak ere računalnog oblaka. (Limp, 2020)

Vjeruje se kako je pojava društvenih mreža označila jednu sasvim novu eru u načinu poslovanja, a posebice marketingu koji više ne slijedi tradicionalne jednosmjerne obrasce oglašavanja, tzv. B2C, već omogućava tvrtkama komunikaciju s njihovim korisnicima i kreiranje analiza i usmjeravanje poslovanja sukladno njihovim željama i potrebama. (Chen, Chiang, Storey, 2012)

f) Osnaživanje krajnjih korisnika

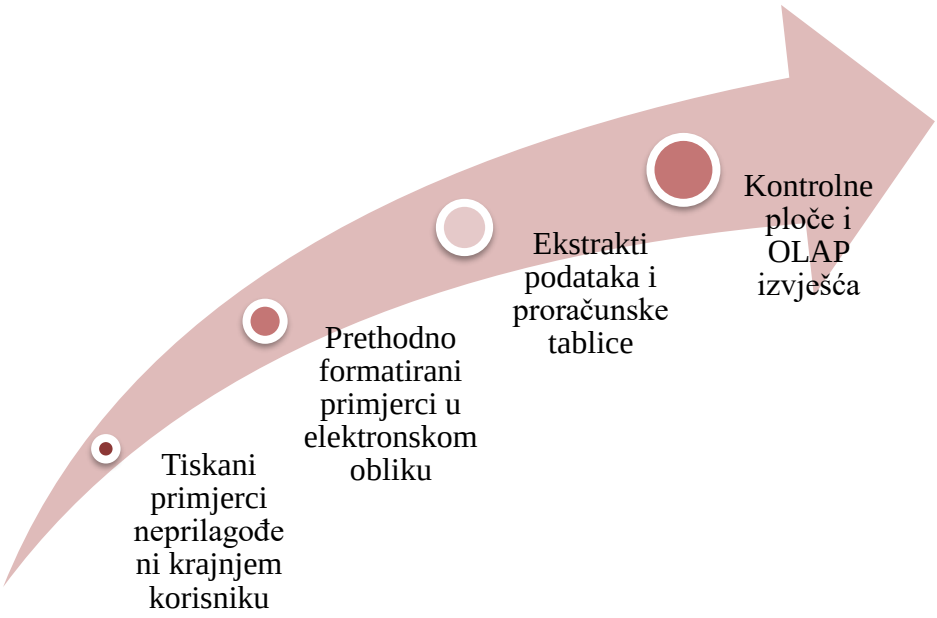
Agilnost i brzina BI platforme iz sredine 2000-ih prošla je intenzivan proces usavršavanja. Tri najvažnije značajke koje je ovo razdoblje donijelo razvoju BI alata su: specifikacija alata, proširenje mogućnosti samoposluživanja i poboljšanje vizualizacije. Pojavljuje se i termin "vertikalizacija *sotvera*" koji je pristupao prilagodbi BI alata industriji u kojoj se koristi a to je značajno utjecalo na porast korištenja BI alata. Revolucija velikih podataka i Interneta omogućila je pristup do tada najvećim i najopsežnijim količinama podataka jer je svaka osoba koja koristi Internet počela stvarati sve veće količine informacija, pa su tvrtke zahtijevale još više alata za vizualizaciju i interpretaciju dobivenih podataka. Alati za vizualizaciju počeli su se razvijati kako bi još više uključili krajnjeg korisnika, a jednostavnost korištenja najviše se ogledala u činjenici da je sada velika većina korisnika mogla koristiti podatke bez prethodne obuke. (Heinze, 2014)

Rastuća snaga modernih analitičkih alata najviše se vidjela kroz razne slučajeve koji su samo potvrđivali snagu i moć koju je Internet imao nad svojim korisnicima i kako je njihova privatnost postala ograničena s informacijama koje dijele na Internetu. Prednost Interneta sve se više počela upotrebljavati u marketinške svrhe, političkim kampanjama, ali i u znanosti. (Limp, 2020)

g) *Cloud* BI i *Mobile* BI

S pojavom velike količine BI alata i rastućim poboljšanjem značajki i mogućnosti Interneta, započela je borba među dobavljačima na način da su eksperimentirali s bržim i jeftinijim alatima, odnosno mogućnošću postizanja najidealnijeg omjera cijene i kvalitete. Jedan od načina da se postigne oboje postalo je korištenje BI-a u oblaku, smanjujući tako troškove pohrane i čineći pristup organizacijskim podacima i uvidima bržim i praktičnijim. Bilježi se i značajan uspjeh i porast korištenja mobilnih platformi, što korisnicima omogućuje rad s BI tehnologijama u pokretu na njihovim pametnim telefonima, tabletima i drugim uređajima. Konstantnim usavršavanjem i poboljšavanjem alata, oni postaju jednostavniji i praktičniji, potičući širu prilagodbu i jednostavniju upotrebu pa je samim time njihova rasprostranjenost sve veća. (Heinze, 2014)

Danas smo došli do trenutka u kojem *Facebook* može prepoznati naše lice na slikama, *Google* može predvidjeti koja vrsta reklame bi najbolje odgovarala našem profilu, a *Netflix* može dati prijedloge koje emisije gledati temeljem analize naših širih preferencija i profila. Živimo u vremenu kada nam mobilni telefoni omogućavaju da razgovaramo s njima, a upravo je sposobnost rukovanja i obrade golemih količina podataka bio glavni korak u razumijevanju nastanka takvog načina funkcioniranja svijeta. Živimo u informacijskom dobu, a poslovna inteligencija ključna je značajka našeg vremena, koja nam pomaže da sve to shvatimo i obradimo. Poslovna analitika postaje dio kolegija i programa na sveučilištima i izučava se kako bi za istu bili spremni. Povijest poslovne inteligencije nije toliko dugačka, no njen je tijek intenzivan i puno je još mogućnosti za razviti i stvari za otkriti, a upravo BI tome doprinosi na najbolji i najkonkretniji mogući način. (Limp, 2020)



Slika 4. Evolucija poslovne inteligencije

(Izvor: izrada autora prema Landeros, Margain Fuentes, 2017)

Razvoj poslovne inteligencije obilježilo je nekoliko ključnih trenutaka, a posebice je tome doprinio razvoj Interneta i novih tehnologija koji su taj tijek ubrzali, odnosno omogućili da se procesi i ideje koji stoje iza pojma poslovne inteligencije odvijaju nesmetano, brzo i jednostavno. Evolucija poslovne inteligencije jasno je pokazala da je tehnologija uspješno slijedila zahtjeve koji su joj se nametali količinom podataka i informacija koja se rapidno povećavala i bilo ju je potrebno bolje i brže organizirati. Širokom rasprostranjenošću tehnologije i jednostavnijom mogućnošću korištenja došlo je i do pronalaženja rješenja da alati koje organizacije koriste budu dobar omjer kvalitete i uloženih financijskih resursa, a porast digitalizacije i razvoj digitalnih vještina daju mogućnost i priliku da kreiranje poslovne inteligencije organizacije uključuje sve više dionika s različitim znanjima i iskustvima. Svakako se okrećemo vremenu u kojem se već događa evolucija i razvoj pojma umjetne inteligencije, a mogućnosti koje nude razni alati svakim su danom sve veće te se iz navedenog može zaključiti kako se u narednom razdoblju može očekivati još veći porast razvoja poslovne inteligencije i mogućnosti koje ista pruža.

2.3. Poslovna inteligencija u organizacijskom kontekstu

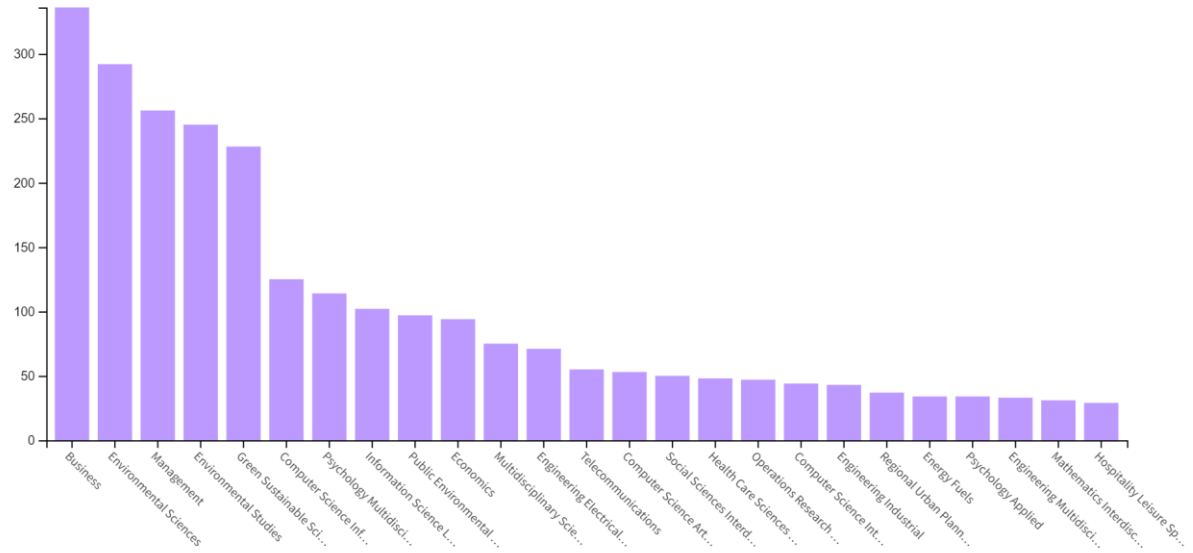
U svrhu što detaljnijeg uvida u znanstvenu perspektivu i istraživačka pitanja vezana uz pojam poslovne inteligencije i njezinu ulogu u organizacijskom kontekstu, u nastavku je prikazan pregled literature na navedenu temu koristeći relevantne znanstvene baze i metodologiju prilagođenu svemu spomenutom. Fokus istraživanja kod izrade pregleda literature bio je odrediti ulogu, kontekst i značaj alata i koncepta poslovne inteligencije za organizaciju unutar koje se ista primjenjuje.

2.3.1. Metodologija

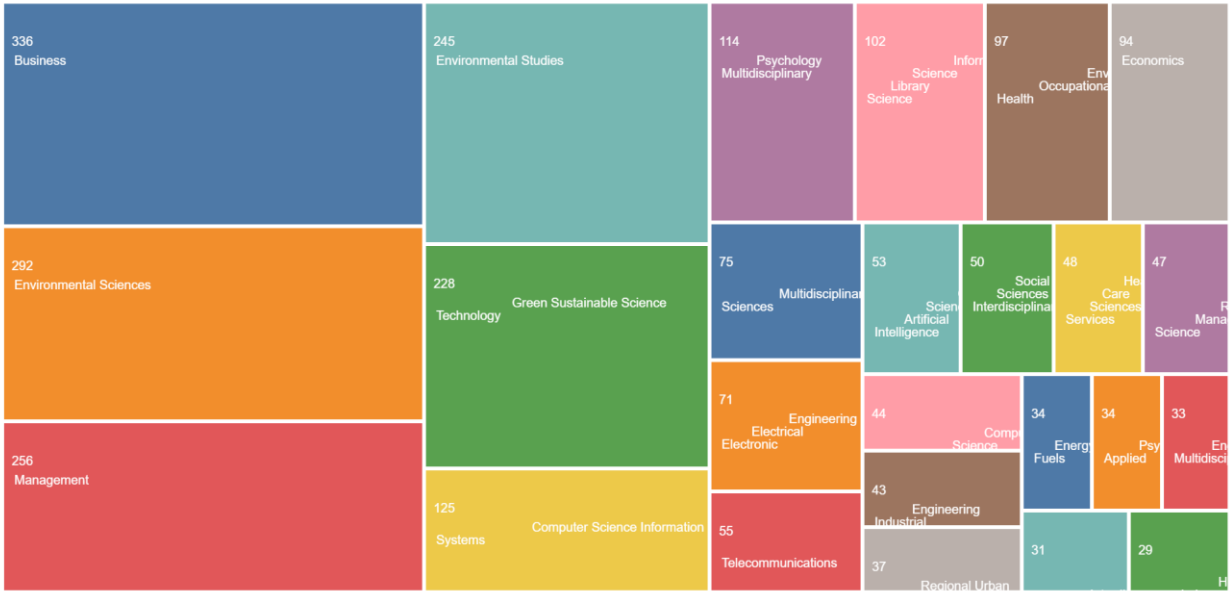
Istraživačka analiza provedena je tijekom lipnja 2022. godine i to putem dvije najveće citatne baze podataka *Web of Science* i *Scopus* kojima je pristupljeno putem stranice *baze.nsk.hr*. Istraživanje je ograničeno na pretraživanje pojma poslovne inteligencije od početka pandemije (2020. godina) do danas (2022. godina), a s obzirom na činjenicu da to razdoblje bilježi značajan razvoj informacijsko-komunikacijskih tehnologija koji je morao slijediti i veći razvoj digitalnih vještina kao i prilagodba na nove uvjete rada „od kuće“. U to su vrijeme i poslovni procesi doživljavali najveće transformacije i bili u fazi najintenzivnijih promjena. Pojam korišten kod pretraživanja bio je: *business intelligence*. Kriteriji koji su dodatno postavljeni i prema kojima je istraživanje dodatno suženo bili su sljedeći:

- U pretragu su uključeni isključivo radovi na engleskom jeziku
- Svi radovi morali su biti u kategoriji otvorenog pristupa
- S obzirom na znanstveno područje studija i kolegija, promatrani su radovi iz kategorije *Social Sciences Citation Indeks (SSCI)*, citatne baze za područje društvenih znanosti u bazi Web of Science, odnosno radovi iz područja društvenih znanosti u bazi Scopus

Nakon zadanih kriterija, u bazi Web of Science pronađeno je ukupno 1.707 radova razvrstanih prema određenim kategorijama, od kojih je najviše radova pronađeno u kategoriji *Business*.

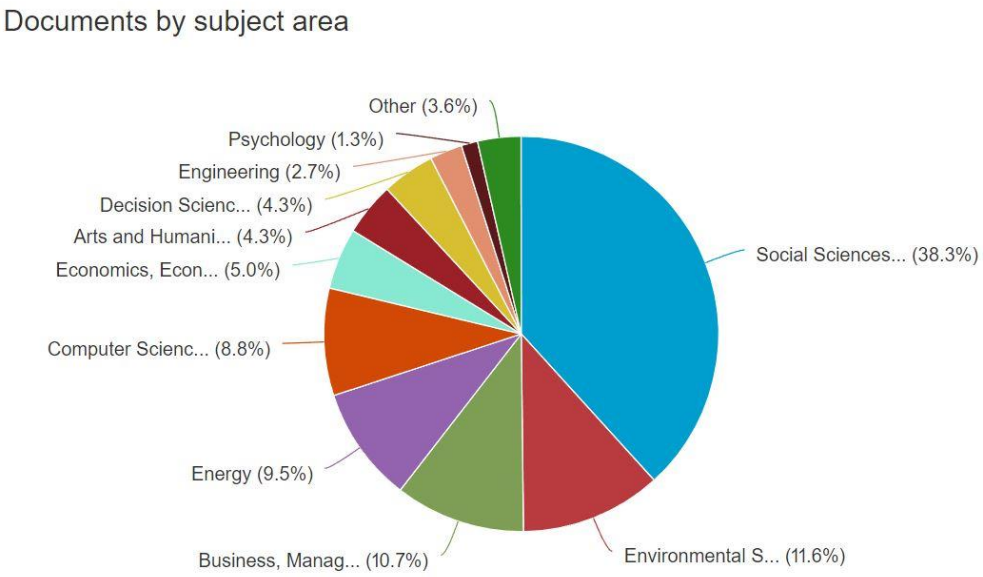


Slika 5. Prikaz količine radova po pojedinim kategorijama unutar pretraživanih kriterija (Izvor: izrada autora putem baze Web of Science)



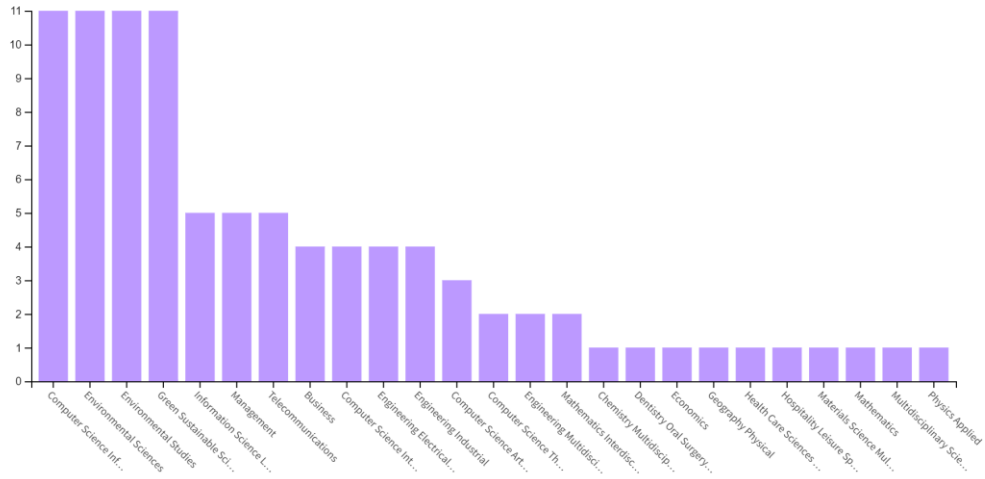
Slika 6. Prikaz radova prema najčešće pojavljivanim kategorijama (Izvor: izrada autora putem baze Web of Science)

U bazi *Scopus* prema zadanim je parametrima pronađeno ukupno 344 rezultata, što čini 38,3% od ukupnog broja radova pronađenih u okviru spomenutih parametara i ujedno kategoriju koja sadržava najveći broj radova na temu poslovne inteligencije.



Slika 7. Prikaz radova prema najčešće pojavljivanim kategorijama
(Izvor: izrada autora putem baze Scopus)

Nakon uvida u naslove i sažetke svih radova u bazi Web of Science, u daljnju su analizu uključeni samo radovi koji su u naslovu ili sažetku sadržavali riječ *business intelligence*. Takvih je radova bilo sveukupno 41, i to 16 radova iz 2020. godine, 19 radova iz 2021. godine i 6 radova iz 2022. godine. Jedan od radova iz 2021. godine naknadno je izbačen iz istraživanja zbog jezika te ih je u 2021. godini ostalo 18, a sveukupno 40 radova razvrstanih po različitim kategorijama unutar pretraživanog pojma.



Slika 8. Prikaz radova nakon revizije kroz najzastupljenije kategorije
(Izvor: izrada autora putem baze Web of Science)

Nakon uvida u naslove i sažetke svih radova u bazi Scopus, u daljnju su analizu uključeni samo radovi koji su u naslovu sadržavali riječ *business intelligence* ili bili na neki način povezani s navedenim pojmom. Takvih je radova bilo sveukupno 27, i to 6 radova iz 2020. godine, 11 radova iz 2021. godine i 10 radova iz 2022. godine. Jedan od radova iz 2021. godine i jedan rad iz 2022. godine naknadno su isključeni iz daljnjeg istraživanja zbog ograničenog pristupa te ih je u 2021. godini ostalo 10, u 2022. godini 9 a sveukupno 25 radova razvrstanih po različitim kategorijama.

	Documents	Citations	<2020	2020	2021	2022	Subtotal	>2022	Total
		Total	0	2	36	32	70	0	70
1	Business intelligence: business evolution after industry 4.0	2021			7	5	12		12
2	Elucidating the determinants of business intelligence adopti...	2020		2	6	2	10		10
3	A business intelligence & analytics framework for clean ...	2021			4	5	9		9
4	IoT data visualization for business intelligence in corporat...	2022				7	7		7
5	A business intelligence framework for analyzing educational ...	2020			6	1	7		7

Slika 9. Prikaz 5 najcitiranijih radova pod pojmom business intelligence
(Izvor: izrada autora putem baze Scopus)

2.3.2. Rezultati

Sljedeća faza uključivala je pregled svih preostalih radova. Nakon izvršene analize ukupno 65 radova, i to 40 radova iz znanstvene baze Web of Science i 25 radova iz znanstvene baze Scopus, 48 ih je izbačeno jer su bili vezani uz specifičnu djelatnost ili industriju ili usko vezani uz tehnologiju ili određeni proučavani postupak, 1 rad je izbačen jer nije bio dostupan u punom obliku, te je detektirano sveukupno 6 radova koji su uključeni u analizu, a nalaze se u obje baze. Konačna analiza napravljena je na sveukupno 10 radova koji su vezani uz temu pojma poslovne inteligencije u organizacijskom kontekstu. Navedeni radovi uključeni su u daljnju obradu na način da su analizirani prema sljedećim kriterijima:

1) Autori
2) Godina
3) Zemlja
4) Ciljana skupina
5) Metoda istraživanja
6) Instrumenti istraživanja

Tablica 1. Sažeti prikaz istraživanja sukladno analiziranim kriterijima

(Izvor: izrada autora)

Autori	**Godina**	**Zemlja**	**Ciljana skupina**	**Metoda istraživanja**	**Instrumenti istraživanja**
Bhatiasevi, V.; Naglis, M.	2020	Tajland	Mala i srednja poduzeća u Bangkoku, BI eksperti iz različitih sektora	Kvantitativna i kvalitativna	Upitnik, intervju
Suša Vugec, D.; Bosilj Vukšić, V.; Pejić Bach, M.; Jaklić, J.; Indihar Štemberger M.	2020	Hrvatska i Slovenija	Top menadžment i/ili zaposlenici zaduženi za BI i BPM u hrvatskim i slovenskim organizacijama s više od 50 zaposlenika	Kvantitativna	Upitnik
Chen,X.; Siau, K.	2020	SAD	Vođe kompanija u SAD-u koji koriste BI u svom poslovanju	Kvantitativna	Upitnik
Skyrius, R.; Valentukevičė, J.	2020	-	-	*desk*-metoda	Pregled literature/dostupnih istraživanja
Hortovanyi, L.; Szabo, R. Z.; Fuzes, P.	2021	Madžarska	Fortune 500 kompanija	Kvalitativna	Studija slučaja, polustrukturirani intervju
Tavera Romero, C.A.; Ortiz, J.H.; Khalaf, O.I.; Ríos Prado, A.	2021	-	-	*desk*-metoda	Pregled literature
Huang, Z.; Savita, K.S.; Zhong-jie, J.	2021		Direktori i eksperti *startup* kompanija	Kvantitativna	Upitnik
Paradza, D.; Daramola, O	2021	-	-	*desk*-metoda	Pregled literature
Darwiesh, A.; Alghamdi, M. I; El-Baz, A. H.; Elhoseny, M.	2022	-	-	*desk*-metoda	Pregled literature
Nazari, F.; Taghavi, S.S.; Valizadeh, E.	2022	Iran	Relevantni stručnjaci i menadžeri u 150 *startup* kompanija	Kvantitativna	Upitnik

Provedeno istraživanje generiralo je članke koji se mogu podijeliti u 2 glavne grupe:

a) Istraživanja fokusirana na organizacijske preduvjete i važnosti za uspješnu implementaciju BI-a u poslovanje
b) Istraživanja usmjerena na vrijednosti implementacije BI-a u poslovanje

U nastavku je dan sažet prikaz svake ranije opisane grupe.

1. Istraživanja fokusirana na organizacijske preduvjete i važnosti za uspješnu implementaciju BI-a u poslovanje organizacije

U dijelu istraživanja fokusiranih na organizacijske preduvjete uspješne implementacija BI-a u poslovanje organizacije identificirana su ukupno 4 znanstvena rada iz 2020. i 2021. godine. Sve studije u ovom dijelu kreirane su s ciljem razumijevanja osnovnih aspekata prilagodbe organizacije na uvođenje BI-a u poslovanje, od čega su dvije provedene putem anketnog upitnika na uzorku kompanija iz Tajlanda i SAD-a, jedna je provedena kao studija slučaja na primjeru Fortune 500 popisa najuspješnijih kompanija SAD-a, dok je jedno istraživanje provedeno putem pregleda dostupnih izvora literature o navedenoj temi. Autori prvog rada u navedenoj kategoriji (Bhatiasevi, Naglis, 2020) proveli su kvantitativno i kvalitativno istraživanje koristeći znanstvene metode upitnika i intervjua, a kao uvod prikazan je pregled literature na temu rada. Studija je predložila sveobuhvatan model koji integrira okvir TOE s okvirom BSC-a kako bi se identificirali čimbenici i stupanj utjecaja na usvajanje BI-a kod malih i srednjih poduzeća na Tajlandu, kao i čimbenici i stupanj utjecaja na organizacijski učinak. Testiranjem hipoteza i faktora koji imaju utjecaj na uvođenje BI-a u poslovanje, utvrđeno je kako je faktor s najvišim stupnjem utjecaja pri usvajanju BI-a od strane tajlandskih malih i srednjih poduzeća bila upravo podrška najvišeg menadžmenta. Druga studija (Chen,Siau, 2020) provedena je metodom upitnika koji je poslan vođama kompanija u SAD-u koji već koriste BI u svom poslovanju. Provedeno je istraživanje s ciljem procjene utjecaja poslovne analitike (BA) i poslovne inteligencije (BI), fleksibilnost IT infrastrukture i njihove interakcije na organizacijsku agilnost. Autori navode kako je navedena studija jedna od rijetkih empirijskih studija koje istražuju važnost BA iz perspektiva upotrebe iste, a sve s ciljem utvrđenja da IT i IS komponente mogu biti ključni izvori organizacijske agilnosti. Utvrđuje se, između ostalog, važnost izgradnje fleksibilne IT infrastrukture kako bi se poboljšala organizacijska agilnost. Treća studija (Skyrius, Valentukevičė, 2020) koristi pregled literature dok je istovremeno orijentirana na agilnost BI-a, informiranja i organizacije polazeći od pretpostavke kako u osiguravanju organizacijske agilnosti, aktivnosti informiranja igraju ključnu ulogu u orijentiranju okoline prema važnim promjenama. Zaključak istraživanja pregledom dostupnih izvora navodi kako bi upravo BI trebao igrati važnu ulogu u osiguravanju organizacijske agilnosti te kako je

tehnološki aspekt uvođenja BI tehnologija u poslovanje mnogo zastupljeniji i češće istraživani u odnosu na ljudski i menadžerski faktor, odnosno kulturološki aspekt u ulozi sredstva informiranja u izgradnji kompetencija agilnosti neke organizacije. Posljednje istraživanje u navedenoj kategoriji (Hortovanyi, Szabo, Fuzes, 2021) predstavlja rezultate longitudinalne studije o putu velike korporacije ka tome da postane ambideksterna organizacija suočenu s novim tehnologijama. Istraživanje je provedeno kroz princip studije slučaja na primjeru američke kompanije Fortune 500 koristeći i metodu polustrukturiranog intervjua s ciljem razumijevanja prilagodbe poslovnih procesa velikih kompanija tržišnim zahtjevima i promjenama. Istražujući međudjelovanje između vrha i srednjeg menadžmenta, rezultati pokazuju da su sustavi poslovne inteligencije omogućili tvrtki da nastavi sa strateškom obnovom vođenom podacima, automatiziranom i pružajući podršku brzom organizacijskom učenju.

2. Istraživanja usmjerena na vrijednosti implementacije BI-a u poslovanje organizacije

U dijelu istraživanja usmjerenih na vrijednosti implementacije BI-a u poslovanje organizacije identificirano je ukupno 6 znanstvenih radova iz 2020., 2021. i 2022. godine. Sve studije u ovom dijelu provedene su s ciljem istraživanja i propitkivanja vrijednosti i pozitivnih strana uvođenja BI-a u poslovanje organizacije, od čega su tri provedene putem anketnog upitnika na uzorku kompanija iz Hrvatske i Slovenije, odnosno direktora, eksperata i relevantnih stručnjaka *startup* kompanija, dok su preostala tri istraživanja provedena putem pregleda dostupnih izvora literature o navedenoj temi. Autori prvog analiziranog rada (Suša Vugec et al. 2020) proveli su istraživanje putem upitnika na organizacijama na području Hrvatske i Slovenije s više od 50 zaposlenika kako bi utvrdili usklađenost BI-a s *Business Process Management*-om, a uzimajući u obzir da je cilj obje inicijative poboljšati performans organizacije. Istraživanje je pokazalo kako poslovna vrijednost može biti generirana kroz korištenje zajedničke terminologije i metodologije kao i snažnu komunikaciju između BI i BPM eksperata, menadžera i timova. Također, istraživanje je pokazalo utjecaj BI-a na organizacijski performans, ali i potvrdilo kako BI i BPM inicijative moraju biti usklađene kako bi se postigla poslovna vrijednost. Drugi rad u ovoj kategoriji (Tavera et al., 2021) analizira koncept industrije 4.0 kao skupa tehnologija koje organizacije koriste kako bi promovirale svoje inovativne strategije i odgovorile na brze i dinamične tržišne promjene te predlaže korištenje tih tehnologija. Također, članak govori o BI tehnologijama i načinima na koje su one pozitivno utjecale na organizaciju. Istraživanje je provedeno metodom pregleda literature, a rezultati pokazuju da tehnologije služe kao razvojni stupovi kompanija jer podržavaju njihov proces donošenja odluka, prognoziranja i korporativnu ekonomiju. Također, pokazalo se kako bi podrška efektivnog vodstva i obuka taj razvoj učinili još boljim. Treći rad (Huang, Savita, Zhong-jie, 2021) kreiran je i napisan s ciljem procjene utjecaja BI koncepta na financijski performans

startup kompanija. Metodom upitnika ispitani su direktori i eksperti *startup* te je statističkom obradom utvrđeno kako nije razvidan direktan utjecaj BI tehnologija na financijski performans, no očit je i jasan direktan utjecaj BI tehnologija na inovacije i mrežno učenje, a ono pak doprinosi bolje financijskom performansu, čime bi se mogao potvrditi indirektan utjecaj BI tehnologija na financijski performans *startup* kompanija gdje spomenute tehnologije igraju posredničku ulogu u tom procesu. Četvrti rad (Paradza, Daramola, 2021) daje pregled literature na temu poslovne inteligencije i poslovne vrijednosti u organizacijama. Kao jedan od glavnih rezultata istraživanja navode se glavni kritični faktori za poslovnu vrijednost implementacijom BI tehnologija, a to su: kvalificirani ljudski kapital, BI infrastruktura, kvaliteta podataka, BI aplikacija i upotreba/podaci, kultura, usklađenost BI-ja s organizacijskim ciljevima i podrška najvišeg menadžmenta, dok se osnovni izazovi odnose na kvalitetu podataka i rukovanje, sigurnost i zaštitu podataka te nedostatak BI infrastrukture i nedostatak kvalificiranog ljudskog kapitala. Peti rad u ovoj kategoriji (Darwiesh et al., 2022) analizira društvene mreže i važnost podataka na društvenim mrežama kako bi se poboljšala konkurentnost poduzeća u svijetu nakon pandemije. Kako se nakon pandemije kompanije suočavaju s brojnim izazovima, one su u velikoj potrebi da razviju nove metodologije i pristupe. Istraživanje je provedeno metodom pregleda literature te je jedno od glavnih saznanja istog predložen okvir u kojem se povezuju društvene mreže i analize velikih baza podataka kako bi se uspostavili BI sustavi. Šesti, ujedno i posljednji rad u ovoj kategoriji (Nazari, Taghavi, Valizadeh, 2022) navodi inovacije, BI i upravljanje znanjem kao važne pokretače *startup* kompanija te nastoji ispitati utjecaj BI koncepta na spomenute kompanije koristeći upravo inovacije i upravljanje znanjem kao posrednike u tom procesu. Metodom upitnika provedeno je istraživanje nad relevantnim stručnjacima i menadžerima u 150 *startup* kompanija. Rezultati istraživanja pokazali su da poslovna inteligencija, inovacije i upravljanje znanjem utječu na performans *startup* kompanija te se menadžerima *startup* kompanija savjetuje da iskoriste prednosti suvremenih tehnologija kako bi se olakšao proces inovacije u njihovom proizvodnom postupku.

2.3.3. Diskusija rezultata

Kad govorimo o konceptu poslovne inteligencije, nemoguće je izostaviti faktor organizacije kao ključnog pokretača svih promjena i procesa. Spremnost organizacije, a posebno vodstva organizacije kao i obuka zaposlenika i organizacijska kultura pokazali su se kao odlučujući faktori kod uspješne implementacije BI koncepta u poslovanje. Uz tehnologiju, od koje se očekuje da bude koncipirana na način da uspješno zadovoljava sve potrebe brzo rastućih promjena te infrastrukture koja je za to potrebna, ljudski je faktor odlučujući u stvaranju uspješnog BI sustava.

Organizacije bi na svim razinama trebale razviti kulturu razumijevanja važnosti takvog koncepta te pružiti odgovarajuća znanja svojim zaposlenicima kako bi isto bili u mogućnosti implementirati u svoj rad i koristiti na ispravan način tako da doprinosi stvaranju poslovne vrijednosti. U tom cijelom procesu, važnu ulogu igraju vođe i menadžment organizacija koji bi trebali biti pokretači i vođe takvih promjena te služiti kao svojevrsni motivator da se takve promjene i dogode.

S aspekta vrijednosti koju BI donosi organizaciji, zaključci su različiti, no svi upućuju na jedno, a to je da je ispravnom organizacijom navedenog koncepta vrijednost za organizaciju višestruka. Osobito je važno spomenuti razvoj tehnologija i brze promjene na tržištu koje dokazuju da danas BI više nije potreba samo velikih kompanija za organizaciju njihovih poslovnih procesa, već je i važna komponenta i aspekt poslovanja malih organizacija, a posebno *startup*-ova. Ta je važnost zasebno analizirana kroz neke znanstvene radove te je potvrđeno kako upravo *startup* kompanije za svoj opstanak i postizanje financijske stabilnosti trebaju implementirati BI sustave u svoje poslovanje jer su upravo oni pokretači velikih inovacija kao i posrednici u upravljanju znanjem, što danas uvelike podiže konkurentnost organizacije na tržištu.

2.3.4. Zaključak poglavlja

Zbog velikog broja i količine izvora na temu poslovne inteligencije, a osobito poslovne inteligencije u organizaciji, analizirani uzorak ograničen je na razdoblje od početka pandemije, s obzirom da navedeno razdoblje bilježi najveće promjene u smislu tehnologija, a samim time i tranzicije u poslovanju organizacija. Iz analiziranih radova vidljiv je trend proučavanja i analize, koji se kretao od proučavanja preduvjeta organizacije za uspješno uvođenje BI-a koji su radovi pretežito iz 2020. i početka 2021. godine, te se kretao prema analizi vrijednosti koje BI ima za organizacije, a koji radovi i analize datiraju pretežito u 2021. i 2022. godinu. U tim je godinama bilo moguće i izraditi preglede literature i analizirati konkretan utjecaj navedenog koncepta. Kako se i od tada tržište već uvelike promijenilo i napredovalo, te uzimajući u obzir da neka istraživanja provedena metodom upitnika datiraju u ranija razdoblja, od prije početka pandemije, svakako bi bilo korisno sagledati i ponoviti isto istraživanje nakon nekog vremena kako bi se utvrdio porast broja takvih radova i utvrdio njihov smjer kretanja. Isto tako, pregled literature usmjeren je samo na poslovne organizacije te bi isti bilo zanimljivo usporediti s drugim organizacijama i njihovim razumijevanjem BI koncepta. Svakako je već sada iz početnih rezultata pretraživanja jasno vidljivo da je smjer istraživanja krenuo više prema umjetnoj inteligenciji te se svakako očekuje porast tog trenda u znanstvenom kontekstu u budućem razdoblju.

2.4. Poslovna inteligencija u tehnološkom kontekstu

Kako bi se poslovna inteligencija koristila na najbolji mogući način, za njezinu su primjenu ključni alati i njihova prilagodba specifičnoj industriji i poslovnom okruženju krajnjeg korisnika. U tu se svrhu provode razne analize alata, trendova i sustava podrške odlučivanju o uvođenju tehnologija kako bi svaka organizacija i pojedinac bili u mogućnosti temeljem informacija koje imaju na raspolaganju donijeti odluku o odabiru vlastitog alata poslovne inteligencije. Veliku ulogu u tom procesu igra američka kompanija *Gartner*, tvrtka za istraživanje i savjetovanje o informacijskim tehnologijama koja je ujedno i svjetski lider u pružanju alata i stručne podrške, kao i u kreiranju praktičnih alata za pomoć poduzećima kod donošenja poslovnih odluka. U nastavku je dan prikaz njihovog istraživanja BI alata, okvira za razumijevanje vremena u kojem živimo i kako ono utječe na poslovne odluke pojedinca i organizacija te jednog od načina na koji oni pomažu organizacijama donositi poslovne odluke.

2.4.1. Trendovi među alatima poslovne inteligencije

Svake godine tokom mjeseca veljače, tvrtka *Gartner* objavljuje svoj magični kvadrant za nadolazeću godinu, a vezano uz platforme poslovne inteligencije i analitike (ABI) i njihovu poziciju na tržištu. *Gartnerov* magični kvadrant grafički je prikaz ranga vodećih dobavljača tehnologije (softver, aplikacije, platforme, alati, itd.) na tržištu, svrstanih u ukupno četiri kategorije: vođe, vizionari, nišni igrači i izazivači. Izvješće je rezultat opsežnog istraživanja tržišta, a objavljuje se i stvara za svaki sektor aktivnosti unutar tehnološke industrije, sa sveukupno više od 100 kategorija čarobnih kvadranata. Unutar tehnološke i poslovne zajednice, rezultati koji se prezentiraju *Gartnerovim* magičnim kvadrantom utječu na IT izvore i prodaju za tvrtke u toj industriji. Način i princip odabira tržišnog vođe u kategoriji BI alata uključuje 12 mogućnosti unutar kojih se alati koji se nude na tržištu promatraju i vrednuju, a to su: sigurnost, upravljanje podacima, analitika omogućena u oblaku, povezivost izvora podataka, priprema podataka, katalog, automatizirani uvidi, vizualizacija podataka, upit prirodnog jezika, prezentacija podataka, generiranje prirodnog jezika, izvještavanje. (bismart, 2022)

Gartnerov magični kvadrant kao vrsta istraživačke metodologije pruža grafičko kompetitivno pozicioniranje četiri vrste pružatelja tehnologije na brzorastućim tržištima: lideri, vizionari, niše igrači i izazivači. U tekstu koji se izdaje kao dokument i prilog magičnom kvadrantu, pruža se dublji uvid u sposobnost i prikladnost IT proizvoda i usluga davatelja na temelju specifičnih ili prilagođenih slučajeva upotrebe. Interaktivnost i ažuriranost takvog sustava vidljiva je u činjenici

da se isti ažurira tokom cijele godine najnovijim istraživanjima na temu magičnog kvadranta i ostalih pratećih dokumenata. (Gartner)

Čarobni kvadrant ima dvije osi, horizontalna je "potpunost vizije" i ona pobliže označava koliko značajki i inovativnih poboljšanja pojedini proizvod ima, a koja tjeraju druge dobavljače da reagiraju kako bi održali korak. Vertikalna os je "sposobnost izvršenja" i određena je prihodima, brojem i kvalitetom preprodavača i distributera, brojem zaposlenika i njihovom distribucijom između inženjeringa, prodaje i podrške te drugim poslovnim pitanjima. (CIOWiki)



Slika 10. Gartnerov magični kvadrant tržišta BI alata

(Izvor: bismart)

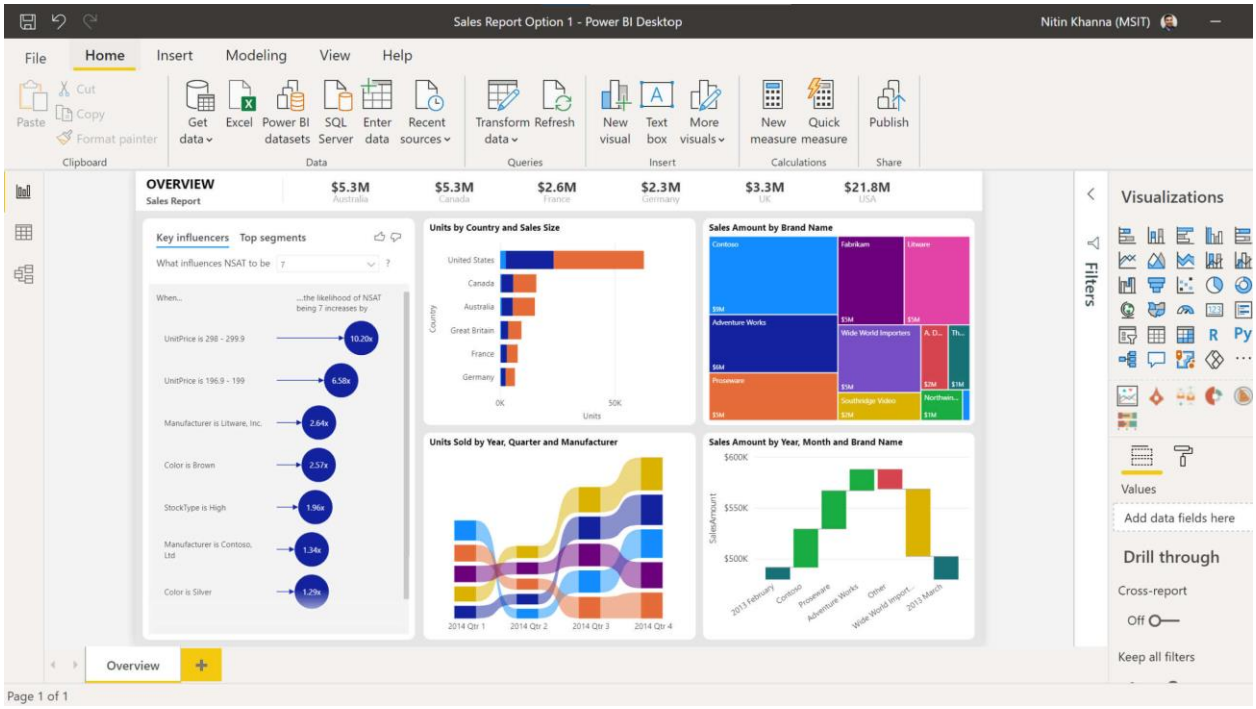
Alati u kategoriji vođe u 2022. godini sadrže splet karakteristika koje uključuju ABI sposobnosti, predanost uspjehu klijenata, te čine jedinstvenu kombinaciju vizije i isporučene vrijednosti potrošaču: (Mitchell, 2022)

1. **Microsoft**
2. **Salesforce (Tableau)**
3. **Qlik**

1. Microsoft

U kategoriji tržišnih lidera, vodeće mjesto zauzima Microsoft i njihov alat koji se koristi u svrhe poslovne inteligencije, a to je Power BI. Power BI je skup softverskih usluga, aplikacija i konektora koji rade zajedno kako bi nepovezane izvore podataka pretvorili u koherentne, vizualno impresivne i interaktivne uvide. Kod uvoza podataka, može se koristiti Excel proračunska tablica ili zbirka hibridnih skladišta podataka temeljenih na oblaku i lokalnih skladišta. Power BI omogućava da se korisnici jednostavno povežu s izvorima podataka, vizualiziraju te podatke i otkriju što je važno te podijele te podatke koje su dobili s ciljanom publikom. (Microsoft, 2022)

Unatoč ograničenjima u mogućnošću obrade većih količina podataka, njegova je prednost jednostavnost korištenja i široka namjena, pa ga tako mogu koristiti i početni i napredni korisnici zbog jednostavnog sučelja. (Taylor, 2022)

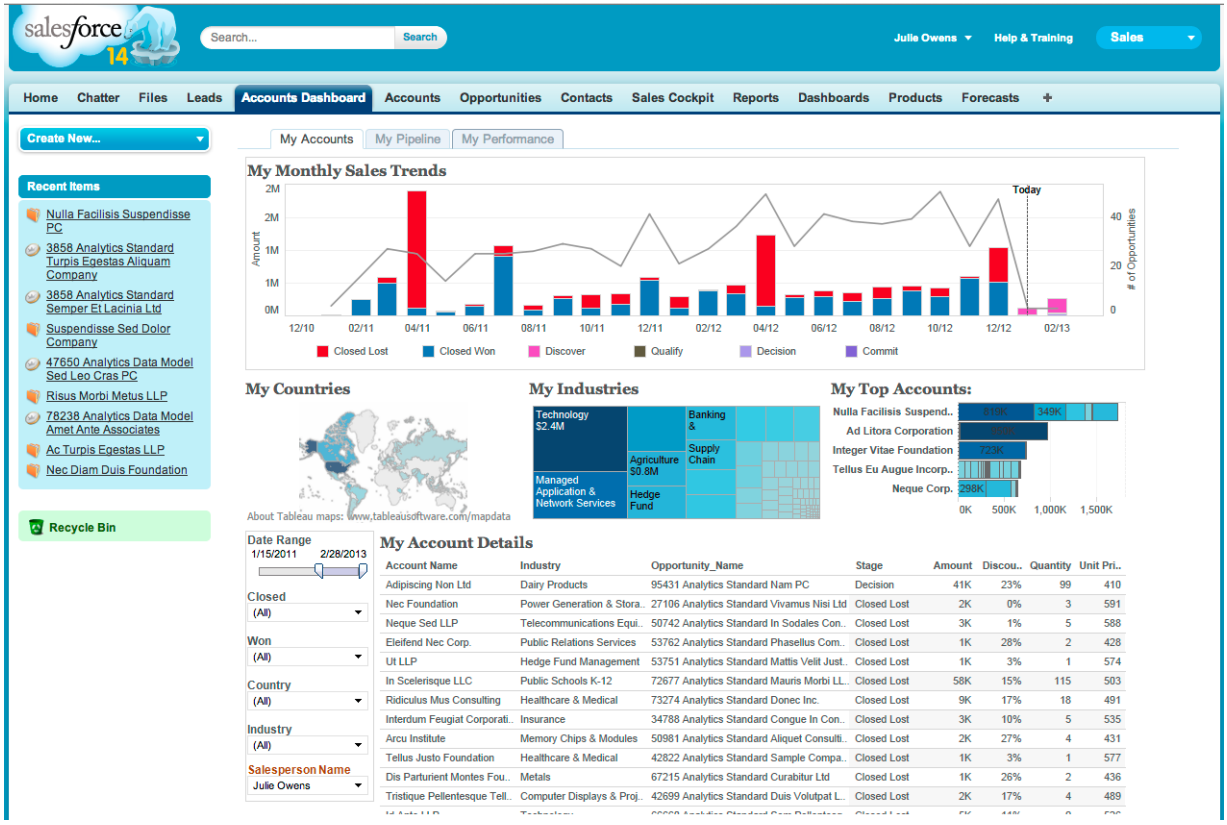


Slika 11. Korisničko sučelje Microsoft Power BI alata

(Izvor: Microsoft)

2. Salesforce (Tableau)

Visoko u kategoriji tržišnih lidera, odmah iza Microsoftovog Power BI-a, našao se i Tableau, alat koji može raditi s većim količinama podataka i ima velike mogućnosti u kategoriji vizualizacije podataka. Najčešće je korišten od strane analitičara i iskusnih korisnika u poslovne, odnosno analitičke svrhe i po svojim karakteristikama više odgovara potrebama srednjih i većih organizacija, a najveće prednosti su mu brzina i činjenica da za njegovo korištenje nije potrebna prethodna obuka ili je ona minimalna. (Taylor, 2022)

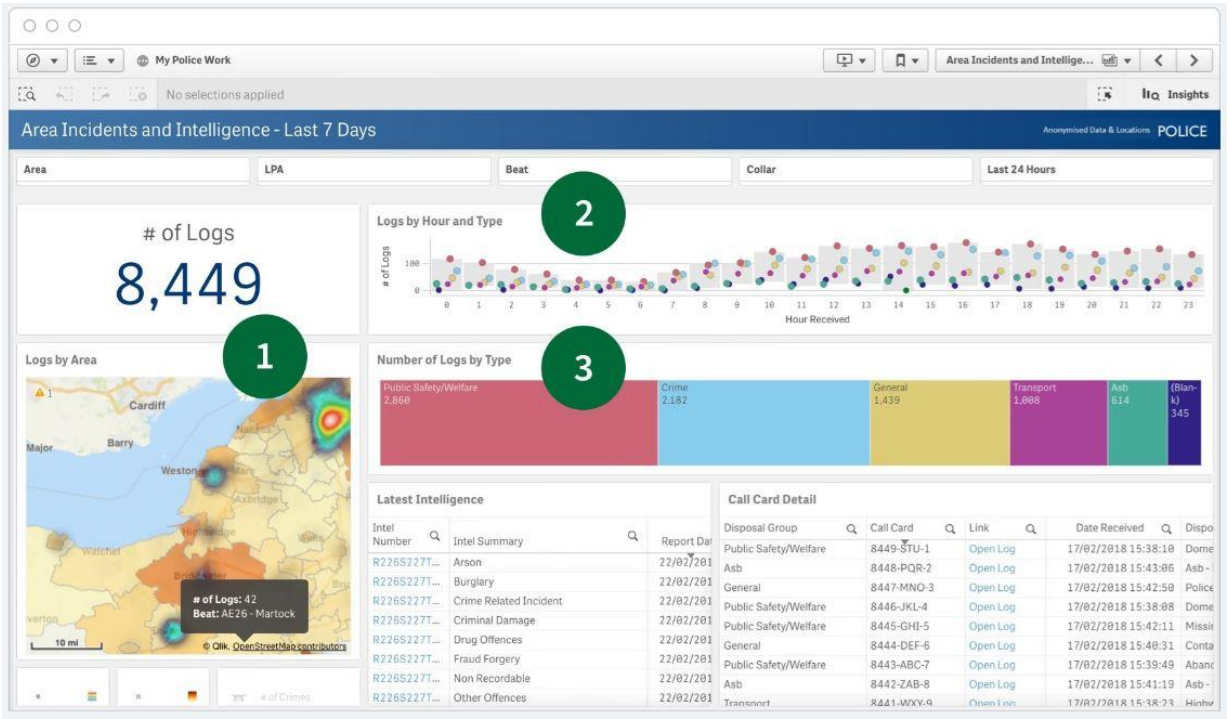


Slika 12. Korisničko sučelje Tableau alata

(Izvor: Fields, 2014)

3. Qlik

Treće, i ujedno posljednje mjesto u kategoriji tržišnih lidera zauzeo je alat Qlik, koji se također odlikuje jednostavnošću upotrebe i velikom količinom mogućnosti i prednosti koje nudi. Osnovne prednosti ovog alata su njegove mogućnosti koje nudi u smislu sučelja kojim korisnici vrlo lako mogu upravljati, istraživati podatke i sami kreirati vlastite vizuale temeljem dobivenih rezultata. On također nudi mogućnost mobilnog praćenja podataka, što danas olakšava upotrebu alata u pokretu. Pokreću ga umjetna inteligencija i tehnologija strojnog učenja, pa su mu u tom pogledu mogućnosti za korisnika velike. Alat je vrlo cijenjen u kompanijama kod obrade i interpretacije velike količine podataka. (vizlib, 2021)



Slika 13. Korisničko sučelje Qlik alata

(Izvor: Qlik)

Alati koji zauzimaju mjesto vođa u Gartnerovom magičnom kvadrantu najčešće se na tom mjestu i zadrže duži niz godina. Neprestano se radi na njihovom poboljšanju sukladno potrebama tržišta, pojednostavljenju kako bi bili pristupačni što većem broju korisnika, kao i na vizualizacijama kako bi one pružile što bolji uvid u podatke i omogućile kvalitetno donošenje poslovnih odluka. Osnovne su im prednosti jednostavnost korištenja, kao i cjenovna kategorija, pa su lideri obično alati koji se jednostavno prilagođavaju krajnjem korisniku i nude velike performanse u odnosu na njihovu cijenu.

2.4.2. Gartnerov *Hype Cycle*

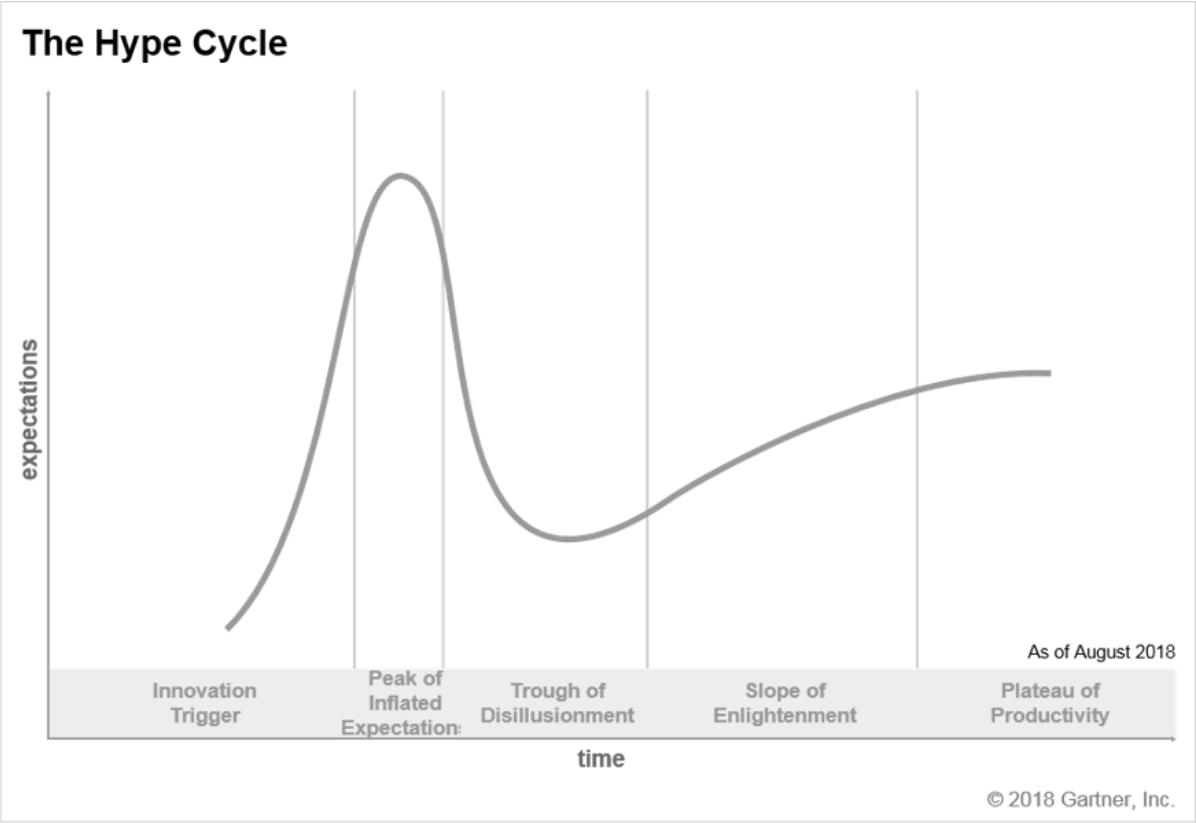
Kad se govori o kompaniji *Gartner* kao lideru u pogledu savjetovanja o tehnološkom aspektu poslovne inteligencije, najčešće to nisu samo savjetovanja o alatima, već i pogled na nadolazeće tehnološke trendove na cjelokupnom tržištu i alati kojima *Gartner* omogućuje detaljan uvid u tržišna kretanja i razvoj pojedinih trendova tijekom vremena. Takav način komunikacije poslovnim korisnicima omogućuje ne samo odabir prikladnog alata za njihovo poslovanje, već procjenu potreba i opravdanosti planiranih investicija sukladno najavljenim trendovima i alatima koji nude posebne metode kojima se vrše takve procjene.

Jedna od najpoznatijih metoda u procjeni tehnologije ili aplikacije i njezinog razvoja tijekom vremena je Gartnerov *Hype Cycle,* koji pruža grafički prikaz zrelosti i usvajanja tehnologija i

aplikacija te kako su one potencijalno relevantne za rješavanje stvarnih poslovnih problema i iskorištavanje novih prilika. Metodologija *Gartner Hype Cycle*, kao brendirani alat tvrtke *Gartner*, pruža svojim korisnicima uvid u istraživanje i savjetovanje u pogledu informacijske tehnologije. Svake godine *Gartner* kreira više od 100 *Hype* ciklusa u različitim domenama kako bi klijentima omogućio praćenje zrelosti inovacija i budućih potencijala. *Hype* ciklusi razvrstani su u ukupno pet faza, a karakteriziraju tipičan napredak inovacije u pogledu neke tehnologije, od velikog entuzijazma, preko razdoblja razočaranja do konačnog razumijevanja relevantnosti i uloge inovacije na tržištu ili domeni. Duljina ciklusa varira brzim promjenama na tržištu, te se u posljednje vrijeme bilježi sve kraće trajanje jednog ciklusa, koji je ranije mogao biti dugačak od dvije do četiri godine, a danas se inovacije koje se brzo kreću mogu zadržati u pojedinoj fazi samo šest do devet mjeseci. (CIOWiki)

Faze koje obilježavaju kretanje neke tehnologije po principu Gartnerovog *Hype Cycle*-a su (CIOWiki):

- **Inovacijski pokretač**: faza u kojoj se događa prvi iskorak u pogledu neke tehnologije, a svijest o njoj počinje se širiti i privlači prvu medijsku pozornost, no u toj fazi ideja je zanimljiva samo investitorima rizičnog kapitala jer iza nje ne stoje podaci o njezinoj korisnosti i održivosti.
- **Vrhunac napuhanih očekivanja**: faza koju karakteriziraju visoka očekivanja pojačana medijskim praćenjem nove tehnologije. U ovoj se fazi polako pobuđuje interes širih masa za novu tehnologiju, no on je najčešće mali ili bez poduzimanja konkretnih koraka.
- **Korito razočarenja:** faza u kojoj prethodni entuzijazam i ulaganja koja su se dogodila prelaze u komercijalna ulaganja koja ne ispunjavaju očekivanja glede izvedbe i/ili prihoda. Ovaj put su takva razočarenja ponovno medijski popraćena, ali u negativnom kontekstu, što uvelike doprinosi padu popularnosti te tehnologije.
- **Padina prosvjetljenja:** nakon razočarenja, slijedi faza prosvjetljenja kada određeni rani korisnici koji su nastavili raditi s tehnologijom počinju doživljavati neto koristi i ponovno dobivati motivaciju. Više ulaganja u tehnologiju čini da ona ima bolje performanse i sve veću iskorištenost.
- **Plato produktivnosti:** finalna faza koja donosi realnu ocjenu tehnologije, a njezino se usvajanje ubrzava.



Slika 14. Prikaz krivulje kretanja prema fazama Gartnerovog Hype ciklusa (Izvor: CIOWiki)

Kretanje prema fazama ima oblik S-krivulje, a objašnjenje takvog kretanja nalazi se u činjenici da se svaka tehnološka inovacija razvija sporo u početku. Unatoč brojnim medijskim istupima i popraćenošću, osnove tehnoloških inovacija u početku su slabo shvaćene i prihvaćene samo od nekolicine. Ovisno o tehnologiji, u nekoj prekretnici tehnološke performanse trebale bi uzletjeti sve dok se ne dosegne plato definiran specifičnim ograničenjima tehnologije, a koji se definira kao korito razočarenja. Nakon razočarenja, pojedini korisnici odustaju od inovacije, dok ju ostali nastavljaju koristiti i ulaze u fazu prosvjetljenja otkrivajući njezine mogućnosti i dobivajući prve neto koristi. Peta, ujedno i posljednja faza tog ciklusa obilježena je realnom ocjenom tehnologije, a karakterizira ju brzo usvajanje od širih masa. Za svaku fazu definirani su pokazatelji koji omogućuju procjenu trenutne faze za bilo koju tehnologiju. (CIOWiki)

2.4.3. Glavni strateški tehnološki trendovi za 2022. godinu prema Gartneru

Osim alata za razumijevanje faze tehnologije, Gartner kroz svoja istraživanja daje i pregled trendova u svijetu tehnologije, a koja bi kompanije trebale slijediti ukoliko žele biti ukorak s konkurentima na tržištu.

Istraživanje strateških tehnoloških trendova za 2022. godinu predložilo je sveukupno 12 strateških tehnoloških trendova za spomenutu godinu, a koji uključuju sljedeće kategorije: (Costello, Rimol, 2021)

1. **Generativna umjetna inteligencija (AI)**

Pojam koji označava *„metode strojnog učenja koje uče o sadržaju ili objektima iz svojih podataka i koriste ih za generiranje potpuno novih, potpuno originalnih, realističnih artefakata“*. (Costello, Rimol, 2021)

2. **Podatkovne strukture (*Data Fabric*)**

Način pružanja integracije izvora podataka na različitim platformama i različitim poslovnim korisnicima, čineći podatke dostupnima svugdje gdje su potrebni bez obzira na to gdje se oni nalaze. (Gartner)

3. **Distribuirana poduzeća**

Koncept distribuiranih poduzeća odražavaju prvi digitalni poslovni model na daljinu za poboljšanje iskustva zaposlenika, digitaliziranje dodirnih točaka potrošača i partnera i izgradnju iskustava proizvoda. Takav trend osmišljen je da bolje služi potrebama udaljenih zaposlenika i potrošača, a potiče i potražnju za virtualnim uslugama i hibridnim radnim mjestima. (Gartner)

4. ***Cloud-Native* platforme (CNP)**

Platforme koje služe kao tehnologije koje omogućuju izgradnju novih otpornijih i agilnijih arhitektura aplikacija, što omogućuje brz odgovor na konstantne digitalne promjene. Platforme koje se temelje na oblaku poboljšavaju tradicionalni pristup oblaku s potrebom stalnog podizanja dokumenata u oblak i njihovog pomicanja, a što predstavlja dodatnu složenost kod održavanja. (Gartner)

5. **Autonomni sustavi**

Autonomni sustavi predstavljaju „*fizičke ili softverske sustave koji uče iz svog okruženja i dinamički modificiraju vlastite algoritme u stvarnom vremenu kako bi optimizirali svoje ponašanje u složenim ekosustavima. Autonomni sustavi stvaraju agilan skup tehnoloških sposobnosti koje su u stanju podržati nove zahtjeve i situacije, optimizirati performanse i obraniti se od napada bez ljudske intervencije*.“ (Gartner)

6. Inteligencija odlučivanja

Inteligencija odlučivanja funkcionira na način da modelira svaku odluku kao skup procesa, koristeći inteligenciju i analitiku za informiranje, učenje i pročišćavanje odluka te svojim mogućnostima vrlo lako može podržati i poboljšati ljudsko donošenje odluka. (Gartner)

7. Sastavljive aplikacije

Sastavljive aplikacije osmišljene su sa svrhom olakšavanja korištenja i ponovne upotrebe koda, ubrzavanja vremena za tržište novih softverskih rješenja i oslobađanja vrijednosti poduzeća, a izgrađene su od poslovno usmjerenih modularnih komponenti. (Gartner)

8. Hiperautomatizacija

Hiperautomatizacija je discipliniran, poslovno vođen pristup za brzo identificiranje, provjeru i automatizaciju što većeg broja poslovnih i IT procesa i omogućuje skalabilnost, daljinski rad i prekid poslovnog modela. (Gartner)

9. Računanje koje poboljšava privatnost (PEC)

Računanje koje poboljšava privatnost koristeći tehnike zaštite privatnosti osigurava obradu osobnih podataka u nepouzdanim okruženjima, što je sve kritičnije zbog razvoja zakona o privatnosti i zaštiti podataka, kao i sve veće zabrinutosti potrošača. (Gartner)

10. Mreža kibernetičke sigurnosti

Mreža kibernetičke sigurnosti fleksibilna je arhitektura koja se može sastaviti, a osnovna joj je svrha integracija široko rasprostranjene i različite sigurnosne usluge. Osnovna joj je prednost da može brzo i pouzdano provjeriti identitet, kontekst i pridržavanje pravila u okruženjima u oblaku i bez oblaka. (Gartner)

11. AI inženjering

AI inženjering omogućava automatiziranje ažuriranja podataka, modela i aplikacija kako bi se pojednostavnila isporuka umjetne inteligencije. (Gartner)

12. Ukupno iskustvo (TX)

Ukupno iskustvo je „*poslovna strategija koja integrira iskustvo zaposlenika, korisničko iskustvo, korisničko iskustvo i višestruko iskustvo na više dodirnih točaka kako bi se ubrzao rast.*

Ukupno iskustvo može potaknuti veće povjerenje kupaca i zaposlenika, zadovoljstvo, lojalnost i zagovaranje kroz holističko upravljanje iskustvima dionika.“ (Gartner)

Prema Gartneru, glavni strateški tehnološki trendovi i njihova implementacija u poslovanje omogućava ubrzanje digitalne sposobnosti i poticanje rasta rješavanjem uobičajenih poslovnih izazova za kompanije te bi se tako osigurao održivi rast i sigurnije poslovanje u trenucima nadolazeće ekonomske krize. (Gartner)

Provedenom analizom poslovne inteligencije počevši od same definicije i pojmovnog određenja te interpretacije iz različitih konteksta gledanja te daljnjim okvirima povijesnog razvoja iste, uz naglasak na razvoj informacijsko-komunikacijske tehnologije koja je uvelike odredila ono što poslovna inteligencija predstavlja danas za svoje korisnike, uočeno je kako sva shvaćanja i interpretacije pojma i razvoja koncepta poslovne inteligencije u sebi sadrže organizacijski i tehnološki koncept, te je u tom smjeru prikazan i drugi dio istraživačkog procesa. Za potrebe organizacijskog konteksta, pregledom relevantnih izvora i članaka na odabranu temu, generalni je zaključak kako je upravo ljudski faktor najvažniji kod implementacije poslovne inteligencije u organizaciji, ali i njezinog korištenja u donošenju poslovnih odluka. Kod ljudskog faktora, poseban se naglasak stavlja na najviši menadžment i poslovne analitičare i zaposlenike koji rade s alatima i konceptima poslovne inteligencije, a koji na jedan određen način diktiraju dinamiku, smjer i reakciju na promjene u okviru promatrane teme i koncepta. Osim svjesnosti menadžmenta o važnosti implementacije poslovne inteligencije u njihove organizacije kako bi se dugoročno poboljšalo cjelokupno poslovanje organizacije, vrlo je važna i edukacija osoblja i onih zainteresiranih za cijeli proces, pravodobno informiranje i praćenje modela i uvažavanje kategorije upravljanje znanjem kao one koja se s poslovnom inteligencijom nadopunjava i čini jedinstven skup podataka važnih kod donošenja ciljeva, strategija i odluka. S tehnološkog koncepta, promjene se događaju brzo, pa je isto tako potrebno brzo na njih odgovoriti. Pri tome je najvažnije pratiti trendove u tehnologiji i kod alata poslovne inteligencije i pokušati identificirati one koji daju najbolji omjer cijene i kvalitete, odnosno funkcionalnosti, a sve za potrebe konkretne organizacije unutar koje se koncept i alati implementiraju. Kao apsolutni *lider* u području tehnološkog istraživanja i savjetovanja spominje se tvrtka *Gartner Inc* te je tehnološki aspekt alata, procesa i trendova prikazan kroz njihove koncepte, istraživanja i izvještaje.

Takvim se načinom obrade i analize koncepta poslovne inteligencije nastojalo pokriti sve potencijalno važne aspekte njezine implementacije u poslovanju i postaviti daljnja podloga za nastavak istraživanja i konkretnog ispitivanja hipoteza putem alata poslovne inteligencije, *lidera* prema tvrtki *Gartner, Microsoft Power BI-a*.

3. Preduvjeti održivog gospodarstva Europske unije

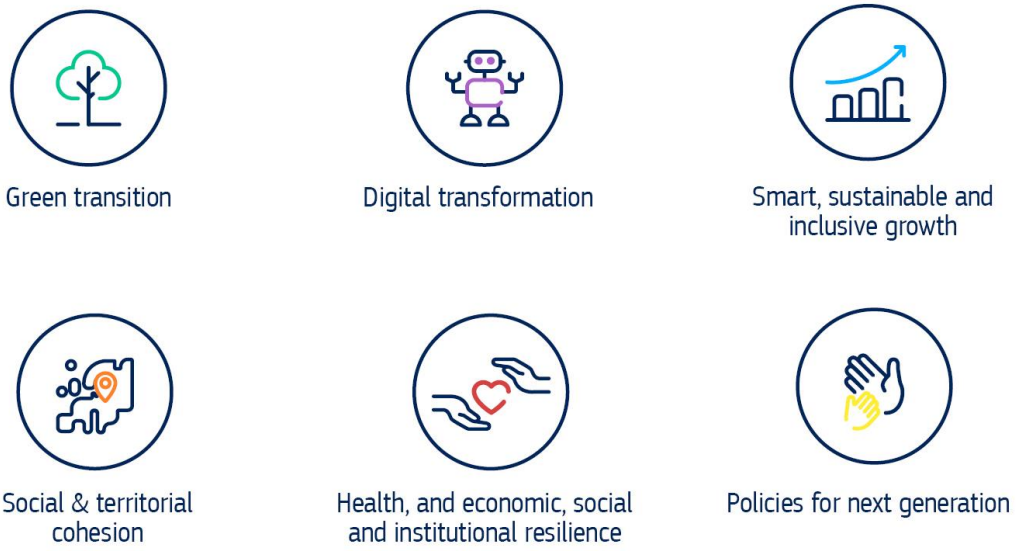
Suočavanje s globalnim izazovima i njihova analiza rezultirali su UN-ovim ciljevima održivog razvoja i, posljedično, zajedničkom strategijom djelovanja Europske unije nazvanom Europa 2030. (Europska komisija, 2019) Kod kreiranja UN-ovih ciljeva održivog razvoja, osnovni cilj bio je staviti zajednički naglasak na sve postojeće izazove u svijetu i pokušati naći rješenja za njih uzimajući pritom u obzir bolju i održiviju budućnost za cjelokupno stanovništvo. Ciljevi održivog razvoja suočavaju se s najvećim globalnim izazovima kao što su siromaštvo, nejednakost, klimatske promjene, degradacija okoliša, mir i pravda, a svi su oni svedeni pod zajednički nazivnik održivosti kao osnovnog preduvjeta ostvarenja svih ciljeva. (UN, 2015) Korištenjem UN-ovih ciljeva održivog razvoja kao smjernica, kreirana je i predložena i strategija Europske unije te su identificirani ključni izazovi s kojima se EU susreće, kao i skupovi faktora koji bi trebali biti glavni pokretači promjena. Jedan od tih skupova, nazvanih horizontalnim čimbenicima za prijelaz na održivost, čine obrazovanje, znanost, tehnologija, istraživanje, inovacije i digitalizacija koje se smatra preduvjetom za ostvarivanje održivog gospodarstva EU-a (Europska komisija, 2019). U tom kontekstu, znanost, tehnologija i inovacije (STI) prepoznati su kao jedan od glavnih pokretača povećanja produktivnosti i ekonomskog rasta i prosperiteta. Osim povećanja ulaganja u ta područja, kao prioritet na koji bi se Europska unija trebala usmjeriti u svojim ciljevima, navodi se potreba povećanja rashoda za istraživanje. Na razini Europske unije, u tom se kontekstu ističe važnost okvirnih programa za istraživanje i inovacije kao katalizatora održive konkurentnosti, rasta i ulaganja, a jedna od vodećih inicijativa Europske unije za potporu istraživanjima i inovacijama je upravo program Obzor Europa. (Europska komisija, 2019)



Slika 15. 17 globalnih ciljeva održivog razvoja

(Izvor: Ružić, 2022)

Nakon postavljanja ciljeva i Strategije Europe, svijet je pogodila pandemija i javila se potreba za ponovnim odgovorom na novonastale izazove. Kao dio širokog odgovora, Europska komisija dala je prijedlog Mehanizma za oporavak i otpornost kojem je glavni cilj ublažiti gospodarski i društveni utjecaj pandemije koronavirusa i učiniti europska gospodarstva i društva održivijima, otpornijima i bolje pripremljenima za izazove i prilike zelenih i digitalnih prijelaza. U tom kontekstu, digitalna transformacija jedan je od stupova i preduvjeta ostvarenja, odnosno realizacije Mehanizma za oporavak i otpornost. (Europska komisija, 2020)



Slika 16. Šest stupova Mehanizma za oporavak i otpornost
(Izvor: Europska komisija, 2020)

3.1. Znanost i tehnologija

Znanost i tehnologija svojim postojanjem sežu daleko u povijest. Oduvijek se tragalo za činjenično i podatkovno utemeljenim objašnjenjima o tome kako funkcionira svijet ili o pojedinim pojavama i promjenama u društvu, kao što su se oduvijek procesi proučavali, razvijali i stavljali u primjenu. Posljednjih godina, a najviše pojavom društvenih mreža i sve većim stupnjem digitalizacije u smislu dostupnosti iste, bilježi se sve značajnije propitkivanje znanosti i pad njezine popularnosti. Glavna kritika odnosi se na hiperprodukciju koja sve češće ne ispunjava svrhu i realnu društvenu potrebu. S druge strane, u vrijeme pandemije i intenzivnih promjena na svim područjima i poljima, potreba za znanošću i znanstveno utemeljenim činjenicama pokazala se većom nego ikad. Europska unija velik naglasak stavlja na važnosti znanosti za razvoj društva, a istovremeno pokušava pronaći rješenje kako da znanost postane pristupačnija i otvorenija za sve

potencijalne sudionike i interesente. U nastavku je prikazano nekoliko ključnih činjenica vezanih uz razvoj znanosti i tehnologije.

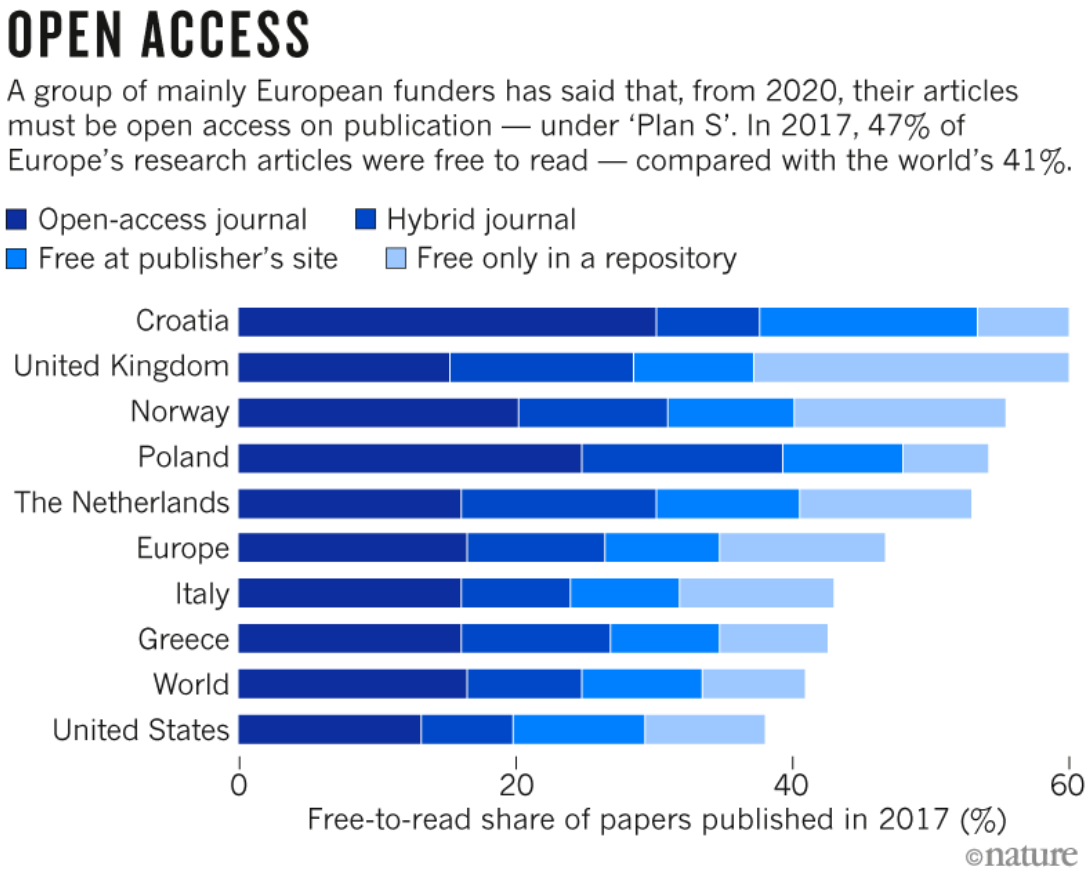
„*Ekonomska je teorija već odavno spoznala važnost znanstveno-tehnološkog razvoja za cjelokupni gospodarski razvoj. Joseph Schumpeter (1981) naglašavao je značenje znanstvene revolucije te pozitivno međudjelovanje gospodarske konkurencije i znanstveno-tehnološkog razvoja jer konkurencija novih roba, nove tehnologije, novih izvora opskrbe… ima odlučnu prednost u smislu troškova ili kakvoće*." (Bejaković, 2003)

„*Moderna tehnika i tehnologija su nesporno proizvod kumulativnog znanstvenog razvoja*." (Milošević, 2014) U posljednje vrijeme bilježi se rastući interes na temu produktivnosti znanstvenih istraživanja i efikasnosti rada znanstvenika kroz proces komercijalizacije i mehanizme zaštite intelektualnog vlasništva. (Szulczewska-Remi, Nowak-Mizgalska, 2021 prema Moutinho et al., 2016; Reyes, 2016; Hayter et al., 2018; Suhaimi et al., 2020) Kao glavni kanal prelijevanja znanja u procesu komercijalizacije istraživanja spominje se poduzetništvo, koje bi također trebalo sudjelovati u tom procesu i poduzeti određene aktivnosti za prijenos znanja u ekonomski korisne koncepte, dok će više znanja stvarati više poduzetničkih prilika. (Szulczewska-Remi, Nowak-Mizgalska, 2021 prema Audretch, Keilbach, 2007; Hayter, 2013) Također, komercijalizacija istraživanja smatra se ključnim načinom na koji ulaganja u javno financirana istraživanja stvaraju utjecaje na društvo i gospodarstvo. (Szulczewska-Remi, Nowak-Mizgalska, 2021 prema Pisano, 2006; Ting et al., 2019)

Europa čini raznolikost zemalja u različitim fazama znanstvenog razvoja, od istraživačko-intenzivne nordijske regije, preko znanstvenih vođa Njemačke i Francuske, do bivših komunističkih država koje pokušavaju ojačati svoje istraživačke kapacitete i baze i zemalja koje se protežu prema azijskom prostoru. Cjelokupno gledajući, EU je svjetski vođa u proizvodnji znanja, ali dokazi govore o slabostima kad dođe do iskorištavanja znanja i stvaranju ekonomske i društvene koristi. Upravo zato, Europska unija stavila je znanost i inovacije u središte svog društvenog i gospodarskog razvoja i kroz svoje programe financira velike istraživačke inicijative koji se protežu šire od same EU i podržavaju suradnička istraživanja i mobilnost u cijelom bloku. Na taj se način nastoji potaknuti primarno europske kreatore politika, donositelje odluka i građane da razmišljaju o budućnosti dugoročnije, tako da svi budu bolje pripremljeni da maksimalno iskoriste prilike koje nude znanost, inženjerstvo i tehnologija. (Malik, 2014; Van Norden, Butler, 2019)

Posebno važnu ulogu u razvoju znanosti igraju upravo sveučilišta, zbog čega se dodatno ističe važnost ulaganja države u istraživanje i razvoj i visoko obrazovanje. Različiti sustavi sveučilišta unutar država svi rezultiraju jednakom potrebom-znatnim državnim ulaganjima. Uz ključni pokazatelj za kvantitativno mjerenje znanosti koji čine publikacije, institucionalni, kadrovski ili

financijski pokazatelji također olakšavaju procjene znanstvenog rasta i razvoja. Povećana znanstvena produktivnost zahtijeva razmjerne resurse, bez obzira na teško mjerljiv utjecaj svakog pojedinog znanstvenog članka. (Powell, Dusdal, 2017 prema Kennedy, 2015:314 i Weingart, 2001)



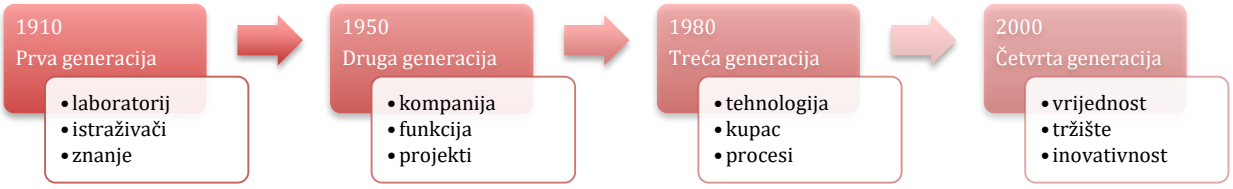
Slika 17. Prikaz odnosa među pojedinim državama u kategoriji časopisa s otvorenim pristupom (Izvor: Van Norden, Butler, 2019)

Živimo u vremenu velikih znanstvenih dostignuća, ali i vremenu poricanja znanosti, vremenu kad su mnogi ljudi generalno skloniji vjerovati društvenim mrežama i medijima nego znanosti. Znanost i njezine spoznaje konstantno se preispituju, a tri ključne stvari koje bi Europu vratile znanosti, prema Moedasu (2019) su otvorenost, međunarodna suradnja i povjerenje javnosti u znanost. Otvorena znanost trebala bi biti prilika da znanost bude jednako dostupna svima, što bi omogućilo ostvarenje inkluzivnosti i uvažavanja, temeljnih vrijednosti EU-a, dok je zadaća Europe da, po uzoru na GDPR, i u znanosti postavi standarde prije nego što se ostvari ideja njezine otvorenosti i široke dostupnosti. Jedna od prvih i osnovnih inicijativa kojima se počeo poticati model i pristup otvorene znanosti na razini Europske unije upravo je program Obzor 2020, kojemu je uvjet za financiranje bila objava u otvorenom pristupu. Inicijativa objave u otvorenom pristupu popularno je nazvana i „Plan S“, pokrenuta 2018. godine od strane *cOAlition S*, konzorcija nacionalnih istraživačkih agencija i donatora iz dvanaest europskih zemalja. Međunarodna suradnja omogućava brže rezultate i promjene i upravo neke od suradnja više znanstvenika iz više

zemalja rezultirale su najkvalitetnijim znanstvenim dostignućima. Prema tome, znanost je ona koja ne bi trebala imati granice i upravo je kod nje suradnja ključ veće uspješnosti. Povjerenje javnosti u znanost gradi se postepeno, najviše pričama samih znanstvenika jezikom prilagođenim da svaki pojedinac razumije. To bi građanima omogućilo aktivno sudjelovanje u znanosti, za razliku od trenutnog položaja kada su samo pasivni promatrači. (Moedas, 2019) Načini postizanja takvih ciljeva usko su vezani uz politike države i njezinu viziju budućnosti, a ulaganja u istraživanje i razvoj koja su vrlo mala na razini Europe, što znanstvenike zabrinjava u smislu financijskih sredstava i potpora, dok se potiče i financiranje kompetitivnih temeljnih istraživanja i to u okviru aktivnosti sveučilišta kao i postizanje kontinuiteta za države koje u ovom segmentu već bilježe određen napredak. (Vernos, 2019 i Nowotny 2019) Podrška znanosti trebala bi biti i ideja Europskog istraživačkog prostora koji bi trebao u potpunosti omogućiti europskim istraživačima otvoren pristup i dijeljenje podataka, i samim time postizanje visokokvalitetnih znanstvenih dostignuća. (Kuster, 2019) Kritika znanstvenika, s druge strane, najveća je u pogledu na istraživačka pitanja koja nisu dovoljno relevantna za današnje vrijeme i društvo te ne sadrže segment interdisciplinarnosti, a znanstvenici nedovoljno poduzimaju inicijative suradnje s neznanstvenim ustanovama u svrhu detekcije stvarnih problema i pokušaja rješavanja istih. (Wouter Vasbinder, Brooks, 2019) Svrha današnjeg ulaganja u istraživanje i razvoj te poticanje znanosti i stvaranja inovacija od strane države, a sve u okvirima koji zadovoljavaju spomenute kriterije, dugoročna je dobrobit sadašnjih, ali i budućih generacija. (Cunningham, 2019)

3.2. Istraživanje, razvoj i inovacije

Svijet se danas polako kreće prema društvu znanja, čija bi suština trebala biti upravo proces otkrivanja novih znanja postavljanjem do sada nepostavljenih pitanja i nastojanjem da se na njih pronađu odgovori. Svrha toga trebao bi biti pojam istraživanja i razvoja, čiji bi se razvoj mogao podijeliti u četiri faze. Četvrta faza istraživanja i razvoja nastala je početkom ovog stoljeća kao odgovor na činjenicu da je inovativnost zapala u krizu i nije bila u stanju odgovoriti potrebama nove informatičke ere i društva znanja te se samim time koncept istraživanja i razvoja morao promijeniti, što je značilo stvaranje novih metoda koje će odgovoriti zahtjevima društva. Faze istraživanja i razvoja ponajviše su se očitovale u području interesa unutar kompanije, organizacijskom fokusu, pristupu otkrićima i odnosu prema okolini, pa je tako četvrta generacija primarno usmjerena na vrijednost, tržište i inovativnost. (Carić,2003:19)



Slika 18. Prikaz kretanja i fokusa četiri generacije istraživanja i razvoja
(Izvor: izrada autora prema Carić, 2003:20)

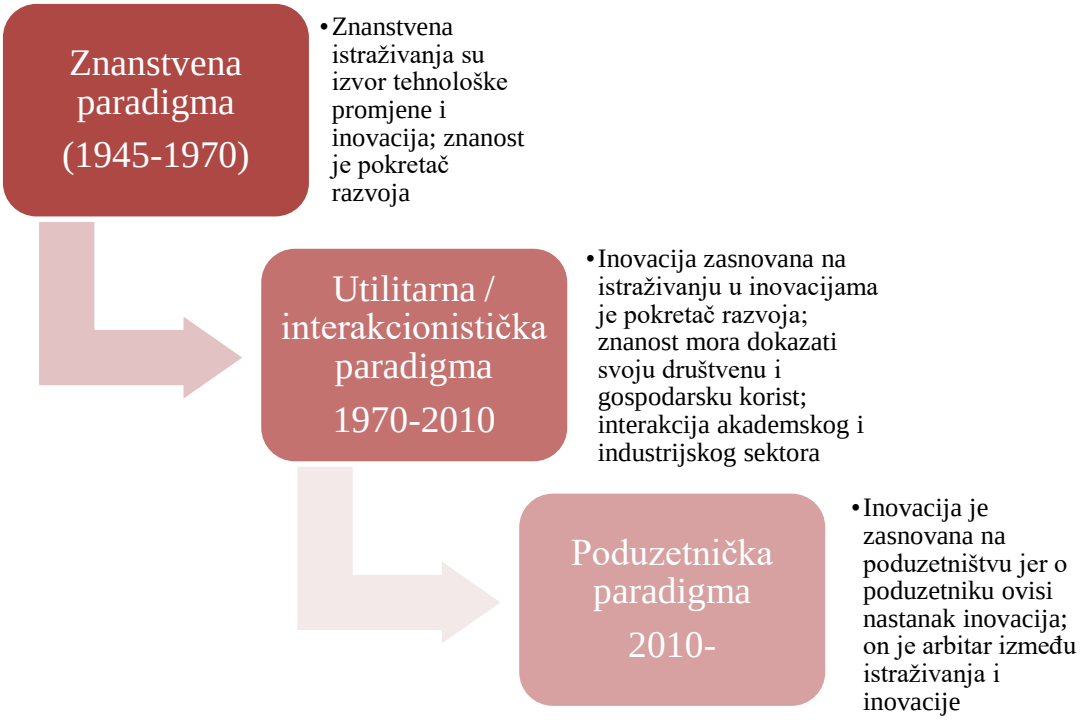
Međusobna povezanost pojmova istraživanje, razvoj i inovacije najbolje se očituje u njihovoj definiciji i suštinskoj svrsi, pri čemu se na istraživanje gleda kao na stvaranje novog znanja, na razvoj se promatra kroz primijenjeno znanje znanstvenika i inženjera, a inovacije su nešto novo općenito ili za okolinu, a plod su istraživačke i razvojne sposobnosti pojedinca. Za razliku od znanosti, za inovacije postoje mehanizmi pravne zaštite, najčešće u vidu zaštite intelektualnog vlasništva. (Bečić, Dabić, 2008 i Enciklopedija.hr)

Istraživačke, razvojne i inovacijske aktivnosti danas se spominju kao glavni pokretač razvoja organizacije, ali i društva u cjelini i na njima se inzistira, ponajviše u vidu ulaganja poduzeća u istraživanje i razvoj, kao osnovne pretpostavke za ispunjenje cilja koji sugerira povećanje broja inovacija. (Devčić, Pleša, 2020) S obzirom na ulogu inovacija u kontekstu rasta i razvoja i težnju Europe k održivosti i društveno obilježje koje inovacije imaju, u novije su se vrijeme razvili koncepti društvenih i uključivih inovacija te eko-inovacija, kao onih inovacija kojima se unapređuje sudjelovanje članova u zajednici, njihovi prihodi, zdravlje, obrazovanje i drugi oblici dobrobiti, odnosno onih inovacija koje su dostupne siromašnima, koje su masovne i jeftine i usmjerene su na zadovoljavanje potreba i rješavanje problema marginaliziranih skupina, odnosno inovacija koje smanjuju upotrebu prirodnih resursa i ispuštanje štetnih tvari tijekom cijelog životnog ciklusa. (Taipale, 2021: 13, Bilas, Franc, 2018:195 i Matešić, 2020) Razvoju takvih vrsta inovacija mogu značajno doprinijeti poduzetnički i digitalno-inovacijski *hubovi* i općenito razvoj digitalnog poduzetništva (Franc, Bilas, Bošnjak, 2021:129 prema Prodanov, 2018).

Kako je osnovni cilj inovacija ubrzati proces njezina prihvaćanja kako bi se ostvario povrat uloženih sredstava u njezino istraživanje i razvoj, ključ i međuovisnost tog procesa ogleda se upravo u osobinama potrošača i inovacije, ali i drugim čimbenicima kojima je potrebni sustavni pristup, čime se u znanstvenim krugovima često bavi područje marketinga. (Božić, 2005) U novije vrijeme na uspješan način predstavljanja inovacije gleda se kroz pretvaranje potrebe u potražnju,

pa onda priču o načinu na koji ta ideja zadovoljava potrebu potencijalnih potrošača. (Brown, 2019:39,137) Ovakvim idejama bavi se pristup *design thinking*, koji se pojavljuje kao odgovor na novi pristup inovacijama koji je moćan, učinkovit i široko dostupan i može biti uključen u sve aspekte poslovanja i društva, a osnovna mu je ideja učiniti svakog dizajnerom stavljajući čovjeka u središte zbivanja i nastojanjem da svatko ima priliku izgraditi ideje s emocionalnim i funkcionalnim značenjem. (Brown, 2019:4)

Prema Druckeru (1992), na inovacije se može gledati kao na specifičan instrument poduzetništva, stvaranje resursa na način da se pronađe način korištenja neke prirodne pojave i podari joj se ekonomska vrijednost. (Drucker, 1992:37) Takvo je razumijevanje popularno i danas, zasnovano na okvirima izgradnje poduzetničkog ekosustava kao treće inovacijske paradigme u kojoj je poduzetniku dodijeljena uloga moderatora između istraživanja i razvoja i inovacije u procesu u kojem je inovacija zasnovana na poduzetništvu i o poduzetništvu ovisi nastanak inovacije. (Švarc, Lažnjak, 2020) Važnu ulogu u tom lancu igraju mala i srednja poduzeća, za koje postoji mišljenje da su upravo ona generatori ekonomskog rasta zbog svoje fleksibilnosti, a jedan od temeljnih izvora njihove konkurentnosti je upravo inovacijski potencijal, a u tom su kontekstu vrlo važne inovacijske strategije koje uključuju stvaranje inovativne organizacije i razvoj inovacijskog kapaciteta. (Baković, Ledić-Purić, 2010)



Slika 19. Tri inovacijske paradigme

(Izvor: izrada autora prema Švarc, Lažnjak, 2020)

Kad se spominje poduzetništvo i mala i srednja poduzeća i na njih gleda u kontekstu globalizacije, može se reći kako se tvrtke svakodnevno suočavaju s konkurencijom i sposobnošću

preživljavanja i samim time se moraju suočiti s brzim promjenama na svjetskom tržištu. (Rodica, Starc, Konda, 2014) Vrlo je popularan i rastući i termin otvorenih inovacija i *crowdsourcinga*, kao svojevrsna prilika za pristupanje znanju vanjskih eksperata, dobavljača i vodećih korisnika, kao i od njihovih vlastitih internih mreža. (Gupta, 2018:85) Još jedan koncept koji je nastao kao odgovor na takve promjene i potrebu održivog razvoja je i koncept inovacijskih ekosustava, čiji je glavni cilj „*međusobno povezivanje regionalnih i nacionalnih aktera u inovacijama na razini Europske unije podržavanjem zajedničkih transnacionalnih i međuregionalnih inovacijskih programa",* a njihova se važnost očituje u činjenici da su u novom programskom razdoblju upravo oni dio III. stupa Obzora Europa, najvećeg programa Europske unije za istraživanje i inovacije. (Ministarstvo znanosti i obrazovanja, Agencija za mobilnost i programe EU, 2020)

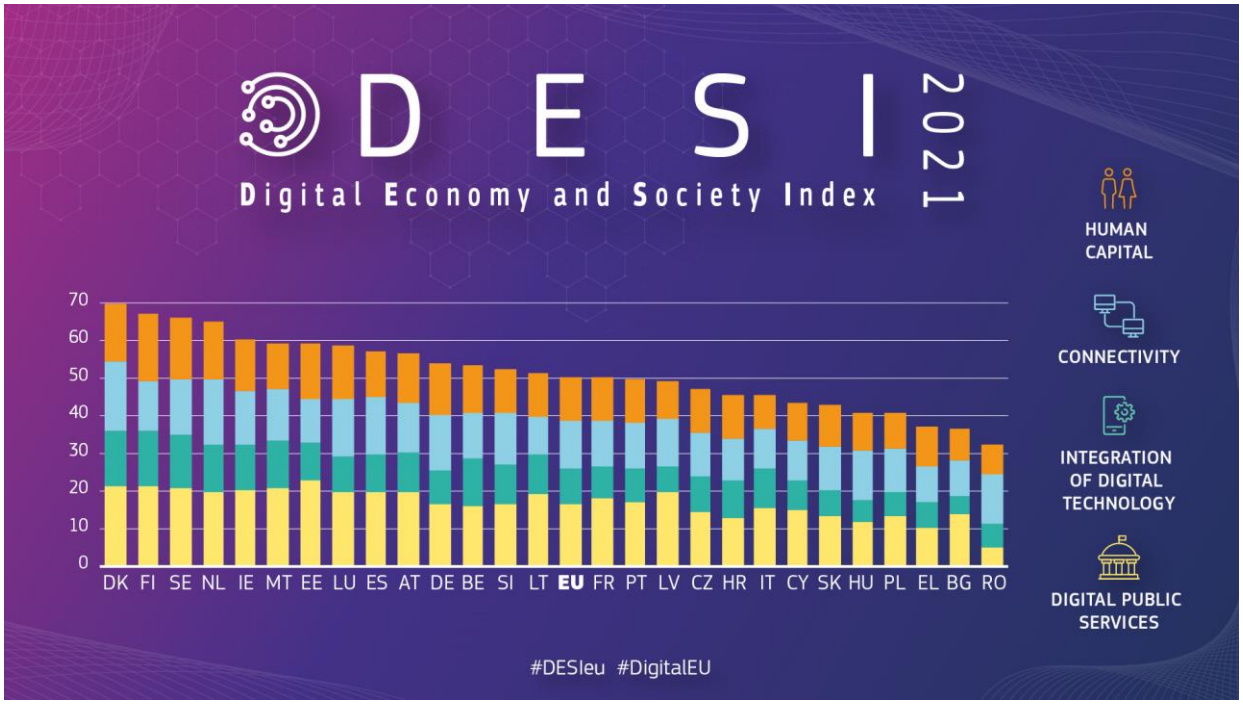
3.3. Digitalna transformacija i digitalne vještine

Digitalna transformacija mogla bi se definirati kao proces koji uključuje upotrebu digitalne tehnologije u svakom aspektu organizacijskog djelovanja kako bi se postigli ekonomska vrijednost, agilnost i brzina. Od organizacija se očekuje da u tom procesu aktivno sudjeluju neprestano prateći nove trendove i eksperimentiraju s njima te se istima prilagođavaju, dok akademske institucije trebaju uzeti u obzir razvoj obrazovnih programa u skladu s potrebama digitalne transformacije te učiti nove vještine trenutne i buduće poslovne vođe. (Siebel, 2019:27) Aspekt digitalnih vještina trenutno je jedan od najneusklađenijih po pitanju ponude i potražnje te se javlja velika potreba da radna snaga uči digitalne vještine i to ne samo one tehničke, već i vještine kodiranja, kreativnosti, timskog rada i rješavanja problema. (Siebel, 2019:29)

Uz koncept digitalne transformacije, razvio se i pojam digitalne ekonomije, a koji „*služi kao krovni pojam za označavanje novih modela poslovanja, proizvoda, usluga, tržišta i brzorastućih sektora ekonomije, posebice onih koji se temelje na digitalnim tehnologijama kao osnovnoj infrastrukturi poslovanja.*" (Spremić, 2017:20) Vrlo važan infrastrukturni čimbenik digitalne ekonomije su upravo digitalne tehnologije koje su zapravo upotreba digitalnih resursa i korištenje digitalnih dobara u računalnom okruženju, a neke od tih tehnologija su: mobilne tehnologije, društvene mreže, računalstvo u oblacima, veliki podaci, senzori i Internet stvari. (Spremić, 2017:21)

Kako bi digitalnu transformaciju stavila u mjerljive okvire, Europska unija osmislila je online alat nazvan Indeks digitalnog gospodarstva i društva (DESI), a koji relevantnim pokazateljima nastoji izmjeriti napredak država članica EU prema digitalnom gospodarstvu i društvu. DESI se sastoji od četiri glavna područja koja predstavljaju ukupno više od 30 pokazatelja: ljudski kapital, povezivost, integracija digitalnih tehnologija i digitalni javni servisi, a za izračun ukupne ocjene neke zemlje, stručnjaci Europske komisije dali su svakom skupu i podskupu pokazatelja posebnu

težinu, pa tako povezivanje i digitalne vještine ('ljudski kapital'), koji se smatraju temeljima digitalnog gospodarstva i društva, pri čemu svaki pridonosi jednako ukupnoj ocjeni, 25%. (European comission a, 2021, European comission b, 2021)



Slika 20. DESI zemalja članica Europske unije za 2021. godinu

(Izvor: European comission a)

Najvažnija strategija Europske unije koja pokriva aspekt digitalizacije i digitalne transformacije bila je Digitalna agenda za Europu koja je istakla udio IKT-a od oko 5% u ukupnom europskom BDP-u kao i problem koji slijedi ta činjenica a to je nedovoljna iskorištenost potencijala novih tehnologija i njihova nedovoljna uključenost u svakodnevni život građana radi ekonomskog, političkog i kulturnog boljitka. (Europska komisija, 2010) Kao nastavak strategije Digitalne agende za Europu smatra se dokument Digitalni kompas 2030.: europski pristup za digitalno desetljeće, a čiji je glavni cilj sve digitalne ambicije pretočiti u konkretne ciljeve i osigurati njihovo ostvarenje. Oslanja se na četiri glavne točke, od kojih su prve dvije usmjerene na digitalne kapacitete u području infrastrukture te obrazovanja i vještina, a druge dvije na digitalnu transformaciju poduzeća i javnih službi. Za svaki cilj u okviru prioritetnih točaka postavljeni su pokazatelji uspješnosti. (Europska komisija, 2021a i Europska komisija, 2021b)

U svrhu boljeg razumijevanja kompetencijskog okvira ključnih vještina potrebnih za napredovanje u digitalnom dobu, razvio se termin digitalne inteligencije (DQ), uz dosadašnje kvocijent inteligencije (IQ) i emocionalnu inteligenciju (EQ). DQ se definira kao "*sveobuhvatan skup tehničkih, kognitivnih, metakognitivnih i socio-emocionalnih kompetencija koje su utemeljene na univerzalnim moralnim vrijednostima i koje omogućuju pojedincima da se suoče s izazovima i iskoriste mogućnosti digitalnog života*." (DQ Institute, 2021) Kao IQ ili EQ koji se

koriste za mjerenje nečije opće i emocionalne inteligencije, sposobnost pojedinca i vladanje digitalnim medijima je kompetencija koja se također može mjeriti. (Park, 2016) DQ obuhvaća sveukupno 24 digitalne kompetencije, a u fokusu ima 8 područja digitalnog života – identitet, korištenje, sigurnost, zaštitu, emocionalnu inteligenciju, pismenost, komunikaciju i prava. Svako od osam navedenih područja moguće je razvijati na tri razine: građanskoj, kreativnoj i kompetitivnoj, pri čemu se građanstvo usredotočuje na osnovne razine vještina potrebnih za korištenje tehnologija na odgovoran, siguran i etički način, kreativnost omogućuje rješavanje problema kroz stvaranje novih znanja, tehnologija i sadržaja, dok su u fokusu konkurentnosti inovacije za promjenu zajednica i gospodarstva za široku korist. (DQ Institute, 2021)

	Digital Identity	Digital Use	Digital Safety	Digital Security	Digital Emotional Intelligence	Digital Communication	Digital Literacy	Digital Rights
Digital Citizenship	1 Digital Citizen Identity	2 Balanced Use of Technology	3 Behavioural Cyber-Risk Management	4 Personal Cyber Security Management	5 Digital Empathy	6 Digital Footprint Management	7 Media and Information Literacy	8 Privacy Management
Digital Creativity	9 Digital Co-Creator Identity	10 Healthy Use of Technology	11 Content Cyber-Risk Management	12 Network Security Management	13 Self-Awareness and Management	14 Online Communication and Collaboration	15 Content Creation and Computational Literacy	16 Intellectual Property Rights Management
Digital Competitiveness	17 Digital Changemaker Identity	18 Civic Use of Technology	19 Commercial and Community Cyber-Risk Management	20 Organisational Cyber Security Management	21 Relationship Management	22 Public and Mass Communication	23 Data and AI Literacy	24 Participatory Rights Management

Slika 21. Okvir digitalnih kompetencija prema 8 područja i 3 razine

(Izvor: DQ Institute, 2021)

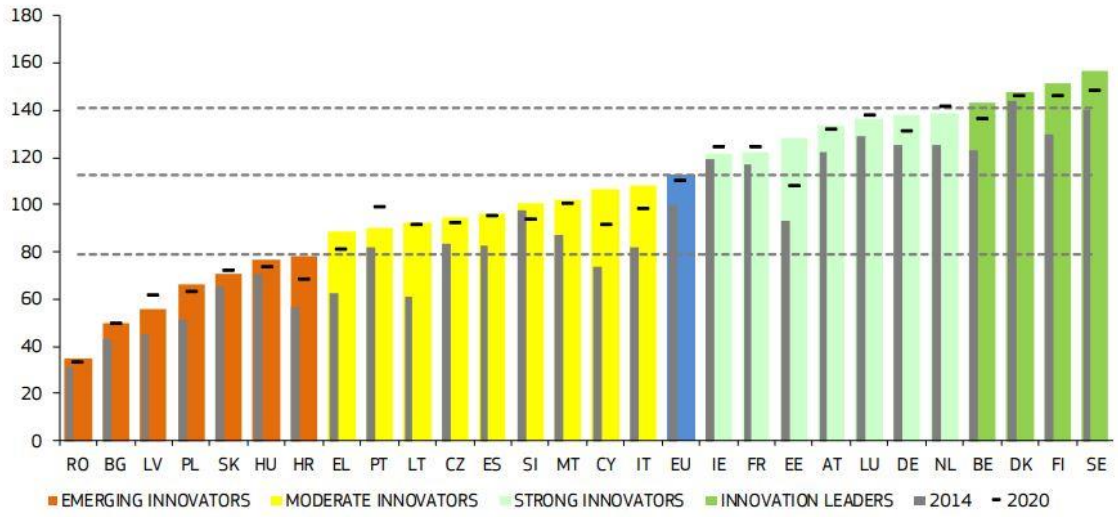
Svi spomenuti okviri, strateška dokumentacija, kao i ciljevi na globalnoj, europskoj i nacionalnoj razini govore u prilog činjenici važnosti digitalizacije kao procesa u tehnološkom smislu, ali i razvoju digitalnih vještina, pismenosti i inteligencije kao jedne od ključnih vještina budućnosti za veću konkurentnost pojedinaca na tržištu rada, kako domaćem, tako i međunarodnom. Predložene strategije i okviri razvoja u području digitalizacije upućuju na važnost i neophodnost digitalizacije svih aspekata društva, a potpora Europske unije u smislu digitalizacije ogleda se kroz mogućnosti korištenja sredstava i potpora iz različitih fondova kako bi se taj proces doista i realizirao. Velik naglasak stavlja se i na pojedinca kao ključan faktor u vođenju tog procesa, pa se stavlja fokus na njihovo razumijevanje važnosti razvoja tog područja ali i razvoj vještina neophodnih za praćenje procesa digitalizacije, a sve kako bi bili u mogućnosti biti aktivni sudionici promjene u svim aspektima gospodarstva i društva.

3.4. Europska ljestvica uspjeha u inoviranju

S obzirom na konstantnu intenciju Europske unije da generalno poboljša inovacije, a time i sve ranije spomenute utjecajne faktore, osnovnu podlogu za analize i prijedloge poboljšanja čine alati osmišljeni kako bi detektirali utjecajna područja i pokušali ocijeniti uspjeh svake države u tim područjima. Jedan od takvih alata je i Europska ljestvica uspjeha u inoviranju (EIS).

„*Europska ljestvica uspjeha u inoviranju pruža komparativnu analizu učinka inovacija u zemljama EU-a, drugim europskim zemljama i regionalnim susjedima. Procjenjuje relativne snage i slabosti nacionalnih inovacijskih sustava i pomaže zemljama da identificiraju područja kojima se trebaju pozabaviti.“* (Europska komisija, 2021)

EIS se objavljuje na godišnjoj razini, kao dokument koji sumira učinke i pokazatelje, ali i kao interaktivni alat koji uključuje skup pokazatelja te pruža mogućnost usporedbe procjena uspješnosti istraživanja i inovacija članica Europske unije, ali i trećih zemalja, te relativne snage i slabosti njihovih istraživačkih i inovacijskih sustava. Na taj se način državama pomaže procijeniti područja na koja bi morale usmjeriti svoje napore i politike, a kako bi u konačnici poboljšale učinak svojih inovacija. Zemlje se sukladno promatranim kategorijama svrstavaju u 4 skupine: inovacijski vođe, snažni inovatori, umjereni inovatori i novi inovatori. (European Comission, 2021)



Slika 22. Pozicije zemalja Europske unije u kategorijama inovatora prema EIS-u (Izvor: Hollanders, Es-Sadki, 2021)

Prva skupina inovacijskih vođa uključuje četiri države članice u kojima je ukupni učinak iznad 125% prosjeka EU: Belgija, Danska, Finska i Švedska.

Druga skupina uključuje sedam država članica s učinkom između 100% i 125% EU prosjeka: Austrija, Estonija, Francuska, Njemačka, Irska, Luksemburg i Nizozemska.

Treća skupina umjerenih inovatora uključuje devet država članica u kojima je učinak između 70% i 100% EU prosjeka: Cipar, Češka, Grčka, Italija, Litva, Malta, Portugal, Slovenija i Španjolska.

Četvrta skupina novih inovatora uključuje sedam država članica koje pokazuju razinu učinka ispod 70% prosjeka EU-a. U ovu grupu spadaju Bugarska, Hrvatska, Mađarska, Latvija, Poljska, Rumunjska i Slovačka.

3.4.1. Okvir za mjerenje inovacijskog indeksa

EIS mjerni okvir razlikuje sveukupno 4 glavne vrste aktivnosti, a koje obuhvaćaju sveukupno 12 inovacijskih dimenzija i 32 različita pokazatelja. (Hollanders, Es-Sadki, 2021)

FRAMEWORK CONDITIONS
Human resources
1.1.1 New doctorate graduates (in STEM)
1.1.2 Population aged 25-34 with tertiary education
1.1.3 Lifelong learning
Attractive research systems
1.2.1 International scientific co-publications
1.2.2 Top 10% most cited publications
1.2.3 Foreign doctorate students
Digitalisation
1.3.1 Broadband penetration
1.3.2 Individuals who have above basic overall digital skills

INVESTMENTS
Finance and support
2.1.1 R&D expenditure in the public sector
2.1.2 Venture capital expenditures
2.1.3 Direct government funding and government tax support for business R&D
Firm investments
2.2.1 R&D expenditure in the business sector
2.2.2 Non-R&D innovation expenditures
2.2.3 Innovation expenditures per person employed in innovation-active enterprises
Use of information technologies
2.3.1 Enterprises providing training to develop or upgrade ICT skills of their personnel
2.3.2 Employed ICT specialists

INNOVATION ACTIVITIES
Innovators
3.1.1 SMEs with product innovations
3.1.2 SMEs with business process innovations
Linkages
3.2.1 Innovative SMEs collaborating with others
3.2.2 Public-private co-publications
3.2.3 Job-to-job mobility of Human Resources in Science & Technology
Intellectual assets
3.3.1 PCT patent applications
3.3.2 Trademark applications
3.3.3 Design applications

IMPACTS
Employment impacts
4.1.1 Employment in knowledge-intensive activities
4.1.2 Employment in innovative enterprises
Sales impacts
4.2.1 Medium and high-tech product exports
4.2.2 Knowledge-intensive services exports
4.2.3 Sales of product innovations
Environmental sustainability
4.3.1 Resource productivity
4.3.2 Air emissions by fine particulates PM2.5 in Industry
4.3.3 Development of environment-related technologies

Slika 23. EIS aktivnosti, dimenzije i pokazatelji (Izvor: Hollanders, Es-Sadki, 2021)

Aktivnost Okvirni uvjeti (*eng. framework conditions*) uključuje 3 dimenzije: Ljudski resursi, Atraktivni istraživački sustav i Digitalizacija. (Hollanders, Es-Sadki, 2021)

1. Dimenzija **Ljudski resursi** uključuje tri pokazatelja kojima mjeri dostupnost visokokvalificirane i obrazovane radne snage, a to su: novi doktorski diplomanti u STEM području, stanovništvo od 25-34 godine sa završenim tercijarnim obrazovanjem, te stanovništvo u dobi od 25-64 uključeni u aktivnosti cjeloživotnog učenja. U usporedbi s EIS 2020, pokazatelj koji mjeri nove diplomante je fokusiraniji jer uključuje samo

diplomirane osobe iz znanosti, tehnologije, inženjerstva i matematike (STEM). (Hollanders, Es-Sadki, 2021)

2. Dimenzija **Atraktivni istraživački sustav** također uključuje tri pokazatelja kojima mjeri međunarodnu konkurentnost znanstvene baze fokusiranjem na međunarodna znanstvena koautorstva te najcitiranije publikacije i inozemne doktorande. (Hollanders, Es-Sadki, 2021)
3. Dimenzija **Digitalizacija** mjeri razinu digitalnih tehnologija i uključuje dva pokazatelja, širokopojasni pristup među poduzećima i pojedince s boljim općim ukupnim digitalnim vještinama. Ova dimenzija zamjenjuje EIS 2020 dimenziju koja je bila Okruženje pogodno za inovacije. Pokazatelj širokopojasnog pristupa je jednak, no novi je pokazatelj koji mjeri digitalne vještine. (Hollanders, Es-Sadki, 2021)

Aktivnost Ulaganja (*eng. investments*) obuhvaća ulaganja u javni i poslovni sektor i uključuje 3 dimenzije: Financije i potpora, Ulaganja poduzeća i Korištenje informacijskih tehnologija. (Hollanders, Es-Sadki, 2021)

1. Dimenzija **Financije i potpora** uključuje tri pokazatelja: izdaci za istraživanje i razvoj kod sveučilišta i vladinih istraživačkih organizacija, privatno financiranje (ulaganja rizičnog kapitala), i direktno državno financiranje i državna porezna potpora poslovnom istraživanju i razvoju. (Hollanders, Es-Sadki, 2021)
   U usporedbi s EIS-om 2020., pokazatelj državne potpore za istraživanje i razvoj je nov. Smatra se relevantnim jer obuhvaća neizravnu poreznu podršku poslovnom istraživanju i razvoju, mehanizam podrške koji koristi sve veći broj zemalja. U EU je 2018. godine ukupno 21 država nudila porezne olakšice za istraživanje i razvoj, što je značajno povećanje u usporedbi sa samo 12 zemalja koje su to radile u 2000. godini Javno financiranje istraživanja i razvoja može imati dva oblika: izravno financiranje istraživanja i razvoja kroz instrumente kao što su bespovratna sredstva i javna nabava te neizravnu potporu kroz porezni sustav. Izravno financiranje obuhvaćeno je u službenim podacima o izdacima za istraživanje i razvoj po izvoru financiranja. Tijekom vremena, sve je više zemalja uvelo porezne poticaje za istraživanje i razvoj. Organizacija za ekonomsku suradnju i razvoj (OECD) započeo je sa sustavnim prikupljanjem takvih podataka u 2017. godini, a uz potporu Europske komisije podaci se trenutno prikupljaju na godišnjoj razini i stavljaju na raspolaganje u bazu OECD-a „OECD baza podataka o poreznim poticajima za istraživanje i razvoj". (Hollanders, Es-Sadki, 2021)

2. Dimenzija **Ulaganja poduzeća** uključuje tri pokazatelja o istraživanju i razvoju i ulaganjima koja nisu namijenjena istraživanju i razvoju, koja poduzeća realiziraju za stvaranje inovacija, uključujući troškove poslovnog istraživanja i razvoja, troškove inovacija koji nisu povezani s istraživanjem i razvojem, i izdatke za inovacije po zaposlenoj osobi. (Hollanders, Es-Sadki, 2021)

   U usporedbi s EIS-om 2020., pokazatelj izdataka za inovacije po zaposlenoj osobi je nov. Indikator mjeri monetarni unos izravno povezan s inovacijskim aktivnostima i koristi podatke iz Ankete o inovacijama u zajednici (CIS), a koja kontrolira razlike u kupovnoj moći među državama članicama. (Hollanders, Es-Sadki, 2021)
3. Dimenzija **Korištenje informacijskih tehnologija** uključuje dva pokazatelja: Poduzeća koja rade na aktivnom povećanju ICT vještina svog osoblja i zaposlenih i ICT specijalisti.

   Kako bi se poboljšalo mjerenje korištenja informacija tehnologije, uključena je nova dimenzija u usporedbi s EIS 2020. Pokazatelj koji mjeri zaposlene ICT stručnjake također je nov i jedan je od pokazatelja preporučenih u istraživačkom izvješću o mjerenju digitalnih vještina. ICT stručnjaci se definiraju kao „radnici koji imaju sposobnost razvijanja, rada i održavanja ICT-a sustava, a za koje ICT čini glavni dio posla". (Hollanders, Es-Sadki, 2021)

Aktivnost **Inovacijske aktivnosti** (*eng. innovation activities*) obuhvaća različite aspekte inovacija u poslovnom sektoru i razlikuje 3 dimenzije: Inovatori, Povezanost i Intelektualna imovina. (Hollanders, Es-Sadki, 2021)

1. Dimenzija **Inovatori** uključuje dva pokazatelja koji mjere udio MSP-ova koji su uveli inovacije na tržište ili unutar svojih organizacija, a obuhvaća inovacije proizvoda i poslovnih procesa. (Hollanders, Es-Sadki, 2021)

   U usporedbi s EIS 2020 definicija oba pokazatelja se promijenila. Prvi pokazatelj sada je fokusira na inovacije proizvoda, a drugi na inovacije poslovnih procesa, kombinirajući procesne marketinške i organizacijske inovacije koje su se koristile u izdanjima CIS-a prije CIS-a 2018. (Hollanders, Es-Sadki, 2021)
2. Dimenzija **Povezanost** uključuje tri pokazatelja koji mjere inovacijske sposobnosti promatrajući napore u suradnji između inovativnih tvrtki, istraživačkoj suradnji privatnog i javnog sektora, te mobilnost ljudskih resursa u znanosti i tehnologiji (HRST) s posla na posao. (Hollanders, Es-Sadki, 2021)

   U usporedbi s EIS 2020, pokazatelj mobilnosti s posla na posao HRST-a je novi, a oslanja se na činjenicu kako mobilnost kvalificiranog osoblja utječe na stupanj

stvaranja znanja, što je jedan od ključnih pokretača inovacija. HRST su ljudi koji ispunjavaju jedan od sljedećih uvjeta: uspješno završena tercijarna razina obrazovanja; nije formalno kvalificirana kategorija obrazovanja, ali zaposleni u znanstveno-tehnološkom zanimanju gdje se obično traže takve kvalifikacije. Mobilnost s posla na posao u ovom kontekstu je definirana kao kretanje pojedinaca između jednog posla i drugog iz godine u godinu. (Hollanders, Es-Sadki, 2021)

U usporedbi s EIS 2020, definicija indikatora mjerenje javno-privatnih zajedničkih publikacija promijenilo se. U EIS-u 2020, publikacije su dodijeljene zemlji ili zemljama gdje se nalaze poduzeća ili druge organizacije privatnog sektora. U EIS 2021, publikacije su dodijeljene i zemlji ili zemljama u kojima se nalaze organizacije javnog sektora, uključujući i zajedničke publikacije između domaće organizacije javnog sektora i stranih poduzeća. (Hollanders, Es-Sadki, 2021)

3. Dimenzija **Intelektualna imovina** obuhvaća različite oblike prava intelektualnog vlasništva generirane inovacijskim procesom, uključujući prijave patenata, prijave zaštitnih znakova i prijave dizajna.

   U usporedbi s EIS 2020, definicija indikatora mjerenje prijava zaštitnih znakova je promijenjena. Pokazatelj više ne uključuje prijave zaštitnih znakova podnesene na svjetskoj razini Ured za intelektualno vlasništvo. (Hollanders, Es-Sadki, 2021)

Aktivnost **Učinci** (*eng. impacts)* obuhvaća učinke inovacijskih aktivnosti poduzeća i razlikuje 3 dimenzije: Učinci zapošljavanja, Učinci prodaje i Održivost okoliša. (Hollanders, Es-Sadki, 2021)

1. Dimenzija **Učinci zapošljavanja** mjeri utjecaj na zapošljavanje i uključuje dva pokazatelja: Zaposlenost u djelatnostima utemeljenima na znanju i Zapošljavanje u inovativnim poduzećima.

   U usporedbi s EIS 2020, pokazatelj Zaposlenost u inovativnim poduzećima je nov. Inovacije u poduzećima imaju velik utjecaj na zapošljivost radnika, a poslovne inovacije pokazale su se posebno važnima tijekom ekonomske recesije. Iako su visokokvalificirani zaposlenici manje pogođeni recesijom nego niskokvalificirani zaposlenici, značajan pozitivan učinak uočen je kod niskokvalificiranih zaposlenika u inovativnim poduzećima. (Hollanders, Es-Sadki, 2021)
2. Dimenzija **Učinci prodaje** mjeri ekonomski učinak inovacija i uključuje tri pokazatelja: Izvoz proizvoda srednje i visoke tehnologije, Izvoz usluga temeljenih na znanju i prodaja koja rezultira iz inovativnih proizvoda. (Hollanders, Es-Sadki, 2021)

U usporedbi s EIS 2020, nije bilo promjena u indikatorima. (Hollanders, Es-Sadki, 2021)

3. Dimenzija **Održivost okoliša** obuhvaća poboljšanja koja rezultiraju smanjenjem negativnog utjecaja na okoliš i uključuje tri pokazatelja: Produktivnost resursa, Izloženost onečišćenju zraka finim česticama PM2.5 i Razvoj tehnologija povezanih s okolišem. (Hollanders, Es-Sadki, 2021)

   Kako prirodni okoliš pati od gubitka bioraznolikosti, zagađenja i klimatskih promjena, ekološke inovacije dobivaju na važnosti, a za poboljšanje mjerenja okolišnih inovacija, dodana je nova dimenzija koja se sastoji od tri nova pokazatelja za mjerenje održivosti okoliša, preporučenih u Istraživačkom izvješću o mjerenju ekoloških inovacija. (Hollanders, Es-Sadki, 2021)

4. Instrumenti Europske unije za znanost, istraživanje i inovacije

U svakom programskom razdoblju Europska unija, među ostalim, stavlja naglasak i na poticanje istraživanja, razvoja i inovacija te razvoj znanosti te na tome kontinuirano radi kroz donošenje strateških dokumenata, smjernica i prioriteta koji, u konačnici, određuju i smjer i okvire za sredstva i prioritete Europskih fondova.

Financiranje istraživanja i razvoja nešto je na čemu Europska unija stavlja veliki naglasak kroz ispreplitanje raznih mogućnosti financiranja unutar raznih programa i drugih akcija koje nudi EU, a među najvažnije od njih se ubrajaju (European Comission):

- **Horizon Europe**, program EU-a za istraživanje i inovacije za razdoblje 2021. – 2027. s proračunom od 95,5 milijardi eura,
- **Zdravstveni program** EU-a s proračunom od 449,4 milijuna eura kao glavni instrument Europske komisije za provedbu zdravstvene strategije EU-a,
- **Kohezijski fond** koji je namijenjen zemljama EU čiji je bruto nacionalni dohodak (BND) po stanovniku manji od 90% prosjeka EU, a cilj mu je smanjiti ekonomske i socijalne razlike i promicati održivi razvoj,
- **Program LIFE**, financijski instrument EU-a koji podupire projekte zaštite okoliša, zaštite prirode i klimatskih mjera diljem EU-a,
- **Europski fond za regionalni razvoj** koji ima za cilj jačanje gospodarske i socijalne kohezije u Europskoj uniji ispravljanjem neravnoteže između njezinih regija, a svoja ulaganja usmjerava na nekoliko ključnih prioritetnih područja, uključujući inovacije i istraživanje,
- **Program potpore strukturnim reformama**, program EU-a koji pruža prilagođenu potporu svim zemljama EU-a za njihove institucionalne, administrativne reforme i reforme za poticanje rasta,
- **Europski strukturni i investicijski fondovi (ESIF)**, kroz koje se kanalizira više od polovice sredstava EU-a kroz ukupno 5 europskih strukturnih i investicijskih fondova (ESIF). Njima zajednički upravljaju Europska komisija i zemlje EU. Svrha svih ovih fondova je ulaganje u otvaranje radnih mjesta te održivo i zdravo europsko gospodarstvo i okoliš. Otvoreni pozivi za dostavu prijedloga koji se odnose na istraživanje i inovacije mogu se pronaći na web stranicama 5 pojedinačnih programa financiranja: Europski fond za regionalni razvoj, Europski socijalni fond, Kohezijski fond, Europski poljoprivredni fond za ruralni razvoj, Europski fond za pomorstvo i ribarstvo,

- **Istraživački fond za ugljen i čelik**, koji podupire istraživačke projekte u sektoru ugljena i čelika. Svake godine oko 55 milijuna eura (47,7 milijuna eura za 2015.) stavlja se na raspolaganje sveučilištima, istraživačkim centrima i privatnim tvrtkama za financiranje projekata u tom području

4.1. Obzor Europa

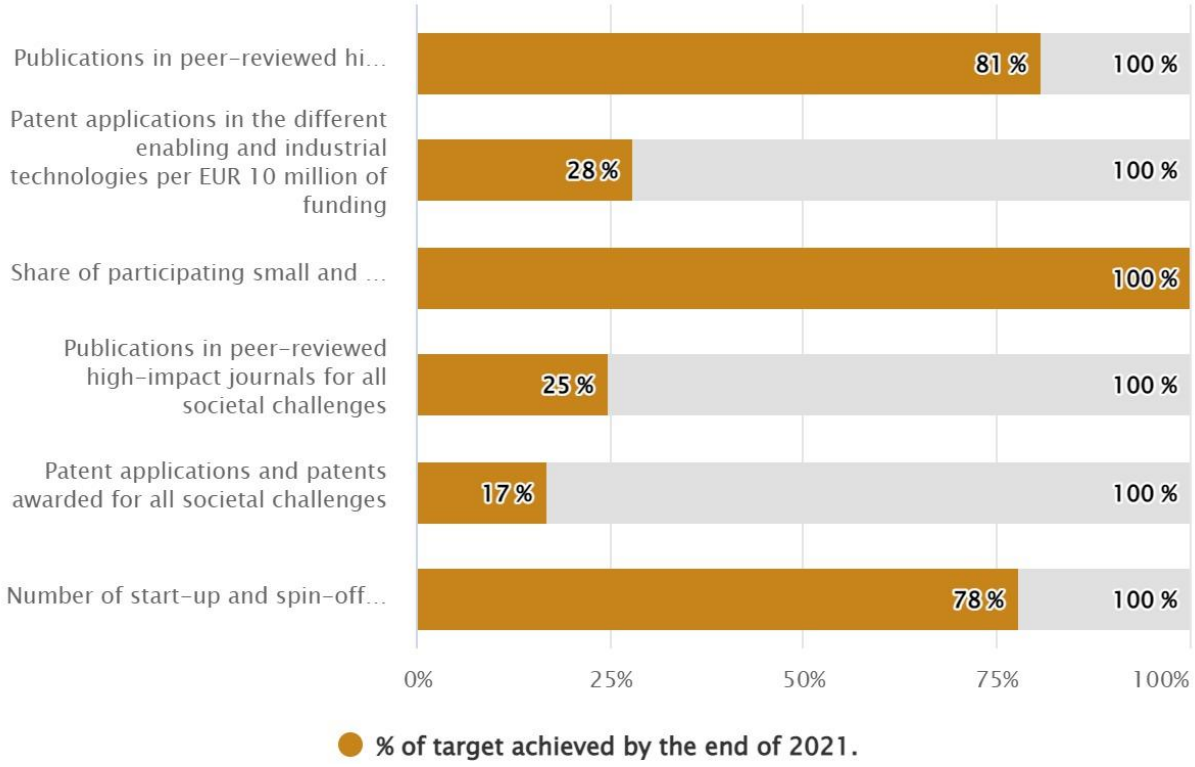
U vrijeme digitalizacije i rastućih promjena koje utječu na sve aspekte života, zemlje članice Europske unije susreću se s brojnim društvenim i gospodarskim izazovima, a za što uspješniju provedbu europskih strategija potreban je angažman i uključenost svih dionika. Uključivanjem javnosti i civilnog društva u provođenje europskih strategija i suradnja među različitim sektorima izravno utječu na povećanje broja društvenih inovacija i kreiranje inovacijskih ekosustava, koji su postali glavni način odgovora na suvremene društvene izazove. Razvoj društvenih inovacija zahtijeva veću fleksibilnost što podrazumijeva smanjenje administrativnih prepreka, otvorenost prema društvu te poticanje suradnje i dijeljenje znanja, a uključuje sve ranije spomenute aspekte i njihovu međusobnu sinergiju. Za zemlju pojedinačno, a u cilju održavanja konkurentnosti, potrebno je razvijati inovacijske strategije i ciljeve koji će integrirati različite dionike i javno mišljenje u procese stvaranja znanja, politika, vrijednosti i normi. Osim unutarnje integracije, velik naglasak stavlja se i na međunarodnu suradnju te razvijanje mehanizama kojima bi se prepoznale prilike, sličnosti i razlike u istraživačkim ciljevima te zajedničkom suradnjom pristupilo proučavanju istih. (Franc, Barišić, Palić, 2020) Jedan od instrumenata i potencijalnih načina suradnje u pogledu istraživačko-razvojnih aktivnosti je upravo program Obzor, najveći program Europske unije za istraživanje i inovacije.

Prema dostupnim podacima, pokazuje se kako je najveći problem Europske unije činjenica da svoj vodeći položaj u znanosti ne uspijeva prenijeti na područje inovacija i poduzetništva, čemu u prilog govori činjenica da Europa posjeduje 1/3 od svih visokokvalitetnih znanstvenih publikacija, a samo 1,3 % ulaganja poduzeća EU-a u istraživanje i razvoj. (Bukovec)

„Obzor 2020. glavni je program Unije za financiranje istraživanja i inovacija. Program je namijenjen borbi protiv klimatskih promjena, doprinosu u postizanju ciljeva održivog razvoja UN-a i poticanju konkurentnosti i rasta u EU-u. Njime se olakšava suradnja i jačanje učinka istraživanja i inovacija u razvoju te podupiru i provode politike EU-a uz rješavanje globalnih pitanja. Programom se podupire stvaranje i bolje širenje izvrsnosti u znanju i tehnologijama. Ujedno se otvaraju radna mjesta, potpuno iskorištavaju baze talenata EU-a, potiče gospodarski rast, promiče konkurentnost u industriji i optimizira učinak ulaganja u okviru ojačanog europskog

istraživačkog prostora. U programu mogu sudjelovati pravni subjekti iz EU-a i pridruženih zemalja.“ (Europska komisija)

Preteča programa Obzor Europa bio je upravo program Obzor 2020 za istraživanje i inovacije za programsko razdoblje 2014.-2020. godine i budžetom od skoro 80 bilijuna eura. Prioriteti programa Obzor 2020 su izvrsna znanost, industrijsko vodstvo i društveni izazovi, a horizontalne i posebne aktivnosti u okviru programa obuhvaćaju širenje izvrsnosti i sudjelovanja, znanost za društvo i u društvu, Europski institut za inovacije i tehnologiju (EIT), Zajednički istraživački centar (JRC) i EURATOM. (eu-projekti.info)



Slika 24. Pregled postavljenih i postotka ostvarenih ciljeva do kraja 2021. godine u programu Obzor 2020

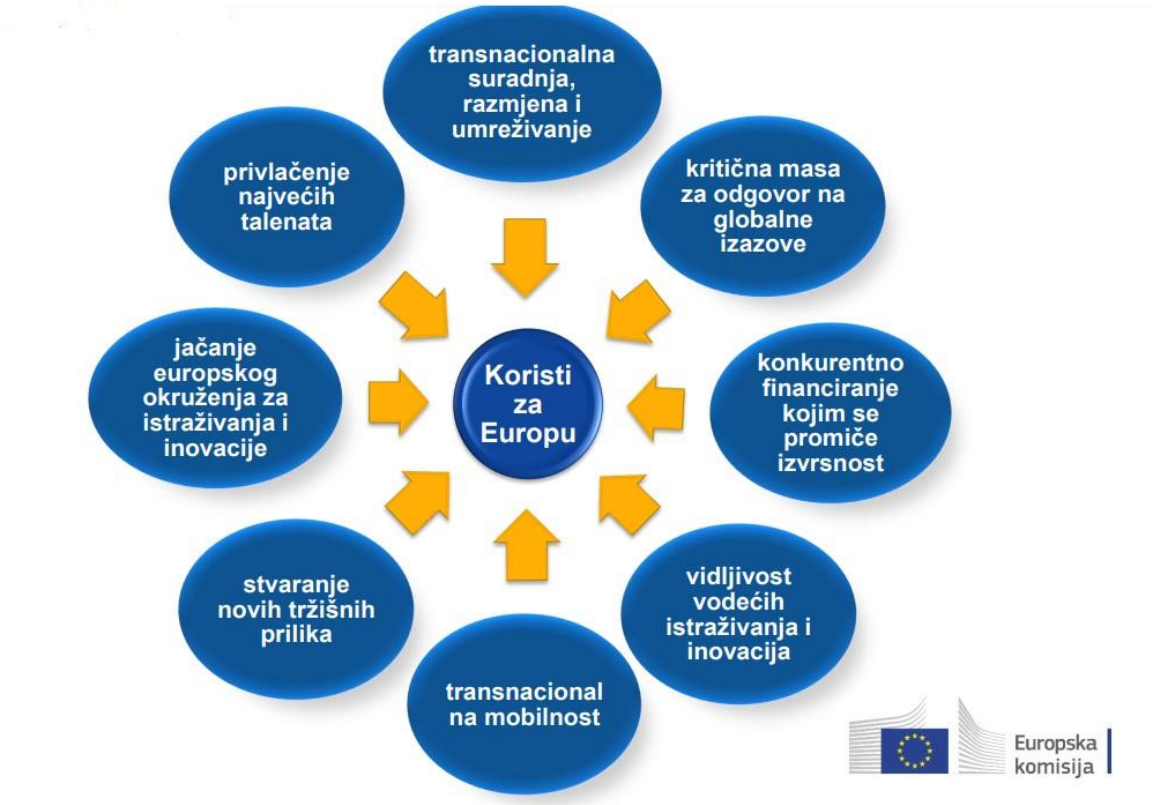
(Izvor: Europska komisija)

Mnogi projekti Obzora 2020 još uvijek su u tijeku, što se odražava u stopi plaćanja koja iznosi 82%, što objašnjava zašto neki ciljevi imaju rok nakon 2020.

Inicijative u okviru stupa **Izvrsna znanost** smatraju se zadovoljavajućima u pogledu realizacije ključnih ciljeva, inicijative u okviru stupa **Industrijsko vodstvo** dobro su napredovale, dok je stup **Društveni izazovi** pokazao umjeren napredak, a pokazatelji financiranja niži su od odgovarajućih ciljeva. Realniji rezultati očekuju se nakon završetka svih projekata, kada se općenito počnu i proizvoditi publikacije i patenti. (Europska komisija)

Kao nastavak programa Obzor 2020 za novo programsko razdoblje, nastao je Obzor Europa, okvirni program Europske unije za istraživanje i razvoj, s glavnim ciljevima jačanje znanstvenih i

tehnoloških temelja EU-a i europskog istraživačkog prostora (ERA), povećanje inovacijskih kapaciteta, konkurentnosti i broja radnih mjesta u Europi te ispunjenje prioriteta građana i održavanje našeg socioekonomskog modela i vrijednosti. Obzor Europa za istraživanje i inovacije za programsko razdoblje 2021.-2027. godine ponovno je povećao budžet, koji sada iznosi 95.51 bilijuna eura. (Bukovec)



Slika 25. Dodana vrijednost u okviru programa Obzor Europa

(Izvor:Bukovec)

U svim europskim strateškim dokumentima, uključujući programski okvir Obzor, nastoji se povezati istraživanja i inovacije te razraditi trokut znanja između obrazovanja, istraživanja i inovacija, a što bi trebalo predstavljati temelj za postizanje sinergijskih učinaka ulaganja u znanost i inovacije iz nacionalnih, regionalnih i međunarodnih fondova. Takva vrsta ulaganja trebala bi omogućiti povezivanje gospodarskog i znanstveno-istraživačkog sektora te bi unutar države dala aktivan doprinos u postizanju međunarodne kompetitivnosti, odnosno, stvaranje nove znanstvene, društvene, kulturne i gospodarske vrijednosti. Nova znanja i ideje, procesi, proizvodi i usluge kao i novo poduzetništvo sastavnice su istraživačkog stvaralaštva koje su međusobno čvrsto povezane. Zbog svega navedenog, cilj svake ekonomije trebala bi biti istraživačka prepoznatljivost, jaki istraživači i istraživačke skupine, koji daju svoj izravan utjecaj na gospodarstvo i društvo u cjelini. Takav način djelovanja zahtijeva autonomiju u upravljanju, financiranju i istraživanju, ali i odgovornost u stvaranju i prijenosu znanstvenih postignuća u društvo i gospodarstvo za sve sudionike takvog istraživačko-razvojnog procesa. (Šimpraga, 2020)

S druge strane, za sada je praksa mnogo drugačija i pokazuje da mnogim zemljama u Europskoj uniji i izvan nje nedostaje znanstveno-istraživački potencijal za razvoj gospodarstva i društva znanja, ali i da institucije inovacijskog sustava (vlada, lokalna uprava, razvojne agencije i sl.) nemaju dovoljno upravljačkih kapaciteta kojima bi imale znanja i bile u mogućnosti usmjeravati tehnološki razvoj. Jedan od velikih problema su i strukturni faktori, primjerice struktura lokalnog gospodarstva, tehnološke kompetencije poduzeća, ali i razvojno-istraživački znanstveni kapaciteti akademskog sektora, što ne doprinosi dovoljnoj efikasnosti znanstveno-istraživačkih sustava. (Švarc, Lažnjak, 2020)

5. Materijali i metodologija

U nastavku se prikazuje istraživački tijek i proces kroz istraživački materijal, metodologiju, postupak provedbe istraživanja te metode obrade podataka.

5.1. Istraživački materijal

Potencijalni utjecajni indikatori na povlačenje sredstava za znanost, istraživanje i inovacije tiču se upravo osnovnih aspekta razvoja neke države u promatranom području. Sveobuhvatna digitalizacija gospodarstva i društva s druge je strane donijela veliku promjenu na tržištu rada, ali i s aspekta povlačenja EU sredstava. Sustavi su se unaprijedili, partneri se umrežavaju putem portala s mogućnostima pretrage međunarodnih partnera u okviru postavljenih parametara, kao i mogućnošću povezivanja s tim partnerima digitalnim putem. Digitalizacija obrazovanja i poslovanja financiraju se na različite načine, a glavni im je cilj unaprijediti i digitalizirati procese. *Eurostat* je, s pojavom pandemijske krize identificirao sasvim novi skup pokazatelja i način mjerenja digitalnih vještina, kako bi se što bolje pokazalo realno stanje društva u tom pogledu i poduzele eventualne radnje za poboljšanja. S druge strane, ulaganja u istraživanje i razvoj neke države, kao i udio ulaganja poduzeća u istraživanje i razvoj mogućnost su sagledavanja suradnje i sinergije znanstvene i gospodarske zajednice, a što bi trebao biti cilj i potencijalni način rješavanja budućih društvenih izazova i globalnih ciljeva.

Za potrebe istraživačkog dijela ovog rada korištene su dvije vrste izvora:

- **Sekundarni izvori**, putem kojih su analizirani pojmovi i procesi unutar teme i predmeta istraživanja
- **Baze i *online* alati poslovne inteligencije**, a koji su sagledavani su okviru povlačenja sredstava za Obzor projekte, Digitalnih vještina, Ulaganja poduzeća u istraživanje i razvoj te inovacijskog uspjeha koji obuhvaća 12 dimenzija s različitim skupovima ranije spomenutih faktora svrstanih u određene kategorije.

5.2. Metodologija

Prikupljanje potrebnih podataka i saznanja provedeno je korištenjem *desk*-metode, odnosno metode istraživanja *za stolom* analiziranjem već prikupljenih podataka, a to se odnosilo na:

- **Analizu sadržaja**, za potrebe konceptualizacije, operacionalizacije, ali i interpretacije istraživanja i istraživačkog sadržaja i problema

- **Analizu statističkih podataka i dokumenata**, što se primarno odnosi na statističke pokazatelje o društvenim djelatnostima i pojavama iz baze *Eurostat,* kategorija Znanost, tehnologija i digitalno društvo te dva alata poslovne inteligencije – alat programa Obzor i alat Europske komisije vezan uz Europsku ljestvicu uspjeha u inoviranju

5.3. Metodologija provedbe istraživanja

Provedba istraživanja može se prikazati kroz nekoliko ključnih faza istraživačkog procesa:

FAZA 1: Obrada teorijskog dijela

Za potrebe teorijskog dijela rada korišteni su sekundarni izvori s osnovnim ciljem što detaljnijeg uvida u dostupne izvore literature i identifikacije najrelevantnijih izvora. U tu svrhu, uočene su 4 glavne kategorije izvora, a koje uključuju knjige, znanstvene članke, Internet izvore, EU strateške dokumente i publikacije. Knjige su korištene kako bi se dobio detaljniji uvid u razvoj i pojmovna određenja proučavanih tema te pokušali utvrditi najznačajniji okviri u kojima bi se kretao sljedeći istraživački korak. Nakon proučavanja knjiga kao izvora, sljedeći korak sadržavao je analizu znanstvenih članaka u okviru promatrane problematike. Kod znanstvenih članaka, a uzimajući u obzir činjenicu brzog razvoja i promjena konteksta svih proučavanih pojmova, za potrebe rada pretražene su baze *Web of Science* i *Scopus*, kao dvije najznačajnije citatne baze podataka, kao i najznačajnije baze hrvatskog zakonodavnog okvira koji pokriva područje izbora u znanstvena i znanstveno-nastavna zvanja. Pretraživanje se odvijalo po ključnim riječima, uz obvezan otvoren pristup i faktor relevantnosti a koji je podrazumijevao radove ne starije od 5 godina. Treća kategorija izvora uključivala je Internet izvore i korištena je u slučaju nepostojanja drugih izvora, odnosno relevantne obrade istraživanih pojmova i okvira putem Internet izvora, ali i za određivanje smjera istraživanja u okviru strateških dokumenata, odluka i publikacija na razini Europske unije. Posljednju kategoriju činili su EU strateški dokumenti i publikacije, a kojima je posebna pozornost posvećena prilikom analize i razumijevanja konteksta funkcioniranja strateških planova i smjernica te osvrta na dosadašnji napredak. Na osnovu osnovnih strateških okvira, a putem službenih stranica Europske komisije, izvršen je uvid i pregledana je većina publikacija koje istraživačku problematiku sagledavaju iz različitih aspekata, područja i dimenzija. Time je ujedno i završena obrada teorijskog dijela, kao prva faza u procesu provedbe istraživanja.

FAZA II: Empirijski dio istraživanja

U drugoj fazi, a nakon izvršene analize i interpretacije dostupnih izvora u promatranim okvirima i temi, za potrebe empirijskog dijela istraživanja pretražene su javno dostupne baze te je primjenom *desk*-metode napravljena osnovna analiza statističkih podataka dostupnih u više baza, a kako bi se moglo selektirati one najrelevantnije za potrebe predmetnog istraživanja. S tim ciljem i nastojanjem, kao i postavljenim okvirima uzorka, korištena je i analizirana baza Eurostat, kao statistički sustav Europske unije koji daje širinu i pruža više mogućnosti kod selekcije relevantnih indikatora. Uz bazu, korištena su i dva interaktivna sustava koja koriste vlastite alate poslovne inteligencije kako bi vizualizirala najvažnije spoznaje i rezultate i to: Qlik alat koji kao *Horizon Dashboard* nudi mogućnosti selekcije i izdvajanja traženih podataka o sredstvima i realizaciji programa Horizon 2020 i ranijih verzija programa za istraživanje i inovacije te modul EIS-RIS, a koji kao interaktivni alat Europske komisije unutar kategorije istraživanja i inovacija pruža brojčane i vizualne rezultate odabranih indikatora i dimenzija.

FAZA III: Prikupljanje rezultata

Treća faza istraživačkog procesa rezultirala je odabirom skupova indikatora unutar promatranih baza i alata. Za svaki od skupova potom su analizirane dodatne mogućnosti te je takva selekcija u konačnici rezultirala s preuzimanjem nekoliko različitih tablica u excel formatu. Prije poduzimanje sljedećeg koraka, a s obzirom na različite baze korištene prilikom preuzimanja podataka, a za potrebe daljnje analize, provedeno je potrebno usklađenje kako bi se sve tablice pripremile za daljnji rad te bi bilo lakše identificirati veze u samom alatu. Excel tablice su dodatno uređene, uklonjeni su viškovi i objašnjenja, dodani nazivi, spojene određene kategorije za potrebe kasnije analize i promatranja, što je u konačnici dovelo do stvorenih svih potrebnih preduvjeta za daljnje analize korištenjem alata poslovne inteligencije.

FAZA IV: Obrada podataka

Četvrta faza istraživačkog procesa odnosila se na obradu podataka, a odvijala se koristeći alat poslovne inteligencije Power BI. Microsoft Power BI alat nudi razne mogućnosti prikaza, od kojih su najvažnije prikaz Izvješća, prikaz Podataka i prikaz Odnosa. Kao takav, čini jedinstven skup pomoćnih sredstava kod nastojanja kreiranja materijala za potrebe elaboracije istraživačkog pitanja, odnosno dokazivanje hipoteza. Mogućnost stavljanja u međusobni odnos 2 ili više različitih indikatora ili varijabli čini ga vrlo interaktivnim u pogledu promatranja utjecajnih faktora jedne dimenzije na drugu ili više njih. U alatu su obrađeni svi pripremljeni podaci te je potom selektirano nekoliko najvažnijih za potrebe daljnje obrade u tekstualnom obliku.

FAZA V: Diskusija rezultata i elaboracija hipoteza

Kao peta i ujedno posljednja faza istraživačkog procesa, pripremljena je diskusija rezultata i elaboracija hipoteza. Tom su prilikom selektirani vizuali opisani tekstualno te su zapažene i istaknute neke najznačajnije spoznaje, zanimljiva saznanja i eventualna odstupanja od trenda. Na taj je način provedena i elaboracija hipoteza i istraživačkog pitanja te je utvrđeno jesu li hipoteze potvrđene, je li odgovoreno na istraživačko pitanje i što je najvažnije zamijećeno prilikom obrade podataka. Iz navedenih su okvira izvedena i istraživačka ograničenja, istaknuti doprinosi te navedene mogućnosti za daljnja istraživanja i analize.

5.4. Metode obrade podataka

Rad se sastoji od dva dijela: teorijskog, kroz koji su obrađeni osnovni pojmovi i saznanja vezani uz proučavanu temu, i empirijskog dijela u okviru kojeg je provedeno istraživanje.

Metode korištene u ovom radu su:

- **Metoda analize** kojom se raščlanjivanjem određenih tvrdnji pokušala stjeći jasnija slika o proučavanim objektima
- **Metoda sinteze** kojom su pojedine jednostavne tvrdnje nastojale biti povezane u one složenije i općenitije kako bi se objekti koje se analiziraju i istražuju mogli detaljnije proučiti
- **Metoda indukcije i dedukcije** koje su primarno služile za izvođenje zaključaka u teorijskom i empirijskom dijelu istraživanja kratkom elaboracijom svakog poglavlja
- **Metoda generalizacije** s ciljem uopćavanja pojmova, od posebnih do općenitijih
- **Metoda deskripcije** koja je korištena prilikom opisivanja pojmova, okvira, grafičkih vizuala, primjera i relevantnih politika
- **Metoda komparacije** kojom se nastojalo usporediti slične činjenične procese.

6. Rezultati

U poglavlju Rezultati istraživanja prikazani su predmet i cilj istraživanja te istraživačko pitanje i hipoteze, a potom je predočena vizualizacija istraživačkih rezultata koja je potkrijepljena tekstualnim opisima vezanim uz korake istraživanje te korištene tehnike i metode za potrebe odabira analiziranog uzorka.

6.1. Predmet i cilj istraživanja

Predmet ovoga rada je povlačenje sredstava iz fondova Europske unije za znanost, istraživanje i inovacije. Radom se želi ukazati na ključne pokazatelje, odnosno čimbenike uspješnosti prijavitelja koji su realizirali projekte u okviru financijskih instrumenata za istraživanje i razvoj.

Cilj rada je identificirati utjecajne faktore promatrajući skup tzv. horizontalnih čimbenika gospodarskog razvoja unutar kategorije znanosti, tehnologije, istraživanja, razvoja i inovacija, uključujući pritom i dimenziju digitalizacije koja se, uz zelenu tranziciju, spominje kao jedna od okosnica i osnovnih faktora razvoja društva u cjelini.

6.2. Istraživačko pitanje i hipoteze

U odnosu na problem i svrhu istraživanja, a koristeći koncept i metode poslovne inteligencije, definirano je **istraživačko pitanje** koje glasi: Kako je moguće primjenom poslovne inteligencije utvrditi potencijal zemlje za povlačenje sredstava za znanost, istraživanje i inovacije iz fondova Europske unije? te su temeljem navedenog pitanja postavljene sljedeće hipoteze:

H1: Povlačenje sredstava iz programa Obzor ovisi o razini digitalnih vještina stanovništva zemlje

H2: Ulaganja poslovnog sektora u istraživanje i razvoj utječu na povlačenje sredstava iz programa Obzor

H3: Alatima poslovne inteligencije moguće je identificirati koje inovacijske dimenzije utječu na povlačenje sredstava iz programa Obzor.

Budući da alati poslovne inteligencije pružaju široke mogućnosti obrade i interpretacije podataka, za potrebe ovog rada cilj je bio podatke ujednačiti za daljnju obradu te pronaći i identificirati veze, kao i pokušati izvući, iz skupa podataka o državama Europske unije one najrelevantnije u kontekstu istraživačkog pitanja, a koje mogu ulaziti u kategoriju međusobne usporedbe. Tim je koracima postavljeno istraživanje, odnosno mogućnost stavljanja u odnos različitih indikatora kako bi se testiralo hipoteze i pokušalo dati odgovor na istraživačko pitanje.

6.3. Opis rezultata istraživanja

U nastavku navedenog poglavlja prikazat će se i pokušati elaborirat najvažnije pokazatelje vezano uz postavljeno istraživačko pitanje i hipoteze, i to pojedinačno kroz određene skupove i kategorije podataka unutar izabranih pokazatelja, a potom i kroz usporedbu s dobivenim Obzor sredstvima.

6.3.1. Obzor 2020

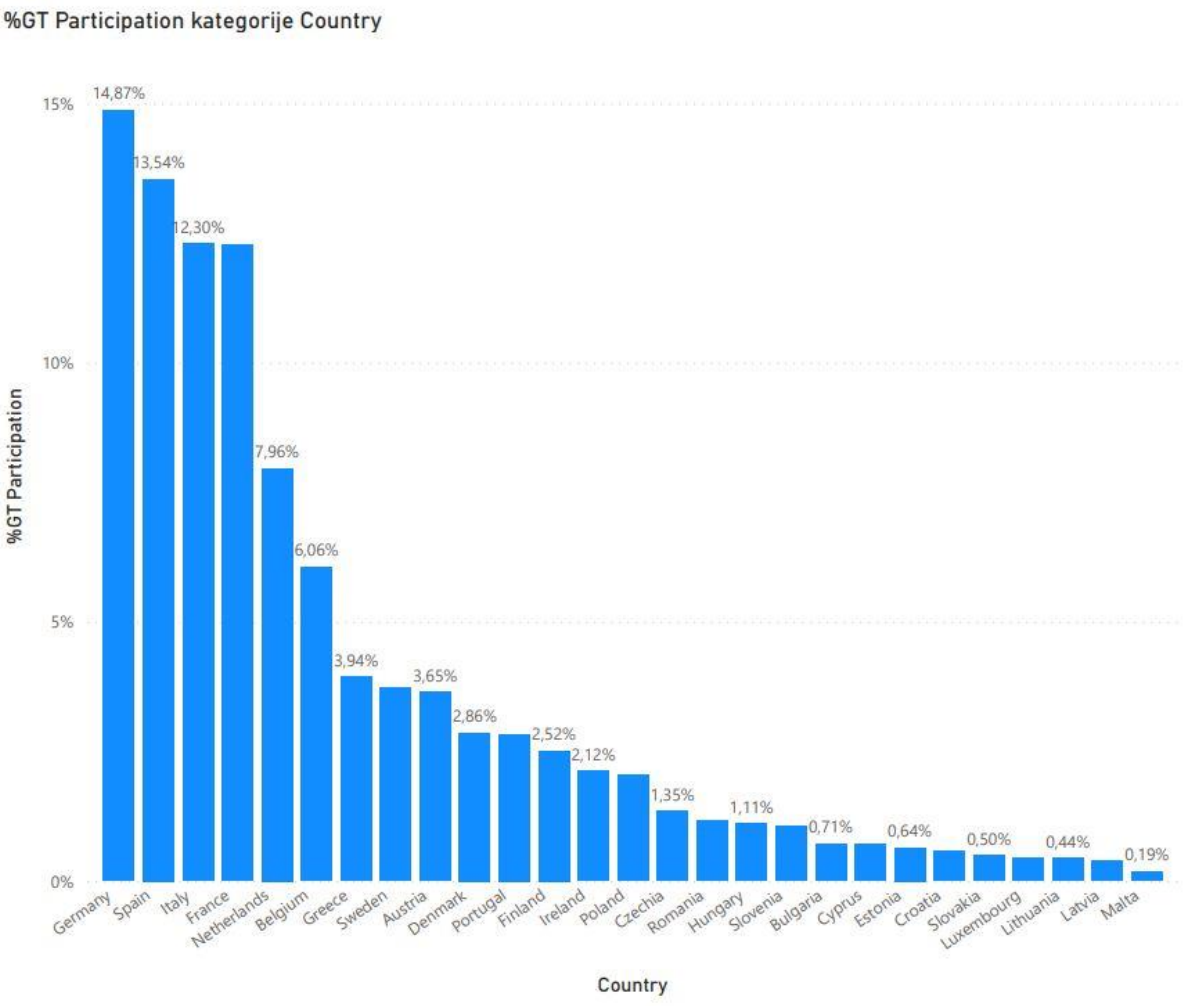
Poglavlje Obzor 2020 prikazuje osnovne pokazatelje, okvire i izvedbu država članica Europske unije u pogledu prijave i realizacije projekata te skupne pokazatelje u pogledu znanstvenog područja u kojem se financiralo najviše projekata, kao i vrste organizacija koje su sudjelovale u spomenutim projektima.

Prvi pokazatelj korišten u prikazu je pokazatelj **Sudjelovanje/partnerstvo**, a koji podrazumijeva uključenost pravne osobe u projekt (sudjelovanje), s time da ta pravna osoba može imati različite uloge i obveze. Jedan sudionik može biti uključen u jednu ili više projekata, te se sukladno tome navedeno promatra kao jedno ili više sudjelovanja. (Horizon 2020-Interreg synergies, Quick guide)

Tablica 2. Tablični prikaz sudjelovanja država članica Europske unije u Obzoru 2020 izražen kao broj i postotak

(Izvor: izrada autora prema Prilog 1, 1.)

Country	Participation	%GT Participation
Austria	5074	3,65%
Belgium	8422	6,06%
Bulgaria	992	0,71%
Croatia	815	0,59%
Cyprus	983	0,71%
Czechia	1880	1,35%
Denmark	3976	2,86%
Estonia	892	0,64%
Finland	3497	2,52%
France	17074	12,28%
Germany	20672	14,87%
Greece	5476	3,94%
Hungary	1545	1,11%
Ireland	2949	2,12%
Italy	17098	12,30%
Latvia	541	0,39%
Lithuania	611	0,44%
Luxembourg	626	0,45%
Malta	259	0,19%
Netherlands	11069	7,96%
Poland	2841	2,04%
Portugal	3944	2,84%
Romania	1615	1,16%
Slovakia	691	0,50%
Slovenia	1477	1,06%
Spain	18823	13,54%
Sweden	5186	3,73%
Ukupno	**139028**	**100,00%**

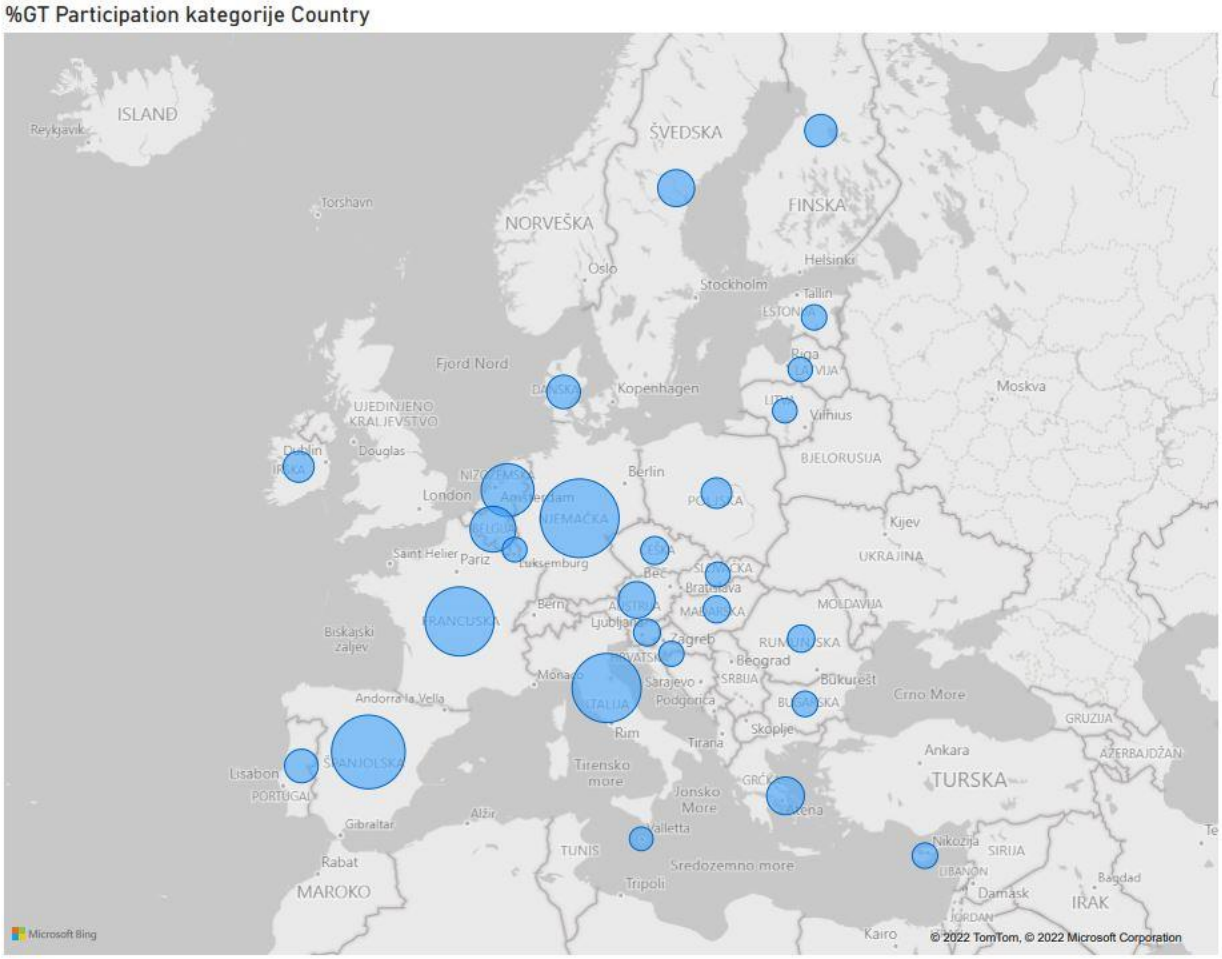


Vizual 1. Grafički prikaz sudjelovanja država članica EU u programu Obzor, izraženo u postotku od ukupnog sudjelovanja svih država

(Izvor: izrada autora prema Prilog 1, 1.)

Prikazom postotak sudjelovanja, odnosno raspodjele sudjelovanja unutar država članica, jasno je vidljivo da su zemlje s najvišim postocima sudjelovanja u Obzor 2020 programu i one zemlje koje su najveće u prostornom kontekstu, broju stanovništva te najrazvijenije u gospodarskom kontekstu, ali su to istovremeno i one zemlje koje u najvećem postotku doprinose budžetu Europske unije kroz vlastiti BDP. Zemlje koje prednjače su Njemačka s 20.672 sudjelovanja, odnosno14.87% ukupnog sudjelovanja, Španjolska s 18.823 sudjelovanja, odnosno 13.54% ukupnog sudjelovanja, te Italija, Francuska i Nizozemska s 17.098, 17.074 i 11.069 sudjelovanja, odnosno 12.30%, 12.28% i 7.96%. Postotak Nizozemske već je osjetno manji u odnosu na ostale 4 zemlje, što se može pripisati veličini te zemlje koja je također osjetno manja, što se može objasniti naglim padom postotka unatoč činjenici da u ukupnom sudjelovanju stoji na petom mjestu na razini Europske unije. Države s najmanje sudjelovanja su Hrvatska s 815 sudjelovanja,

odnosno 0,59% ukupnog sudjelovanja, Slovačka sa 691, odnosno 0,50% ukupnog sudjelovanja, Luksemburg s 626, odnosno 0,45% ukupnog sudjelovanja, te Litva, Latvija i Malta s 611, 541 i 259 sudjelovanja, 0,44%, 0,39% i 0,19%. Prema navedenom prikazu za države s najmanje sudjelovanja razvidno je kako nemaju zajedničku poveznicu u gospodarskom smislu, no imaju u prostornom i ljudskom potencijalu, uzimajući u obzir da su to sve države koje su prostorno i po pitanju stanovništva manje, no svaka ima svoj zasebni politički, gospodarski i prostorni kontekst, a što je vidljivo i iz vizuala niže.



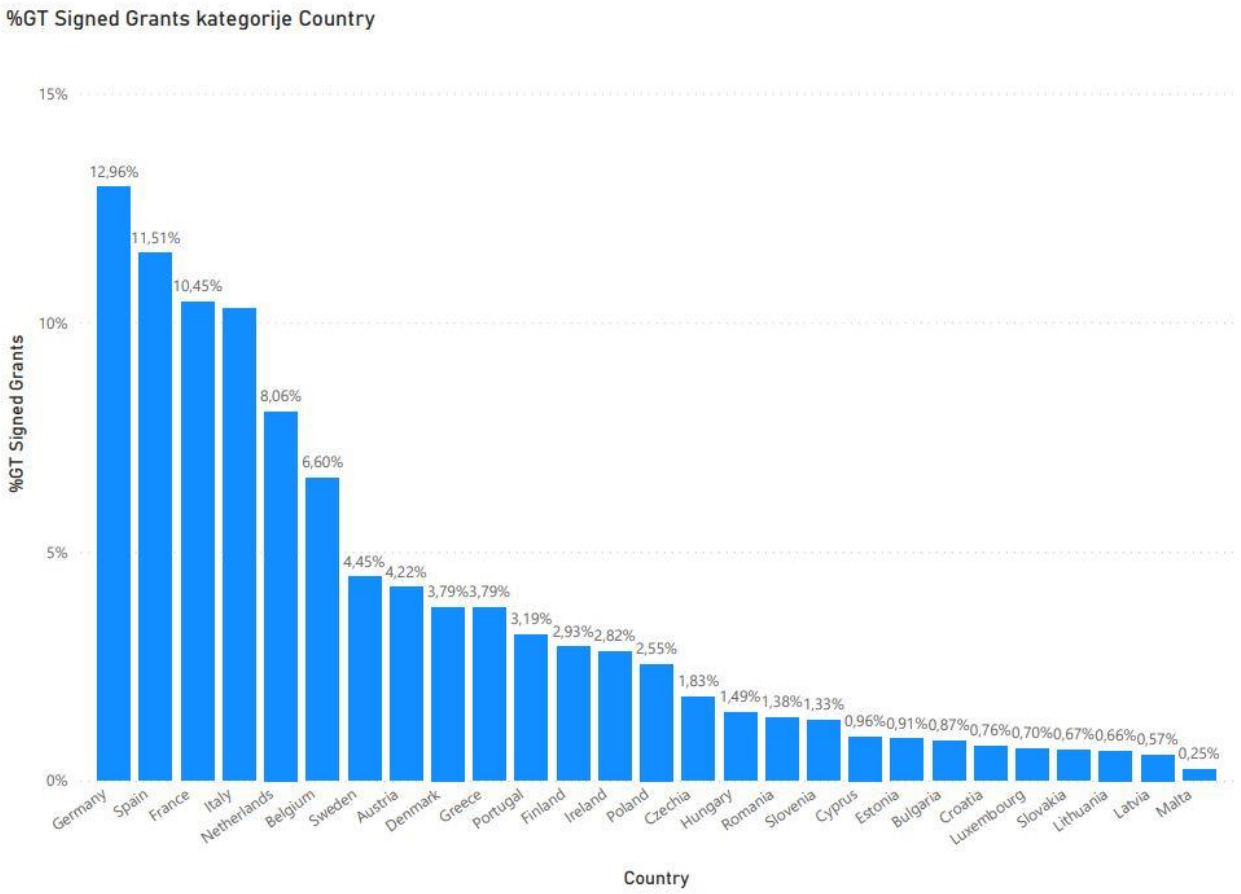
Vizual 2. Geografski prikaz sudjelovanja država članica EU u programu Obzor, izraženo u postotku od ukupnog sudjelovanja svih država
(Izvor: izrada autora prema Prilog 1, 1.)

Sljedeći promatrani i analizirani pokazatelj je **Broj potpisanih ugovora**, promatran po pojedinim državama, prikazan kao ukupan broj po državi, a potom kao postotak od ukupnog zbroja potpisanih ugovora.

Tablica 3. Tablični prikaz broj potpisanih ugovora unutar Obzora 2020 po državama članicama Europske unije u Obzoru 2020 izražen kao broj i postotak
(Izvor: izrada autora prema Prilog 1, 1.)

Country	Signed Grants	%GT Signed Grants
Austria	3226	4,22%
Belgium	5051	6,60%
Bulgaria	663	0,87%
Croatia	581	0,76%
Cyprus	735	0,96%
Czechia	1397	1,83%
Denmark	2900	3,79%
Estonia	698	0,91%
Finland	2239	2,93%
France	7993	10,45%
Germany	9910	12,96%
Greece	2896	3,79%
Hungary	1143	1,49%
Ireland	2154	2,82%
Italy	7887	10,31%
Latvia	436	0,57%
Lithuania	502	0,66%
Luxembourg	536	0,70%
Malta	192	0,25%
Netherlands	6164	8,06%
Poland	1949	2,55%
Portugal	2439	3,19%
Romania	1052	1,38%
Slovakia	511	0,67%
Slovenia	1014	1,33%
Spain	8805	11,51%
Sweden	3402	4,45%
Ukupno	**76475**	**100,00%**

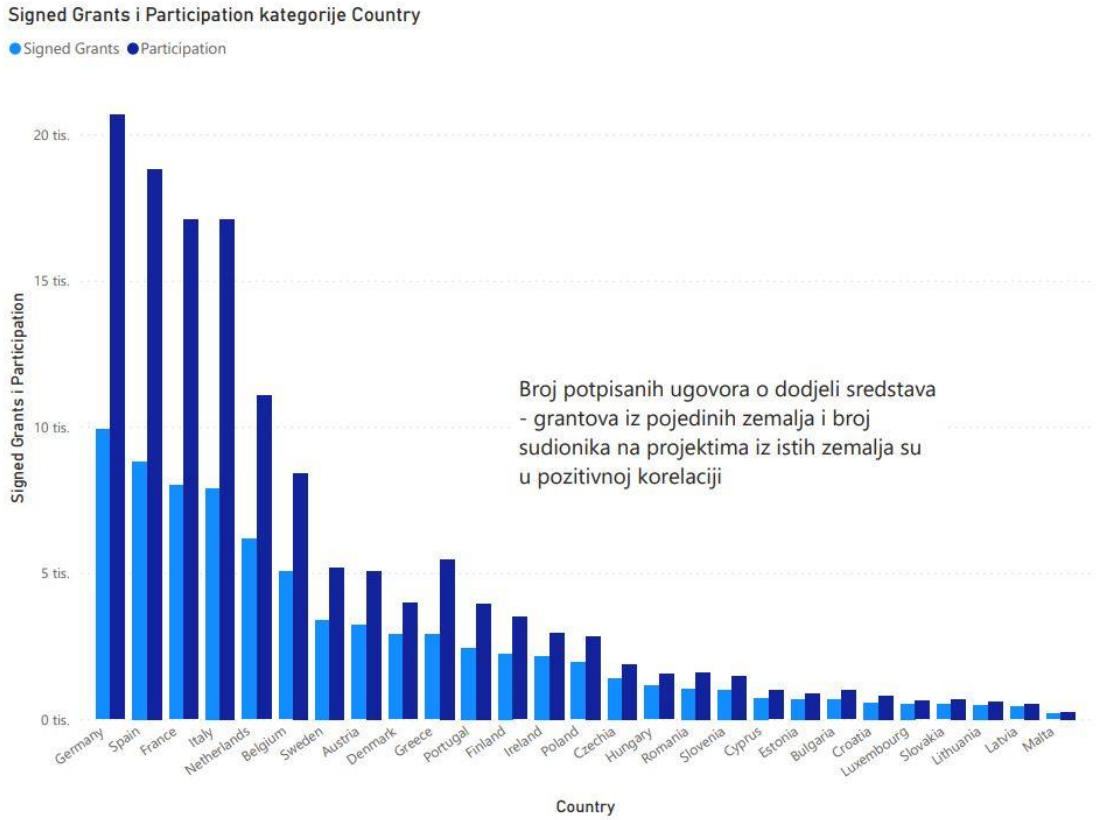
Iz tablice je vidljivo da i u ovom segmentu prednjače Njemačka, Španjolska, Francuska, Italija i Nizozemska koje sve redom imaju udio veći od 10% u okviru kategorije udio potpisanih ugovora po državi u odnosu na ukupan broj potpisanih ugovora, dok je Nizozemska, vjerojatno iz ranije spomenutih razloga također visoko na ljestvici, na 5. mjestu, ali s ukupno nešto više od 8% udjela u ukupnom broju potpisanih ugovora. Države koje su najslabije u ovoj kategoriji također su vrlo slične prethodnoj kategoriji, pa su tako posljednjih 6 država na ljestvici, a koje ujedno imaju i udio manji od 1% u kategoriji Hrvatska, Luksemburg, Slovačka, Litva, Latvija i Malta. Tablični prikaz pretvoren je i u vizual, a koji je vidljiv u nastavku.



Vizual 3. Grafički prikaz potpisanih ugovora unutar Obzora 2020, izraženo u postotku od ukupnog zbroja za sve države

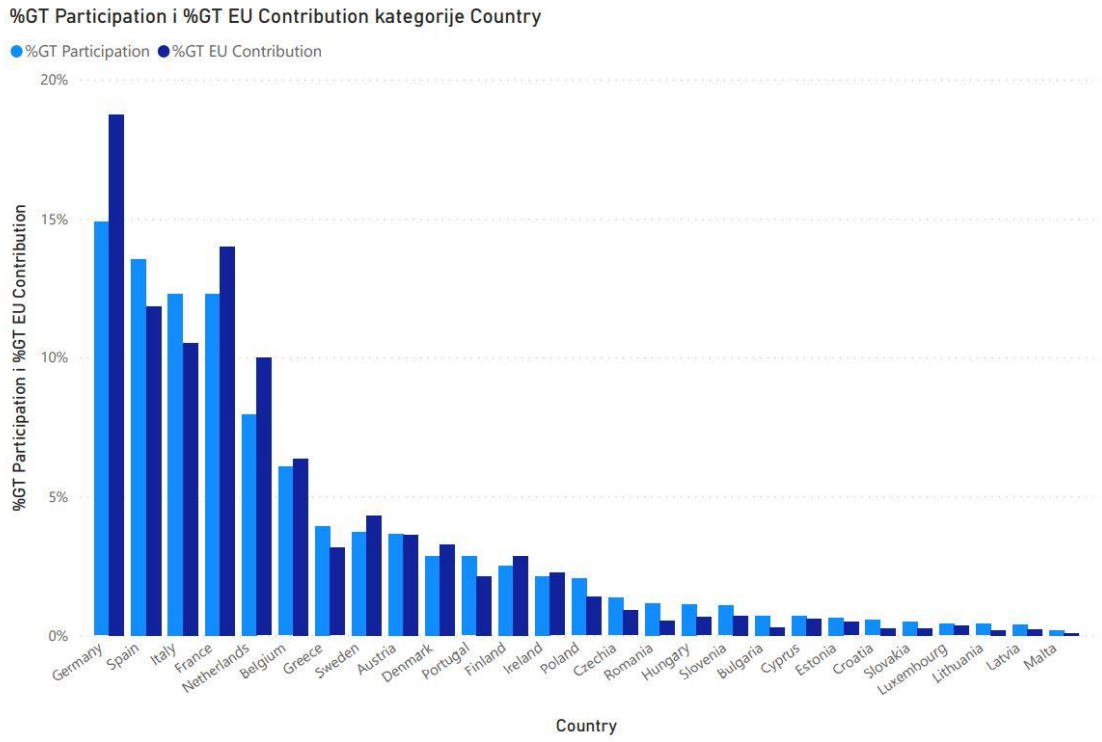
(Izvor: izrada autora prema Prilog 1, 1.)

Stavljanjem u odnos ove dvije promatrane kategorije, broja potpisanih ugovora o dodjeli sredstava i broja sudionika za svaku pojedinu zemlju, jasno je vidljiva njihova pozitivna korelacija, koja pokazuje ranije elaborirano na primjeru svih država Europske unije korisnica programa Obzor 2020, odnosno da su države koje imaju najveći broj sudionika u Obzoru ujedno i one države koje potpisuju najviše ugovora, pri čemu je potpisani ugovor kategorija koja je vezana uz instituciju iz države kao nositelja projekta, dok je kod sudjelovanja to moguće biti i u nekom drugom svojstvu izuzev nositelja. Takvu pozitivnu korelaciju prikazuje vizual 4. Pozitivna korelacija vidljiva je i na vizualu 5, i to između udjela zemalja u potpisanim ugovorima i udjela u ukupno dodijeljenim sredstvima. Naime, iz vizuala je razvidno kako su države koje su najzastupljenije u Obzoru po pitanju sudjelovanja ujedno i one države koje imaju znatno veći udio u primljenim EU sredstvima od udjela u sudjelovanju, što može značiti da povlače i veće iznose financiranja, natječaje koje sufinanciraju 100% projekta i/ili stupove i natječaje s najvišim iznosima maksimalnog financiranja.



Vizual 4. Prikaz korelacije između broja potpisanih ugovora o dodjeli sredstava i broja sudionika na projektima po zemljama

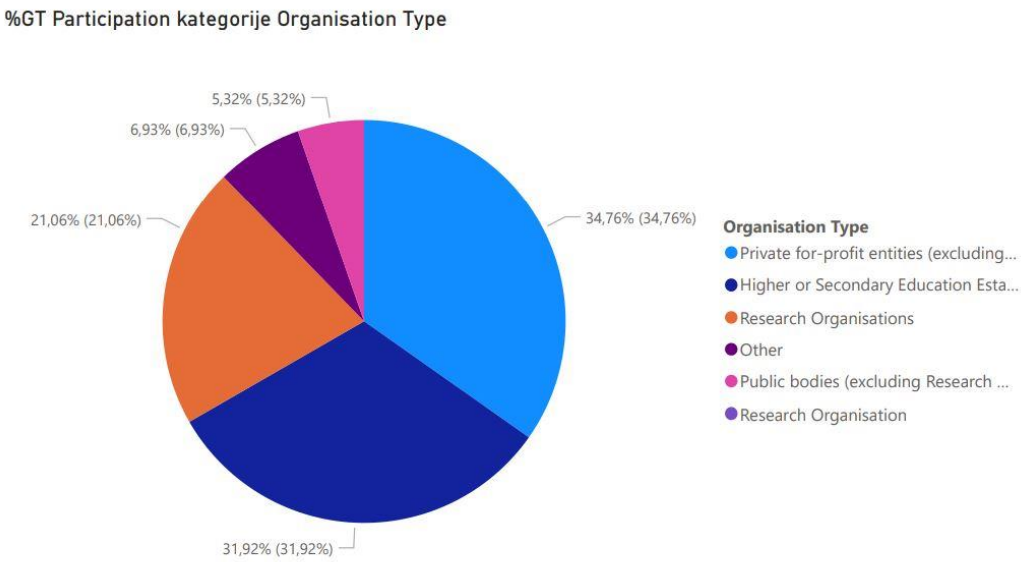
(Izvor: izrada autora prema Prilog 1, 1.)



Vizual 5. Prikaz korelacije između broja sudionika na projektima i udjela u primljenim sredstvima za Obzor

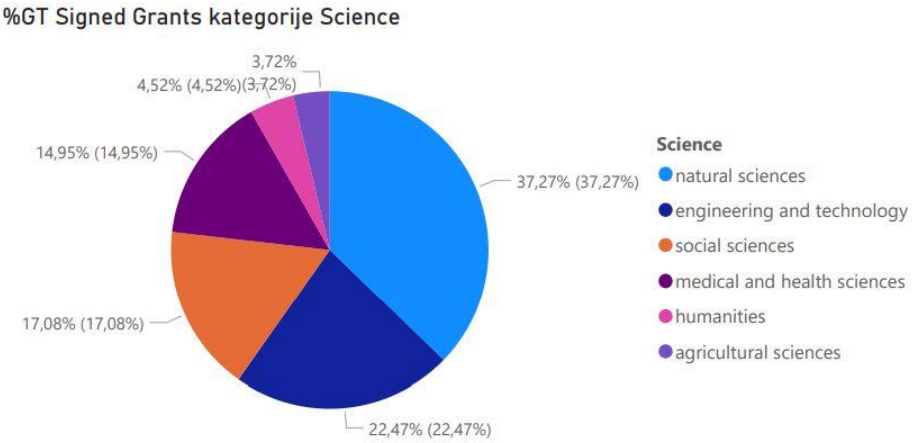
(Izvor: izrada autora prema Prilog 1, 1.)

Kod analize cjelokupnog Obzor programa, važno je i sagledati sveukupno sudjelovanje u kategoriji organizacija koje sudjeluju i u kojem omjeru te koja područja znanosti su najzastupljenija kod financiranih projekata.



Vizual 6. Prikaz udjela sudjelovanja različitih vrsta organizacija u programu Obzor 2020
(Izvor: izrada autora prema Prilog 1, 1.)

Od ukupno 5 različitih kategorija organizacija koje sudjeluju u Obzoru, najzastupljenija kategorija je privatni profitni subjekti (ne uključujući srednje ili više obrazovne ustanove) koja sudjeluje sa skoro 35% udjela, slijede ju više ili srednje obrazovne ustanove sa skoro 32% sudjelovanja, a potom su to istraživačke organizacije s nešto više od 21% sudjelovanja, ostali koji nisu dio niti jedne od spomenutih kategorija sa skoro 7% sudjelovanja, slijede ih javna tijela koja nisu istraživačke organizacije ili ustanove srednjeg i višeg obrazovanja s više od 5% udjela.



Vizual 7. Prikaz udjela različitih znanstvenih područja i polja u programu Obzor 2020
(Izvor: izrada autora prema Prilog 1, 1.)

Od znanstvenih područja i polja, najzastupljenije po pitanju povlačenja sredstava su prirodne znanosti sa skoro 40% udjela u ukupnom sudjelovanju, slijedi ih inženjerstvo i tehnologija s 22,47%, društvene znanosti s 17,08%, medicinske i zdravstvene znanosti s 14,95% te humanističke znanosti sa 4,52% i poljoprivredne znanosti s 3,72%.

Iz navedenih grafova proizlazi činjenica da su najvažnije ustanove za prijavu Obzor natječaja upravo privatni sektor i ustanove srednjeg i višeg obrazovanja, a najzastupljenije kategorije spadaju u STEM područja.

6.3.2. Digitalne vještine

Kod analize digitalnih vještina, glavni promatrani indikator odnosi se na digitalne vještine populacije pojedine zemlje, unutar kojih je analizirano i nekoliko drugih popratnih kategorija indikatora koje *Eurostat* prati.

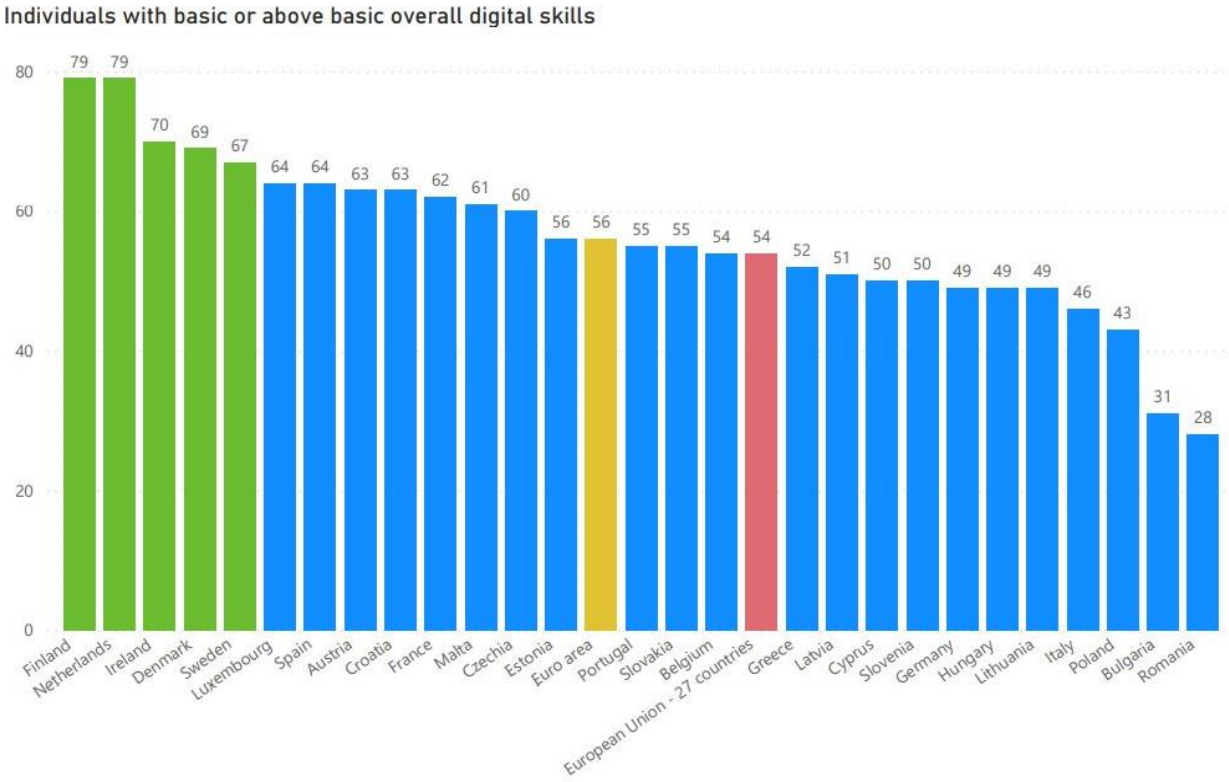
Prema *Eurostatu*, tumačenja i kategorizacija za navedenu vještinu se promijenila prilikom novog mjerenja za 2021. godinu te je skup vještina u ovom slučaju promijenjen, odnosno prilagođen činjenici pandemije i života u virtualnom svijetu te potrebi za savladavanjem sasvim novog seta vještina, kao i činjenice da bi ljestvica trebala biti viša, a kategorizacija prilagođenija. U tablici je prikazan indikator i njegove glavne karakteristike do 2019. godine i od 2021. godine.

Tablica 4. Usporedba indikatora digitalnih vještina i digitalnih vještina 2.0

(Izvor: izrada autora prema Prilog 1, 2. i Prilog 1, 3.)

Digitalne vještine – objašnjenje i okviri do 2019. godine	**Digitalne vještine 2.0 – objašnjenje i okviri od 2021. godine**
Indikator digitalnih vještina koji se temelji na odabranim aktivnostima koje obavljaju pojedinci u dobi od 16 do 74 godine na internetu u **četiri specifična područja (informacije, komunikacija, rješavanje problema, stvaranje sadržaja)**. Pretpostavlja se da pojedinci koji su obavljali određene aktivnosti imaju odgovarajuće vještine, stoga se pokazatelj može smatrati zamjenom digitalnih kompetencija i vještina pojedinaca. Pojedinci s "iznad osnovnom" (I_DSK_AB) razinom vještina: - "iznad osnovnog" u sva 4 područja. Pojedinci s "osnovnom" (I_DSK_B) razinom vještina: - **barem jedan "osnovni"**, ali ne i "bez vještina" u sva 4 područja.	Indikator digitalnih vještina 2.0 (DSI) složeni je pokazatelj koji se temelji na odabranim aktivnostima povezanim s korištenjem interneta ili softvera koje pojedinci u dobi od 16 do 74 godine obavljaju u **pet specifičnih područja (informacijska i podatkovna pismenost, komunikacija i suradnja, stvaranje digitalnog sadržaja, sigurnost i rješavanje problema**). Pretpostavlja se da pojedinci koji su obavljali određene aktivnosti imaju odgovarajuće vještine. Pokazatelji se mogu smatrati zamjenom digitalnih vještina pojedinaca. Pojedinci s "iznad osnovnom" (I_DSK2_AB) razinom vještina: - "iznad osnovnog" u svih 5 područja. Pojedinci s "osnovnom" (I_DSK2_B) razinom vještina: - **ako je svih 5 područja barem osnovna razina** (neka mogu biti "osnovna", a neka mogu biti "iznad osnovne", ali nisu svih 5 područja "iznad osnovne").

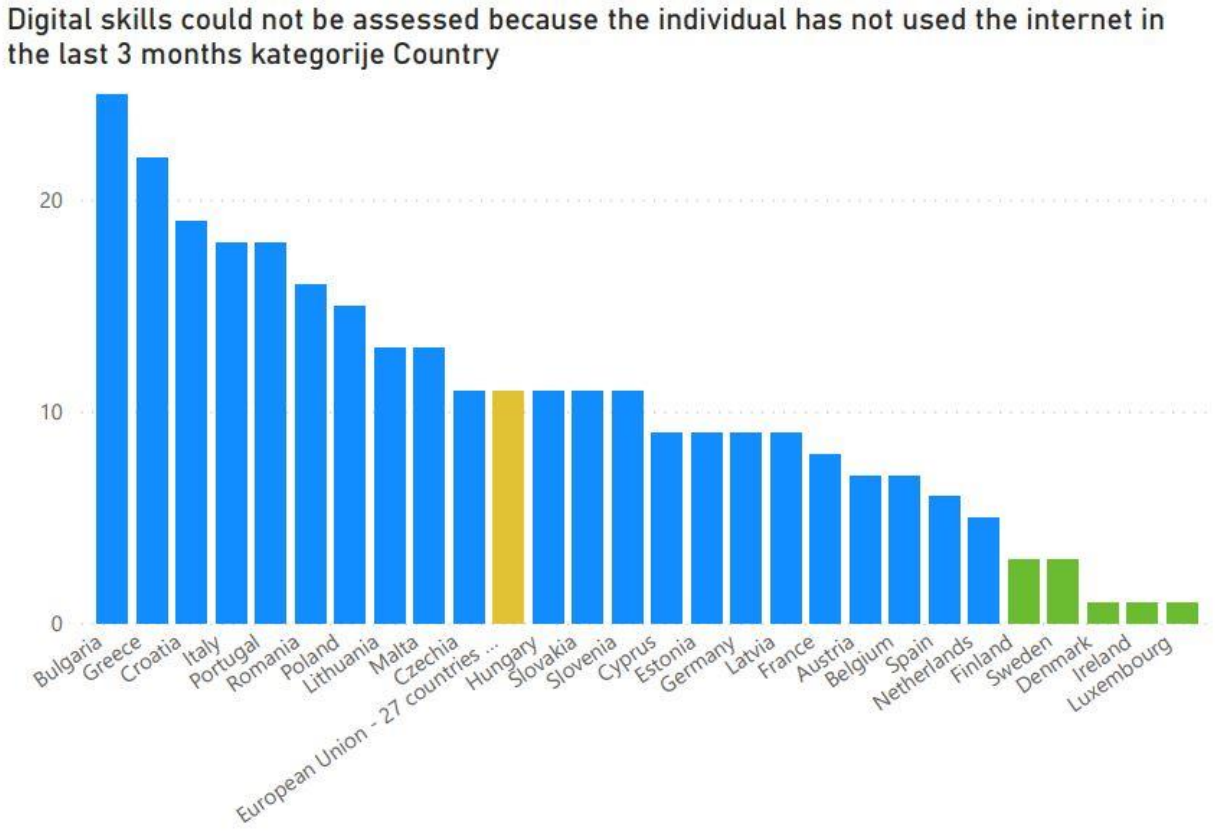
Za daljnje analize uglavnom su analizirane digitalne vještine prema pokazateljima iz 2021. godine, u postotku, a s obzirom da su isti relevantniji i širi, a samim time i sveobuhvatniji u pogledu potreba današnjeg gospodarstva i društva.



Vizual 8. Prikaz digitalnih vještina u kategoriji osnovne ili više digitalne vještine

(Izvor: izrada autora prema Prilog 1, 4.)

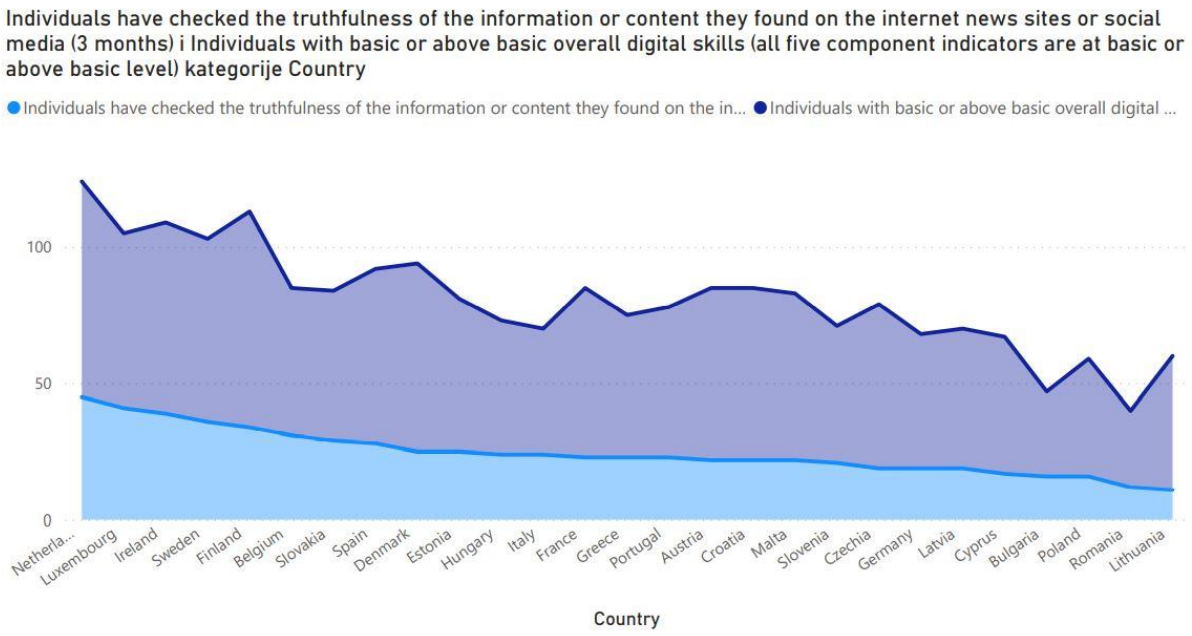
Iz vizuala 8 vidljiva je razina digitalnih vještina svih zemalja članica, kao i prosjek Eurozone (56) i Europske unije (54). Prvih 5 zemalja članica s najviše pojedinaca s osnovnim ili višim digitalnim vještinama su Finska, Nizozemska, Irska, Danska i Švedska. Sve su po broju stanovnika male ili srednje države EU, a razina digitalnih vještina stanovništva kreće se u rasponu 67% - 79%. Države članice s najniže razvijenim digitalnim vještinama su Italija, Poljska, Bugarska i Rumunjska, s 46% i manje populacije s osnovnim i iznad osnovnih digitalnih vještina.



Vizual 9. Pojedinci po državama kod kojih digitalne vještine nisu mogle biti analizirane jer nisu koristili Internet u posljednja tri mjeseca

(Izvor: izrada autora prema Prilog 1, 4.)

Iz vizuala 9 razvidno je kako 5 država koje su vodeće po broju pojedinaca s osnovnim i većim ukupnim digitalnim vještinama su ujedno i 5 država u kojima najmanje pojedinaca nije koristilo internet u zadnja 3 mjeseca. Takva korelacija ne može se primijeniti na sve države koje su na samom vrhu po broju pojedinaca koji nisu koristili Internet u posljednja tri mjeseca, budući da u tu kategoriju ulaze i Hrvatska i Portugal, koji su visoko na ljestvici po postotku pojedinaca koji nisu koristili internet u zadnja 3 mjeseca, dok su im digitalne vještine u rangu ili više od prosjeka Europske unije.

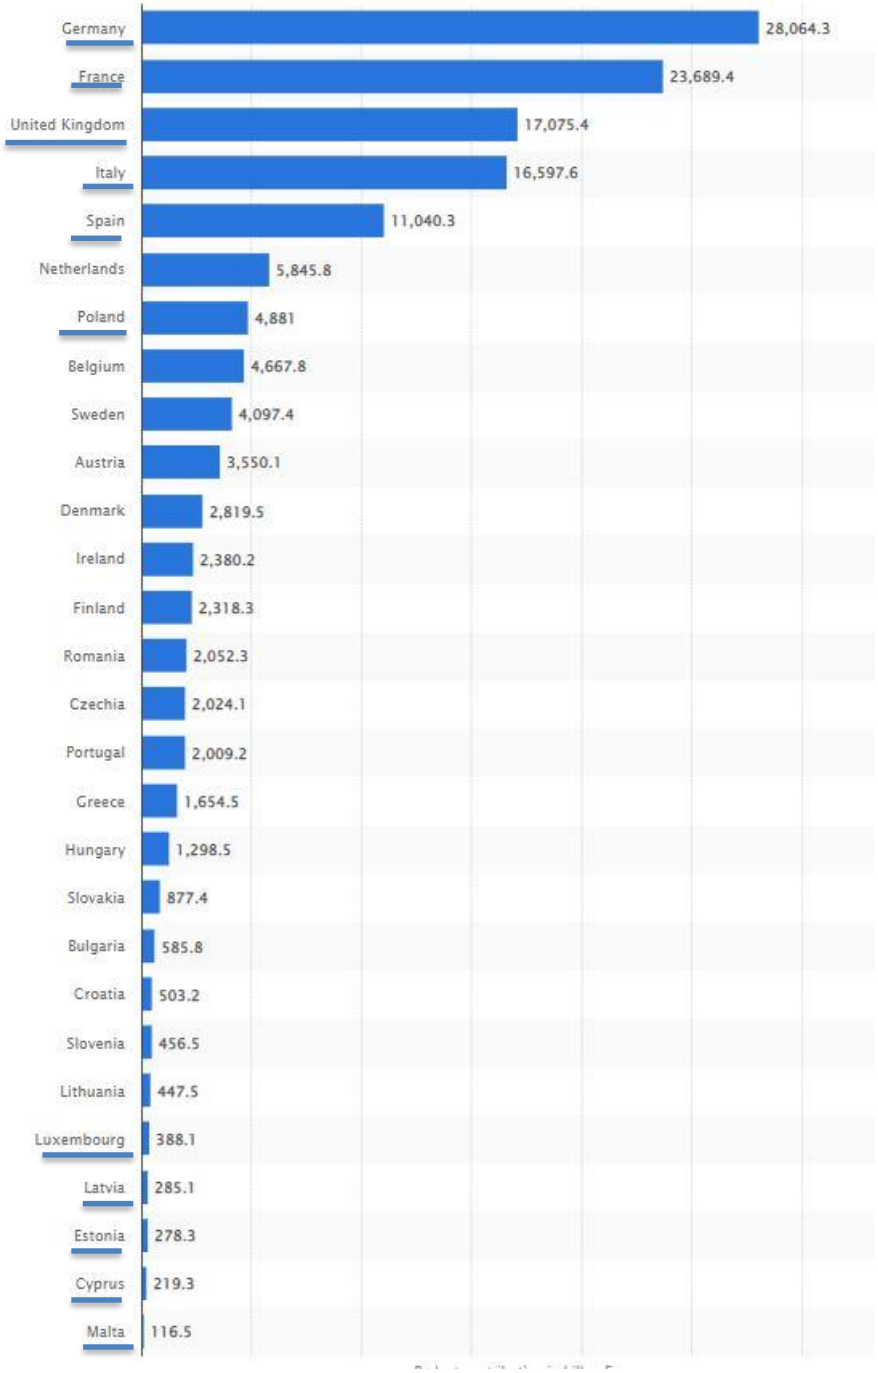


Vizual 10. Prikaz odnosa osnovnih i viših ukupnih digitalnih vještina pojedinaca po državama i njihove tendencije provjeravanja informacija koje pronalaze na internetu
(Izvor: izrada autora prema Prilog 1, 4., 5.)

Vizual 10 pokazuje kako nije pravilo da pojedinci u državama u kojima ima najviše pojedinaca s osnovnim i višim digitalnim vještinama najviše provjeravaju istinitost informacija na internetu, što može značiti njihovu sigurnost u informacije koje pronađu zbog vještina koje imaju, ali i indikatora koji bi trebalo revidirati u trenutku ispitivanja pojedinaca, a u pogledu ove kategorije.

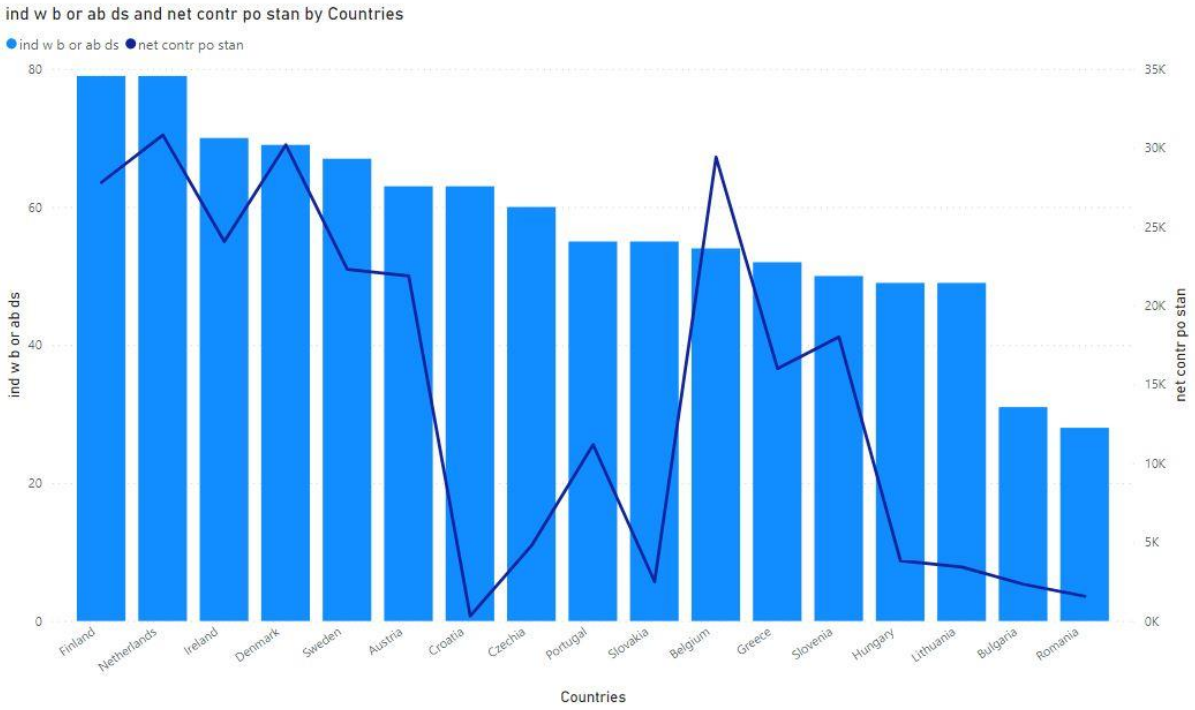
6.3.3. Digitalne vještine i Obzor

U koraku koji je slijedio, a za potrebe daljnje usporedbe i stavljanja u odnos razvijenosti države po pitanju digitalnih vještina države i osnovnih pokazatelja uspješnosti države u Obzor projektima, učinjene su daljnje analize u alatu te je zbog odstupanja iz daljnje analize izbačeno je ukupno 10 država i to: države koje su najveće u teritorijalnom smislu, najveći doprinos u proračunu Europske unije, ali i povlače najviše sredstava iz Obzor projekata: Njemačka, Španjolska, Francuska i Italija, te Poljska. Izbačene su i teritorijalno najmanje države, koje najmanje doprinose u proračun Europske unije i imaju zanemarivo sudjelovanje u Obzor projektima: Cipar, Estonija, Luksemburg, Latvija i Malta. Nizozemska je zadržana unatoč činjenici da ima velik doprinos u proračunu Europske unije jer brojem stanovnika odgovara državama iz promatranog skupa. U skupu su na kraju preostale: Finska, Nizozemska, Irska, Danska, Švedska, Austrija, Hrvatska, Češka, Portugal, Slovačka, Belgija, Grčka, Slovenija, Madžarska, Litva, Bugarska i Rumunjska.



Vizual 11. Iznos doprinosa proračunu Europske unije u 2020., po državama članicama (u milijardama eura)

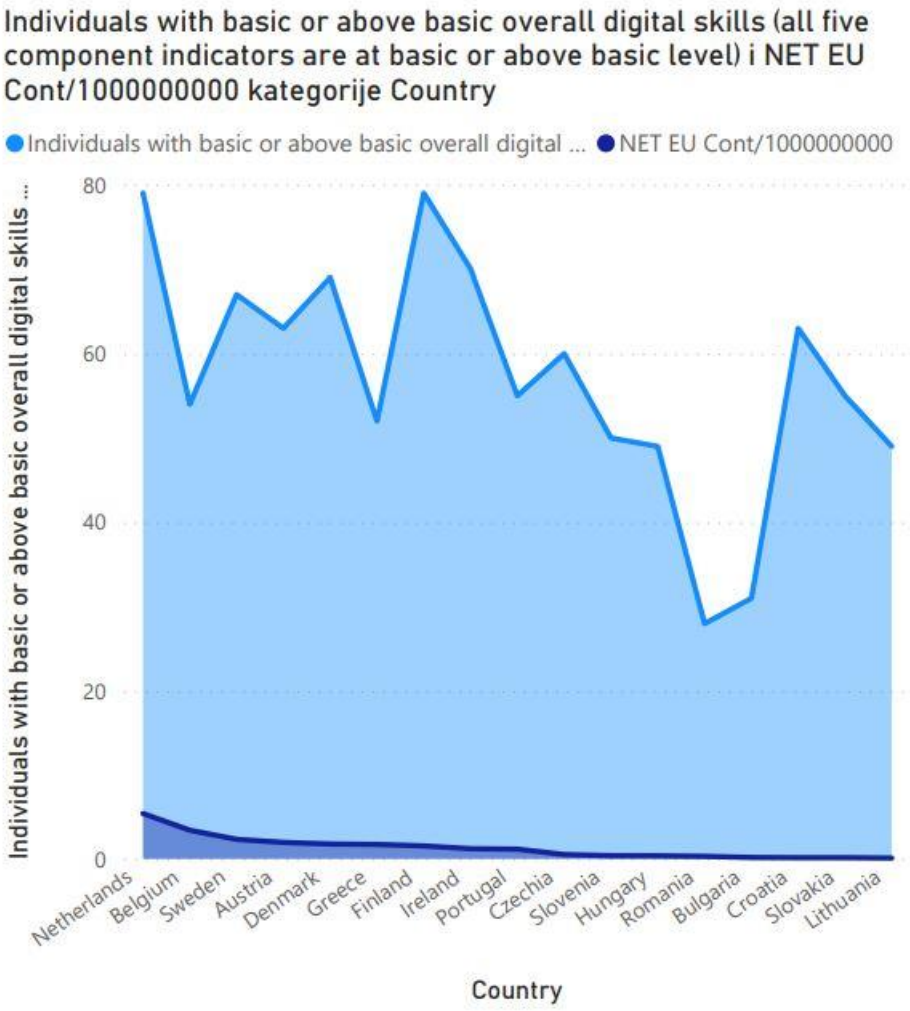
(Izvor: Statista)



Vizual 12. Usporedba osnovnih i viših ukupnih digitalnih vještina pojedinaca i neto doprinosa Europskoj uniji po stanovniku, po državama unutar promatranog skupa

(Izvor: izrada autora prema Prilog 1, 1., 4.)

Iz vizuala 12 razvidno je kako neto doprinos po stanovniku varira među državama te da u toj kategoriji prednjače Nizozemska, Danska i Belgija, a najlošije su Slovačka, Bugarska i Rumunjska, dok su digitalne vještine na razini promatranog skupa država uglavnom ujednačene, osim za Bugarsku i Rumunjsku kod kojih je razvidna razvijenost digitalnih vještina u manje od 50% populacije.



Vizual 13. Usporedba osnovnih i viših ukupnih digitalnih vještina pojedinaca i neto doprinosa Europske unije u programu Obzor po državama unutar promatranog skupa

(Izvor: izrada autora prema Prilog 1, 4., 5.)

Kako bi se dodatno testiralo promatrani skup podataka, vizualom 13 prikazan je ukupan neto doprinos Europske unije po državi u odnosu na razvijenosti osnovnih i viših ukupnih digitalnih vještina kod država unutar promatranog skupa.

6.3.4. Ulaganja u istraživanje i razvoj

U kontekstu istraživanja i razvoja glavni promatrani indikator prema *Eurostatu* je (Prilog 1, 6.):

- **Izdaci za istraživanje i razvoj, po sektorima učinka**, promatrani sektor: poslovni; promatrano vremensko razdoblje: godišnje; način mjerenja: kao postotak BDP-a (BERD) - Istraživanje i razvoj (R&D) obuhvaća kreativan rad koji se poduzima na

sustavnoj osnovi kako bi se povećala zaliha znanja, uključujući znanje o čovjeku, kulturi i društvu, te korištenje te zalihe znanja za osmišljavanje novih primjena. Izdaci za istraživanje i razvoj uključuju sve izdatke za istraživanje i razvoj koji se provode u poslovnom sektoru (BERD) na nacionalnom teritoriju tijekom određenog razdoblja, neovisno o izvoru sredstava. Izdaci za istraživanje i razvoj u BERD-u prikazani su kao postotak BDP-a (intenzitet istraživanja i razvoja).

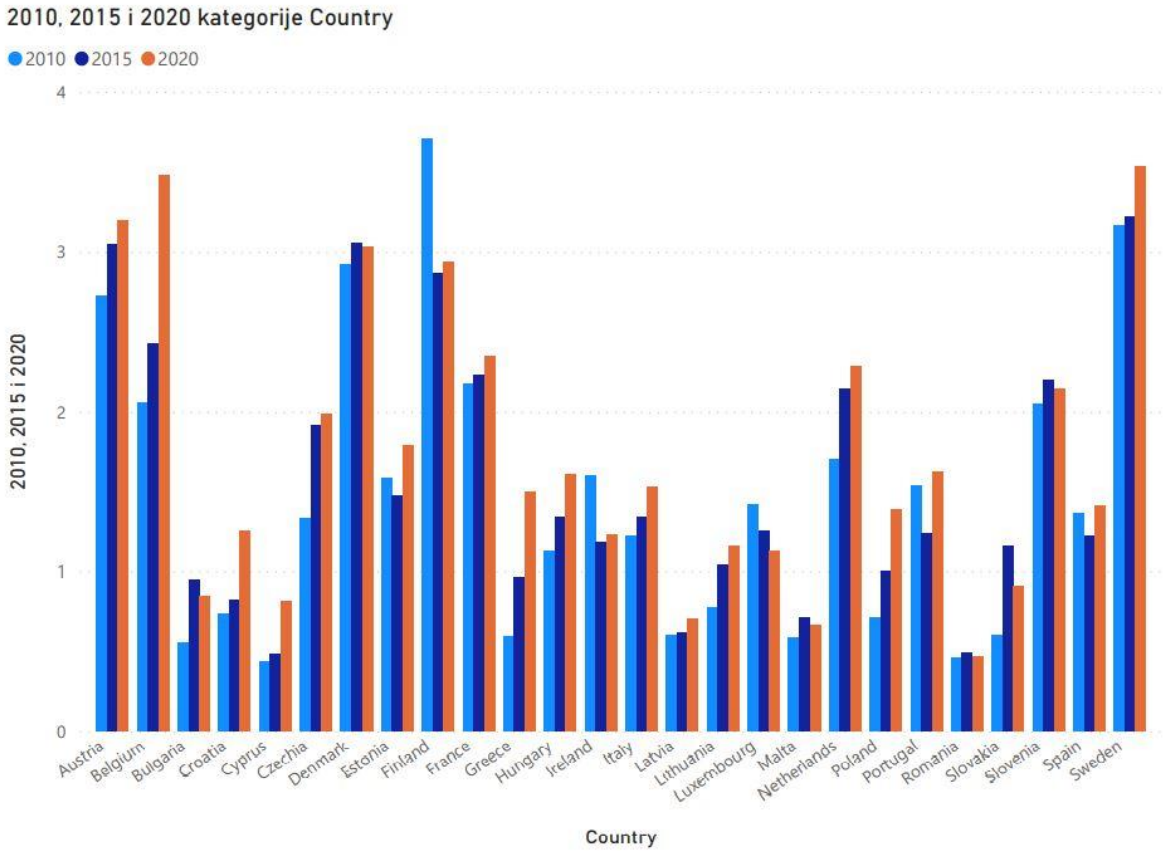
Uz navedeni, a u kontekstu i povezanosti s temom unutar koje se analizira, promatrani je i indikator (Prilog 1, 6.):

- ***Gross domestic expenditure on R&D* (GERD)**, i to tablice u kategorijama izdvajanja za istraživanje i razvoj kao postotak BDP-a i tablice GERD po izvoru sredstava), a koje prikazuju relativne udjele različitih izvora sredstava u istraživanju i razvoju, 5 tablica s prikazom postotka GERD-a (bruto domaćih izdataka za istraživanje i razvoj) koji financiraju redom: poslovni sektor, država, visoko obrazovanje, privatni neprofitni sektor i ostatak svijeta.

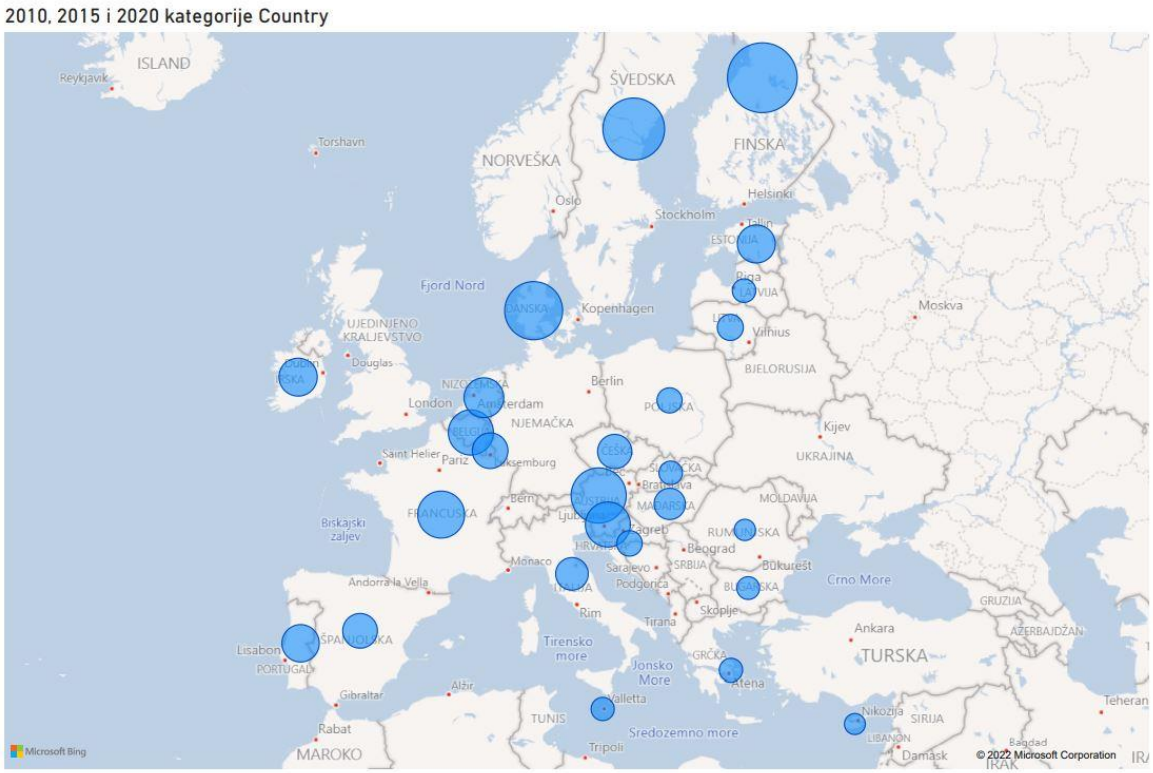
Tablica 5. Izdvajanja za istraživanje i razvoj kao postotak BDP-a po državama i godinama (Izvor: izrada autora prema Prilog 1, 7.)

Country	2010	2015	2020
Austria	2,73	3,05	3,20
Belgium	2,06	2,43	3,48
Bulgaria	0,56	0,95	0,85
Croatia	0,74	0,83	1,25
Cyprus	0,44	0,48	0,82
Czechia	1,33	1,92	1,99
Denmark	2,92	3,06	3,03
Estonia	1,58	1,47	1,79
Finland	3,71	2,87	2,94
France	2,18	2,23	2,35
Germany	2,73	2,93	3,14
Greece	0,60	0,97	1,50
Hungary	1,13	1,34	1,61
Ireland	1,60	1,18	1,23
Italy	1,22	1,34	1,53
Latvia	0,61	0,62	0,71
Lithuania	0,78	1,04	1,16
Luxembourg	1,42	1,25	1,13
Malta	0,59	0,72	0,67
Netherlands	1,70	2,15	2,29
Poland	0,72	1,00	1,39
Portugal	1,54	1,24	1,62
Romania	0,46	0,49	0,47
Slovakia	0,61	1,16	0,91
Slovenia	2,05	2,20	2,15
Spain	1,36	1,22	1,41
Sweden	3,17	3,22	3,53

Iz tablice 5 vidljiva je kategorija izdvajanje za istraživanje i razvoj kao postotak BDP-a, i to za sve države Europske unije za promatrane godine: 2010., 2015. i 2020. Pri tome su države koje značajno zaostaju za postavljenim ciljevima na razini Europske unije, a koji je izdvajanje od 3% BDP-a države koje taj postotak imaju i dalje manji od 1% i ne bilježe kontinuirani rast kroz godine: Rumunjska, Malta, Latvija, Cipar i Bugarska. Jedina država koja je iznad planiranog prosjeka Europske unije i bilježi kontinuirani rast kroz promatrani vremenski period je Švedska, dok su Austrija, Danska, Belgija i Njemačka taj postotak prešle u 2020. godini, no unutar promatranog perioda bilježe značajan rast. Ti su odnosi vidljivi i na vizualu 14, a koji daje grafički prikaz iz kojeg je razvidan rast spomenutih država. Iz navedenog je vizuala vidljiv i pad izdvajanja za istraživanje i razvoj u 2020. godini u odnosu na 2010. godinu kod Finske, Islanda, Luksemburga.



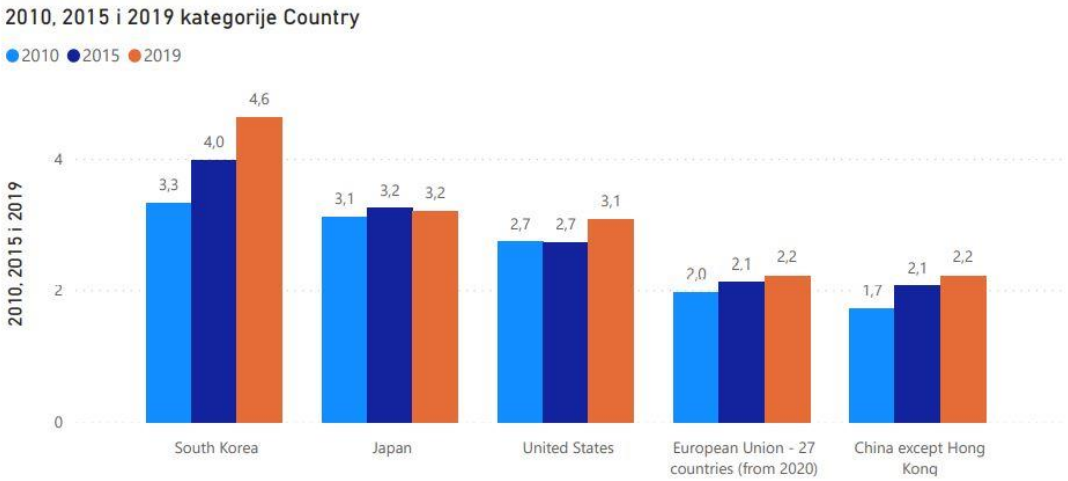
Vizual 14. Izdvajanja za istraživanje i razvoj kao postotak BDP-a po državama i godinama (Izvor: izrada autora prema Prilog 1, 7.)



Vizual 15. Geografski prikaz Izdvajanja za istraživanje i razvoj kao postotak BDP-a na razini Europske unije

(Izvor: izrada autora prema Prilog 1, 7.)

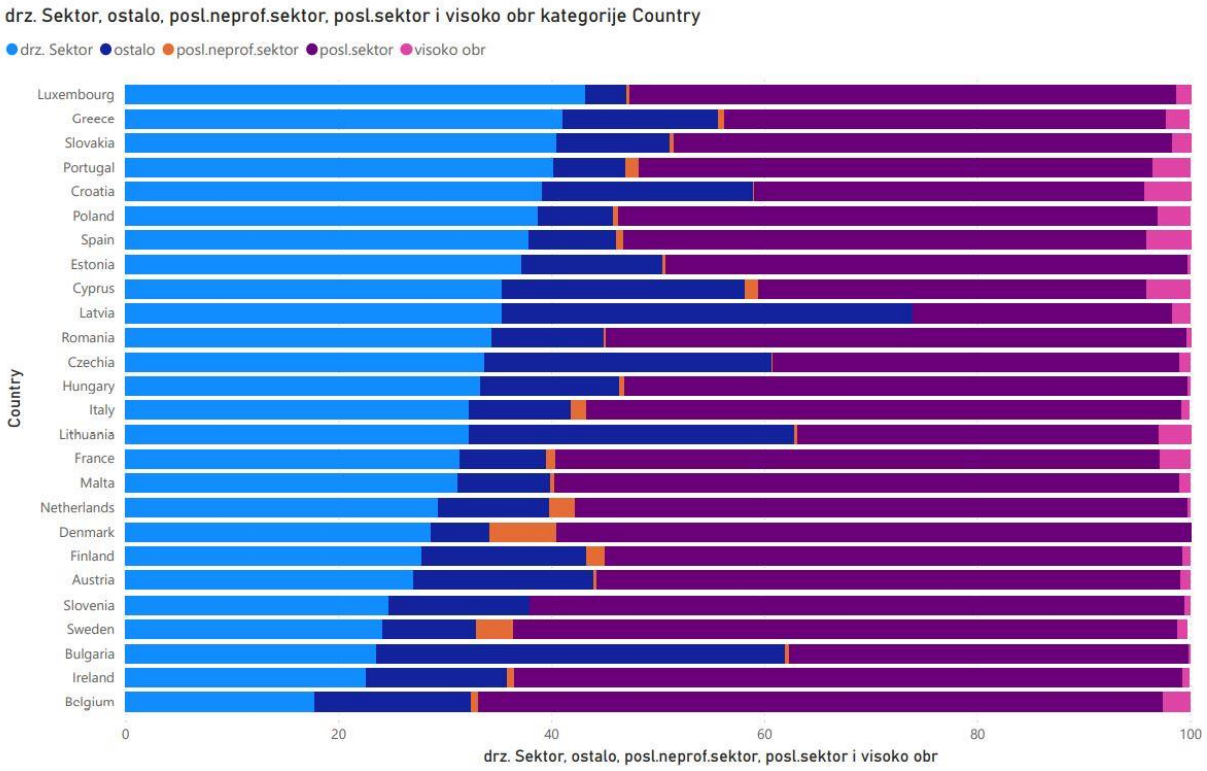
U usporedbi s ostalim vodećim svjetskim gospodarstvima, vidljiv je porast ulaganja kod svih promatranih država, pri čemu se vidi kako prosjek Europske unije bilježi najmanji porast i time zaostaje za konkurencijom.



Vizual 16. Izdvajanja za istraživanje i razvoj kao postotak BDP-a Europske unije i vodećih svjetskih gospodarstva

(Izvor: izrada autora prema Prilog 1, 7.)

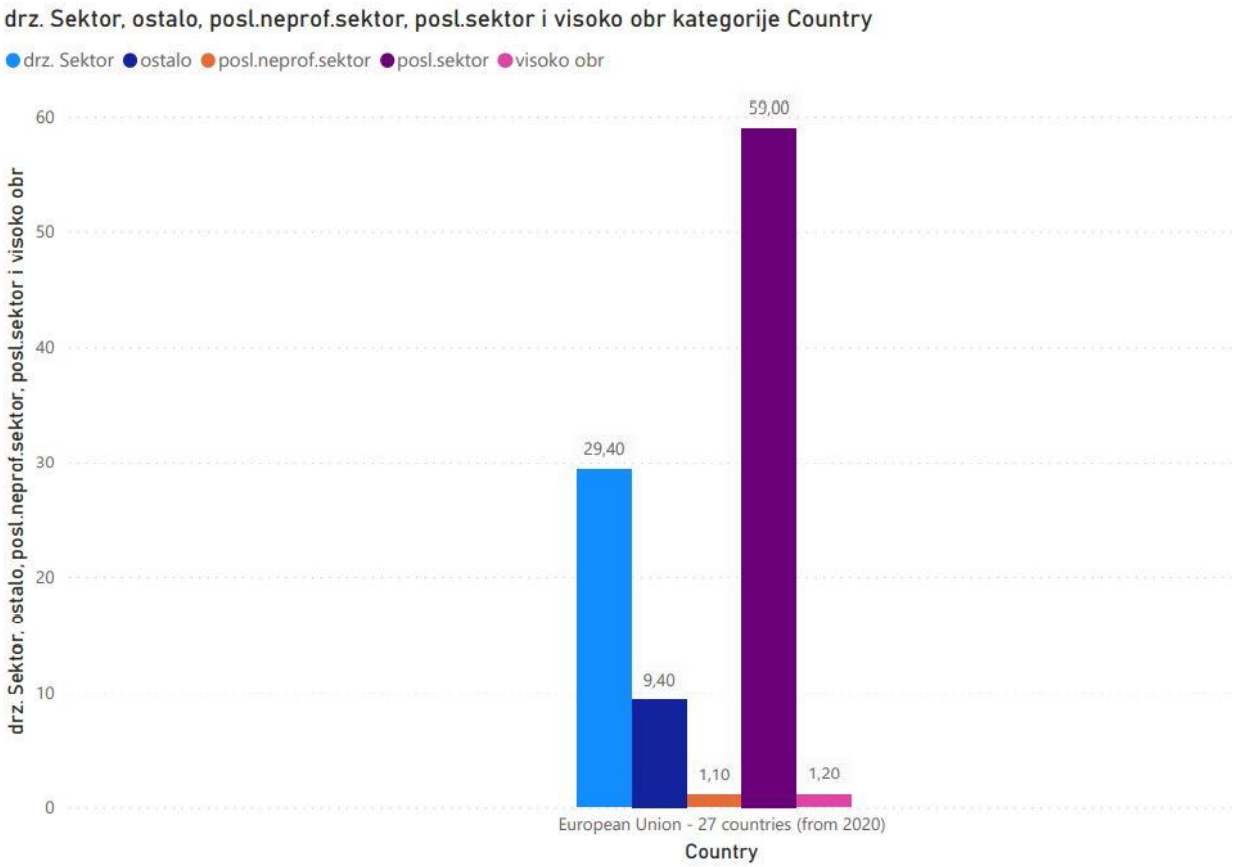
Važnost izvora financiranja prepoznata je u jednom od barcelonskih ciljeva Lisabonske strategije koja sugerira da je odgovarajuća podjela za istraživanje i razvoj 1/3 financirana javnim sredstvima, a 2/3 privatnim.



Vizual 17. Udio ulaganja u istraživanje i razvoj po sektorima

(Izvor: izrada autora prema Prilog 1, 8.)

Iz vizuala 17 vidljivo je da su udjeli ulaganja vrlo različiti po državama Europske unije. Države koje su dosegle ili se približavaju cilju Lisabonske strategije kao što su Belgija, Irska, Italija, Luksemburg, Malta i Francuska najčešće imaju manje udjele ulaganja državnog sektora i ostatka svijeta nego ostale države u promatranom skupu, a koje imaju niži udio ulaganja poslovnog sektora. Države koje imaju niže udjele ulaganja poslovnog sektora kao što su Bugarska, Latvija, Litva i Češka imaju značajan udio ulaganja iz ostatka svijeta. Države koje su među najboljima po pitanju udjela ulaganja visokog obrazovanja su Portugal, Hrvatska, Poljska, Španjolska, Cipar, Litva, Francuska i Belgija.

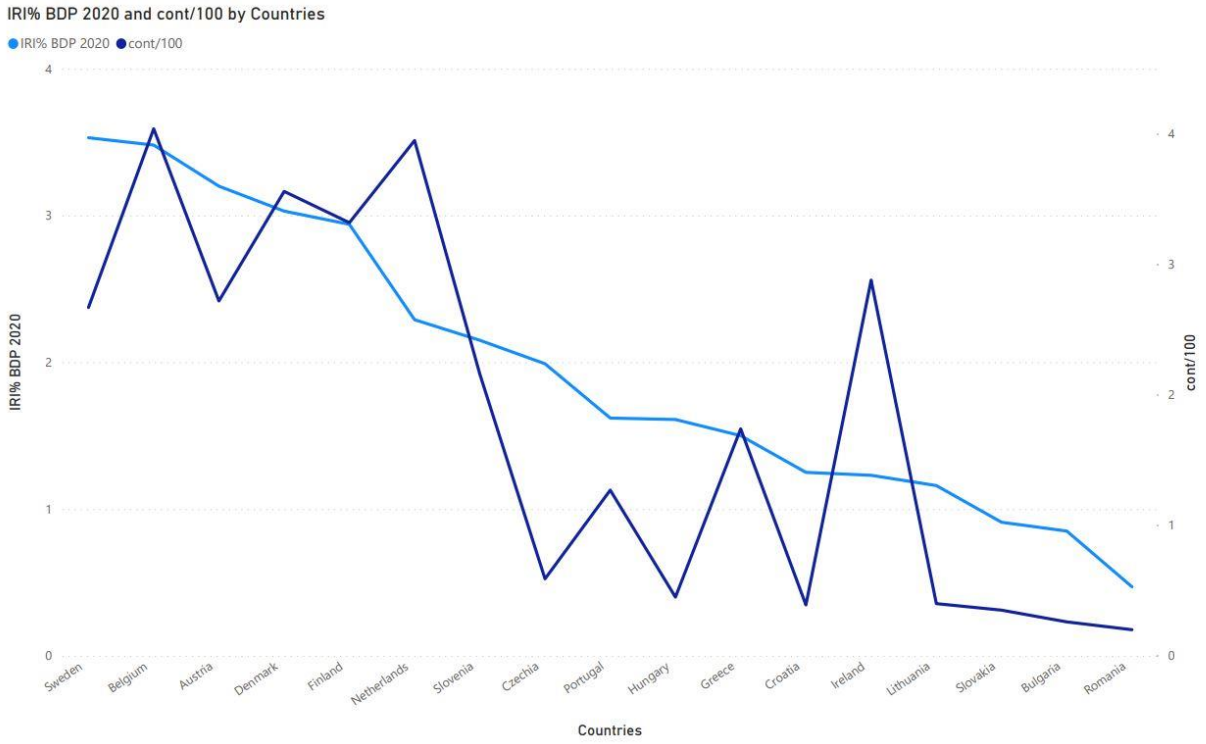


Vizual 18. Udio ulaganja u istraživanje i razvoj po sektorima na razini Europske unije (Izvor: izrada autora prema Prilog 1, 8.)

Na razini Europske unije, udio ulaganja u istraživanje i razvoj približava se ciljevima Lisabonske strategije, a najznačajnija visina ulaganja bilježi se kod poslovnog sektora i državnog sektora. Ostatak svijeta je, pokazalo se i ranije, važan za nerazvijene države po pitanju ulaganja u istraživanje i razvoj.

6.3.5. Ulaganja u istraživanje i razvoj i Obzor

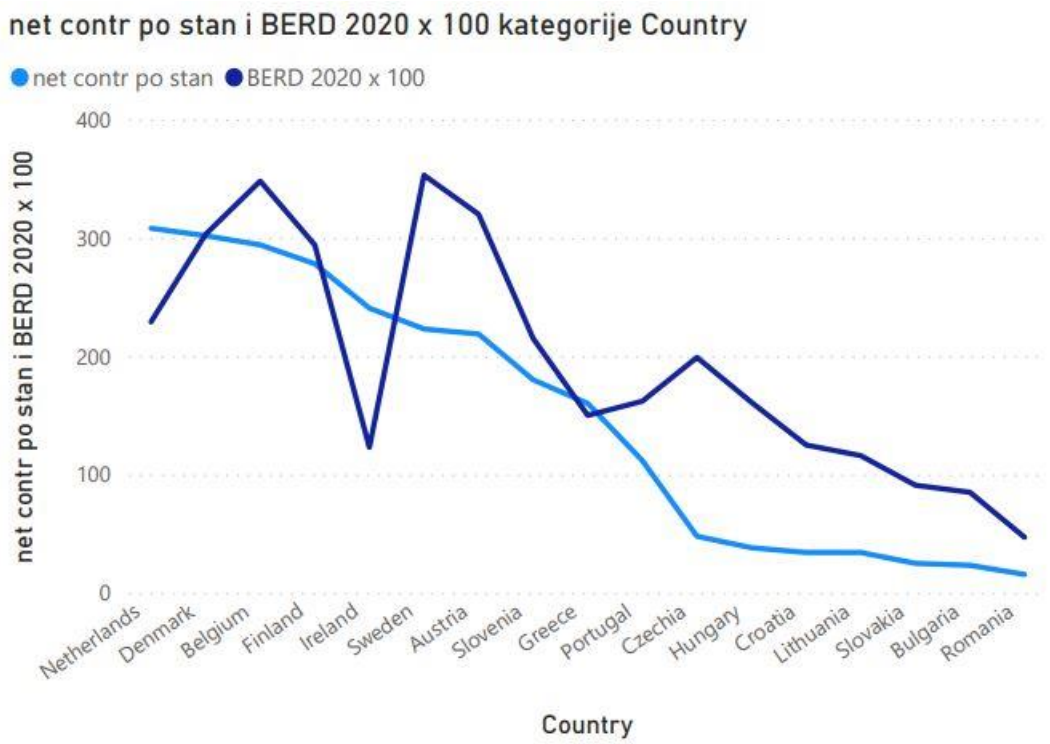
Za potrebe daljnje usporedbe i stavljanja u odnos ulaganja u istraživanje i razvoj i osnovnih pokazatelja uspješnosti države u Obzor projektima, iz daljnje analize ponovno je izbačeno ukupno 10 država i to: Njemačka, Španjolska, Francuska, Italija, Poljska, Cipar, Estonija, Luksemburg, Latvija i Malta. Nizozemska je zadržana unatoč činjenici da ima velik doprinos u proračunu Europske unije jer brojem stanovnika odgovara državama iz promatranog skupa. U skupu su na kraju preostale: Finska, Nizozemska, Irska, Danska, Švedska, Austrija, Hrvatska, Češka, Portugal, Slovačka, Belgija, Grčka, Slovenija, Madžarska, Litva, Bugarska i Rumunjska. Razlozi za navedeno jednaki su kao kod prethodne analize i usporedbe u kategoriji digitalnih vještina.



Vizual 19. Usporedba ulaganja u istraživanje i razvoj kao postotka BDP-a i neto doprinosa Europske unije sredstvima Obzora po državama unutar promatranog skupa

(Izvor: izrada autora prema Prilog 1, 1., 7.)

Stavljanjem u usporedbu kategorije ulaganja u istraživanje i razvoj kao postotak BDP-a i neto doprinos Europske unije sredstvima Obzora uočena je pozitivna korelacija između navedenih varijabli. Zemlje koje imaju veći postotak ulaganja u istraživanje i razvoj u BDP-u najčešće povlače više sredstava po stanovniku za Obzor projekte (Belgija, Danska, Finska, Nizozemska), dok države s malim postotkom ulaganja u istraživanje i razvoj u BDP-u imaju i vrlo malo sudjelovanja u projektu Obzor s najmanje povučenih sredstava (Hrvatska, Litva, Slovačka, Bugarska i Rumunjska).



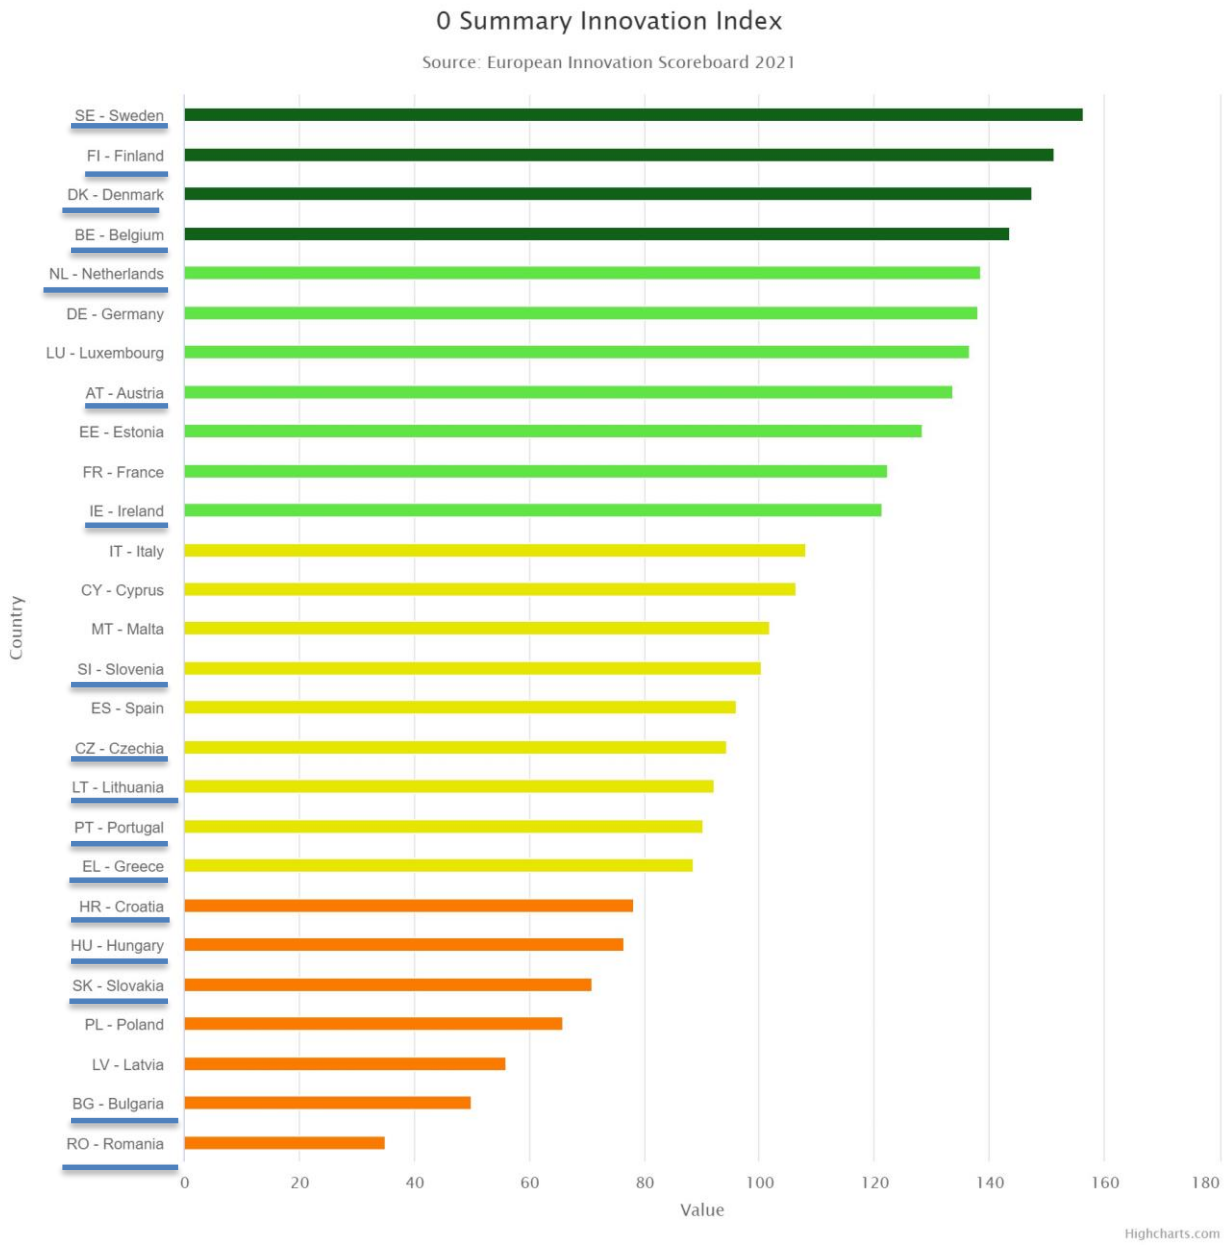
Vizual 20. Usporedba ulaganja u istraživanje i razvoj poduzeća kao postotka BDP-a i neto doprinosa Europske unije sredstvima Obzor po državama unutar promatranog skupa

(Izvor: izrada autora prema Prilog 1, 1., 7.)

Stavljanjem u usporedbu kategorije ulaganja u istraživanje i razvoj poduzeća kao postotak BDP-a i neto doprinos Europske unije sredstvima Obzora uočena je pozitivna korelacija između navedenih varijabli. Zemlje koje imaju veći postotak ulaganja u istraživanje i razvoj poduzeća u BDP-u najčešće povlače više sredstava po stanovniku za Obzor projekte (Danska, Belgija, Švedska, Austrija), dok države s malim postotkom ulaganja u istraživanje i razvoj poduzeća u BDP-u imaju i vrlo malo sudjelovanja u projektu Obzor s najmanje povučenih sredstava (Mađarska, Hrvatska, Litva, Slovačka, Bugarska i Rumunjska).

Sličan trend vidljiv je i za prethodan vizual (19), kao i za vizual 20, što dovodi do zaključka kako većina zemalja s općenito više ulaganja u istraživanja i razvoj kao postotka BDP-a taj postotak povlače iz poslovnog sektora, odnosno imaju ujedno i više ulaganja u istraživanje i razvoj poslovnog sektora.

6.3.6. Europska ljestvica uspjeha u inoviranju



Vizual 21. Sumarni inovacijski indeks po državama Europske unije

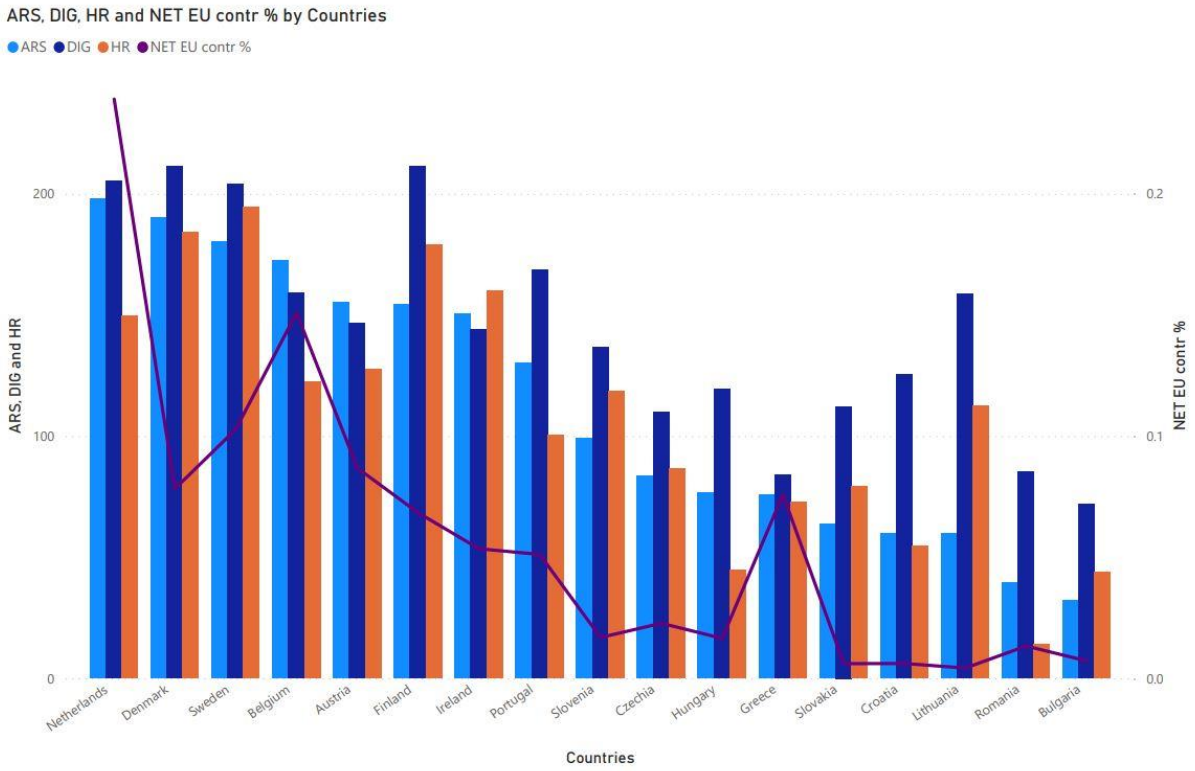
(Izvor: Prilog 1, 9.)

Iz promatranog skupa država koje su uključene u daljnje analize, a sukladno kategorijama prema kojima se države svrstavaju sukladno EIS-u, u nastavku će biti analizirane:

- 4 države koje spadaju u kategoriju voditelja inovatora unutar sumarnog inovacijskog indeksa (Švedska, Finska, Danska i Belgija), a koje su ujedno i jedine države u toj kategoriji

- 3 države od ukupno 7 koje spadaju u kategoriju snažnih inovatora unutar sumarnog inovacijskog indeksa (Nizozemska, Austrija i Irska)
- 5 država od ukupno 9 koje spadaju u kategoriju umjerenih inovatora unutar sumarnog inovacijskog indeksa (Slovenija, Češka, Litva, Portugal i Grčka)
- 5 država od ukupno 7 koje spadaju u kategoriju novih inovatora unutar sumarnog inovacijskog indeksa (Hrvatska, Mađarska, Slovačka, Bugarska i Rumunjska)

6.3.7. Inovacijske aktivnosti i dimenzije i program Obzor



Vizual 22. Usporedba inovacijskih dimenzija aktivnosti Okvirni uvjeti postotkom od ukupne NET EU potpore za program Obzor

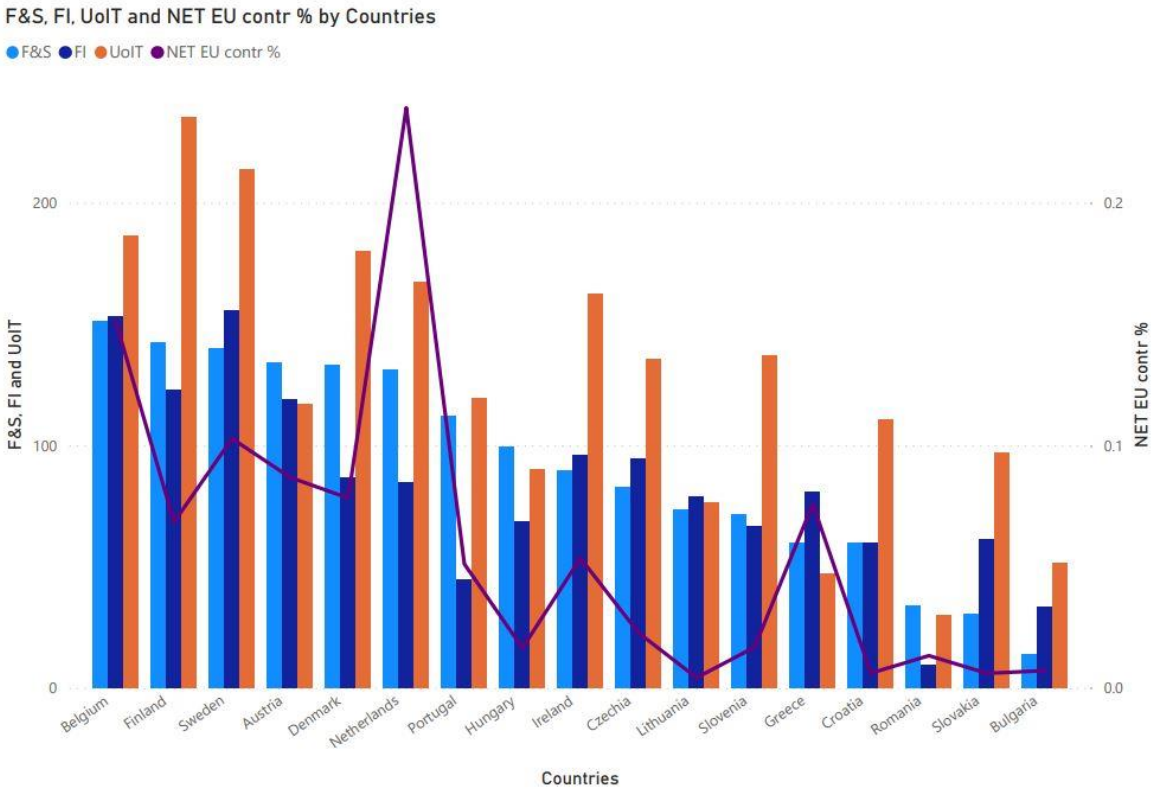
(Izvor: izrada autora prema Prilog 1,1., 9.)

Aktivnost Okvirni uvjeti (*eng. framework conditions*) uključuje 3 analizirane dimenzije: Ljudski resursi (HR), Atraktivni istraživački sustav (ARS) i Digitalizacija (DIG). Unutar navedene aktivnosti, a analizom alata stavljanjem u odnos s postotkom od ukupne neto EU potpore za program Obzor (NET EU contr%), kroz ispitivanje najznačajnijih varijabli zaključeno je kako je Nizozemska zemlja s najrazvijenijom dimenzijom ARS (198,10), te da je taj iznos čak 518,68% viši od Bugarske, koja ima najmanje razvijenu dimenziju ARS s vrijednošću iste 32,02. ARS i

ukupna dimenzija DIG međusobno su u pozitivnoj korelaciji. Kod svih 17 zemalja, ARS je u rasponu od 32,02 do 198,10, DIG u rasponu od 72,02 do 211,43, a HR u rasponu od 14 do 194,61.

Švedska ima najviši HR koji je 1.290,07% viši od Rumunjske, koja je imala najniži HR (14). HR i ukupni NETO EU contr % međusobno su u pozitivnoj korelaciji. Švedska čini 10,54% HR. HR i NETO EU kontr % najviše su se razlikovali kod Švedske, kada je HR bio 194,51 viši od NETO EU kontr %.

S 211,43, Danska je imala najviši DIG i bio je 193,57% viši od Bugarske, koja je imala najniži DIG s 72,02. DIG i ukupni NETO EU contr % međusobno su u pozitivnoj korelaciji. Danska je imala 8,61% DIG-a. DIG i NET EU contr % najviše su se razlikovali kod Danske, kada je DIG bio 211,35 viši od NET EU contr %.



Vizual 23. Usporedba inovacijskih dimenzija aktivnosti Ulaganja s postotkom od ukupne neto EU potpore za program Obzor

(Izvor: izrada autora prema Prilog 1,1., 9.)

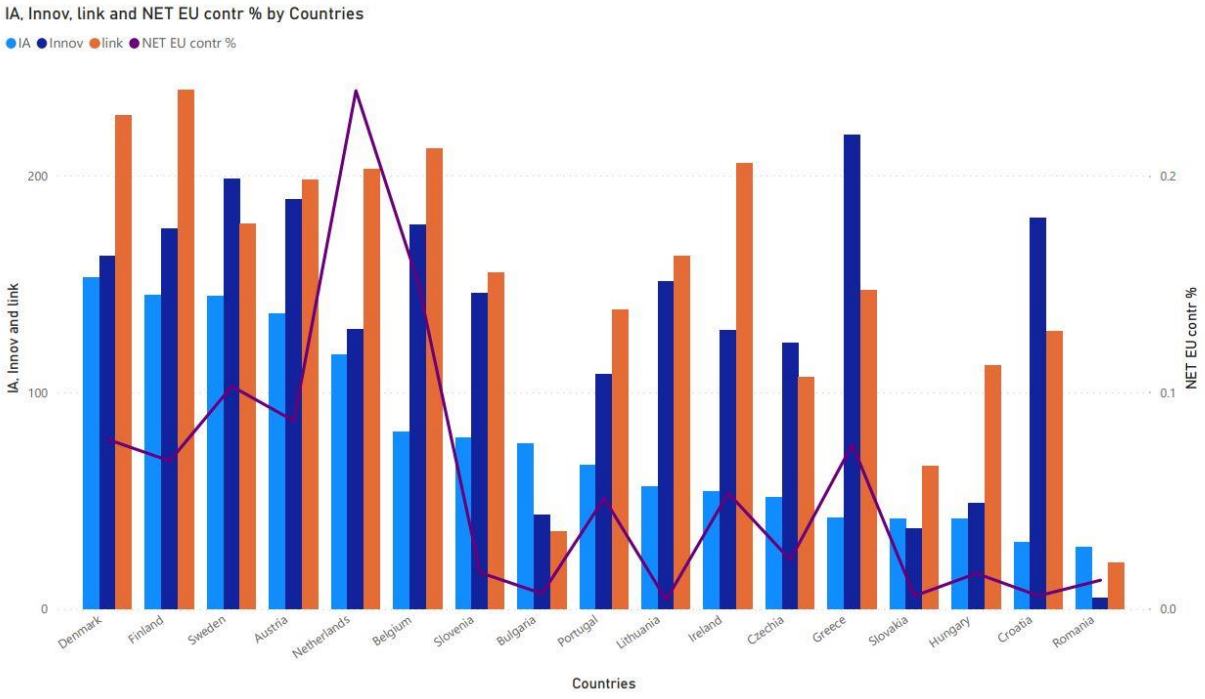
Aktivnost Ulaganja (*eng. investments*) uključuje 3 analizirane dimenzije: Financije i potpora (F&S), Ulaganja poduzeća (FI) i Korištenje informacijskih tehnologija (UoIT). Unutar navedene aktivnosti, a analizom alata stavljanjem u odnos s postotkom od ukupne neto EU potpore za program Obzor (NET EU contr%), kroz ispitivanje najznačajnijih varijabli zaključeno je kako je s vrijednošću 151,21, Belgija imala najviši F&S i bio je 969,38% viši od Bugarske, koja je imala

najniži F&S s 14,14. F&S i ukupni FI međusobno su u pozitivnoj korelaciji. Belgija je činila 9,70% F&S. U svih 17 zemalja, F&S je bio u rasponu od 14,14 do 151,21, FI u rasponu od 9,44 do 155,49, a UoIT u rasponu od 30,17 do 235,08.

F&S i NETO EU contr % najviše su se razlikovali kod Belgije, kada su F&S bili 151,06 viši od NETO EU contr %.

FI i NETO EU kontr % najviše su se razlikovali kod Švedske, kada su FI bili 155,39 viši od NETO EU kontr %. Švedska čini 10,97% FI. FI i ukupni NETO EU kontr % međusobno su u pozitivnoj korelaciji. S 155,49, Švedska je imala najviši FI i bio je 1.547,14% viši od Rumunjske, koja je imala najniži FI od 9,44.

S 235,08, Finska je imala najveći UoIT i bila je 679,18% viša od Rumunjske, koja je imala najniži UoIT s 30,17. UoIT i ukupna NETO EU contr % međusobno su u pozitivnoj korelaciji. Finska čini 10,90% UoIT-a. UoIT i NET EU contr % najviše su se razlikovali kod Finske, kada je UoIT bio 235,01 viši od NET EU contr %.

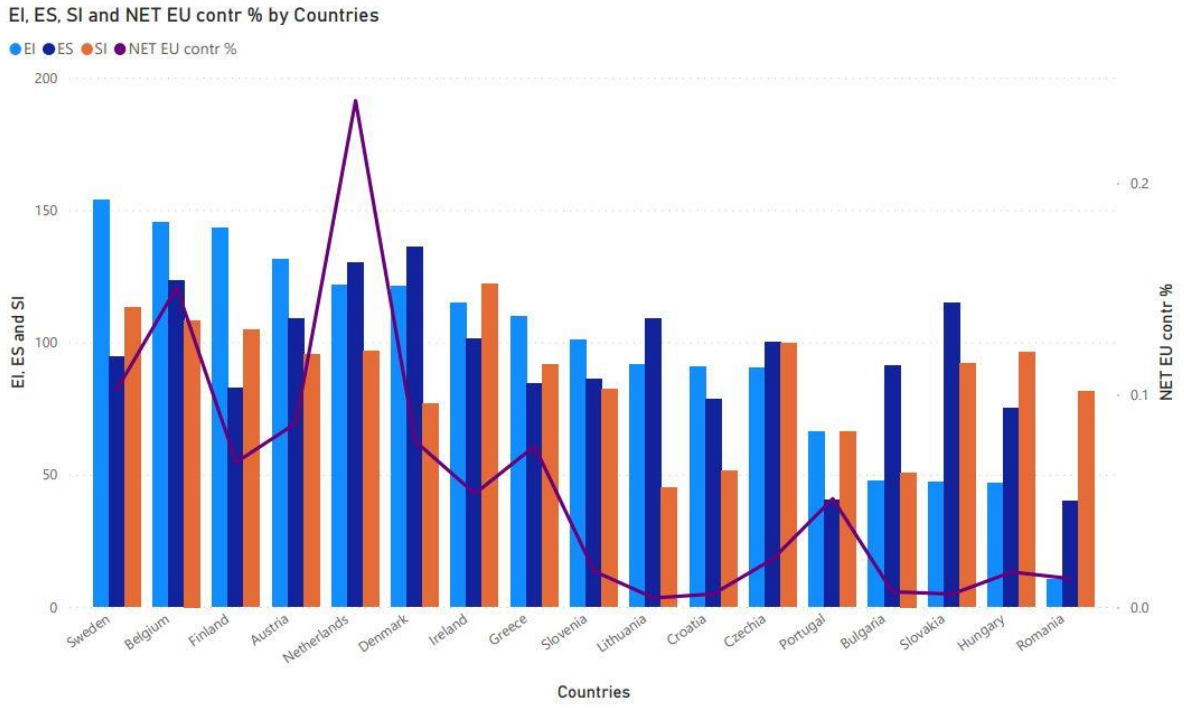


Vizual 24. Usporedba inovacijskih dimenzija aktivnosti naziva Inovacijske aktivnosti s postotkom od ukupne neto EU potpore za program Obzor

(Izvor: izrada autora prema Prilog 1,1., 9.)

Aktivnost Inovacijske aktivnosti (*eng. innovation activities*) uključuje 3 analizirane dimenzije: Inovatori (Innov), Povezanost (link) i Intelektualna imovina (IA). Unutar navedene aktivnosti, a analizom alata stavljanjem u odnos s postotkom od ukupne neto EU potpore za program Obzor (NET EU contr%), kroz ispitivanje najznačajnijih varijabli zaključeno je kako su dimenzije IA i Innov međusobno u negativnoj korelaciji. Danska je imala 152,86 IA, 163,15 Innov i 228,02 link.

S 218,87, Grčka je imala najvišu Innovaciju i bila je 4.149,90% viša od Rumunjske, koja je imala najnižu Innovaciju od 5,15. Grčka je činila 9,84% Innov. Innov i NETO EU kontr % najviše su se razlikovale kod Grčke, kada su Innov bile 218,79 veće od NETO EU kontr %. S 239,36, Finska je imala najvišu link i bila je 1.011,23% viša od Rumunjske, koja je imala najnižu link s 21,54. Link i ukupni NETO EU contr % međusobno su u pozitivnoj korelaciji. Finska je imala 9,43% link. Link i NETO EU kontr % najviše se razlikuju kod Finske, kada je Link bila 239,29 veća od NETO EU kontr %. S 152,86, Danska je imala najviši IA i bio je 437,48% viši od Rumunjske, koja je imala najniži IA s 28,44. IA i ukupni NETO EU contr % međusobno su u pozitivnoj korelaciji. Danska je činila 11,34% IA. IA i NETO EU kontr % najviše se razlikuju kod Danske, kada je IA 152,78 viši od NETO EU kontr %.



Vizual 25. Usporedba inovacijskih dimenzija aktivnosti Učinci s postotkom od ukupne neto EU potpore za program Obzor

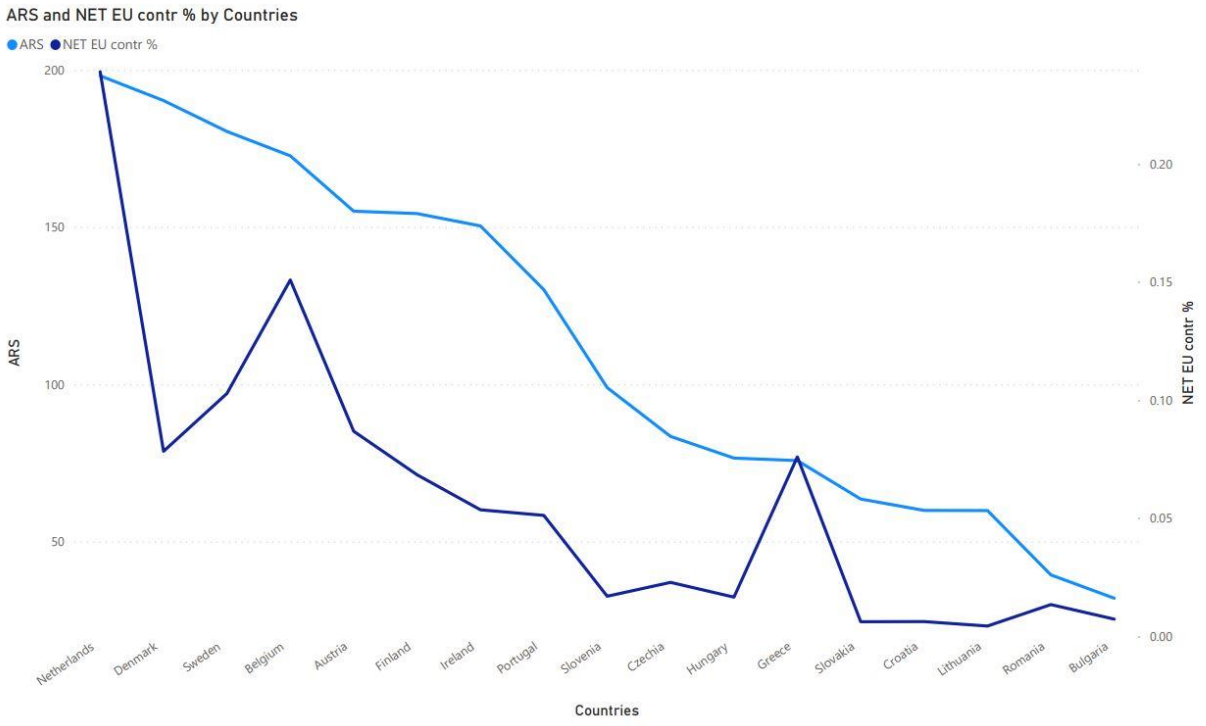
(Izvor: izrada autora prema Prilog 1,1., 9.)

Aktivnost Učinci (eng. *impacts*) uključuje 3 analizirane dimenzije: Učinci zapošljavanja (EI), Učinci prodaje (SI) i Održivost okoliša (ES). Unutar navedene aktivnosti, a analizom alata stavljanjem u odnos s postotkom od ukupne neto EU potpore za program Obzor (NET EU contr%), kroz ispitivanje najznačajnijih varijabli zaključeno je kako je s 153,80, Švedska ima najviši EI i bio je 1.364,76% viši od Rumunjske, koja je imala najniži EI od 10,50. EI i ukupni ES međusobno

su u pozitivnoj korelaciji. Švedska je imala 9,42% EI. U svih 17 zemalja, EI je bio u rasponu od 10,50 do 153,80, ES u rasponu od 39,80 do 136,03, a SI u rasponu od 45,08 do 121,91.

Sa 121,91, Irska je imala najviši SI i bio je 170,43% viši od Litve, koja je imala najniži SI sa 45,08. Irska je činila 8,27% SI. SI i NETO EU kontr % najviše se razlikuju kod Irske, kada je SI bio 121,86 viši od NETO EU kontr %.

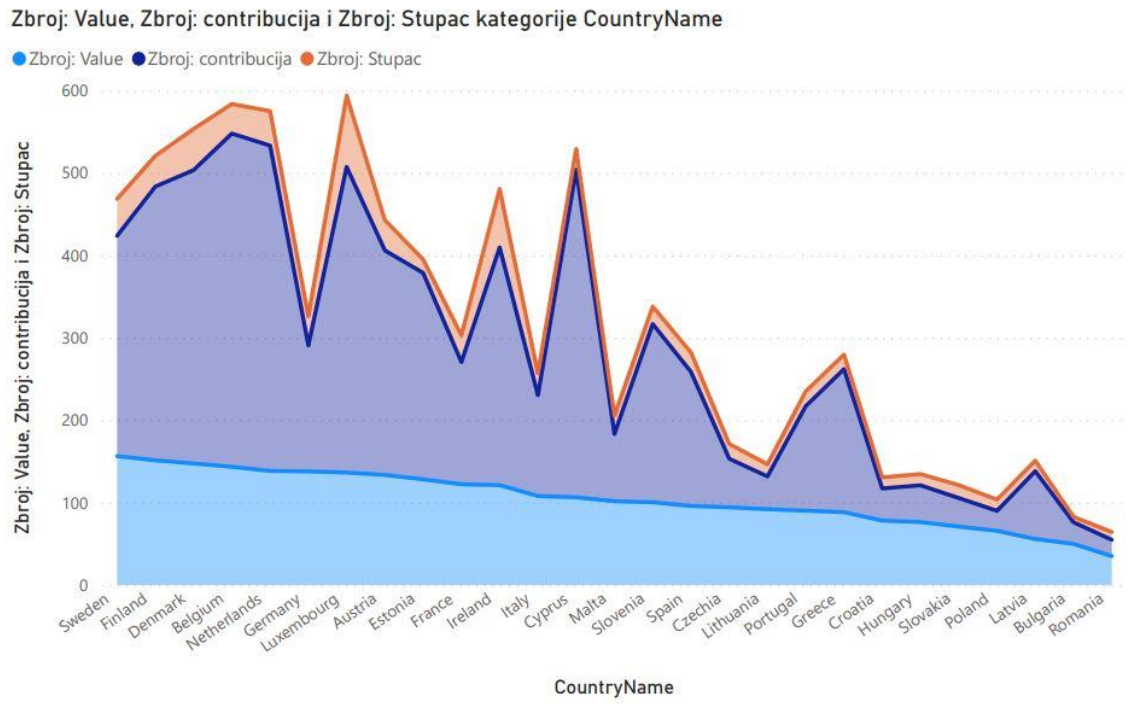
Sa 136,03, Danska je imala najviši ES i on je 241,75% viši od Rumunjske, koja ima najniži ES od 39,80. Danska čini 8,53% ES-a. ES i NETO EU kontr % najviše se razlikuju kod Danske, kada je ES 135,95 viši od NETO EU kontr %.



Vizual 26. Usporedba inovacijske dimenzije Atraktivni istraživački sustav s postotkom od ukupne neto EU potpore za program Obzor

(Izvor: izrada autora prema Prilog 1,1., 9.)

Kod pojedinačno promatranih dimenzija, najviše izražen trend međusobne korelacije između dimenzije i ukupne neto EU potpore za program Obzor vidljiv je kod dimenzije Atraktivni istraživački sustav, čija krivulja pokazuje određena odstupanja od prosjeka jedino u slučaju Danske, kada je neto EU potpora za program Obzor znatno niža od dimenzije Atraktivni istraživački sustav te kod Grčke, u kojem je slučaju situacija obrnuta gdje je trend indikatora neto EU potpora za program Obzor znatno niži nego što je trend dimenzije atraktivan istraživački sustav.



Vizual 27. Usporedba ukupnog inovacijskog indeksa, EU doprinosa za program Obzor i BDP-a po stanovniku

(Izvor: izrada autora prema Prilog 1,1., 9., 10.)

Posljednja usporedba sastavljena je od tri indikatora i svih zemalja Europske unije:

- Plava linija = ukupan inovacijski indeks po državama
- Ljubičasta linija = EU doprinos za program Obzor po stanovniku podijeljeno s brojem stanovnika u 2021. godini
- Narančasta linija = BDP po stanovniku podijeljen s tisuću.

Linija trenda i međusobna povezanost vidljiva je za sva tri indikatora, a posebno BDP po stanovniku i EU doprinos za program Obzor, za koje je očito da su u međusobnoj pozitivnoj korelaciji i da razvijenije države povlače više sredstava za Obzor, s obzirom na BDP i na njihov ukupan inovacijski indeks sastavljen od 12 različitih dimenzija i 32 indikatora.

7. Diskusija

Diskusija rezultata podijeljena je u 3 glavna segmenta: elaboracija istraživačkog pitanja, elaboracija hipoteza te kritički osvrt, primjena rezultata i preporuke.

7.1. Elaboracija istraživačkog pitanja

Osnovni cilj provedenog istraživanja kroz sekundarne izvore, znanstvene baze i statističke podatke bio je identificirati utjecajne faktore promatrajući skup tzv. horizontalnih čimbenika gospodarskog razvoja unutar kategorije znanosti, tehnologije, istraživanja, razvoja i inovacija, uključujući pritom i dimenziju digitalizacije koja se, uz zelenu tranziciju, spominje kao jedna od okosnica i osnovnih faktora razvoja društva u cjelini, a sve kako bi se odgovorilo na postavljeno istraživačko pitanje – *Kako je moguće primjenom poslovne inteligencije utvrditi potencijal zemlje za povlačenje sredstava za znanost, istraživanje i inovacije iz fondova Europske unije?*

Odgovor na istraživačko pitanje podijeljen je u nekoliko zasebnih faza teorijskog istraživanja koje su uključivale pojedine segmente istraživačkog pitanja kako bi se na kraju moglo odabrati relevantne indikatore, definirati hipoteze i provesti empirijski dio istraživanja.

FAZA I: Analiza pojma i koncepta poslovne inteligencije

S ciljem što opsežnijeg sagledavanja konteksta poslovne inteligencije, ova je istraživačka faza promatrala koncept poslovne inteligencije s nekoliko različitih aspekata: teorijskog određenja, povijesnog razvoja, organizacijskog konteksta i tehnologijskog konteksta. Takav je tijek i sistem definiran činjenicom da poslovna inteligencija i njezin razvoj bilježe svoj najveći porast razvojem informacijsko-komunikacijskih tehnologija. Za primjenu tehnologija vrlo je bitna organizacijska i ljudska komponenta bez koje je nemoguće identificirati utjecajne faktore za promatrano organizacijsko pitanje te iz skupa podataka izvući najrelevantnije zaključke korištenjem alata poslovne inteligencije. Ta je istraživačka faza provedena kroz analizu knjiga za definiciju koncepta poslovne inteligencije, analizu Internet izvora stranica koje se bave razvojem koncepta poslovne inteligencije i povezanih znanstvenih izvora kako bi se odredio tijek i smjer razvoja, analizom literature u posljednjih pet godina u znanstvenim bazama *Web of Science* i *Scopus* kako bi se sagledao organizacijski kontekst poslovne inteligencije i odredili najvažniji utjecajni faktori u okviru tog konteksta, te analizom napretka i najnovijih saznanja tvrtke *Gartner Inc* na temu poslovne inteligencije s ciljem utvrđivanja tehnološkog razvoja i budućih koraka u kontekstu tehnologija kod primjene koncepta poslovne inteligencije.

FAZA II: Analiza čimbenika održivog gospodarskog razvoja

U svrhu što uspješnije identifikacije glavnih čimbenika koji određuju potencijal zemlje za povlačenje sredstava za znanost, istraživanje i inovacije, sagledani su temeljni globalni ciljevi i Strategija Europa 2030 u kontekstu odgovora na izazove i postavljene globalne ciljeve. U segmentu definiranja horizontalnih čimbenika za prijelaz na održivost i približavanje ispunjavanju strateških ciljeva, skup komponenta koji je bio u najvećoj mjeri povezan s postavljenim istraživačkim pitanjem su upravo obrazovanje, znanost, tehnologija, istraživanje, inovacije i digitalizacija te je u tom okviru nastavljen istraživački rad analize sekundarnih izvora. Poglavlja su, sukladno istraživanom, podijeljena u najvažnije segmente, a koji uključuju znanost i tehnologiju, istraživanje, razvoj i inovacije te digitalizaciju. Iz istraživanja je izuzeta komponenta obrazovanja, budući da ista nije imala relevantnu povezanost u kontekstu promatranog skupa i pitanja. Istraživanje je provedeno analizom relevantnih znanstvenih i Internet izvora, s brojnim osvrtima međunarodnih časopisa koji objavljuju najbolja recenzirana istraživanja u svim područjima znanosti i tehnologije na temelju svoje originalnosti, važnosti, interdisciplinarnog interesa, pravovremenosti, dostupnosti i zaključaka i time pružaju relevantna tumačenja aktualnih i nadolazećih trendova koji utječu na znanost, znanstvenike i širu javnost. Istraživanje je također obuhvatilo i kontekst Europske unije analizom publikacije Europske komisije u promatranim područjima. Uz navedeno, analizirani su i sagledani specifični mjerni alati i ljestvice koje pomažu Europskoj uniji da u navedenom kontekstu, uzimajući u obzir relevantne faktore, sagleda problematiku svake pojedine zemlje i EU općenito u kontekstu uspješnosti u znanosti, tehnološkom razvoju, istraživanju, razvoju, inovacijama i digitalizaciji.

FAZA III: Analiza instrumenata Europske unije koji izdvajaju sredstva za znanost, istraživanje i inovacije

Kroz treću fazu istraživačkog procesa bilo je potrebno utvrditi koji su to najvažniji instrumenti i fondovi Europske unije za povlačenje sredstava za znanost, istraživanje i inovacije kako bi se odabrani čimbenici mogli analizirati u kontekstu tih instrumenata i njihovih glavnih segmenata. Kad su u pitanju istraživanje, razvoj i inovacije, velika sredstva su namijenjena istima, a to se najviše manifestira kroz postavljene ciljeve i prioritete svakog pojedinog programa te kroz natječaje koji se unutar programa plasiraju. Istraživanje je identificiralo sveukupno 8 glavnih instrumenata kojima se u pojedinim segmentima financira istraživanje i razvoj kroz infrastrukturu, razvoj ljudskih potencijala, ali i kreiranje budućih strategija i planova za pojedina područja i grane. Najvažniji i najveći instrument i fond Europske unije koji svoja sredstva gotovo isključivo usmjerava na znanost, istraživanje i razvoj i poticanjem i stvaranjem strategije razvoja znanosti i njezinog usmjeravanja k većoj suradnji s poslovnim sektorom u kontekstu stvaranja inovacija

upravo je program Obzor Europa. Svako programsko razdoblje Obzor definira ključne probleme u znanosti, istraživanju i inovacijama te sukladno tome određuje osnovne stupove unutar kojih se raspoređuju sredstva za buduće natječaje. Osnovne komponente koje Obzor u sebi sadržava su svakako naglasak na međunarodnom povezivanju i suradnji prilikom provođenja istraživanja, potenciranje suradnje između znanstvene zajednice i poslovnog sektora u istraživanju i donošenju relevantnih rješenja/inovacija za gospodarstvo i društvo te objavljivanje rezultata istraživanja ali i nastalih finalnih proizvoda u otvorenom pristupu, transparentno, javno i dostupno svima kako bi se omogućio lakši pristup i razvoj koncepta otvorenih inovacija, odnosno sudjelovanja svih razina društva u donošenju rješenja za opću dobrobit. Finalan cilj, a i jedan od stupova Obzora za novo programskog razdoblje je poticaj kreiranju europskih inovacijskih ekosustava, odnosno mrežnih zajednica kojima je cilj kombinirati resurse s ciljem stvaranja zajedničkih inovacija i rezultata.

FAZA IV: Odabir indikatora i postavljanje hipoteza

Za potrebe četvrte faze istraživačkog procesa definirani su temeljni pojmovi za promatranje i daljnju analizu: znanost, tehnologija, istraživanje, razvoj, inovacije i digitalizacija. U tom su kontekstu identificirana tri čimbenika na koja se u literaturi stavlja velik naglasak i potreba njihovog razvoja i unapređenja: digitalne vještine iz pojma digitalizacija te ulaganja poduzeća u istraživanje i razvoja iz pojma istraživanje, razvoj i inovacije. Treći cilj bio je pokušati sagledati što više utjecajnih faktora unutar promatranog skupa horizontalnih čimbenika. Za potrebe stavljanja u odnos s povučenim sredstvima za znanost, istraživanje i inovacije po državama uzet je program Obzor, najveći instrument Europske unije za istraživanje i inovacije. Uvidom u statističke baze dostupnih podataka, za potrebe daljnje analize identificirani su ključni indikatori za dokazivanje hipoteza, a to su digitalne vještine, ulaganja poduzeća u istraživanje i razvoj i Europska ljestvica uspjeha u inoviranju i njezine aktivnosti i dimenzije koje sadrže razne skupove pokazatelja i pokrivaju sva teorijom analizirana područja.

Temeljem navedenog postavljene su 3 istraživačke hipoteze:

H1: Povlačenje sredstava iz programa Obzor ovisi o razini digitalnih vještina stanovništva zemlje

H2: Ulaganja poslovnog sektora u istraživanje i razvoj utječu na povlačenje sredstava iz programa Obzor

H3: Alatima poslovne inteligencije moguće je identificirati koje inovacijske dimenzije utječu na povlačenje sredstava iz programa Obzor.

FAZA V: Provedba empirijskog dijela istraživanja

U posljednjoj fazi prije elaboracije rezultata, proveden je empirijski dio istraživanja korištenjem alata i koncepata poslovne inteligencije. Iz javno dostupnih statističkih baza podataka izdvojeni su relevantni indikatori za razdoblja za koja su isti bili dostupni, iz interaktivnog alata poslovne inteligencije Europske komisije izdvojeni su podaci o inovacijskim dimenzijama po državama Europske unije za razdoblje 2014-2020, a podaci oko realizacije i osnovnih činjenica vezanih uz Obzor korišteni su i izdvojeni iz alata poslovne inteligencije kreiranog zasebno za praćenje relevantnih indikatora unutar pojedinih programskih razdoblja i drugih kategorija. Kombinacijom 2 alata poslovne inteligencije i alata *Microsoft Excel*, finalni podaci su prebačeni u alat *Microsoft Excel* i potom uvezeni u alat poslovne inteligencije korišten za daljnje obrade i analize, *Microsoft Power BI*. Sve su tablice pročišćene i pripremljene za analizu. Uspješno su identificirane države koje su isključene iz daljnje analize jer u određenim kategorijama odstupaju od prosjeka te samim time potencijalno utječu na istraživački rezultat. Provedene su opsežne analize i uključeni dodatni faktori promatranja unutar pojedinih hipoteza te je finalnim rezultatima dobivenim kroz alat dobiven i odgovor na postavljeno istraživačko pitanje: *Kako je moguće primjenom poslovne inteligencije utvrditi potencijal zemlje za povlačenje sredstava za znanost, istraživanje i inovacije iz fondova Europske unije?*

Potencijal zemlje za povlačenje sredstava za znanost, istraživanje i inovacije primjenom poslovne inteligencije moguće je utvrditi:

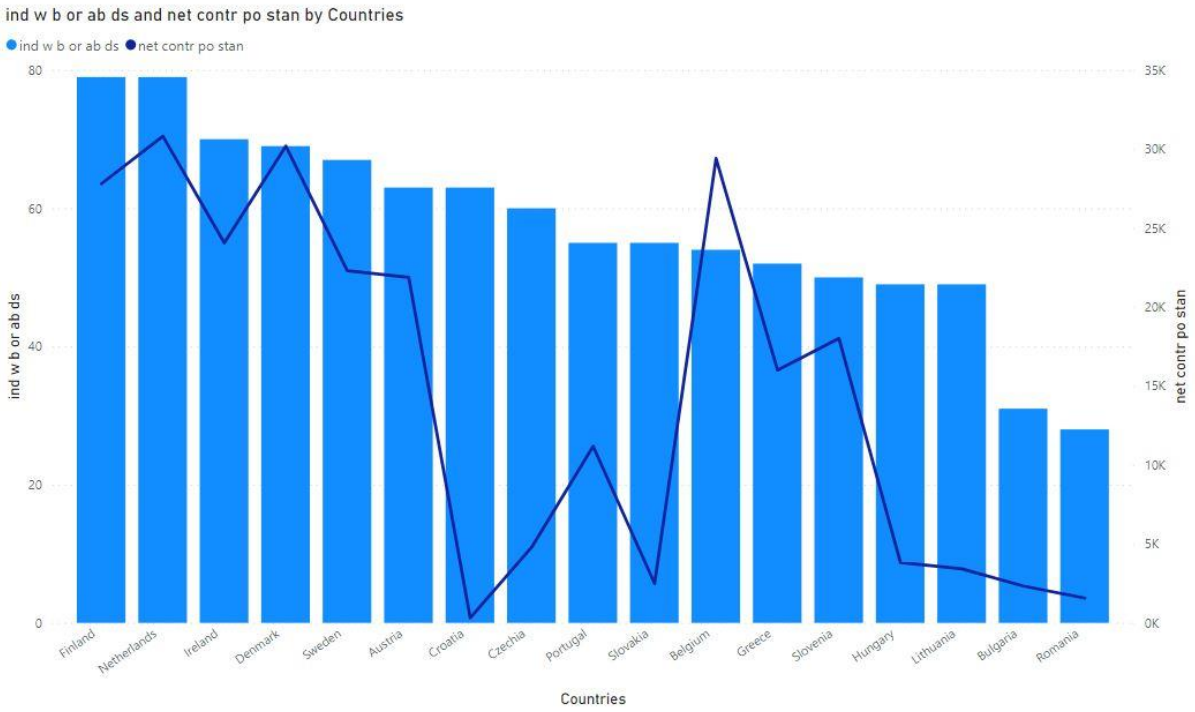
1. Razumijevanjem pojma i konteksta poslovne inteligencije
2. Primjenom koncepta poslovne inteligencije, i to: tehnološki, kroz korištenje alata i organizacijski, kroz aspekt ljudskih potencijala i njihovo razumijevanje utjecajnih čimbenika na određene pojave i probleme kako bi se uopće bilo u mogućnosti iste identificirati i analizirati i potom izvesti zaključke, utvrditi probleme i kreirati daljnje strategije
3. Primjenom relevantnih pokazatelja i to iz više dimenzija i promatranih kutova, budući da alati poslovne inteligencije izvode najkvalitetnije i najbolje zaključke kad se u promatrane probleme uključi više različitih potencijalnih utjecajnih čimbenika.

7.2. Elaboracija hipoteza

U okviru istraživačkog pitanja postavljene su 3 hipoteze koje su odredile daljnji smjer istraživanja. U nastavku su prikazani najznačajniji rezultati:

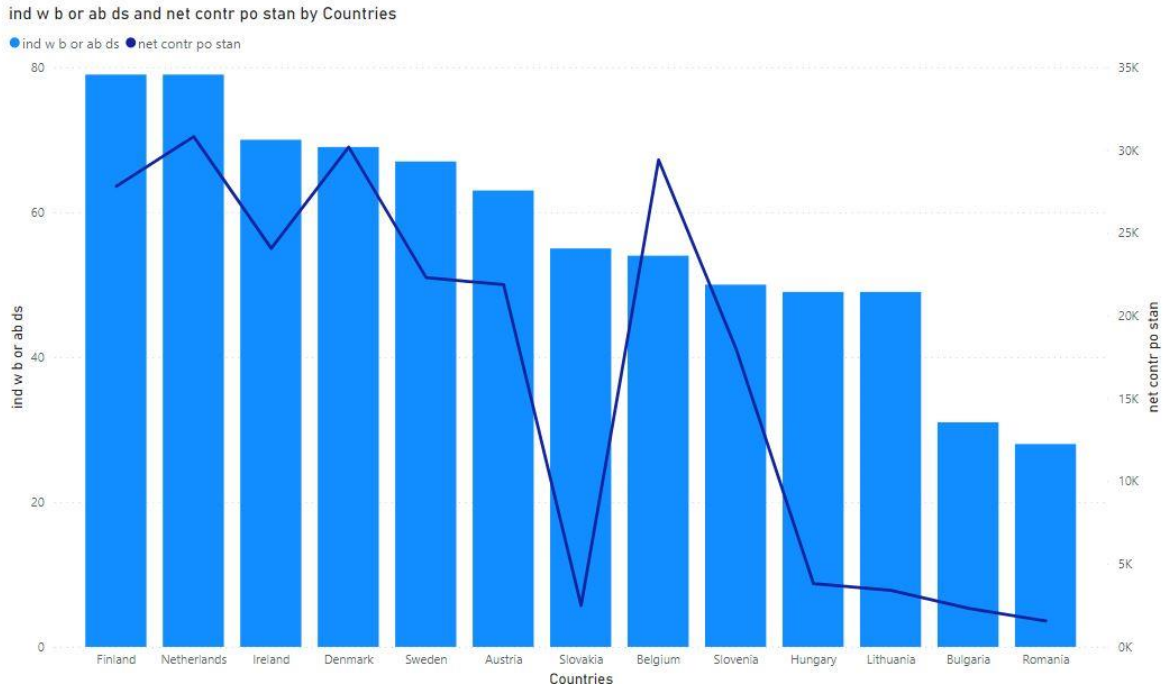
H1: Povlačenje sredstava iz programa Obzor ovisi o razini digitalnih vještina stanovništva zemlje

Za potrebe ispitivanja navedene hipoteze, formiran je skup od 17 država Europske unije koje isključuju one najveće i gospodarski najsnažnije, kao i one najmanje čija su sredstva povučena iz programa Obzor zanemarivo niska. Glavni promatrani čimbenik bile su digitalne vještine za 2021. godinu, budući da iste sadržajno i definicijom značajnije odgovaraju potrebama današnjeg društva, kao i znanstvene i istraživačke zajednice. Rezultati su pokazali kako države s najvišim postotkom populacije s razvijenim osnovnim i višim ukupnim digitalnim vještinama (Nizozemska, Danska, Austrija, Finska i Irska) imaju i najveći udio povučenih sredstava iz programa Obzor po stanovniku.



Vizual 28. Usporedba osnovnih i viših ukupnih digitalnih vještina u odnosu na neto doprinos Europske unije po pojedinoj državi za program Obzor
(Izvor: izrada autora prema Prilog 1,1., 4.)

U ovom segmentu, nakon daljnjih analiza, alat prepoznaje pozitivnu korelaciju između ova dva indikatora. Najveća odstupanja su kod Hrvatske, Češke, Portugala i Slovačke koje imaju znatno razvijenije digitalne vještine stanovništva nego rezultate i realizaciju u programu Obzor, dok je taj rezultat veći u korist Obzora nego kod digitalnih vještina kod Belgije, Grčke i Slovenije. Kako je kod Hrvatske, Češke, Portugala i Grčke slučaj u kojem kod pojedinaca digitalne vještine nisu mogle biti ocijenjene jer nisu koristili Internet u posljednja tri mjeseca viši od europskog prosjeka, iste se dalje izdvojilo, kako bi se hipoteza još detaljnije sagledala.



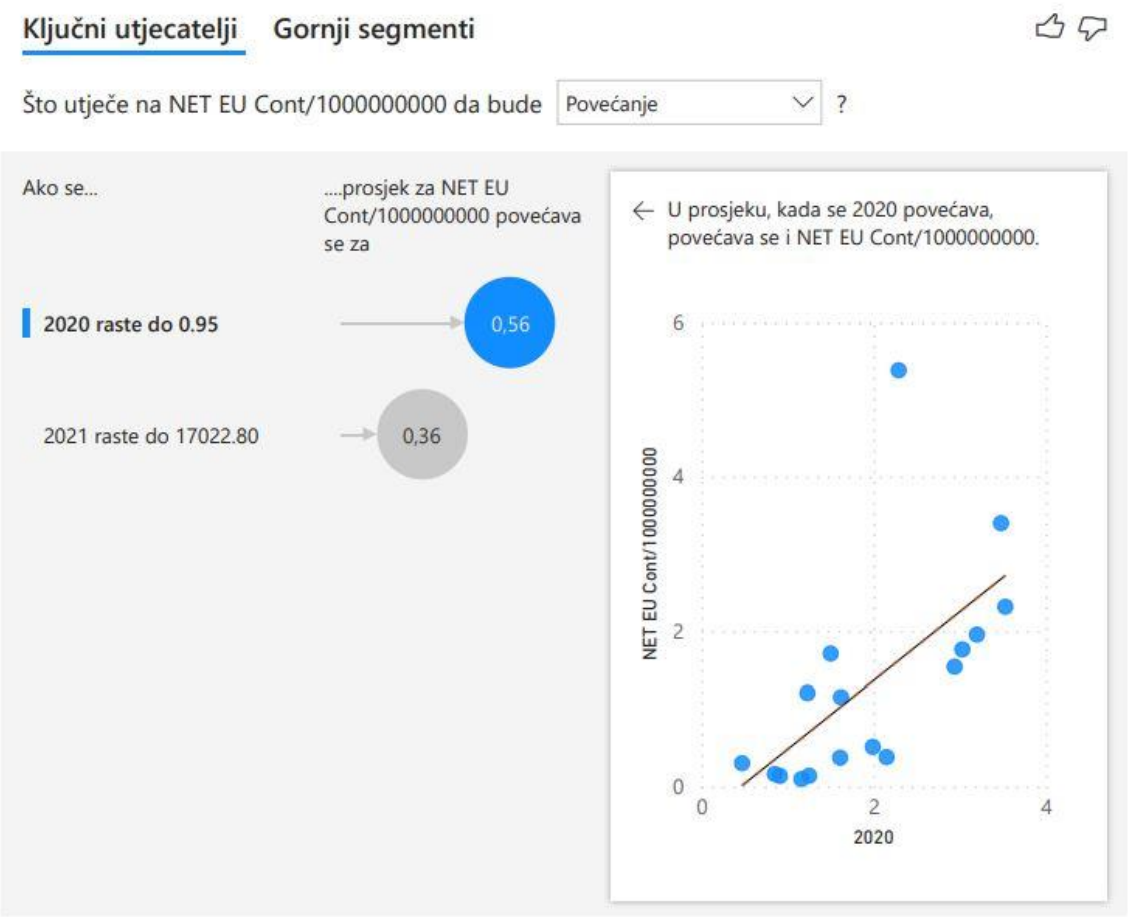
Vizual 29. Usporedba osnovnih i viših ukupnih digitalnih vještina kod država koje nisu eliminirane u kategoriji nemogućnosti ocjenjivanja digitalnih vještina u odnosu na neto doprinos Europske unije po pojedinoj državi za program Obzor

(Izvor: izrada autora prema Prilog 1,1., 4.)

Slijedom navedenog, može se utvrditi pozitivna korelacija između varijable digitalne vještine i neto doprinosa Europske unije po pojedinoj državi za program Obzor te se zaključiti kako je **H1 potvrđena.**

H2: Ulaganja poslovnog sektora u istraživanje i razvoj utječu na povlačenje sredstava iz programa Obzor

Kod ulaganja poslovnog sektora u istraživanje i razvoj glavni analizirani indikator bio je ulaganje poslovnog sektora u istraživanje i razvoj kao postotak BDP-a. U tom su kontekstu analizirana i ukupna istraživanja i razvoj kao postotak BDP-a i sve je stavljeno u odnos s dodijeljenim sredstvima svakoj pojedinoj državi u okviru programa Obzor. Prilikom analize, alat je odmah prepoznao povezanost tih komponenata.



Slika 26. Prikaz dokazivanja H2 u alatu poslovne inteligencije
(Izvor: izrada autora prema Prilog 1,1., 7.)

Slijedom navedenog, može se utvrditi pozitivna korelacija između varijable ulaganja poslovnog sektora u istraživanje i razvoj i neto doprinosa Europske unije po pojedinoj državi za program Obzor i zaključiti kako je **H2 potvrđena.**

H3: Alatima poslovne inteligencije moguće je identificirati koje inovacijske dimenzije utječu na povlačenje sredstava iz programa Obzor

Za potrebne dokazivanja hipoteze 3 korištene su dimenzije određene putem Europske ljestvice uspjeha u inoviranju, a kojoj je finalan cilj uzimajući u obzir sve navedene dimenzije odrediti status država po pitanju inovacijskog potencijala i realizacije u tom području. Izdvojeno je ukupno 12 dimenzije i dodijeljene su im šifre te su iste razvrstane u 4 kategorije aktivnosti kojima pripadaju i u tom su skupu promatrane u odnosu na neto EU doprinos Obzor sredstava po državama koje su odabrane kao istraživački uzorak prema ranije spomenutom modelu. U alatu su dimenzije i aktivnosti unutar dimenzija stavljene u odnos te je Microsoft Power BI sam

identificirao ključne odnose, veze i korelacije. Iz navedenog je zaključeno kako su dimenzije kod kojih nisu prepoznate pozitivne korelacije s povučenim Obzor sredstvima:

- **Učinci prodaje,** koja mjeri ekonomski učinak inovacija i uključuje tri pokazatelja: Izvoz proizvoda srednje i visoke tehnologije, Izvoz usluga temeljenih na znanju i Prodaja koja rezultira iz inovativnih proizvoda
- **Održivost okoliša,** koja obuhvaća poboljšanja koja rezultiraju smanjenjem negativnog utjecaja na okoliš i uključuje tri pokazatelja: Produktivnost resursa, Izloženost onečišćenju zraka finim česticama PM2.5 i Razvoj tehnologija povezanih s okolišem iz aktivnosti Učinci i **Inovatori** iz aktivnosti Inovacijske aktivnosti koja dimenzija uključuje dva pokazatelja koji mjere udio MSP-ova koji su uveli inovacije na tržište ili unutar svojih organizacija, a obuhvaća inovacije proizvoda i poslovnih procesa, a pri čemu dimenzija Inovatori također negativno korelira unutar Inovacijskih aktivnosti s dimenzijom
- **Intelektualna imovina** koja obuhvaća različite oblike prava intelektualnog vlasništva generirane inovacijskim procesom, uključujući prijave patenata, prijave zaštitnih znakova i prijave dizajna i u usporedbi s EIS 2020, definicija indikatora mjerenje prijava zaštitnih znakova je promijenjena. Pokazatelj više ne uključuje prijave zaštitnih znakova podnesene u svijetu Ured za intelektualno vlasništvo, što bi svakako trebalo detaljnije istražiti i procijeniti utjecaj tog faktora na njihovu negativnu korelaciju.

Dimenzija koja pokazuje najizraženiju međusobnu korelaciju s promatranim indikatorom sredstava je dimenzija **Atraktivni istraživački sustav** koja pripada aktivnosti **Okvirni uvjeti** i uključuje tri pokazatelja kojima mjeri međunarodnu konkurentnost znanstvene baze fokusiranjem na međunarodna znanstvena koautorstva te najcitiranije publikacije i inozemne doktorande.

Slijedom navedenog, može se sagledati inovacijske dimenzije unutar njihovih aktivnosti i zaključiti o njihovom utjecaju na povlačenje sredstava iz programa Obzor na sljedeći način:

- Aktivnost **Okvirni utjecaji** mogla bi se gledati kao najvažnija utjecajna aktivnost u pogledu povlačenja sredstava za Obzor jer dimenzija **Atraktivni istraživački sustav** pokazuje najizraženiju međusobnu korelaciju s promatranim indikatorom sredstava i pozitivnu međusobnu korelaciju s dimenzijom **Digitalizacija** unutar iste aktivnosti.
- Aktivnost **Ulaganja** druga je najvažnija aktivnost unutar promatranih kategorija jer sve njezine dimenzije pokazuju pozitivnu korelaciju s promatranim indikatorom sredstava kao i pozitivnu korelaciju dimenzija **Financije i potpora** i **Ulaganja**

poduzeća. Ta je aktivnost stavljena na drugo mjesto jer postoje značajnija odstupanja od prve aktivnosti unutar promatranog skupa.

- Aktivnost **Inovacijske aktivnosti** treća je po redu aktivnost na ljestvici promatranog utjecaja jer kod dimenzije **Inovatori** alat ne prepoznaje korelaciju s promatranim indikatorom sredstava, a promatrana dimenzija također unutar iste aktivnosti ima negativnu korelaciju s dimenzijom Intelektualna imovina**.**
- Aktivnost **Učinci** posljednja je dimenzija po važnosti u kontekstu realiziranih sredstava jer kod dimenzija **Učinci prodaje** i **Održivost okoliša** nije prepoznata korelacija s promatranim indikatorom sredstava, a unutar iste aktivnosti te dvije dimenzije također pokazuju međusobnu negativnu korelaciju.

Slijedom navedenog, jasno je kako je alatima poslovne inteligencije moguće identificirati koje inovacijske dimenzije utječu na povlačenje sredstava iz programa Obzor i zaključiti kako je **H3 potvrđena.**

7.3. Primjena rezultata i preporuke

Za potrebe ovog rada provedena je analiza i selekcija potencijalnih utjecajnih čimbenika na povlačenje predstava za znanost, istraživanje i inovacije iz fondova Europske unije, pri čemu je bilo ključno i utvrditi relevantne instrumente Europske unije za takvu vrstu projekata. U tijek istraživanja uključeni su koncept i alati poslovne inteligencije kako bi se prikazale njihove mogućnosti i prednosti korištenja kod takvih vrsta analiza. Svrha istraživačkog procesa bila je primjena BI alata i koncepata u detektiranju utjecajnih faktora na povlačenje sredstava za znanost, istraživanje i inovacije. Promatrani skup u početku je uključio sve države Europske unije, od kojih su neke zbog svojih specifičnosti izuzete iz daljnjih istraživanja. Takva vrsta istraživanja uključila je međunarodnu komponentu i dala veću mogućnost usporedbe, ne samo unutar zemlje, već i s onima koji u pojedinim kategorijama imaju bolje i lošije rezultate, te je time važnost istraživanja i ovaj rad u konačnici, prepoznata kroz dva osnovna doprinosa:

Aplikativni doprinos: zaključcima izvedenima iz istraživačkog pitanja i dokazivanjem hipoteza, postavljena je osnovna podloga za kreiranje nacionalnih smjernica i politika vezanih za povlačenje sredstava za znanost, istraživanje i inovacije te učinkovitije iskorištavanje takvih instrumenata i fondova. Iz analiza je moguće ocijeniti utjecajne čimbenike i dimenzije za svaku promatranu kategoriju, te utvrditi kategorije koje su važne u tom kontekstu, a potrebno ih je značajnije razviti ili poboljšati.

Znanstveni doprinos: provedenim istraživanjem postavljeni su okviri i temelji za kreiranje informacijskog modela utjecajnih čimbenika na povlačenje sredstava za znanost, istraživanje i inovacije iz fondova Europske unije.

Istraživačka ograničenja najviše su izražena u kontekstu nekih nepotpunih podataka te nemogućnosti da se pojedini indikatori iz istog razloga prošire i još neki od njih uključe u analizu, što bi bila dodatna prednost jer je upravo svrha i cilj poslovne inteligencije i alata poslovne inteligencije da iz većih količina podataka stvara široku sliku i definira smjernice i fokuse grupiranjem tih podataka i utvrđivanjem njihovih međusobnih korelacija.

Daljnja istraživanja bavila bi se upravo navedenom tematikom te bi se, s ciljem kreiranja modela utjecajnih čimbenika na povlačenje sredstava za znanost, istraživanje i inovacije iz fondova Europske unije i ostali horizontalni čimbenici uključili u istraživanje i ocijenila njihova međusobna korelacija s povučenim sredstvima. Istraživanje se može i proširiti kroz pojedinačno sagledavanje horizontalnih čimbenika i analizu većeg skupa indikatora vezanih uz svaki pojedini čimbenik, a koji pokrivaju komponente vještina i infrastrukture kako bi se dobila što cjelovitija slika koji od čimbenika u kojoj mjeri utječe na povlačenje sredstava za znanost, istraživanje i inovacije iz fondova Europske unije, ali i koji indikatori su zaslužni za taj utjecaj.

8. Zaključak

Temeljem provedenog teorijskog i empirijskog istraživanja došlo se do određenih zaključaka koji mogu služiti u znanstvenoj zajednici kao podloga za daljnja istraživanja i proširenja analizirane teme, unutar pojedine države za kreiranje nacionalnih smjernica i politika, ali i za potencijalne promjene unutar određenih sektora i poticanje suradnje znanstvenog i poslovnog sektora. Potvrđivanjem svih hipoteza i odgovaranjem na istraživačko pitanje dodatno je stavljen naglasak na važnost strateškog promišljanja o takvim temama, kao i detaljnog planiranja daljnjih koraka za poboljšanje. Povlačenje sredstava Europske unije omogućava razvoj i napredak u određenim segmentima, no nije ga moguće provesti bez mijenjanja sustava, međunarodnog povezivanja i vidljivosti, kao ni bez kvalitetnog ljudskog i infrastrukturnog okvira.

S obzirom da neke zemlje još uvijek ne pronalaze efikasne načine kojima bi povukle sredstva nacionalnih zaklada, ali i takvih instrumenata te se potencijalno pozicionirale u nacionalnom i međunarodnom istraživačkom prostoru, saznanja i zaključci iz ovog specijalističkog rada svakako mogu služiti kao podloga za ostvarivanje veće učinkovitosti i boljeg pozicioniranja u kontekstu povlačenja sredstava za znanost, istraživanje i inovacije.

Literatura[1]

KNJIGE:

1. Bilas, V., Franc, S. (2018) *Inovacije i razvoj*. Zagreb: Notitia
2. Brown, T. (2019) *Change by design*. Zagreb: Mate
3. Carić, A. (2003) *Istraživanje i razvoj u informacijskoj i komunikacijskoj tehnologiji*. Zagreb: Element
4. Drucker, P. (1992) *Inovacije i poduzetništvo*. Zagreb: Globus
5. Franc, S., Bilas, V., Bošnjak, M. (2021) *Konkurentnost i komparativne prednosti u globalnoj digitalnoj ekonomiji*. Zagreb: Ekonomski fakultet
6. Gupta, S. (2018) *Driving Digital Strategy*. Boston, Massachusetts: Harvard Business Review Press
7. Javorović, B., Bilandžić, M. (2007) *Poslovne informacije i business intelligence.* Zagreb: Golden marketing – Tehnička knjiga
8. Kennedy, M. (2015). *Globalizing Knowledge*. Stanfor: Stanfor University Press
9. Liataud, B., Hammond, M. (2006) *E-poslovna inteligencija*. Zagreb: Prudens Consilium
10. Panian, Ž., Klepac, G. (2003) *Poslovna inteligencija*. Zagreb: Masmedia
11. Pisano, G.P. (2006) *Science Business: The Promise, the Reality, and the Future of Biotech*. Harvard Business Press, Boston, MA.
12. Siebel, T.M. (2019) *Digital Transformation*. New York: RosettaBooks
13. Spremić, M. (2017) *Digitalna transformacija poslovanja*. Zagreb: Ekonomski fakultet
14. Taipale, I. (2021) *Sto društvenih inovacija iz Finske*. Zagreb: Knjigra
15. Weingart, Peter. [2001] (2015) *Die Stunde der Wahrheit? Zum Verha¨ltnis der Wissenschaft zu Politik,Wirtschaft und Medien in der Wissensgesellschaft*. Weilerswist: Velbru¨ck Wissenschaft

RADOVI (znanstveni članci, prethodna priopćenja, pregledni radovi):

1. Audretch, D.B. and Keilbach, M. (2007) *The localization of entrepreneurship capital – evidence from Germany*. Jena Economic Research Paper, Vol. 2007-029, DOI:10.1111/j.1435-5957.2007.00131.x
2. Baković, T., Ledić-Purić, D- (2010) *Uloga inovacija u poslovanju malih i srednjih poduzeća*. Poslovna izvrsnost, Vol. 5 No. 2, 2011., str.27-42. Preuzeto s: https://hrcak.srce.hr/file/112074 (Datum pristupa: 3.07.2022.)

[1] Za literaturu preuzetu s mrežnih izvora evidentiran je posljednji datum pristupa i provjere autora

3. Bečić, E., Dabić, M. (2007) *Analiza ulaganja poslovnog sektora Republike Hrvatske u istraživanje i razvoj*. Revija za sociologiju, Vol. 39 No. 1-2, 2008., str. 69-84. Preuzeto s: https://hrcak.srce.hr/file/41964 (Datum pristupa: 2.07.2022.)
4. Bejaković, P. (2003) *Financiranje istraživanja i razvoja.* Financijska teorija i praksa 27 (2) str. 181-212 (2003.). Preuzeto s: https://hrcak.srce.hr/file/8938 (Datum pristupa: 2.07.2022.)
5. Bhatiasevi, V., Naglis, M. (2020) *Elucidating the determinants of business intelligence adoption and organizational performance*. Information Development 2020, Vol. 36(1) 78–96. 10.1177/0266666918811394
6. Bilandžić, M. et al. (2012) *Business intelligence u hrvatskom gospodarstvu*, Poslovna izvrsnost, 6(1), str. 9-27. Preuzeto s: https://hrcak.srce.hr/84678 (Datum pristupa: 25.06.2022.)
7. Božić, Lj. (2005). *Multinacionalni modeli širenja inovacija*. Ekonomski pregled, Vol. 56 No. 9, 2005., str. 671-683. Preuzeto s: https://hrcak.srce.hr/file/15972 (Datum pristupa: 2.07.2022.)
8. Ceboteran, E. (2011) *Business Intelligence*. Journal of Knowledge Management, Economics and Information Technology, ScientificPapers.org, vol. 1(2), str. 1-10
9. Chen, H., Chiang, R. H. L., & Storey, V. C. (2012). *Business Intelligence and Analytics: From Big Data to Big Impact*. MIS Quarterly, 36(4), 1165–1188. https://doi.org/10.2307/41703503
10. Chen, X., & Siau, K. (2020) *Business Analytics/Business Intelligence and IT Infrastructure: Impact on Organizational Agility*. Journal of Organizational and End User Computing (JOEUC), 32(4), 138-161. http://doi.org/10.4018/JOEUC.2020100107
11. Darwiesh, A., Alghamdi, M. I, El-Baz, A.H., Elhosney, M. (2022) *Social Media Big Data Analysis: Towards Enhancing Competitiveness of Firms in a Post-Pandemic World.* Hindawi Journal of Healthcare Engineering Volume 2022, Article ID 6967158, 14 pages. https://doi.org/10.1155/2022/6967158
12. Devčić, A., Pleša, D. (2020) *Što Europska unija čini na području promoviranja inovacija u obrazovanju*. Agroeconomia Croatica, Vol. 10 No. 1, 2020., str. 106-112. Preuzeto s: https://hrcak.srce.hr/file/365808 (Datum pristupa: 2.07.2022.)
13. Franc, S., Barišić, A. i Palić, P. (2020) *Društvene inovacije kao važan element europskih razvojnih strategija*. Revija za socijalnu politiku, 27 (3), 309-327. https://doi.org/10.3935/rsp.v27i3.1719

14. Hayter, C. (2013) *Conceptualizing knowledge-based entrepreneurship networks: perspectives from the literature*. Small Business Economic, https://doi.org/10.1007/s11187-013-9512-x
15. Hayter, C., Nelson, A.J., Zayed, S., O'Connor, A.C. (2018) *Conceptualizing academic entrepreneurship ecosystems: a review, analysis and extension of the literature.* The Journal of Technology Transfer, Vol. 43 No. 4, pp. 1039-1082., https://doi.org/10.1007/s10961-018-9657-5
16. Hortovanyi, L., Szabo, R.Z. and Fuzes, P. (2021) *Extension of the strategic renewal journey framework: the changing role of middle management*. Technology in Society, Vol. 65, p. 101540, doi: 10.1016/j.techsoc.2021.101540.
17. Huang, Z., Savita, K.S., Zhong-jie, J. (2022) *The Business Intelligence impact on the financial performance of start-ups.* Information Processing & Management Volume 59, Issue 1, January 2022, https://doi.org/10.1016/j.ipm.2021.102761
18. Khan, R. A., Quadri, S. K. (2012) *Dovetailing of Business Intelligence and Knowledge Management: An Integrative Framework.* Information and Knowledge Management, ISSN 2224-5758 (Paper) ISSN 2224-896X (Online), Vol 2, No.4, 2012
19. Landeros, J.R., & Fuentes, M.D. (2016) *Development of a Framework for the Use of a Tool for Machine Learning and Data Mining*. Res. Comput. Sci., 122, 127-139. 10.13053/rcs-122-1-10
20. Matešić, M. (2020). *Eko-inovacije za održivi razvoj*. Socijalna ekologija : journal for environmental thought and sociological research = Socijalna ekologija : Zeitschrift für Umweltgedanken und soziologische Forschung, Vol. 29 No. 2, 2020., str. 153-177. https://doi.org/10.17234/SocEkol.29.2.1
21. Milošević, B. (2014) *Znanost, organizacija, tehnologija i društveni napredak*. Media, culture and public relations, 5, 2014, 1, 52-59. Preuzeto s: https://hrcak.srce.hr/file/180981 (Datum pristupa: 2.07.2022.)
22. Moutinho, R., Au-Yong-Oliveira, M., Coelho, A. and Manso, J.P. (2016) *Determinants of knowledge-based entrepreneurship: an exploratory approach*. International Entrepreneurship and Management Journal, Vol. 12 No. 1, pp. 171-197, https://doi.org/10.1007/s11365-014-0339-y
23. Muhammad, G., Ibrahim, J., Bhatti, Z., Waqas, A. (2014) *Business Intelligence as a Knowledge Management Tool in Providing Financial Consultancy Services*. American Journal of Information Systems, vol. 2, no. 2 (2014): 26-32. doi: 10.12691/ajis-2-2-1.
24. Nazari, F., Taghavi, S.S., Valizadeh, E., Soleymani, M., Shahrabi Farahani, D., Bagheri, R. (2022) *An Investigation on the Impact of Business Intelligence over the*

Performance of Startup Companies according to Innovation and Knowledge Management as Mediators. Hindawi Mathematical Problems in Engineering Volume 2022, Article ID 3834696, 12 pages. https://doi.org/10.1155/2022/3834696

25. Nolan J. (2000) *Building an effective and inexpensive internal Buisness Intelligence Network.* Business Intelligence 2000, 2. Hrvatska konferencija o pribavljanju, organiziranju i uporabi poslovnih informacija, Zavod za poslovna istraživanja, Zagreb, 2000.
26. Paradza, D.; Daramola, O. (2021) *Business Intelligence and Business Value In Organisations: A Systematic Literature Review*. Sustainability 2021, 13, 11382. https://doi.org/10.3390/su132011382
27. Popovič, A., Turk, T., Jaklič, J. (2010) *Conceptual model of business value of business intelligence systems*. Management: Journal of Contemporary Management Issues 15 (1): 5-30.
28. Powell, J.J.W., Dusdal, J. (2017) *Science Production in Germany, France, Belgium, and Luxembourg: Comparing the Contributions of Research Universities and Institutes to Science, Technology, Engineering, Mathematics, and Health.* Minerva (2017) 55:413–434. DOI: 10.1007/s11024-017-9327-z
29. Prodanov, H. (2018) *Social entrepreneurship and digital technologies*. Economic Alternatives, 2018, Issue 1, pp. 123-138. Preuzeto s: https://www.unwe.bg/uploads/Alternatives/9_Prodanov_EAlternativi_en_1_2018.pdf (Datum pristupa: 2.07.2022.)
30. Ravlić, D. (2015) *From Information to Knowledge: Business Intelligence Usage and Perspectives*. Proceedings of the ENTRENOVA - ENTerprise REsearch InNOVAtion Conference, Kotor, Montengero, 10-11 rujan 2015, str. 96-103
31. Reyes, C.N. (2016) *Framing the entrepreneurial university: the case of the national university of Singapore*. Journal of Entrepreneurship in Emerging Economies, Vol. 8 No. 2, pp. 134-161, https://doi.org/10.1108/JEEE-09-2015-0046
32. Rodica, B., Starc, J. i Konda, I. (2014) *Globalni ekosustav sa novim izazovima i otvoreno inoviranje*. Tranzicija, 16 (33), 61-70. Preuzeto s https://hrcak.srce.hr/file/188757 (Datum pristupa: 2.07.2022.)
33. Savić, G., Luić, Lj. (2016) *Business intelligence in managing of technical-information system*. Proceedings of the 13th International Conference on Industrial Logistics, ICIL 2016., str. 231-238

34. Skyrius R., & Valentukevičė J. (2020) *Business Intelligence Agility, Informing Agility and Organizational Agility: Research Agenda*. Information & Media, 90, 8-25. https://doi.org/10.15388/Im.2020.90.47
35. Suhaimi, N.S., Abdul Halim, M.A.S., Hashim, H.A. (2020) *Commercialization of academic research: assessing the perception of academicians at a public university in Malaysia*, Journal of Applied Research in Higher Education, Vol. ahead-of-print No. ahead-of-print, https://doi.org/10.1108/JARHE-04-2020-0071
36. Suša Vugec, D., Bosilj Vukšić, V., Pejić Bach, M.; Jaklič, J., Indihar Štemberger, M. (2020) *Business intelligence and organizational performance: The role of alignment with business process management*. Business process management journal, 26 (2020), 6; 1709-1730. doi:10.1108/bpmj-08-2019-0342
37. Szulcewska-Remi, A., Nowak-Mizgalska, H. (2021) *Who really acts as an entrepreneur in the science commercialisation process: the role of knowledge transfer intermediary organisations*. Journal of Entrepreneurship in Emerging Economies, Vol. ahead-of-print No. ahead-of-print. ISSN: 2053-4604. DOI: https://doi.org/10.1108/JEEE-09-2020-0334
38. Šimpraga, M. (2020) *Inovacije i transfer tehnologije ključni su čimbenik razvoja hrvatskog gospodarstva.* Annual of the Croatian Academy of Engineering, 2020 (1), 3-9. Preuzeto s https://hrcak.srce.hr/266790 (Datum pristupa: 3.04.2022.)
39. Švarc, J., Lažnjak, J. (2020) *Pametna specijalizacija i lokalni razvoj: posljedice na znanstvenu i inovacijsku politiku u razdoblju 2009.-2019*. Radovi Zavoda za znanstvenoistraživački i umjetnički rad u Bjelovaru, Vol. 0 No. 14, 2020., str. 53-78. https://doi.org/10.21857/90836c7exy
40. Tavera Romero, C.A., Ortiz, J.H., Khalaf, O.I., Ríos Prado, A. (2021) *Business Intelligence: Business Evolution after Industry 4.0.* Sustainability 2021, 13, 10026. https://doi.org/10.3390/su131810026
41. Ting, S.H., Yahya, S. and Tan, C.L. (2019) *The influence of researcher competence on university-industry collaboration. The mediating role of domain knowledge transfers and spillovers*, Journal of Entrepreneurship in Emerging Economies, Vol. 11 No. 2, pp. 277-303. https://doi.org/10.1108/JEEE-06-2018-0054

MREŽNI IZVORI

1. Ahmed, R. (2020) *Business Intelligence: A brief history* [online]. Mjesto izdavanja: AnalyticaBI. Dostupno na: https://analyticabi.app/Blog/BI-brief-history [22.06.2022.]

2. *Amount contributed to the budget of the European Union in 2020, by member state* [online]. Mjesto izdavanja: Statista. Dostupno na: https://www.statista.com/statistics/316691/eu-budget-contributions-by-country/ [3.07.2022.]
3. Bukovec, M. [online]. *Obzor Europa – Sljedeći program EU-a za istraživanje i inovacije (2021-2027)*. Mjesto izdavanja: DocPlayer. Dostupno na: http://docplayer.rs/192784858-Obzor-europa-horizoneu-sljede%C4%87i-program-eu-a-za-istra%C5%BEivanje-i-inovacije.html [3.07.2022.]
4. *Create a data-driven culture with business intelligence for all* [online]. Mjesto izdavanja: Microsoft. Dostupno na https://powerbi.microsoft.com/en-us/ [22.06.2022.]
5. Costello, K., Rimol, M. (2021). *Gartner Identifies the Top Strategic Technology Trends for 2022* [online]. Mjesto izdavanja: Gartner. Dostupno na: https://www.gartner.com/en/newsroom/press-releases/2021-10-18-gartner-identifies-the-top-strategic-technology-trends-for-2022 [22.06.2022.]
6. *Dashboard Design* [online]. Mjesto izdavanja: Qlik. Dostupno na: https://www.qlik.com/us/dashboard-examples/dashboard-design [22.06.2022.]
7. DQ Institute (2021). *What is the DQ Framework?* Dostupno na: https://www.dqinstitute.org/global-standards/ [3.07.2022.]
8. Fields, E. (2014) *Dreamy Sales Analytics with Tableau and Salesforce (And Where to Find us at Dreamforce)* [online]. Mjesto izdavanja: salesforce. Dostupno na: https://www.tableau.com/about/blog/2014/10/dreamy-sales-analytics-tableau-and-salesforce-and-where-find-us-dreamforce-33718 [22.06.2022.]
9. *Gartner Magic Quadrant & Critical Capabilities* [online]. Mjesto izdavanja: Gartner. Dostupno na: https://www.gartner.com/en/research/magic-quadrant [22.06.2022.]
10. *Gartner Magic Quadrant* [online]. Mjesto izdavanja: CIOWiki. Dostupno na: https://cio-wiki.org/wiki/Gartner_Magic_Quadrant [22.06.2022.]
11. *Gartner's Hype Cycle Methodology* [online]. Mjesto izdavanja: CIOWiki. Dostupno na: https://cio-wiki.org/wiki/Gartner%27s_Hype_Cycle_Methodology#What_is_Gartner.27s_Hype_Cycle_Methodology [22.06.2022.]
12. *Gartner Top Strategic Technology Trends for 2022* [online]. Mjesto izdavanja: Gartner. Dostupno na: https://www.gartner.com/en/information-technology/insights/top-technology-trends?utm_source=press-release&utm_medium=promotion&utm_campaign=RM_GB_2022_ITTRND_NPP_PR1_TTT22&utm_term=hubpage [22.06.2022.]

13. Heinze, J. (2014) *History of Business Intelligence* [online]. Mjesto izdavanja: BI Software Insight . Dostupno na: http://www.bisoftwareinsight.com/history_of_business_intelligence/ [22.06.2022.]
14. *Inovacija* [online]. Mjesto izdavanja: enciklopedija.hr. Dostupno na: https://www.enciklopedija.hr/natuknica.aspx?id=27516 [3.07.2022.]
15. Limp, P. (2020) Exploring the History of Business Intelligence [online]. Mjesto izdavanja: Project Managers. Dostupno na: https://www.toptal.com/project-managers/it/history-of-business-intelligence [22.06.2022.]
16. *Microsoft Power BI Is the Leader of Gartner's Magic Quadrant 2022* [online]. Mjesto izdavanja: bismart. Dostupno na https://blog.bismart.com/en/microsoft-power-bi-leader-gartner-magic-quadrant-2022 [22.06.2022.]
17. Ministarstvo znanosti i obrazovanja, Agencija za mobilnost i programe EU (2020) *Europski inovacijski ekosustavi*. Dostupno na: https://www.obzoreuropa.hr/struktura-treci-stup/europski-inovacijski-ekosustavi [3.07.2022.]
18. Mitchell, C. (2022). *Gartner Magic Quadrant for Analytics and Business Intelligence Platforms 2022* [online]. Mjesto izdavanja: CX Today. Dostupno na: https://www.cxtoday.com/data-analytics/gartner-magic-quadrant-for-analytics-and-business-intelligence-platforms-2022/ [22.06.2022.]
19. *OBZOR 2020 (HORIZON 2020)* [online]. Mjesto izdavanja: eu-projekti.info. Dostupno na: https://www.eu-projekti.info/fond/obzor-2020/# [3.07.2022.]
20. *Općenito o Business Intelligence sustavima* [online]. Mjesto izdavanja: mitSOFTWARE. Dostupno na: http://www.mit-software.hr/usluge/bi/bi1/ [22.06.2022.]
21. Park, Y. (2016) *8 digital life skills all children need – and a plan for teaching them*. Mjesto izdavanja: World Economic Forum. Dostupno na: https://www.weforum.org/agenda/2016/09/8-digital-life-skills-all-children-need-and-a-plan-for-teaching-them [3.07.2022.]
22. *Qlik analytics platform: meeting modern BI needs* (2021). Mjesto izdavanja: vizlib. Dostupno na: https://home.vizlib.com/qlik-analytics-platform-meeting-modern-bi-needs/?utm_term=&utm_campaign=(GROW)+-+DSA+campaign&utm_source=adwords&utm_medium=ppc&hsa_acc=4502887352&hsa_cam=16339930975&hsa_grp=133357045826&hsa_ad=583930792305&hsa_src=s&hsa_tgt=dsa-1637237660076&hsa_kw=&hsa_mt=&hsa_net=adwords&hsa_ver=3&gclid=EAIaIQobChMIovjlqte9-AIVg7p3Ch0HJQWGEAAYASAAEgJccfD_BwE [22.06.2022.]

23. *Quick guide: Horizon 2020- Interreg synergies* [online]. Dostupno na: https://ec.europa.eu/research/participants/data/ref/h2020/other/events/h2020-interreg/h2020-interreg-matchmaking-guide_en.pdf [5.07.2022.]
24. Ružić, M. (2022). *Ciljevi održivog razvoja.* Mjesto izdavanja: Info centar mogućnosti. Dostupno na: https://icm-mogucnosti.info/ciljevi-odrzivog-razvoja/ [1.07.2022.]
25. Stedman, C. (2020). *business intelligence (BI)* [online]. Mjesto izdavanja:TechTarget. Dostupno na: https://www.techtarget.com/searchbusinessanalytics/definition/business-intelligence-BI [22.06.2022.]
26. Taylor, D. (2022). *Tableau vs Power BI: Key Differences* [online]. Mjesto izdavanja: Guru99. Dostupno na: https://www.guru99.com/tableau-vs-power-bi-difference.html [22.06.2022.]
27. *What is Power BI?* (2022) [online]. Mjesto izdavanja: Microsoft. Dostupno na: https://docs.microsoft.com/en-us/power-bi/fundamentals/power-bi-overview [22.06.2022.]
28. *What are the Sustainable Development Goals?* [online]. Mjesto izdavanja: UNDP. Dostupno na: https://www.undp.org/sustainable-development-goals?utm_source=EN&utm_medium=GSR&utm_content=US_UNDP_PaidSearch_Brand_English&utm_campaign=CENTRAL&c_src=CENTRAL&c_src2=GSR&gclid=Cj0KCQjw8amWBhCYARIsADqZJoU5sn9x1I0kAnBh1u1D86mATQIMURnC5uQazjq50BsKqLk0AACyyRcaAo3TEALw_wcB [1.07.2022]

AKTI I PUBLIKACIJE EUROPSKE KOMISIJE:

1. *Digital Economy and Society Index (DESI) 2021, DESI methodological note (2021)*. European Comission. Dostupno na: https://digital-strategy.ec.europa.eu/en/policies/desi [3.07.2022.]
2. *Dokument za razmatranje O održivoj Europi do 2030. (2019)*. ISBN: 978-92-79-98961-2, doi:10.2775/636608
3. Europska komisija (2010) *Communication from the Commission to the European Parliament, the Council, the European Economic and Social Committee and the Committee of the Regions A Digital Agenda for Europe*. Dostupno na: https://eur-lex.europa.eu/procedure/EN/199329 [3.07.2022.]
4. Europska komisija (2021). *Komunikacija Komisije Europskom parlamentu, Vijeću, Europskom gospodarskom i socijalnom odboru i Odboru regija: Digitalni kompas 2030.: europski pristup za digitalno desetljeće*. Dostupno na: https://eur-lex.europa.eu/legal-content/hr/ALL/?uri=CELEX:52021DC0118 [3.07.2022.]

5. Europska komisija (2021). *PRILOG, Komunikacija Komisije Europskom parlamentu, Vijeću, Europskom gospodarskom i socijalnom odboru i Odboru regija: Digitalni kompas za 2030.: europski pristup za digitalno desetljeće*. Dostupno na: https://eur-lex.europa.eu/legal-content/hr/ALL/?uri=CELEX:52021DC0118 [3.07.2022.]
6. Europska komisija (2021) *Europska ljestvica uspjeha u inoviranju*. Dostupno na: https://ec.europa.eu/info/research-and-innovation/statistics/performance-indicators/european-innovation-scoreboard_hr#documents-and-media [4.07.2022.]
7. European Comission (2021) *European Innovation Scoreboard 2021*. Dostupno na: https://ec.europa.eu/docsroom/documents/46411 [4.07.2022.]
8. European Comission [online]. *Funding programmes and open calls*. Dostupno na: https://ec.europa.eu/info/research-and-innovation/funding/funding-opportunities/funding-programmes-and-open-calls_en [4.07.2022.]
9. Europska komisija [online]. *Obzor Europa*. Dostupno na: https://ec.europa.eu/info/funding-tenders/find-funding/eu-funding-programmes/horizon-europe_hr [4.07.2022.]
10. Europska komisija [online]. *Horizon Europe – Performance*. Dostupno na: https://ec.europa.eu/info/strategy/eu-budget/performance-and-reporting/programme-performance-overview/horizon-europe-performance_en#mff-2014-2020-horizon-2020 [4.07.2022.]
11. Hollanders, H. Es-Sadki, N. (2021). *European Innovation Scoreboard*. Impremerie Centrale in Luxembourg, 2021, ISBN 978-92-76-38407-6, ISSN 2467-4435. doi:10.2873/725879
12. Malik, X. (2014). *The Future of Europe is Science*. Luxembourg: Publications Office of the European Union, 2014. ISBN 978-92-79-40178-7. doi:10.2796/28973
13. *Recovery and Resilience Facility* (2020). Mjesto izdavanja: Europska komisija. Dostupno na: https://ec.europa.eu/info/business-economy-euro/recovery-coronavirus/recovery-and-resilience-facility_en#the-recovery-and-resilience-facility [1.07.2022.]
14. *The Digital Economy and Society Index (DESI)* (2021). European Comission. Dostupno na: https://digital-strategy.ec.europa.eu/en/policies/desi [3.07.2022.]

MEĐUNARODNI ČASOPISI KOJI OBJAVLJUJU NAJBOLJE RECENZIRANA ISTRAŽIVANJA:

1. Cunningham, P. (2019). *Ireland: More money please*. Nature 569, 481-484 (2019). https://doi.org/10.1038/d41586-019-01569-w
2. Kuster, S. (2019). *ERA: no time for complacency*. Nature 569, 481-484 (2019). https://doi.org/10.1038/d41586-019-01569-w
3. Moedas, C. (2019). *Rekindle the love affair*. Nature 569, 481-484 (2019). https://doi.org/10.1038/d41586-019-01569-w
4. Nowotny, H. (2019). *Austria: Slow but steady*. Nature 569, 481-484 (2019). https://doi.org/10.1038/d41586-019-01569-w
5. Van Norder, R., Butler, D. (2019). *Science in Europe: by the numbers*. Nature 569, 470-471 (2019). https://doi.org/10.1038/d41586-019-01565-0
6. Vernos, I. (2019). *Spain: invest or regret it.* Nature 569, 481-484 (2019). https://doi.org/10.1038/d41586-019-01569-w
7. Wouter Vasbinder, J., Brooks D.R. (2019). *Climate change above all*. Nature 569, 481-484 (2019). https://doi.org/10.1038/d41586-019-01569-w

Popis slika

Slika 1. Prikaz odnosa poslovne inteligencije i upravljanja znanjem kod procesa donošenja odluka 8
Slika 2. Prikaz modela poslovne inteligencije 9
Slika 3. Ilustrativni prikaz utjecaja razvoja IKT-a na razvoj BI-a 10
Slika 4. Evolucija poslovne inteligencije 15
Slika 5. Prikaz količine radova po pojedinim kategorijama unutar pretraživanih kriterija 17
Slika 6. Prikaz radova prema najčešće pojavljivanim kategorijama 17
Slika 7. Prikaz radova prema najčešće pojavljivanim kategorijama 18
Slika 8. Prikaz radova nakon revizije kroz najzastupljenije kategorije 18
Slika 9. Prikaz 5 najcitiranijih radova pod pojmom business intelligence 19
Slika 10. Gartnerov magični kvadrant tržišta BI alata 26
Slika 11. Korisničko sučelje Microsoft Power BI alata 27
Slika 12. Korisničko sučelje Tableau alata 28
Slika 13. Korisničko sučelje Qlik alata 29
Slika 14. Prikaz krivulje kretanja prema fazama Gartnerovog Hype ciklusa 31
Slika 15. 17 globalnih ciljeva održivog razvoja 35
Slika 16. Šest stupova Mehanizma za oporavak i otpornost 36
Slika 17. Prikaz odnosa među pojedinim državama u kategoriji časopisa s otvorenim pristupom 38
Slika 18. Prikaz kretanja i fokusa četiri generacije istraživanja i razvoja 40
Slika 19. Tri inovacijske paradigme 41
Slika 20. DESI zemalja članica Europske unije za 2021. godinu 43
Slika 21. Okvir digitalnih kompetencija prema 8 područja i 3 razine 44
Slika 22. Pozicije zemalja Europske unije u kategorijama inovatora prema EIS-u 45
Slika 23. EIS aktivnosti, dimenzije i pokazatelji (Izvor: Hollanders, Es-Sadki, 2021) 46
Slika 24. Pregled postavljenih i postotka ostvarenih ciljeva do kraja 2021. godine u programu Obzor 2020 53
Slika 25. Dodana vrijednost u okviru programa Obzor Europa 54
Slika 26. Prikaz dokazivanja H2 u alatu poslovne inteligencije 95

Popis vizuala

Vizual 1. Grafički prikaz sudjelovanja država članica EU u programu Obzor, izraženo u postotku od ukupnog sudjelovanja svih država 62
Vizual 2. Geografski prikaz sudjelovanja država članica EU u programu Obzor, izraženo u postotku od ukupnog sudjelovanja svih država 63
Vizual 3. Grafički prikaz potpisanih ugovora unutar Obzora 2020, izraženo u postotku od ukupnog zbroja za sve države 65
Vizual 4. Prikaz korelacije između broja potpisanih ugovora o dodjeli sredstava i broja sudionika na projektima po zemljama 66
Vizual 5. Prikaz korelacije između broja sudionika na projektima i udjela u primljenim sredstvima za Obzor 66
Vizual 6. Prikaz udjela sudjelovanja različitih vrsta organizacija u programu Obzor 2020 67
Vizual 7. Prikaz udjela različitih znanstvenih područja i polja u programu Obzor 2020 67
Vizual 8. Prikaz digitalnih vještina u kategoriji osnovne ili više digitalne vještine 69
Vizual 9. Pojedinci po državama kod kojih digitalne vještine nisu mogle biti analizirane jer nisu koristili Internet u posljednja tri mjeseca 70
Vizual 10. Prikaz odnosa osnovnih i viših ukupnih digitalnih vještina pojedinaca po državama i njihove tendencije provjeravanja informacija koje pronalaze na internetu 71
Vizual 11. Iznos doprinosa proračunu Europske unije u 2020., po državama članicama (u milijardama eura) 72
Vizual 12. Usporedba osnovnih i viših ukupnih digitalnih vještina pojedinaca i neto doprinosa Europskoj uniji po stanovniku, po državama unutar promatranog skupa 73
Vizual 13. Usporedba osnovnih i viših ukupnih digitalnih vještina pojedinaca i neto doprinosa Europske unije u programu Obzor po državama unutar promatranog skupa 74
Vizual 14. Izdvajanja za istraživanje i razvoj kao postotak BDP-a po državama i godinama 76
Vizual 15. Geografski prikaz Izdvajanja za istraživanje i razvoj kao postotak BDP-a na razini Europske unije 77
Vizual 16. Izdvajanja za istraživanje i razvoj kao postotak BDP-a Europske unije i vodećih svjetskih gospodarstva 77
Vizual 17. Udio ulaganja u istraživanje i razvoj po sektorima 78
Vizual 18. Udio ulaganja u istraživanje i razvoj po sektorima na razini Europske unije 79
Vizual 19. Usporedba ulaganja u istraživanje i razvoj kao postotka BDP-a i neto doprinosa Europske unije sredstvima Obzora po državama unutar promatranog skupa 80

Vizual 20. Usporedba ulaganja u istraživanje i razvoj poduzeća kao postotka BDP-a i neto doprinosa Europske unije sredstvima Obzor po državama unutar promatranog skupa.....81
Vizual 21. Sumarni inovacijski indeks po državama Europske unije 82
Vizual 22. Usporedba inovacijskih dimenzija aktivnosti Okvirni uvjeti postotkom od ukupne NET EU potpore za program Obzor.....83
Vizual 23. Usporedba inovacijskih dimenzija aktivnosti Ulaganja s postotkom od ukupne neto EU potpore za program Obzor.....84
Vizual 24. Usporedba inovacijskih dimenzija aktivnosti naziva Inovacijske aktivnosti s postotkom od ukupne neto EU potpore za program Obzor.....85
Vizual 25. Usporedba inovacijskih dimenzija aktivnosti Učinci s postotkom od ukupne neto EU potpore za program Obzor.....86
Vizual 26. Usporedba inovacijske dimenzije Atraktivni istraživački sustav s postotkom od ukupne neto EU potpore za program Obzor.....87
Vizual 27. Usporedba ukupnog inovacijskog indeksa, EU doprinosa za program Obzor i BDP-a po stanovniku.....88
Vizual 28. Usporedba osnovnih i viših ukupnih digitalnih vještina u odnosu na neto doprinos Europske unije po pojedinoj državi za program Obzor.....93
Vizual 29. Usporedba osnovnih i viših ukupnih digitalnih vještina kod država koje nisu eliminirane u kategoriji nemogućnosti ocjenjivanja digitalnih vještina u odnosu na neto doprinos Europske unije po pojedinoj državi za program Obzor.....94

Popis tablica

Tablica 1. Sažeti prikaz istraživanja sukladno analiziranim kriterijima.....20
Tablica 2. Tablični prikaz sudjelovanja država članica Europske unije u Obzoru 2020 izražen kao broj i postotak.....61
Tablica 3. Tablični prikaz broj potpisanih ugovora unutar Obzora 2020 po državama članicama Europske unije u Obzoru 2020 izražen kao broj i postotak.....64
Tablica 4. Usporedba indikatora digitalnih vještina i digitalnih vještina 2.0.....68
Tablica 5. Izdvajanja za istraživanje i razvoj kao postotak BDP-a po državama i godinama.....75

Prilog 1[2]

Popis tablica korištenih u svrhu statističke obrade podataka:

1. R&I projects. Dostupno na: https://webgate.ec.europa.eu/dashboard/sense/app/98dcd94d-ca66-4ce0-865b-48ffe7f19f35/sheet/erUXRa/state/analysis [3.07.2022.]
2. Individuals who have basic or above basic overall digital skills by sex. Dostupno na: https://ec.europa.eu/eurostat/cache/metadata/en/tepsr_sp410_esmsip2.htm [3.07.2022.]
3. Individuals' level of digital skills (from 2021 onwards). Dostupno na: https://ec.europa.eu/eurostat/cache/metadata/en/isoc_sk_dskl_i21_esmsip2.htm [3.07.2022.]
4. Eurostat: Individuals' level of digital skills (from 2021 onwards). Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/ISOC_SK_DSKL_I21/default/table?lang=en&category=isoc.isoc_sk.isoc_sku [3.07.2022.]
5. Evaluating data, information and digital content (2021 onwards). Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/ISOC_SK_EDIC_I21/default/table [3.07.2022.]
6. Eurostat: Research and development (R&D). Dostupno na: https://ec.europa.eu/eurostat/cache/metadata/en/rd_esms.htm [3.07.2022.]
7. Research and development expenditure, by sectors of performance. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/TSC00001/default/table [3.07.2022.]
8. Intramural R&D expenditure (GERD) by source of funds. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/TSC00031/default/table [3.07.2022.]
9. EIS – RIS 2021. Dostupno na: https://ec.europa.eu/research-and-innovation/en/statistics/performance-indicators/european-innovation-scoreboard/eis [3.07.2022.]
10. Real GDP per capita. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/SDG_08_10/default/table [3.07.2022.]

[2] Kod preuzetih statističkih podataka evidentiran je posljednji datum pristupa i provjere autora

Sveučilište
Sjever

SVEUČILIŠTE
SJEVER

IZJAVA O AUTORSTVU

I

SUGLASNOST ZA JAVNU OBJAVU

Završni/diplomski rad isključivo je autorsko djelo studenta koji je isti izradio te student odgovara za istinitost, izvornost i ispravnost teksta rada. U radu se ne smiju koristiti dijelovi tuđih radova (knjiga, članaka, doktorskih disertacija, magistarskih radova, izvora s interneta, i drugih izvora) bez navođenja izvora i autora navedenih radova. Svi dijelovi tuđih radova moraju biti pravilno navedeni i citirani. Dijelovi tuđih radova koji nisu pravilno citirani, smatraju se plagijatom, odnosno nezakonitim prisvajanjem tuđeg znanstvenog ili stručnoga rada. Sukladno navedenom studenti su dužni potpisati izjavu o autorstvu rada.

Ja, ***Neva Babić***, pod punom moralnom, materijalnom i kaznenom odgovornošću, izjavljujem da sam isključivi autorica **poslijediplomskog specijalističkog rada** pod naslovom ***Identifikacija utjecajnih faktora na povlačenje sredstava za znanost, istraživanje i inovacije iz fondova Europske unije primjenom poslovne inteligencije*** te da u navedenom radu nisu na nedozvoljeni način (bez pravilnog citiranja) korišteni dijelovi tuđih radova.

Studentica:
Neva Babić

Babić Neva

(vlastoručni potpis)

Sukladno Zakonu o znanstvenoj djelatnost i visokom obrazovanju završne/diplomske radove sveučilišta su dužna trajno objaviti na javnoj

internetskoj bazi sveučilišne knjižnice u sastavu sveučilišta te kopirati u javnu internetsku bazu završnih/diplomskih radova Nacionalne i sveučilišne knjižnice. Završni radovi istovrsnih umjetničkih studija koji se realiziraju kroz umjetnička ostvarenja objavljuju se na odgovarajući način.

Ja, **Ne*va Babić***, neopozivo izjavljujem da sam suglasna s javnom objavom **poslijediplomskog specijalističkog rada** pod naslovom ***Identifikacija utjecajnih faktora na povlačenje sredstava za znanost, istraživanje i inovacije iz fondova Europske unije primjenom poslovne inteligencije*** čija sam autorica.

Studentica:
Neva Babić

Babić Neva

(vlastoručni potpis)