Analiza ključnih pokazatelja uspješnosti proizvodnje i poslovanja u uvjetima pandemije

Brumen, Dominik

Master's thesis / Diplomski rad

2020

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:235:427098

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

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







SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Dominik Brumen

Zagreb, 2020. godina

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Mentor:

dr. sc. Hrvoje Cajner, izv. prof.

Student:

Dominik Brumen

Zagreb, 2020. godina

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

Zahvaljujem se mentoru izv. prof. Hrvoju Cajneru na savjetima i pomoći prilikom pisanja rada.

Posebne zahvale upućujem obitelji i djevojci zbog podrške i razumijevanja tijekom trajanja studija.

Dominik Brumen

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

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum:	Prilog:
Klasa: 602 - 04 / 20 - 6 / 3	
Ur. broj: 15 - 1703 - 20 -	

DIPLOMSKI ZADATAK

Student: **DOMINIK BRUMEN** Mat. br.: 0035200416

Naslov rada na hrvatskom jeziku: **Analiza ključnih pokazatelja uspješnosti proizvodnje i poslovanja u uvjetima pandemije**

Naslov rada na engleskom jeziku: **The analysis of the business KPI in a pandemic**

Opis zadatka:

Analiza ključnih pokazatelja uspješnosti proizvodnje i poslovanja omogućuje identifikaciju trenutnog stanja procesa te otkriva potrebu za korektivnim radnjama u svrhu prilagodbe i poboljšanja novonastalim uvjetima. Promjena uvjeta na tržištu može značajno utjecati na poslovanje te posljedično i u većoj mjeri promijeniti vrijednosti ključnih pokazatelja uspješnosti. S obzirom na to da se nalazimo u vremenu izrazitih promjena u poslovanju uzrokovanih pandemijom pokazuje se potreba za detaljnim praćenjem i modeliranjem kretanja ključnih pokazatelja.

U radu je potrebno:
1. Odabrati značajnije gospodarske subjekte u RH i inozemstvu te prikupiti podatke o relevantnim pokazateljima. Posebice se osvrnuti na prerađivačku industriju.
2. Usporediti kretanja ključnih pokazatelja uspješnosti prije i za vrijeme pandemije.
3. Analizirati korelacijsku strukturu ključnih pokazatelja i pokazatelja razmjera pandemije.
4. Modelirati uzročno posljedične veze ključnih pokazatelja poslovanja i standardnih pokazatelja razmjera pandemije.
5. Korištenjem metoda statističke analize izraditi model predviđanja za odabrane gospodarske subjekte.

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

Zadatak zadan:	Rok predaje rada:	Predviđeni datum obrane:
24. rujna 2020.	26. studenog 2020.	30. studenog do 4. prosinca 2020.

Zadatak zadao:
doc. dr. sc. Hrvoje Cajner

Predsjednica Povjerenstva:
prof. dr. sc. Biserka Runje

SADRŽAJ

SADRŽAJ I
POPIS SLIKA III
POPIS TABLICA V
SAŽETAK VIII
SUMMARY IX
1. UVOD 1
1.1. Pandemija COVID-19 i metrika razmjera pandemije 1
1.2. Novo desetljeće i novi virus 1
1.3. Globalno stanje 4
1.4. Hrvatska i Europa 10
1.5. Mjere za sprječavanje širenja zaraze 12
2. UTJECAJ NA GOSPODARSTVO 15
2.1. Opći pokazatelji 15
2.1.1. BDP 15
2.1.2. Robna razmjena 22
2.1.3. Trgovina na malo 25
2.1.4. Industrijska proizvodnja i građevinarstvo 26
2.1.5. Zaposlenost 28
2.1.6. Turizam 30
2.1.7. Transport 32
2.2. Utjecaj na gospodarske subjekte – usporedba uspješnosti poslovanja 33
2.2.1. Trgovina, prijevoz i skladištenje, smještaj, priprema i usluživanje hrane 34
2.2.1.1. Zračni prijevoz 34
2.2.1.2. Smještaj, priprema i usluživanje hrane 35
2.2.2. Prerađivačka industrija 36
2.2.2.1. Proizvodnja mliječnih proizvoda 36
2.2.2.2. Proizvodnja proizvoda od gume i plastike 38
2.2.2.3. Proizvodnja osnovnih farmaceutskih proizvoda i farmaceutskih pripravaka 39
2.2.2.4. Proizvodnja koksa i rafiniranih naftnih proizvoda 40
2.2.2.5. Proizvodnja računala te elektroničkih i optičkih proizvoda 41

2.2.3. Opskrba električnom energijom, plinom, parom i klimatizacija 42
2.2.4. Informacije i komunikacije 43
2.3. Mjere za pomoć gospodarstvu 44
3. KORELACIJSKA ANALIZA 45
3.1. Razdoblje uz mjere za suzbijanje širenja zaraze 50
3.2. Razdoblje nakon popuštanja/ukidanja mjera 55
4. REGRESIJSKA ANALIZA 66
4.1. Razdoblje uz mjere za suzbijanje širenja zaraze 66
4.2. Razdoblje nakon popuštanja/ukidanja mjera 74
5. ZAKLJUČAK 80
LITERATURA 81

POPIS SLIKA

Slika 1. Prikaz virusa SARS-CoV-2 [2] 2
Slika 2. Broj zaraženih po zemljama do 7. listopada 2020. [8] 5
Slika 3. Broj zaraženih po zemljama na milijun stanovnika do 7. listopada 2020. [8] 6
Slika 4. Klasifikacija transmisije virusa po zemljama 7. listopada 2020. [8] 7
Slika 5. Broj umrlih po zemljama do 7. listopada 2020. [8] 8
Slika 6. Broj umrlih po zemljama na milijun stanovnika do 7. listopada 2020. [8] 9
Slika 7. Trend kretanja tjednog broja novozaraženih i preminulih u svijetu [8] 10
Slika 8. Trend kretanja dnevnog broja novozaraženih po zemljama u Europi [9] 11
Slika 9. Trend kretanja tjednog broja novozaraženih i preminulih u Hrvatskoj [8] 12
Slika 10. Realne stope rasta tromjesečnog BDP-a Hrvatske [12] 16
Slika 11. Usporedba realne stope rasta tromjesečnog BDP-a [13][14][15] 17
Slika 12. Usporedba realne stope rasta tromjesečnog BDV-a [13] 18
Slika 13. Usporedba tromjesečne realne stopa rasta finalne potrošnje [13] 20
Slika 14. Usporedba stopa promjene vrijednosti uvoza [13] 22
Slika 15. Usporedba stopa rasta vrijednosti izvoza [13] 23
Slika 16. Usporedba stopa rasta vrijednosti uvezene zaštitne opreme [13] 24
Slika 17. Usporedba stopa rasta vrijednosti uvezenih dezinfekcijskih sredstava [13] 25
Slika 18. Usporedba stopa rasta prometa trgovine na malo [13] 26
Slika 19. Usporedba stopa promjene indeksa obujma industrijske proizvodnje [13] 27
Slika 20. Usporedba stopa promjene indeksa obujma proizvodnje u građevinarstvu [13] .. 28
Slika 21. Usporedba stopa promjene broja zaposlenih na području industrije [13] 29
Slika 22. Usporedba stopa nezaposlenosti [13] 30
Slika 23. Usporedba stopa promjene dolazaka turista [13] 31
Slika 24. Usporedba stopa promjene noćenja turista [13] 32
Slika 25. Broj prevezenih putnika zračnim modom transporta [13] 33
Slika 26. Vremenske serije kretanja prosječnih tjednih cijena dionica poduzeća Maistra d.d., AD Plastik d.d. i Hrvatski telekom d.d. u 2020. godini [60] 47
Slika 27. Vremenske serije kretanja prosječnih tjednih cijena dionica poduzeća Dukat d.d. i Ericsson Nikola Tesla d.d. u 2020. godini [60] 48

Slika 28. Vremenska serija kretanja prosječne tjedne cijene dionice poduzeća INA d.d. u 2020. godini [60] 49
Slika 29. Dijagrami rasipanja - cijena dionica DUK, broj novih slučajeva i novih slučajeva na milijun stanovnika u Hrvatskoj 54
Slika 30. Dijagrami rasipanja - cijene dionica MAIS, ADPL, INA, ERNT i HT i broj novih slučajeva zaraze u svijetu 55
Slika 31. Dijagrami rasipanja - cijena dionica MAIS, broja testova po slučaju, broj novo hospitaliziranih i broj novo hospitaliziranih na milijun stanovnika u Hrvatskoj .. 60
Slika 32. Dijagrami rasipanja - cijena dionica DUK, broj novih slučajeva zaraze i novih slučajeva zaraze na milijun stanovnika u svijetu 61
Slika 33. Dijagrami rasipanja - cijena dionica ADPL, broj testiranja po slučaju zaraze u Hrvatskoj i broj preminulih u svijetu 62
Slika 34. Dijagrami rasipanja - cijena dionica INA, broj testiranja po slučaju zaraze u Hrvatskoj, broj novih slučajeva i broj novih slučajeva na milijun stanovnika u svijetu 63
Slika 35. Dijagrami rasipanja – cijena dionica ERNT, broj novo napravljenih testova i broj novo napravljenih testova na tisuću stanovnika u Hrvatskoj 64
Slika 36. Dijagrami rasipanja – cijena dionica HT, broj novo napravljenih testova i broj novo napravljenih testova na tisuću stanovnika u Hrvatskoj 65
Slika 37. Jednostavan linearan regresijski model – MAIS, prvo razdoblje 66
Slika 38. Kubni regresijski model – MAIS, prvo razdoblje 68
Slika 39. Jednostavan linearan regresijski model – DUK, prvo razdoblje 69
Slika 40. Kubni regresijski model – ADPL, prvo razdoblje 70
Slika 41. Kubni regresijski model – INA, prvo razdoblje 71
Slika 42. Kubni regresijski model – ERNT, prvo razdoblje 72
Slika 43. Kubni regresijski model – HT, prvo razdoblje 73
Slika 44. Jednostavan linearan regresijski model – MAIS, drugo razdoblje 74
Slika 45. Jednostavan linearan regresijski model – DUK, drugo razdoblje 75
Slika 46. Jednostavan linearan regresijski model – ADPL, drugo razdoblje 76
Slika 47. Jednostavan linearan regresijski model – INA, drugo razdoblje 77
Slika 48. Jednostavan linearan regresijski model – ERNT, drugo razdoblje 78

POPIS TABLICA

Tablica 1. Realne stope rasta tromjesečnog BDV-a Hrvatske po NKD-u 2007. u usporedbi s istim razdobljem prethodne godine (%) [12] 19
Tablica 2. Tromjesečne realne stope rasta komponenata BDP-a Hrvatske s rashodne strane (%) [12] 21
Tablica 3. Usporedba uspješnosti poslovanja grupa Croatia Airlines i Aegean Airlines [16][17][18][19][20] 34
Tablica 4. Usporedba uspješnosti poslovanja grupa Maistra i NH Hotel Group [21][22][23][24][25] 35
Tablica 5. Usporedba uspješnosti poslovanja poduzeća Dukat d.d. i Kri-Kri Milk Industry S.A. [26][27][28][29][30] 37
Tablica 6. Usporedba uspješnosti poslovanja grupa AD Plastik i Sanok Rubber [31][32][33][34][35] 38
Tablica 7. Usporedba uspješnosti poslovanja grupa JGL i Krka [36][37][38] 39
Tablica 8. Usporedba uspješnosti poslovanja poduzeća INA d.d. i Petrol d.d. [39][40][41][42][43] 40
Tablica 9. Usporedba uspješnosti poslovanja grupa Ericsson Nikola Tesla i HMS Networks [44][45][46][47][48][49] 41
Tablica 10. Usporedba uspješnosti poslovanja grupa HEP i ENDESA [50][51][52] 42
Tablica 11. Usporedba uspješnosti poslovanja poduzeća Hrvatski Telekom d.d. i Telekom Slovenije d.d. [53][54][55][56][57] 43
Tablica 12. Podaci cijene dionica i razmjera pandemije za korelacijsku analizu prvog razdoblja [60][61][62] 51
Tablica 13. Matrica korelacija cijene dionica i pokazatelja razmjera pandemije za prvo razdoblje 53
Tablica 14. Jakost korelacije 53
Tablica 15. Podaci cijene dionica i razmjera pandemije za korelacijsku analizu drugog razdoblja [60][61][62] 56
Tablica 16. Matrica korelacija cijene dionica i pokazatelja razmjera pandemije za drugo razdoblje 59

POPIS OZNAKA I KRATICA

Oznaka	Jedinica	Opis
SARS	-	Teški akutni respiratorni sindrom, engl. *severe acute respiratory syndrome*
RNK	-	Ribonukleinska kiselina
MERS	-	bliskoistočni respiratorni sindrom, engl. *Middle East respiratory syndrome*
WHO	-	Svjetska zdravstvena organizacija (*engl. World Health Organization*)
COVID/COVID-19	-	Virus SARS-CoV-2
SAD	-	Sjedinjene Američke Države
BDP	kn	Bruto domaći proizvod
EU	-	Europska unija
BDV	kn	Bruto dodana vrijednost
NKD 2007.	-	Nacionalna klasifikacija djelatnosti, verzija 2007.
HBOR	-	Hrvatska banka za obnovu i razvitak
HR_nsluc_SUM	-	Ukupan broj novih slučajeva zaraze u tjednu u Hrvatskoj
HR_nsluc_AVG	-	Prosječan broj novih slučajeva zaraze u tjednu u Hrvatskoj
HR_nprem_SUM	-	Ukupan broj preminulih od bolesti koronavirusa u tjednu u Hrvatskoj
HR_nprem_AVG	-	Prosječan broj preminulih od bolesti koronavirusa u tjednu u Hrvatskoj
HR_nslucmil_SUM	-	Ukupan broj novih slučajeva zaraze na milijun stanovnika u tjednu u Hrvatskoj
HR_nslucmil_AVG	-	Prosječan broj novih slučajeva zaraze na milijun stanovnika u tjednu u Hrvatskoj
HR_npremmil_SUM	-	Ukupan broj preminulih od bolesti koronavirusa na milijun stanovnika u tjednu u Hrvatskoj
HR_npremmil_AVG	-	Prosječan broj preminulih od bolesti koronavirusa na milijun stanovnika u tjednu u Hrvatskoj
HR_hosppac_AVG	-	Prosječan broj hospitaliziranih pacijenata u tjednu u Hrvatskoj
HR_hosppacmil_AVG	-	Prosječan broj hospitaliziranih pacijenata na milijun stanovnika u tjednu u Hrvatskoj
HR_tjprimbol	-	Broj novo hospitaliziranih pacijenata u tjednu u Hrvatskoj
HR_tjprimbolmil	-	Broj novo hospitaliziranih pacijenata na milijun stanovnika u tjednu u Hrvatskoj

HR_ntest_SUM	-	Ukupan broj novo napravljenih testova u tjednu u Hrvatskoj
HR_ntest_AVG	-	Prosječan broj novo napravljenih testova u tjednu u Hrvatskoj
HR_ntesttis_SUM	-	Ukupan broj novo napravljenih testova na tisuću stanovnika u tjednu u Hrvatskoj
HR_ntesttis_AVG	-	Prosječan broj novo napravljenih testova na tisuću stanovnika u tjednu u Hrvatskoj
HR_testposluc_AVG	-	Prosječan broj napravljenih testova po slučaju zaraze u tjednu u Hrvatskoj
HR_stoppoztest_AVG	-	Prosječna stopa pozitivnih testova u tjednu u Republici Hrvatskoj
SVJ_nsluc_SUM	-	Ukupan broj novih slučajeva zaraze u tjednu u svijetu
SVJ_nsluc_AVG	-	Prosječan broj novih slučajeva zaraze u tjednu u svijetu
SVJ_nprem_SUM	-	Ukupan broj preminulih od bolesti koronavirusa u tjednu u svijetu
SVJ_nprem_AVG	-	Prosječan broj preminulih od bolesti koronavirusa u tjednu u svijetu
SVJ_nslucmil_SUM	-	Ukupan broj novih slučajeva zaraze na milijun stanovnika u tjednu u svijetu
SVJ_nslucmil_AVG	-	Prosječan broj novih slučajeva zaraze na milijun stanovnika u tjednu u svijetu
SVJ_npremmil_SUM	-	Ukupan broj preminulih od bolesti koronavirusa na milijun stanovnika u tjednu u svijetu
SVJ_npremmil_AVG	-	Prosječan broj preminulih od bolesti koronavirusa na milijun stanovnika u tjednu u svijetu
MAIS	kn	Prosječna cijena dionica poduzeća Maistra d.d. u tjednu
DUK	kn	Prosječna cijena dionica poduzeća Dukat d.d. u tjednu
ADPL	kn	Prosječna cijena dionica poduzeća AD Plastik d.d. u tjednu
INA	kn	Prosječna cijena dionica poduzeća INA d.d. u tjednu
ERNT	kn	Prosječna cijena dionica poduzeća Ericsson Nikola Tesla d.d. u tjednu
HT	kn	Prosječna cijena dionica poduzeća Hrvatski Telekom d.d. u tjednu
r	-	Personov koeficijent korelacije
α	-	Razina pouzdanosti
R^2	-	Koeficijent determinacija
SS	-	Suma kvadrata odstupanja

SAŽETAK

Tema ovoga rada je „Analiza ključnih pokazatelja uspješnosti proizvodnje i poslovanja u uvjetima pandemije“. U radu su ukratko predstavljene karakteristike novog koronavirusa nakon čega je analiziran trend kretanja pokazatelja razmjera pandemije. Nadalje, provedena je usporedba kretanja ekonomskih pokazatelja uspješnosti na razini države i poslovnih rezultata gospodarskih subjekata za razdoblja prije i za vrijeme pandemije. Glavni fokus stavljen je na Hrvatsku čiji su rezultati uspoređeni s onima iz inozemstva. Izvršena je korelacijska analiza kako bi se utvrdile značajnije povezanosti među ključnim pokazateljima uspješnosti poslovanja i pokazateljima razmjera pandemije. Spoznaje dobivene korelacijskom analizom iskorištene su kako bi se modelirale uzročno posljedične veze odnosno izradili modeli koji bi mogli objasniti trendove kretanja ključnih pokazatelja u odnosu na mjeru razmjera pandemije.

Ključne riječi: Pandemija, Ključni pokazatelji uspješnosti, Korelacija, Regresijski modeli.

SUMMARY

The theme of this paper is „The analysis of the business KPI in a pandemic“. The paper briefly presents the characteristics of the new coronavirus, after which the movement trend of indicators regarding the pandemic scale is analysed. Furthermore, a comparison of the economic key performance indicators at the state level and business results of economic entities for periods before and during the pandemic was conducted. The main focus was put on Croatia, whose results were compared with those from abroad. A correlation analysis was performed to identify more significant correlations between key business performance indicators and pandemic scale indicators. The findings gained by conducting the correlation analysis were used to model cause-and-effect relationships and create prediction models.

Keywords: Pandemic, Key performance indicators, Correlation, Regression.

1. UVOD

Novi koronavirus koji se prvi puta pojavio koncem prošle godine promijenio je način na koji svijet funkcionira. Virus je iskoristio činjenicu da je svijet uistinu postao globalno selo i ubrzo se proširio diljem planete ostavljajući za sobom značajne posljedice na živote ljudi. Kako bi očuvale zdravlje svojih stanovnika, mnoge zemlje bile su prisiljene reagirati preventivno s ciljem sprječavanja širenja zaraze. Migracije ljudi gotovo su iščeznule i pokušavajući očuvati jedan aspekt života, drugi je još jače pogođen. Radi se naravno o gospodarstvu koje je uslijed dolaska pandemije doživjelo najveće posljedice. Mnogi su ostali bez svojih poslova, rad od kuće postao je normalnost, zatvorene su obrazovne ustanove, a najjače su ostale pogođene uslužne djelatnosti. Za zemlje kao što je Hrvatska upravo je taj uslužni sektor veliki izvor zarade, pogotovo u ljetnim mjesecima kada je turistička sezona na vrhuncu. Uvjeti na tržištu znatno su se promijenili i potreba za praćenjem podataka i prilagođavanjem novonastalim uvjetima veća je nego ikad. Iz tog razloga u radu će se proučiti kretanje nekih ključnih pokazatelja uspješnosti na razini države i gospodarskih subjekata koji će se usporediti s ostalim rezultatima iz svijeta. Kako bi se nova situacija što bolje razumjela i odgovor na nju bio što adekvatniji, pokušat će se pronaći i modelirati veza među pokazateljima vezanim uz pandemiju i gospodarstvo.

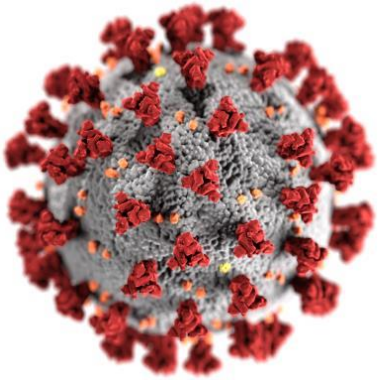
1.1. Pandemija COVID-19 i metrika razmjera pandemije

U prosincu 2019. godine u gradu Wuhanu u kineskoj provinciji Hubei pojavilo se nekoliko klastera ljudi koji su hospitalizirani diljem grada zbog upale pluća nepoznatog uzroka. Ono što je bilo zajedničko svim oboljelima je posjet „mokroj“ tržnici.

1.2. Novo desetljeće i novi virus

Iz prethodnih iskustava koje je Kina imala s virusima, prvenstveno misleći na SARS, poslan je tim stručnjaka iz Kineskog Centra za Kontrolu i Prevenciju Bolesti da obavi epidemiološku i etiološku istragu nad navedenim klasterima. Sakupljeni su relevantni uzorci kako bi se otkrio uzrok bolesti i detaljnije se proučio slučaj 3 hospitalizirana pacijenta u Wuhanu. Bolnička slika 2 od 3 pacijenta bila je poznata i uključivala je vrućicu i kašalj uz osjećaj nelagode u prsima. Kod jednog pacijenta temperatura je nakon nekoliko dana nestala, međutim kašalj se pogoršao kao i osjećaj nelagode, te je pacijentu dijagnosticirana upala pluća. Kod drugog

pacijenta nakon vrućice i kašlja pojavio se i respiratorni poremećaj koji je pogoršao stanje pacijenta te je započeta mehanička ventilacija. Kod ovog pacijenta nakon pogoršanja stanja nastupila je smrt, dok su preostala 2 otpuštena iz bolnice. Preminuli pacijent imao je 61 godinu, dok su ostali bili 49 i 32 godine stari. Testirajući sakupljene uzorke stručnjaci su uspješno sekvencirali genom novog virusa. Izolirani virus privremeno su nazvali 2019-nCoV zbog njegove pripadnosti skupini koronavirusa i činjenici da je u tom trenutku bio novootkriven[1]. Koronaviruse, koji spadaju u porodicu RNK virusa, karakteriziraju proteinski izdanci koji izgledom sliče na krunu, pa su stoga i dobili ime temeljem latinskog izraza za krunu, *corona*. Na Slici 1. prikazan je izgled dotičnog koronavirusa čije je službeno ime kasnije promijenjeno u SARS-CoV-2.



Slika 1. Prikaz virusa SARS-CoV-2 [2]

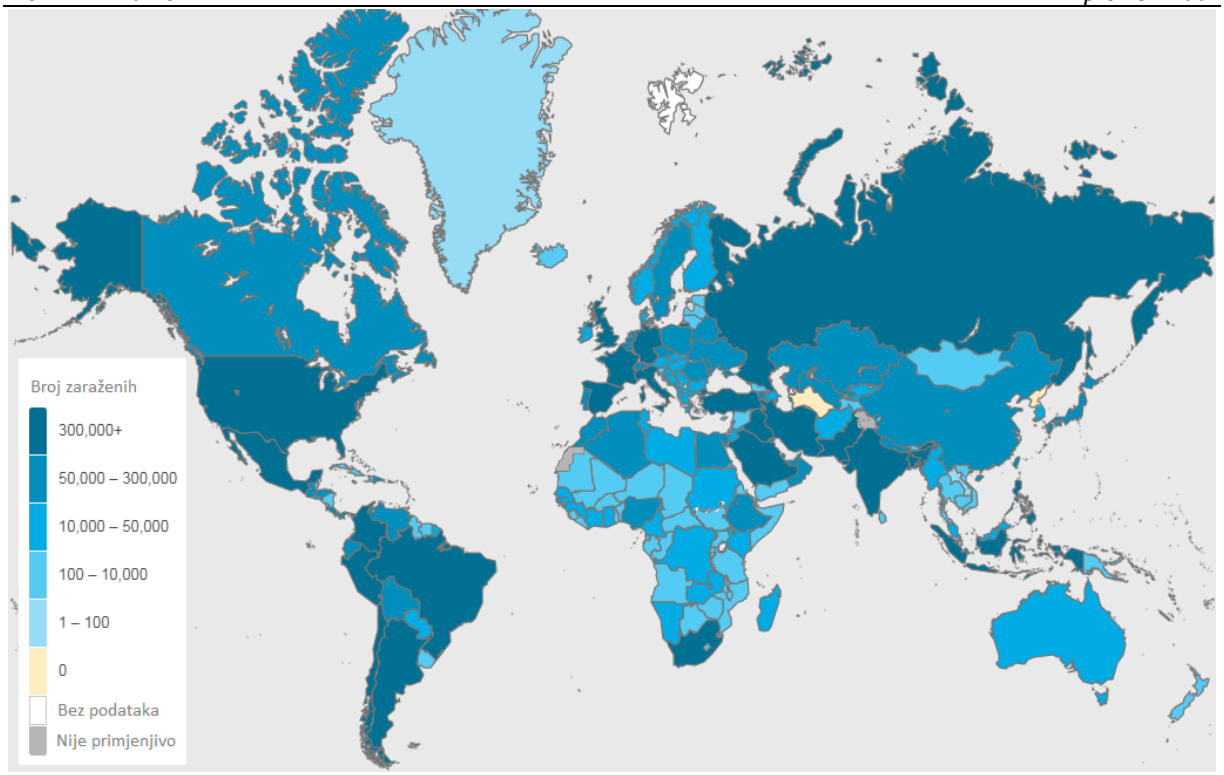
Do otkrića novoga virusa 2019. godine svijetu je poznato bilo 6 virusa iz iste porodice koji uzrokuju različite bolesti kod ljudi. Osim kod ljudi, ovi virusi pojavljuju se i kod ostalih sisavaca i ptica. Kod ljudi prevladavaju 4 virusa 229E, OC43, NL63 i HKU1 koji su uglavnom uzročnici običnih prehlada. Međutim, preostala 2 virusa ipak ostavljaju ozbiljnije posljedice na ljudsko zdravlje. Oba su zoonotska, odnosno prešla su sa životinja na ljude, i zovu se SARS (teški akutni respiratorni sindrom, engl. *severe acute respiratory syndrome*) i MERS (bliskoistočni respiratorni sindrom, engl. *Middle East respiratory syndrome*)[1]. Do pojave SARS-a došlo je u Kini 2002.-2003. godine i kasnije se proširio uglavnom Istočnom Azijom, a zabilježen je u 37 zemalja diljem Zemlje. Uzročnik je virus SARS-CoV-1 koji je na ljude prešao s cibetke palmašice, životinje koja se također prodavala na kineskim „mokrim“ tržnicama, a kasnije je utvrđeno da je virus najvjerojatnije potekao od šišmiša. Simptomi koji su ukazivali na SARS slični su onima zabilježenima kod prvih slučajeva novog virusa iz 2019. godine i uključuju povišenu tjelesnu temperaturu, zimicu, glavobolju i bol u mišićima. SARS je kasnije najčešće završavao pojavom upale pluća. Prema WHO-u je do kraja 2003.

godine tijekom epidemije zabilježeno ukupno 8096 slučajeva sa stopom smrtnosti od 9,6 %[3]. Bliskoistočni respiratorni sindrom prvi se puta pojavio 2012. godine u Saudijskoj Arabiji nakon čega je uslijedilo širenje Arapskim poluotokom, a kasnije su zabilježeni slučajevi u ukupno 27 zemalja. Uzročnik je virus MERS-CoV koji je na ljude prešao s deva, a također pokazuje iznimnu sličnost s virusima zabilježenim kod šišmiša. Simptomi zabilježeni kod zaraženih ljudi uključuju vrućicu, kašalj i kratkoću daha uz pojavu proljeva. U većini slučajeva MERS je rezultirao upalom pluća. Od rujna 2012. godine WHO je zabilježio 2494 laboratorijski potvrđena slučaja MERS-a od kojih je 858 imalo smrtni ishod, tj. smrtnost kod zabilježenih slučajeva iznosi otprilike 34 %[4]. Nakon pojave dva koronavirusa u 21. stoljeću treće desetljeće donosi novi koronavirus. Nakon što je sekvenciran genom virusa, kao i kod SARS-a i MERS-a, utvrđena je iznimna sličnost od preko 85 % s koronavirusom zabilježenim kod šišmiša (bat-SL-CoVZC45, MG772933.1), ali i različitost od SARS CoV-a i MERS-CoV-a[1]. Što se tiče kliničkih karakteristika bolesti koronavirusa (COVID-19) koju uzrokuje spomenuti virus one su podosta slične onima kod dva prethodeća virusa. Na 1099 pacijenata hospitaliziranih zbog bolesti koronavirusa čije su podatke vezane uz kliničko stanje sakupili Guan et al. vrućica je bila najprisutnija prilikom primitka u bolnicu s udjelom od 43,8 %. Kasnije tijekom hospitalizacije udio pacijenata kod kojih se pojavila vrućica porastao je na 88,7 %. Simptomi koji slijede povišenu tjelesnu temperaturu su kašalj sa 67,8 % i nešto rjeđi, mučnina s 5,0 % i proljev s 3,8 %. Demografski pokazatelji govore da je 43,9 % pacijenata bilo iz grada Wuhana, dok je od preostalog udjela 72,3 % pacijenata bilo u kontaktu s građanima Wuhana uključujući 31,3 % pacijenata koji su posjetili dotični grad. Što se tiče vremena inkubacije virusa medijalna vrijednost iznosila je 4 dana. Zanimljiv je i uvid u starost pacijenata gdje je medijalna vrijednost 47 godina što znači da je virus prisutniji kod starije populacije. Također većina zaraženih bili su muškarci s udjelom od 58,1 %. Cilj istraživanja bio je odrediti koliki udio pacijenata je završio na intenzivnoj njezi, zatrebao invazivnu mehaničku ventilaciju ili preminuo. Navedeni ishodi zabilježeni su kod 67 pacijenata (6,1 %). Na odjel intenzivne njege zaprimljeno je njih 5,0 %, invazivnu mehaničku ventilaciju zatrebalo je 2,3 % dok je udio preminulih iznosio 1,4 %. Prilikom primitka u bolnicu kod 926 pacijenata bolest COVID-19 klasificirana je kao manje opasna dok je kod ostatka bila opasna. Zanimljivo je za primijetiti kako su pacijenti kod kojih je bolest opasna stariji za medijalnu vrijednost od 7 godina. Također kod tih bolesnika zabilježena je i veća prisutnost već postojećih dijagnoza odnosno bolesti (38,7 %) za razliku od onih s klasifikacijom manje opasna bolest (21,0 %). Trajanje hospitalizacije u prosjeku je iznosilo

12,8 dana (medijan 12,0 dana) i tijekom hospitalizacije upala pluća dijagnosticirana je kod 91,1 % pacijenata. Dijagnoza upale pluća također je prisutnija kod osoba s klasifikacijom bolesti kao opasna s udjelom od 99,4 %, dok je kod druge skupine udio 89,5 %[5]. Temeljem podataka sakupljenih u istraživanju može se zaključiti kako je smrtnost kod bolesti koronavirusa uzrokovanoj virusom SARS-CoV-2 manja nego kod SARS-a i MERS-a. S druge strane u trenutku istraživanja (zaključno 31. siječnja 2020.) moglo se uvidjeti kako bi ukupan broj zaraženih pa tako i umrlih mogao premašiti brojke vezane uz ostala 2 virusa. Veći ukupan broj zaraženih ima uzrok i u načinu prenošenja virusa. Prema WHO-u virus se prenosi direktnim, indirektnim (preko kontaminiranih objekata/površina) ili bliskim kontaktom (unutar 1 metra) među ljudima putem nazalnih i oralnih sekreta. Najčešće se radi o kapljicama nastalim kašljanjem, kihanjem ili pričanjem. One uglavnom ne prelaze velike udaljenosti, pa se zato i preporučuje izbjegavanje bliskih kontakata. Budući da lijeka odnosno cjepiva još uvijek nema, najbolje je pridržavati se propisanih mjera prevencije kako bi se mogućnost zaraze, a i širenja zaraze umanjila što je više moguće. Upravo zato za zaražene osobe propisane su mjere izolacije u trajanju od 14 dana koliko je u prosjeku najdulje potrebno za inkubaciju virusa. Veći problem kod širenja stvaraju asimptomatske odnosno osobe koje ne razviju simptome, a u mogućnosti su širiti zarazu. Glavne mjere upravo zato sastoje se od nošenja maski, držanja razmaka i pranja/dezinfekcije ruku te suzdržavanja od diranja lica[6].

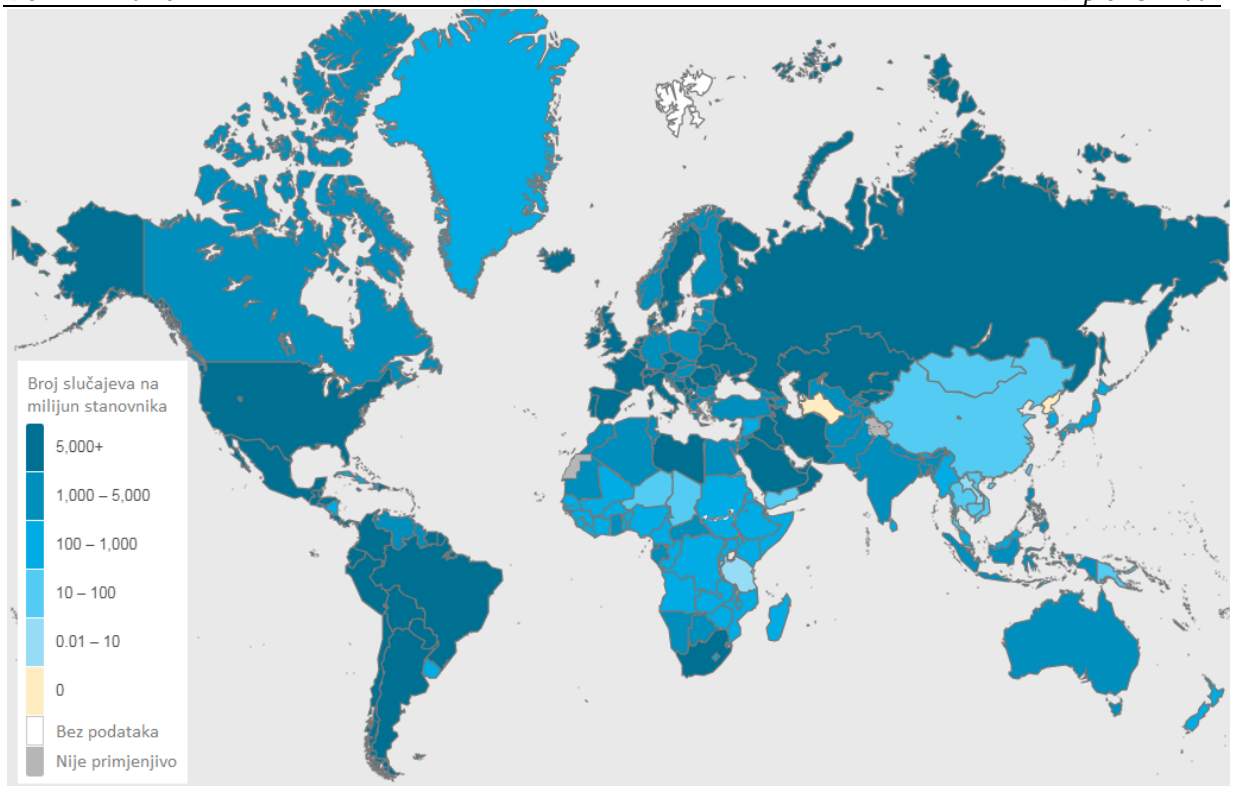
1.3. Globalno stanje

Početak sada pandemije virusa SARS-CoV-2 dogodio se krajem prosinca 2019. godina u gradu Wuhanu u kineskoj provinciji Hubei. Kao što je već navedeno nakon pojave malog klastera hospitaliziranih ljudi zbog upale pluća nepoznatog uzroka Kina je WHO-u prijavila zabilježenu pojavu. Virus se nastavio širiti da bi 13. siječnja bio zabilježen prvi slučaj van Kine, a nakon toga u 5 regija WHO-a odnosno na drugim kontinentima. Nakon toga WHO je reagirao proglašenjem Međunarodne hitne situacije. Nastavkom širenja virusa i prelaskom 100 000 zaraženih početkom ožujka, WHO je proglasio stanje pandemije 11. ožujka 2020[7]. Do dana 7. listopad 2020. godine u svijetu je broj potvrđenih slučajeva zaraze novim koronavirusom 35 537 491 dok je broj smrtnih slučajeva 1 042 798[8]. Na Slici 2. prikazano je trenutno stanje broja zaraženih u svijetu po zemljama.



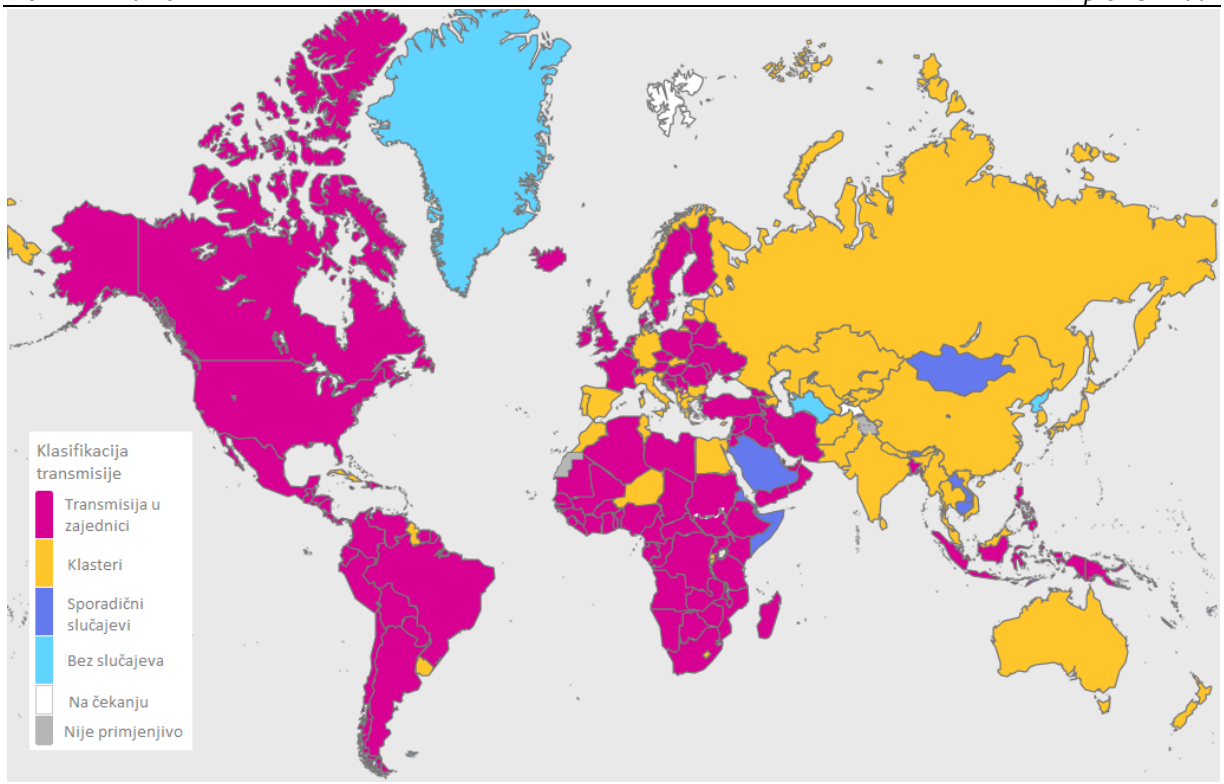
Slika 2. Broj zaraženih po zemljama do 7. listopada 2020. [8]

Prema ukupnom broju slučajeva zaraze prvi se ističe SAD koji trenutno ima najveći broj zaraženih sa skoro 7,5 milijuna, a slijede ga Indija s 6,8 milijuna, Brazil sa skoro 5 milijuna i Rusija s 1,2 milijuna. U Europi zemlja koja ima najveći broj zaraženih je Španjolska, dok je u Africi zemlja s najvećim brojem slučajeva Južnoafrička Republika. Zemlja iz koje se virus proširio svijetom, Kina, u usporedbi s ostalim dosad navedenim zemljama ima neznatan ukupan broj zaraženih od oko 91 000[8]. Kada se u obzir uzme i brojno stanovništvo Kine moglo bi se reći da je ta brojka gotovo pa zanemariva, pa će Slika 3. dati bolji uvid u proširenost zaraze stanovništvom tako da prikaže broj slučajeva na milijun stanovnika.



Slika 3. Broj zaraženih po zemljama na milijun stanovnika do 7. listopada 2020. [8]

Ovaj pogled na stanje u svijetu dakako prikazuje realniju sliku proširenosti zaraze po zemljama. Odmah na prvu se može primijetiti da je kontinent Južna Amerika veoma pogođen zarazom, a ističu se Peru s nešto više od 25 000 i Čile sa skoro istim brojem slučajeva na milijun stanovnika. SAD ponovno se ističe kao jedan od globalnih lidera po broju zaraženih na milijun stanovnika s nešto vise od 22 400, a u Europi se ponovno ističe Španjolska sa skoro 18 000, te u Africi također Južnoafrička Republika s 11 500. U Aziji se ističu Irak (9 700) i Rusija (8 600) dok su Kina, Indija i Indonezija najbolji primjer važnosti ovog pogleda. Kina ima tek približno 62 slučaja na milijun stanovnika, a Indija nešto manje od 5 000. Zanimljivo je da se stanje u Africi znatno promijenilo u odnosu na pogled prema ukupnom broju zaraženih i gotovo cijeli kontinent je za kategoriji viši u odnosu na prošli pogled. Očito je da postoje zemlje u kojima se virus lakše i brže širi stanovništvom, pa će Slika 4. prikazati koji je utvrđeni način transmisije po zemljama svijeta da bi se pronašla moguća poveznica između broja zaraženih i načina transmisije.



Slika 4. Klasifikacija transmisije virusa po zemljama 7. listopada 2020. [8]

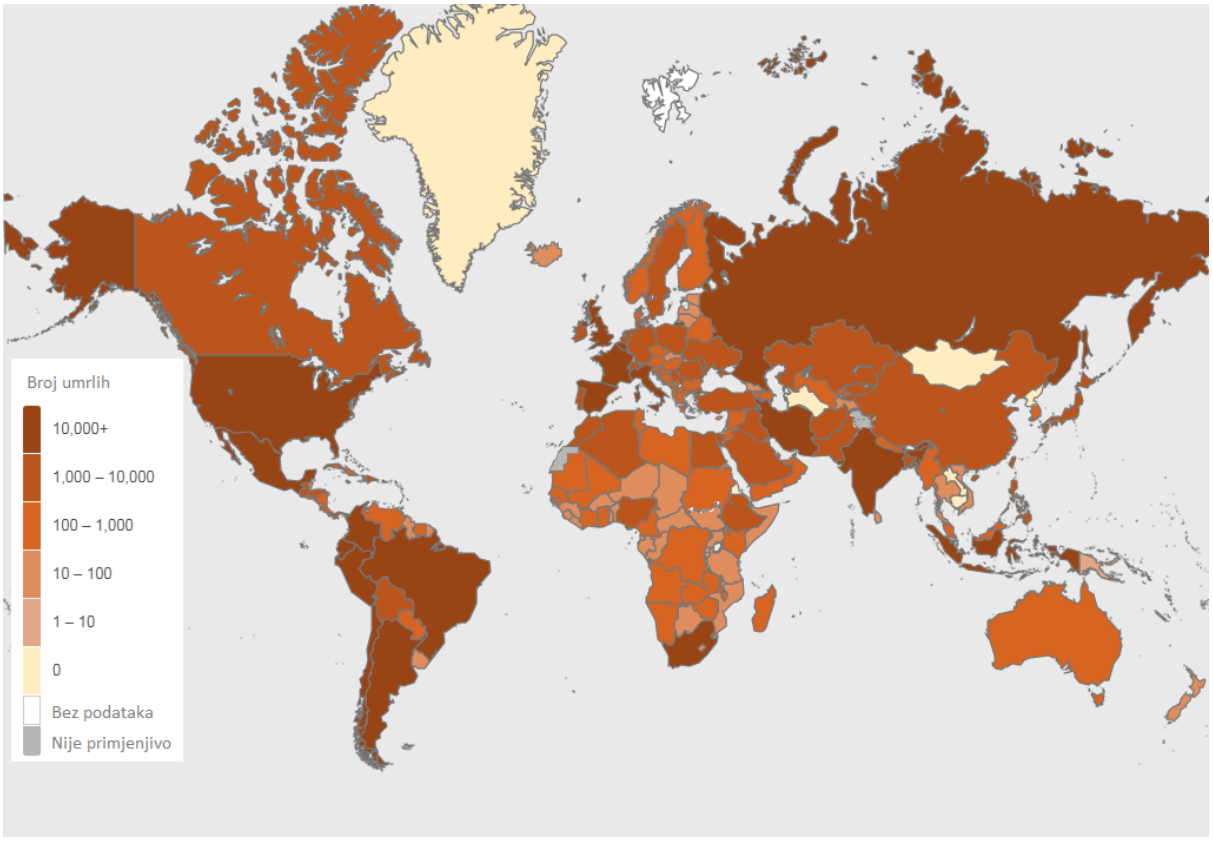
Prema WHO postoje 4 različite vrste transmisija[8]:

1. Bez slučajeva: zemlje bez slučajeva zaraze.
2. Sporadični slučajevi: zemlje s jednim ili više uvezenih ili lokalno uočenih slučajeva.
3. Klasteri: zemlje sa slučajevima klasteriranim na vremenskoj bazi, po geografskoj lokaciji ili zajedničkom izlaganju.
4. Transmisija u zajednici: zemlje s većim brojem lokalne transmisije definiranih prema nepovezanosti s lancima transmisije i većim brojem nepovezanih klastera.

Sami pogled na sliku otkriva jasnu povezanost. Zemlje u kojima je veći broj zaraženih na milijun stanovnika i koje su napredovale u kategoriji u odnosu na ukupan broj uglavnom imaju transmisiju u zajednici. Samim time virus se nekontrolirano, pa posljedično i brže, širi stanovništvom te stručnjaci nisu u mogućnosti pratiti ili utvrditi odakle je zaraza stigla. Na prvu odmah je moguće uočiti kako su gotovo obje Amerike s iznimkom Kube, Urugvaja i Gvajane obojene u ljubičasto odnosno karakterizira ih transmisija u zajednici. Afrika također služi kao primjer navedenoj teoriji. Kao i kod Amerika postoji nekoliko zemalja koje ne karakterizira transmisija u zajednici i čine iznimku, već je prisutna transmisija klasterima. U Europi je moguće primijetiti istočni dio koji karakterizira lokalna transmisija, dok je zapadni

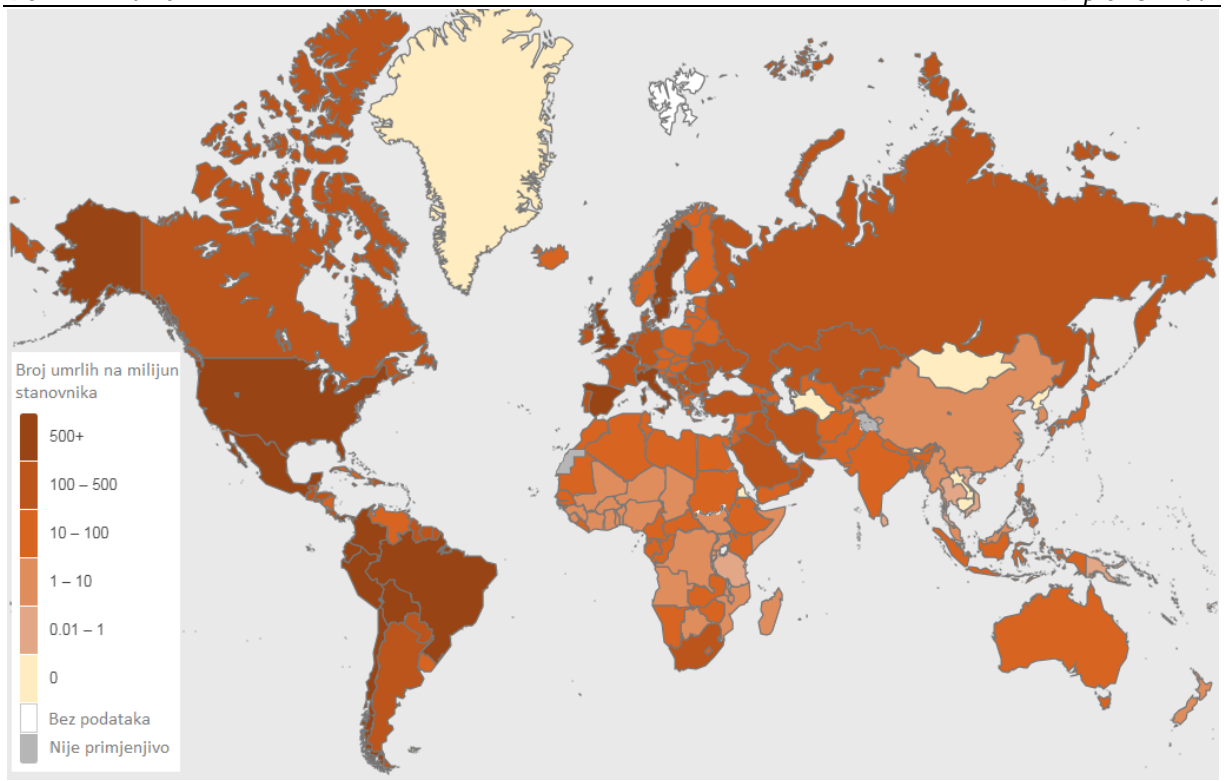
dio podijeljen između transmisije u zajednici u Francuskoj, Velikoj Britaniji i zemljama Beneluxa i transmisije klasterima u ostalima. Istočni dio služi kao potkrjepa pravilu da zemlje u kojima je broj slučajeva na milijun stanovnika veći imaju transmisiju u zajednici, dok je iznimka koja zapne za oko Španjolska. Zemlja koja predvodi Europu i po ukupnom i po broju slučajeva na milijun stanovnika spada u kategoriju transmisije klasterima. Zemlje Bliskog Istoka također imaju veći broj zaraženih na milijun stanovnika i transmisiju u zajednici dok je ostatak Azije pretežito okarakteriziran klasifikacijom klasterima.

Osim broja zaraženih, na Slici 5. prikazan je broj umrlih po zemljama.



Slika 5. Broj umrlih po zemljama do 7. listopada 2020. [8]

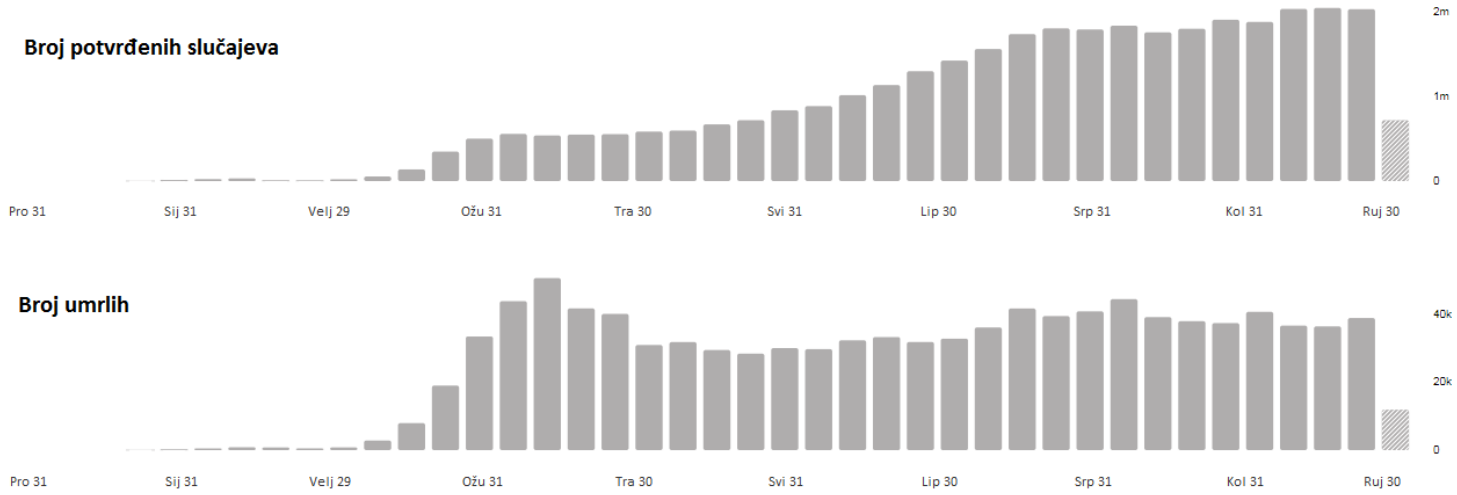
U usporedbi sa stanjem broja zaraženih po zemljama moguće je povući jasnu poveznicu kada se gleda ukupan broj umrlih. Zemlje s većim ukupnim brojem zaraženih imaju i veći broj umrlih. Stanje na obje mape gotovo pa da je identično i takav rezultat mogao se očekivati. Nameće se pitanje hoće li se ista poveznica moći povući i kod usporedbe istih gledano na milijun stanovnika. Slika 6. pružit će odgovor na to pitanje.



Slika 6. Broj umrlih po zemljama na milijun stanovnika do 7. listopada 2020. [8]

Situacija je za većinu zemalja u ovome slučaju ipak obrnuta. Dok je kod broja zaraženih na milijun stanovnika puno više zemalja upalo u najvišu kategoriju, u ovome slučaju su te zemlje svrstane u kategoriju niže. Postoji nekoliko razloga tome. Jedan je da postoje zemlje s velikim brojem stanovnika i iako se ukupan broj preminulih u usporedbi s drugima čini velik stavljajući u omjer i broj stanovnika dobiva se realnija usporedba. Osim samoga broja stanovnika veliku ulogu igra razvijenost i kapacitet zdravstvenog sustava pojedine zemlje. Možda glavni razlog ovakvoj pojavi su stopa smrtnosti i koeficijent reprodukcije virusa odnosno broj ljudi na koje se prenese virus od zaraženih. U usporedbi s drugim koronavirusima SARS-om i MERS-om stopa smrtnosti je daleko manja, pa je i broj umrlih na milijun stanovnika realniji pokazatelj ako se želi sagledati stopa smrtnosti virusa. S druge strane, COVID-19 je puno zarazniji, pa je broj zaraženih daleko premašio brojke preostala dva virusa u toj kategoriji i ponovno je pogled na broj zaraženih na milijun stanovnika onaj koji daje realniji uvid u proširenost tog virusa svijetom.

Osim različitih pogleda na brojeve zaraženih i umrlih zanimljivo je sagledati trend kretanja novih slučajeva i broja umrlih po tjednima od pojave virusa do 7. listopada 2020. Slika 7. daje upravo taj prikaz.



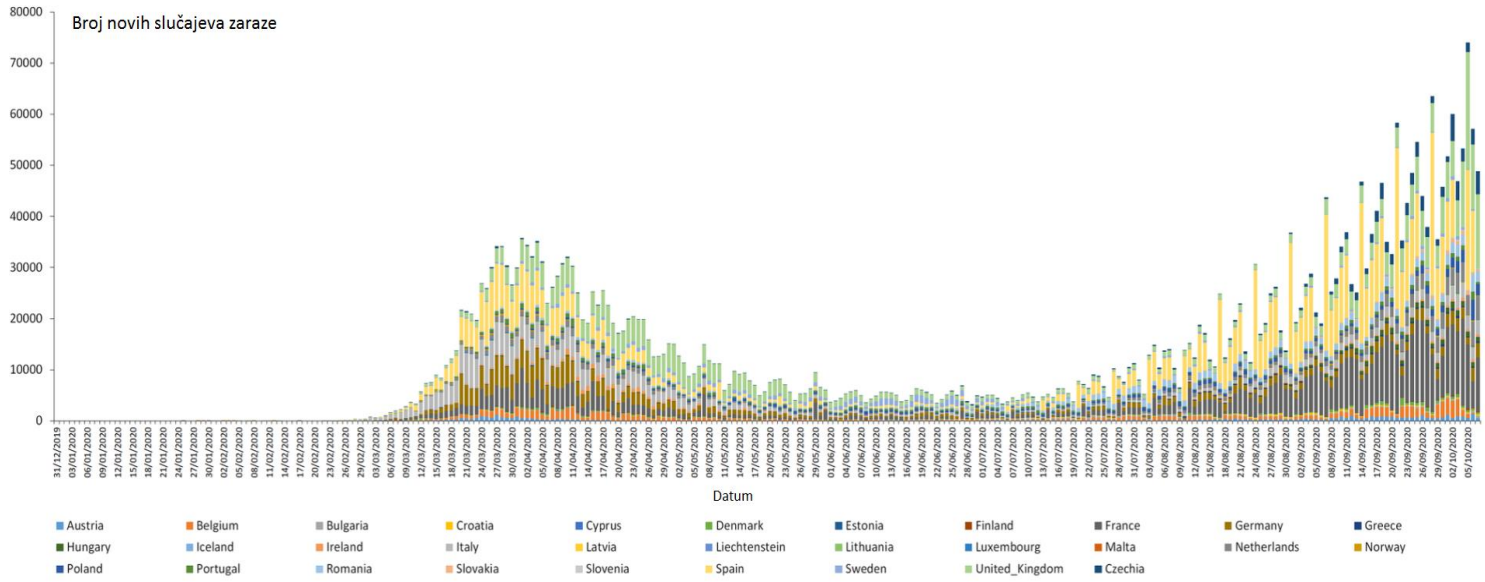
Slika 7. Trend kretanja tjednog broja novozaraženih i preminulih u svijetu [8]

Gotovo tri mjeseca od pojave virusa došlo je do značajnog porasta broja novozaraženih. Kraj ožujka bio je početak trenda rasta tjednog broja novozaraženih koji do 7. listopada 2020. još uvijek nije prestao. Nakon ožujka i uvođenja mjera ograničavanja kretanja stanovništva s ciljem suzbijanja zaraze trend se stabilizirao, međutim ukidanjem istih krajem svibnja, te dolaskom ljeta, pa s time i turističke sezone, kroz lipanj i srpanj ponovno dolazi do značajnog porasta na tjednoj razini. S oko 750 000 tjedno s kraja svibnja, kraj srpnja, pa onda kolovoz i rujan u prosjeku imaju 1,8 milijuna zabilježenih novih slučajeva svaki tjedan.

Kao i kod broja novozaraženih i u slučaju preminulih mjesec ožujak je prekretnica. Iz stanja s brojem slučajeva blizu 0, u drugoj polovici ožujka tjedni broj preminulih bilježi nagli porast koji se nastavlja sve do polovice travnja kada se pojavljuje dosad najveći tjedni broj umrlih. Kako je prethodno navedeno to je razdoblje u kojem su zemlje uvele razne mjere ograničavanja kretanja stanovništva, pa i broj preminulih tada bilježi pad i nastavlja se kretati oko 30 000 sve do druge polovice srpnja. Ljeto i turistička sezona očekivano ponovno potpomažu porastu, no ovoga puta blažem, i od tada je broj zaraženih u prosjeku blizu 40 000.

1.4. Hrvatska i Europa

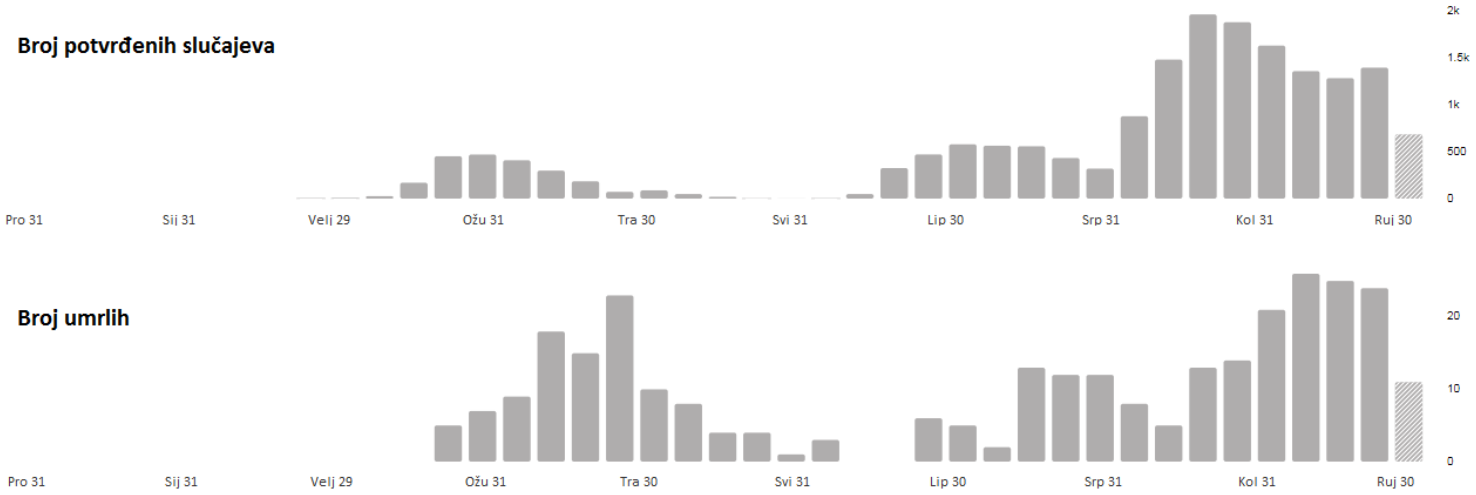
U ovome radu ipak će se detaljnije analizirati utjecaj COVID-a na Hrvatsku, pa će se u ovome poglavlju analizirati broj zaraženih umrlih i trend kretanja istih u Hrvatskoj, susjedstvu i dati opća slika stanja u Europi. Za početak na Slici 8. prikazan je trend kretanja broja zaraženih u Europi od početka zaraze.



Slika 8. Trend kretanja dnevnog broja novozaraženih po zemljama u Europi [9]

Moguće je podijeliti ukupno razdoblje od pojave virusa na 4 dijela. Prvi dio odnosi se na zarazu koja do ožujka nije prisutna u Europi već pretežito na području Azije. Nakon toga slijedi drugi dio koji je označen dolaskom virusa u Europu i njegovim naglim širenjem. Zemlje koje su tada bile najpogođenije zarazom i zabilježile najveće dnevne poraste broja zaraženih su Španjolska i Italija, a slijede ih Njemačka, Ujedinjeno Kraljevstvo i Francuska. Tada dolazi do uvođenja spomenutih mjera ograničavanja s ciljem suzbijanja zaraze što je rezultiralo postupnim smanjenjem broja zaraženih iz dana u dan kroz svibanj. Nakon toga počinje treće razdoblje u kojem su se održavali postignuti rezultati suzbijanja i dnevni broj novozaraženih kretao se oko 7 000. Dolaskom ljeta i početkom kakve takve turističke sezone navike ljudi su se promijenile i uslijedilo je četvrti dio koji počinje sredinom srpnja. Ponovno dolazi do rasta broja zaraženih međutim ne tako brzo kao u ožujku, ali ovoga puta postepeni rast rezultirao je postavljanjem novih rekordnih dnevnih brojeva novozaraženih iz dana u dan kroz rujan i početak listopada. U tome razdoblju prema broju novozaraženih ističu se dvije zemlje, Španjolska i Francuska, zemlje s većim brojem stanovnika i izraženim ljetnim turističkim sezonama.

U Hrvatskoj se virus prvi puta pojavio 25. veljače 2020. nakon čega se zaraza počela polako širiti i od tada je zabilježeno skoro 19 000 slučajeva zaraze i malo preko 300 smrtnih slučajeva kao posljedica bolesti uzrokovane virusom[8]. Na Slici 9. prikazan je tjedni trend kretanja broja novih slučajeva i preminulih u Hrvatskoj.



Slika 9. Trend kretanja tjednog broja novozaraženih i preminulih u Hrvatskoj [8]

Trend kretanja broja novozaraženih po tjednima prati opće stanje u Europi, pa u neku ruku i svijetu. Dolaskom zaraze dolazi do naglog porasta kroz ožujak i travanj što rezultira uvođenjem mjera ograničavanja kretanja. One su rezultirale znatnim smanjenjem broja zaraženih nakon čega slijedi ponovni porast kroz lipanj i srpanj nakon popuštanja mjera, da bi kolovoz donio nove rekordne tjedne brojeve novozaraženih koji su se nešto ublažili tijekom rujna. Razlog značajnijem porastu je dolazak do transmisije virusa u zajednici kao posljedice popuštanja mjera i turističke sezone što je rezultiralo znatno bržim i nekontroliranim širenjem virusa. Gledajući broj preminulih može se naći djelomična usporedba sa svjetskim trendom. U ožujku i travnju došlo je rasta broja preminulih po tjednima koji se smanjio kao posljedica spomenutih mjera. Nakon toga slijedi razdoblje u kojem je broj preminulih znatno smanjen, da bi srpanj, a zatim kolovoz donijeli značajne promjene. U drugoj polovici srpnja dolazi do značajnog porasta broja preminulih koji se početkom kolovoza ponovno smanjio međutim do kraja istog mjeseca dolazi do porasta većeg nego u kolovozu i rekordnog broja preminulih na tjednoj razini. U svijetu je također došlo do porasta broja preminulih u srpnju, međutim tijekom kolovoza i rujna taj se broj ponovno smanjio, tako da situacija u Hrvatskoj za to razdoblje odstupa od svjetskog trenda.

1.5. Mjere za sprječavanje širenja zaraze

Kao što je već kazano u ovome radu nakon pojave koronavirusa širom svijeta mnoge zemlje uključujući Hrvatsku uvele su mjere koje su za cilj imale sprječavanje širenja novog koronavirusa. Na primjeru Hrvatske navest će se koje su mjere implementirane budući da je komplet mjera bio relativno sličan u svim državama. 19. ožujka 2020. godine Stožer civilne

zaštite Republike Hrvatske predstavio je mjere za suzbijanje širenja zaraze koje su nastupile na snagu nakon ponoći. Mjere su se sastojale od 2 veća dijela, jedan je uveo ograničavanje društvenih okupljanja, rada u trgovini, uslužnih djelatnosti te održavanja sportskih i kulturnih događanja, dok je drugi uveo privremenu zabranu prelaska preko graničnih prijelaza Republike Hrvatske. Prvi dio mjera uveo je sljedeća ograničenja[10]:

- → zabranu održavanja javnih okupljanja više od 5 osoba na jednom mjestu
- → obustava rada djelatnosti trgovine osim onih nužnih za nastavak života (npr. prodavaonice prehrambenih i higijenskih artikala, ljekarne, benzinske postaje te logistički i distributivni centri hrane, pića i higijenskih proizvoda)
- → obustava rada kulturnih djelatnosti (npr. muzeji, kina i kazališta)
- → obustava rada ugostiteljskih objekata
- → obustava rada uslužnih djelatnosti u kojima se ostvaruje bliski kontakt s klijentima (npr. frizeri, bazeni, kozmetičari)
- → obustava održavanja dječjih i drugih radionica
- → obustava rada autoškola i škola stranih jezika
- → obustava vjerskih okupljanja

Međutim i kod onih djelatnosti koje su mogle nastaviti poslovanje uvedene su mjere koje je bilo potrebno osigurati da bi se minimizirao rizik od prijenosa virusa, a one su sljedeće[10]:

- → osigurati da se ne stvaraju gužve na ulasku u objekte
- → zapakirati rasutu robu
- → primijeniti mjere pojačane higijene i svakodnevnog čišćenja prostora
- → osigurati što veću međusobnu udaljenost radnika uz poštovanje mjere socijalnog distanciranja
- → provjetravati prostore
- → postaviti punktove s dezinfekcijskim sredstvima i istaknuti upute i preporuke za pridržavanje mjera o higijeni i socijalnom distanciranju

Svim poslodavcima izdane su upute kako su obavezni osigurati rad od kuće ako je moguće, te otkazati sastanke ili organizirati ih putem neke druge tehnologije koja omogućava održavanje istih na daljinu, otkazati službena putovanja (osim prijeko potrebnih), te zabraniti dolazak na radna mjesta radnicima koji pokazuju simptome zaraze COVID-om[10].

Drugi dio mjera odnosio se na međunarodne migracije stanovnika kojima se privremeno zabranio odnosno ograničio prelazak osoba preko graničnih prijelaza. Hrvatskim državljanima se omogućio povratak u Hrvatsku, odnosno odlazak u zemlju u kojoj rade i borave uz primjenu uputa i mjera Hrvatskog zavoda za javno zdravstvo. Povratak u matične države omogućio se građanima država članica Europske unije odnosno država članica schengenskog prostora i država pridruženih istom te članovima njihovih obitelji, nadalje isto će se omogućiti državljanima trećih zemalja koji su osobe s dugotrajnim boravištem temeljem određenih direktiva. Postojali su i izuzeci od ovih mjera, a oni su se odnosili na razne zdravstvene djelatnike, prekogranične radnike, prijevoznike robe (u određenoj mjeri), diplomate, policijske službenike i članove sličnih domaćih i međunarodnih organizacija te putnike u tranzitu[10].

Kao što je iz trenda kretanja broja novozaraženih i umrlih moguće vidjeti paket mjera uspio je odraditi svoju dužnost i suzbio je širenje zaraze. S druge strane uvedene mjere bile su prilično rigorozne te su obustavile rad mnogih gospodarskih djelatnosti, pa će se u idućim poglavljima proučiti posljedice koje je virus ostavio na gospodarstvo i njegove subjekte.

2. UTJECAJ NA GOSPODARSTVO

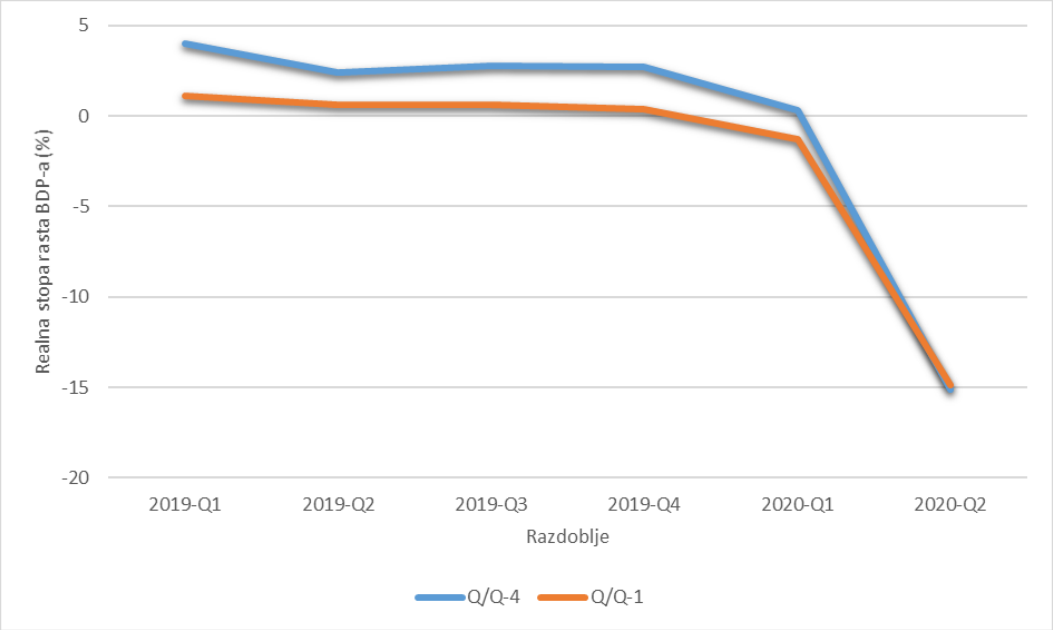
Nakon uvida u brzinu širenja novog koronavirusa mnoge zemlje bile su prisiljene reagirati. Uvođenjem ranije spomenutih mjera postignut je željen rezultat, pa su i mjere počele polako popuštati. No koronavirus nije nakon toga iščeznuo, dapače ljeto i dolazak kakve takve turističke sezone ponovno su započeli novi val širenja zaraze koji je premašio onaj početni. Samim time i mjere nisu nikada u potpunosti ukinute već je potrebno konstantno pratiti situaciju oko širenja zaraze i reagirati prikladnim mjerama. Sve navedeno ostavilo je značajan utjecaj na gospodarstvo, pa će se u ovome poglavlju proučiti posljedice na gospodarstvo i gospodarske subjekte koje je ostavio novi koronavirus.

2.1. Opći pokazatelji

Za početak usporedit će se neki generalni pokazatelji vezani uz gospodarstvo kao što su BDP, industrijska proizvodnja i zaposlenost gdje će u glavnom fokusu biti rezultati Hrvatske koji će se usporediti s prosjekom Europske unije te nekih drugih država.

2.1.1. BDP

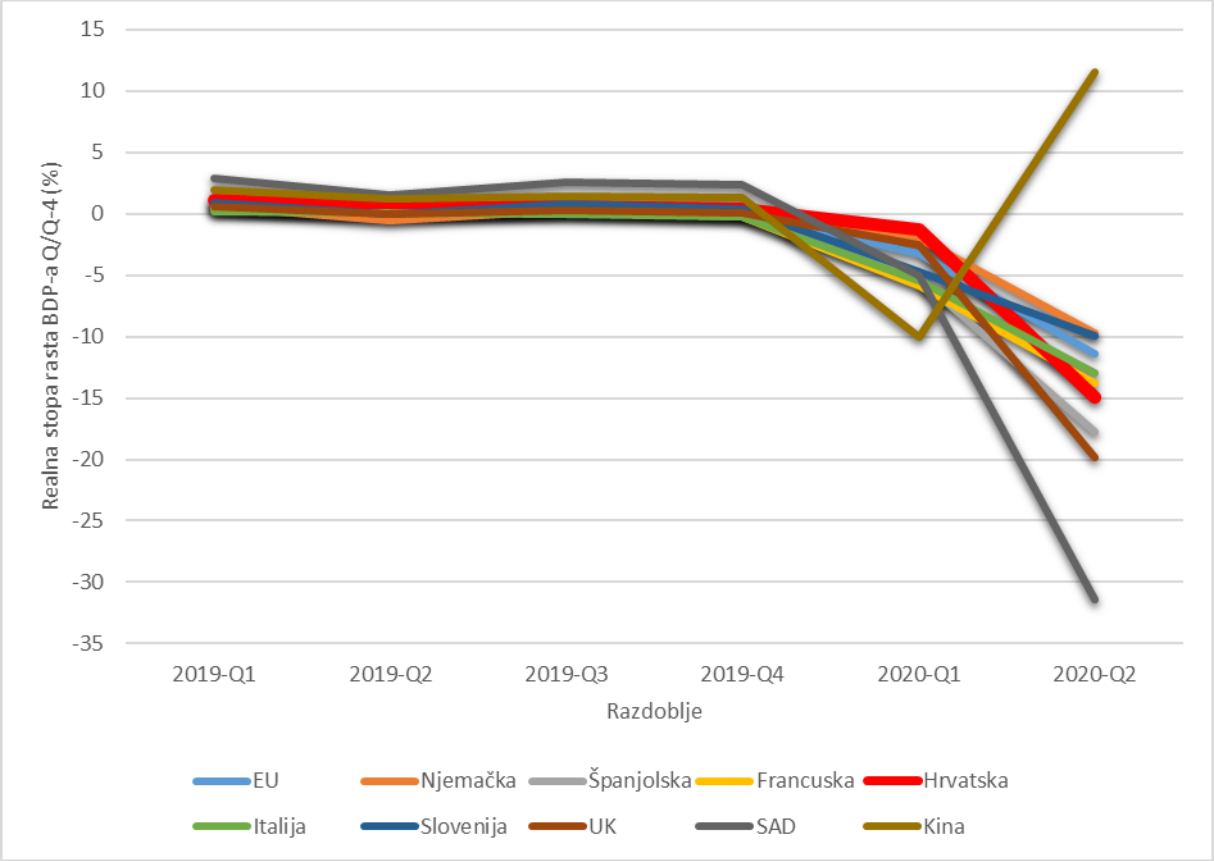
Bruto domaći proizvod vjerojatno je pokazatelj koji se najčešće koristi kada se gleda gospodarstvo neke države, a govori o tome koliko je robe i usluga proizvedeno u nekom gospodarstvu u određenom razdoblju. Upravo zato BDP je prvi pokazatelj koji će se sagledati kako bi se dobio uvid u promjene na razini cijelog gospodarstva. Prikazat će se i promjene na komponentama dvije različite metode izračuna BDP-a, proizvodnoj uz koju je vezana bruto dodana vrijednost, i rashodnoj koja gleda izdatke na područjima kao što su investicije, uvoz i izvoz, te kućanstva i država[11]. Prvo su na Slici 10. prikazane realne stope rasta tromjesečnog BDP-a Republike Hrvatske od 2019. do drugog tromjesečja 2020. godine u usporedbi s istim razdobljem prethodne godine i paralelno usporedba s prethodnim tromjesečjem. Prikazani podaci su sezonski prilagođeni za obje usporedbe kako bi se eliminirala sezonalnost BDP-a (npr. razlika u ljetnim i zimskim mjesecima) i onda prvenstveno otvorila mogućnost usporedbe tekućeg s prethodnim tromjesečjem.



Slika 10. Realne stope rasta tromjesečnog BDP-a Hrvatske [12]

U 2019. godini u svakom kvartalu ostvaren je porast u odnosu na isti iz prethodne godine te u odnosu na prethodni kvartal. Najveći porast ostvaren je u prvom kvartalu u oba slučaja, a iznosi 4 % u odnosu na isti prethodne godine i 1,1 % u odnosu na prethodni. U 2020. godini stanje je ipak nešto drugačije. Iako je u odnosu na prethodnu godinu u prvom kvartalu ipak ostvaren mali porast od 0,3 %, u odnosu na prethodni kvartal zabilježen je pad od 1,3 %. No, ti rezultati su blagi naspram onih za drugi kvartal. Naime, u tom razdoblju ostvaren je pad od 15,1 % u odnosu na isti kvartal prethodne godine, te 14,9 % u odnosu na prethodni kvartal. Takav rezultat najslabiji je koji je zabilježen od početka praćenja ovog pokazatelja prema podacima dostupnim na stranicama Državnog zavoda za statistiku Republike Hrvatske[12]. Prvo tromjesečje je zbog kasne pojave koronavirusa u tom periodu, tj. krajem veljače na neki način pošteđeno krize koju je on donio. Same mjere koje su djelomično zatvorile gospodarstvo i spriječile normalnu gospodarsku aktivnost, a posljedica su pojave virusa, ovdje imaju najveći utjecaj. Uvedene su u drugoj polovici ožujka pa nisu mogle ostaviti značajan utjecaj na prvi kvartal već su pokazale utjecaj u drugom kvartalu. U tom kvartalu počinje i turistička predsezona u Hrvatskoj koje zbog pojave zaraze gotovo da nije ni bilo, i zasigurno je ostavila značajan trag na ovom pokazatelju.

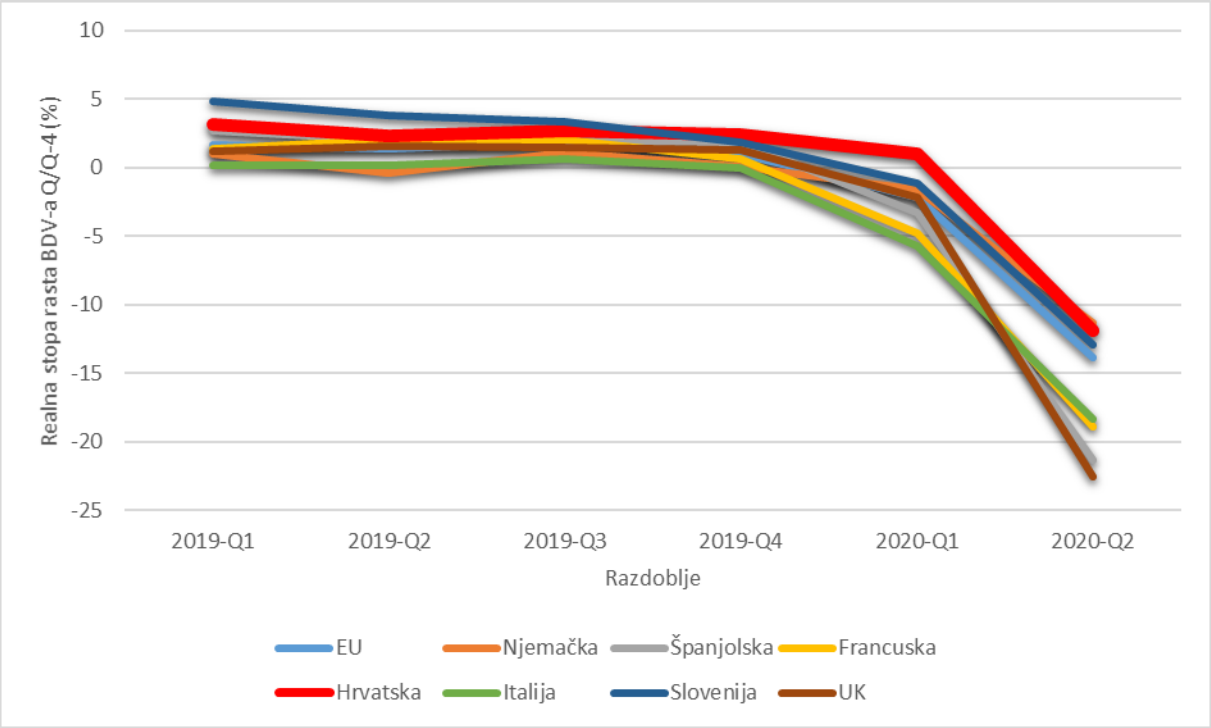
Osim Hrvatske, zanimljivo je sagledati na koji način se kreće tromjesečni BDP u usporedbi s istim razdobljem prethodne godine nekih ostalih zemalja i prosječan rezultat Europske unije prikazani na Slici 11.



Slika 11. Usporedba realne stope rasta tromjesečnog BDP-a [13][14][15]

Prosječni pad sezonski i kalendarski prilagođenog BDP-a u odnosu na prethodni kvartal na razini Europske unije u prvom kvartalu 2020. godine iznosi 3,3 %, dok je u drugom kvartalu očekivano veći i iznosi 11,4 %. Dok je Hrvatska u prvom kvartalu ostvarila rezultat bolji od prosjeka EU, u drugom kvartalu ostvarila je jedan od slabijih. Gledajući 2019. godinu kod većine prikazanih EU zemalja ostvareni rezultati bolji su od onih iz prethodnih kvartala, no taj se trend nije nastavio u tekućoj godini. U prvom tromjesečju najveći pad BDP-a od EU država dogodio se kod Francuske (-5,9 %), a slijede ju Italija (-5,5 %) i Španjolska (-5,2 %). Sve tri zemlje u prvom valu dolaska COVID-a u Europu bile su najpogođenije i imale iznimno velike brojeve novozaraženih i preminulih slučajeva. Od tih zemalja najveću borbu sa zarazom vodila je Italija. Hrvatski susjed iz Europske unije, Slovenija, u prvome kvartalu ostvarila je lošiji rezultat od Hrvatske s padom od 4,7 %, dok je u drugom tromjesečju ostvarila rezultat bolji prosjeka Europske unije, pa tako i Hrvatske s padom od 9,9 %. Gledajući ostale zemlje u tom kvartalu, nakon relativno dobrog rezultata Ujedinjenog Kraljevstva u prvom kvartalu sada je situacija drugačija. Upravo najveći pad ostvarilo je Ujedinjeno Kraljevstvo s padom od 19,8 %. Osim same pandemije značajan utjecaj na ovakav rezultat imao je i odlazak

dotične zemlje iz Europske unije. Idući najveći pad ostvarila je Španjolska (-17,8 %), zemlja koja vodi konstantu borbu sa zarazom i trenutno predvodi Europu po broju zaraženih. Najzanimljiviji rezultati međutim nisu oni vezani uz Europe već uz dvije zemlje koje su obilježile pandemiju COVID-a. Kina, zemlja iz koje se virus proširio svijetom, te SAD koji trenutno u svijetu ima najveći broj zaraženih i preminulih. Obje zemlje su također jedna od vodećih gospodarstva svijeta. Oba gospodarstva su kroz 2019. godinu kao i navedena europska bilježila rast iz kvartala u kvartal, ali u 2020. godini COVID-19 napravio je velike promjene kao i u Europi. Dok je Kina u prvom tromjesečju ostvarila rekordan pad od 10,0 % na koji je utjecala pojava zaraze od samog početka godine, u drugom pak kvartalu bilježi rast od 11,5 % u odnosu na prethodni. Kao što je iz ranijeg poglavlja moguće vidjeti Kina je širenje zaraze dovela pod kontrolu, značajno smanjila broj novozaraženih i to je rezultiralo oporavkom gospodarstva. Za razliku od Kine, kod SAD-a slika je potpuno drugačija. Nakon pada od 5,0 % u prvom kvartalu drugi kvartal donosi rekordan pad od 31,4 % u odnosu na prethodni. Ovakav pad najveći je u povijesti mjerenja ovog pokazatelja te zemlje i ukazuje na ozbiljnost situacije. Osim samih realnih stopa rasta BDP-a, na Slici 12. prikazane su kvartalne stope promjene bruto dodane vrijednosti, komponente BDP-a gledano s proizvodne metode izračuna, u odnosu na isti kvartal prethodne godine.



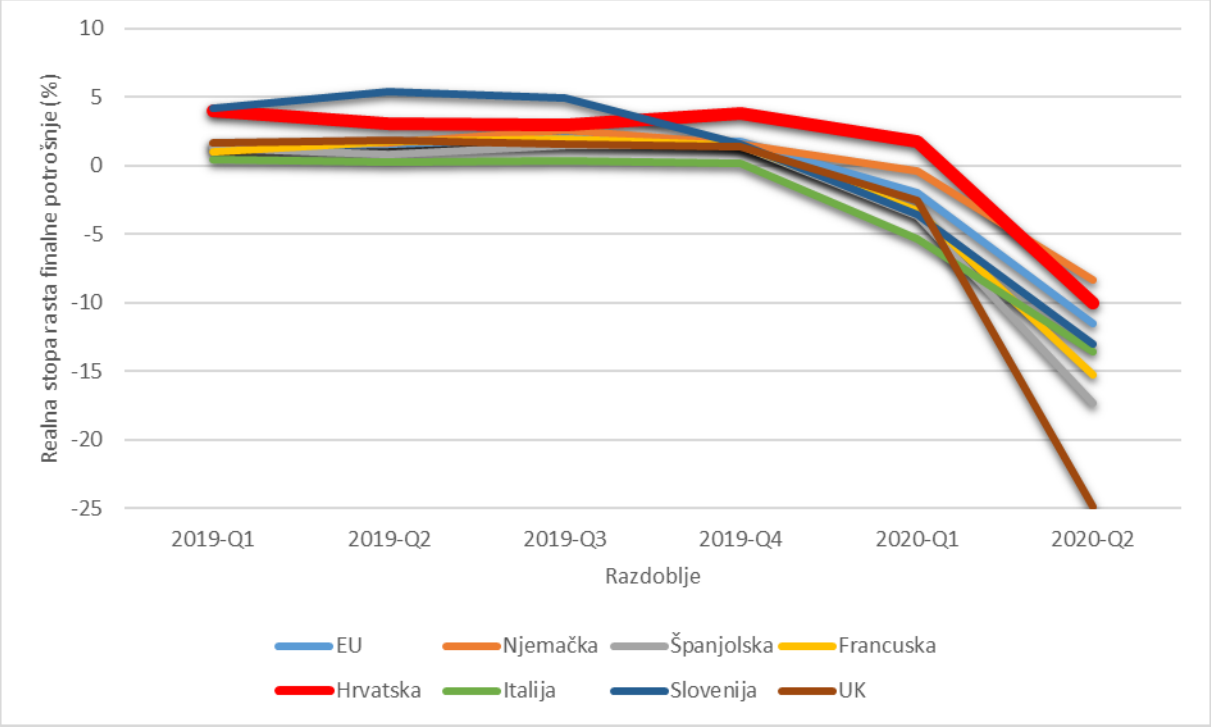
Slika 12. Usporedba realne stope rasta tromjesečnog BDV-a [13]

Za sve navedene zemlje, pa tako i prosjek Europske unije, BDV je u gotovo svim kvartalima bilježio rast u odnosu na iste kvartale 2018. godine. U 2020. godini trend je kao i kod BDP-a promijenjen. Prosječni pad EU u prvom tromjesečju iznosi 2,2 %, dok je u drugom kao i kod BDP-a znatno veći i iznosi 13,9 %. Najveći pad u prvom tromjesečju zabilježila je Italija (-5,7 %), a nakon nje Francuska (-4,8 %) i Španjolska (-3,3 %). Ponovno isti sastav zemalja kao i kod BDP-a, samo su zamijenile mjesta Italija i Francuska. U drugom tromjesečju kao i kod BDP-a istaknulo se Ujedinjeno Kraljevstvo s padom od 22,6 %, a slijede Španjolska (-21,3 %), Francuska (-18,9 %) i Italija (-18,3 %). Hrvatska je u oba tromjesečja ostvarila bolje rezultate od EU prosjeka, dok je u prvom tromjesečju čak ostvaren rast od 1,0 %. Susjedna zemlja Slovenija, također se kretala u tome smjeru, ali ipak je u oba tromjesečja ostvaren pad (-1,1 % i -12,9 %). U Tablici 1. dan je detaljniji uvid u kretanje BDV-a Hrvatske po kvartalima u odnosu na isto razdoblje prethodne godine za područja djelatnosti prema NKD-u 2007.

Tablica 1. Realne stope rasta tromjesečnog BDV-a Hrvatske po NKD-u 2007. u usporedbi s istim razdobljem prethodne godine (%) [12]

		2019.			2020.	
		IV. – VI.	VII. – IX.	X. – XII.	I. – III.	IV. – VI.
A	Poljoprivreda, šumarstvo i ribarstvo	-0,1	4,5	-1,0	4,2	-2,9
B, C, D, E	Prerađivačka industrija, rudarstvo i vađenje te ostale industrije	0,0	1,9	0,1	-2,5	-7,8
C	Prerađivačka industrija	-1,5	1,0	-1,6	-2,5	-9,3
F	Građevinarstvo	7,3	6,5	7,0	6,4	0,3
G, H, I	Trgovina, prijevoz i skladištenje, smještaj, priprema i usluživanje hrane	4,0	3,2	4,6	-0,7	-33,7
J	Informacije i komunikacije	4,9	3,3	5,0	5,6	1,8
K	Financijske djelatnosti i djelatnosti osiguranja	1,2	1,2	1,4	-0,5	-6,3
L	Poslovanje nekretninama	1,0	0,7	0,8	0,6	-0,2
M, N	Stručne, znanstvene, tehničke, administrativne i pomoćne uslužne djelatnosti	3,0	3,1	3,3	3,0	-11,2
O, P, Q	Javna uprava i obrana, obrazovanje, djelatnosti zdravstvene zaštite i socijalne skrbi	1,7	2,1	1,9	2,9	2,2
R, S, T, U	Ostale uslužne djelatnosti	3,2	2,8	4,2	1,9	-32,9
BDV	Bruto dodana vrijednost	2,4	2,7	2,5	1,0	-11,9

Nakon kontinuiranog rasta kroz kvartale u 2019. godini u odnosu na 2018., s iznimkom djelatnosti Poljoprivreda, šumarstvo i ribarstvo, te Prerađivačka industrija, u prvom kvartalu 2020. godine još uvijek je uglavnom nastavljen taj trend. Zabilježena su padovi u 3 područja djelatnosti, Prerađivačka industrija, rudarstvo i vađenje te ostale industrije (-2,5 %) s istim padom kao i samostalno Prerađivačka industrija te Financijske djelatnosti i djelatnosti osiguranja (-0,5 %). Drugi kvartal donosi značajne promjene s padovima kroz gotovo sva područja djelatnosti. Najveći pad očekivano je ostvaren u područjima koja su najviše pogođena pandemijom, točnije mjerama koje su uvedene za suzbijanje, a to su Trgovina, prijevoz i skladištenje, smještaj, priprema i usluživanje hrane (-33,7 %) i Ostale uslužne djelatnosti (-32,9 %). Prerađivačka industrija je u drugom tromjesečju ostvarila pad BDV-a od 9,3 %, a značajniji pad ostvaren je još na području Stručne, znanstvene, tehničke, administrativne i pomoćne uslužne djelatnosti (-11,2 %). Osim proizvodne metode izračuna BDP-a postoji i ona rashodna, pa će Slika 13. prikazati realne stope rasta finalne potrošnje, jedne od komponenata za izračun BDP-a po rashodnoj metodi. Stope rasta odnose se na isto razdoblje prethodne godine.



Slika 13. Usporedba tromjesečne realne stopa rasta finalne potrošnje [13]

Kroz 2019. godinu zabilježen je rast potrošnje kod svih navedenih zemalja, pa posljedično i prosjeka EU. U prvom kvartalu je u EU prosječno zabilježen pad od 1,9 %, gdje se ističu Italija (-5,4 %), Španjolska (-3,7 %), Slovenija (-3,5 %) i Francuska (-3,3 %). Hrvatska je u

ovom kvartalu zabilježila rast potrošnje od 1,8 %, jedina od navedenih zemalja. U drugom kvartalu pridružila se općem trendu EU i zabilježila pad od 10,1 %, nešto manji od prosjeka EU (-11,5 %). Najveći pad ostvarilo je Ujedinjeno Kraljevstvo (-24,8 %) te Španjolska (-17,3 %) i Francuska (-15,3 %). Detaljniji prikaz kretanja svih komponenata BDP-a s rashodne strane za Republiku Hrvatsku prikazan je u Tablici 2.

Tablica 2. Tromjesečne realne stope rasta komponenata BDP-a Hrvatske s rashodne strane (%) [12]

	2019.			**2020.**	
	IV. – VI.	VII. – IX.	X. – XII.	I. – III.	IV. – VI.
Konačna potrošnja	3,0	3,0	3,8	1,8	-10,1
Kućanstva	2,7	3,1	4,0	0,7	-14,0
NPUSK	2,4	0,5	0,6	3,9	-1,0
Država	3,9	2,9	3,5	4,8	0,7
Bruto investicije u fiksni kapital	8,2	5,0	4,0	3,1	-14,7
Izvoz roba i usluga	3,3	5,1	5,6	-3,0	-40,6
Robe	0,4	8,4	2,1	0,3	-10,9
Usluge	6,2	3,1	12,1	-9,4	-67,4
Uvoz roba i usluga	8,3	4,3	0,1	-5,8	-28,1
Robe	9,7	4,9	0,8	-1,6	-25,3
Usluge	1,9	1,8	-3,1	-25,1	-42,5
Bruto domaći proizvod	**2,4**	**2,9**	**2,5**	**0,4**	**-15,1**

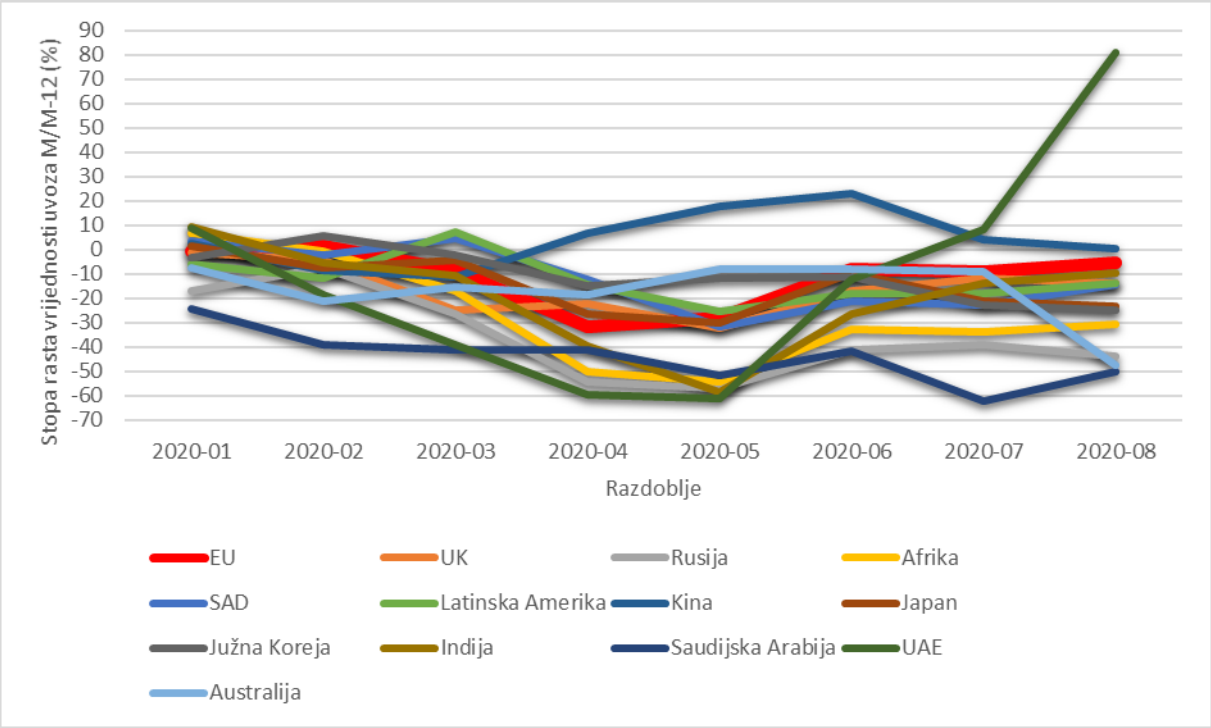
U prvom kvartalu konačna potrošnja i bruto investicije u fiksni kapital bilježe rast, međutim izvoz i uvoz roba i usluga kreću se u drugom smjeru. Poseban pad ostvaren je na izvozu, a pogotovo uvozu usluga. U drugom kvartalu sve komponente ostvarile su pad, jedino je potrošnja države (dio komponente konačna potrošnja) ostvarila rast od 0,7 %. Pandemija je poseban utjecaj ostavila ponovno na izvoz i uvoz roba, a pogotovo usluga.

Svi pokazatelji vezani uz BDP generalno slijede identičan trend. Nakon rasta u 2019. godini, u prvom kvartalu 2020. godine dogodili su se prvi blaži padovi, nakon kojih su slijedili značajni u drugom kvartalu. Rezultati zemalja variraju, dok zemlje Europe, Ujedinjeno Kraljevstvo, Francuska i Španjolska bilježe značajne padove u drugome kvartalu, Njemačka, Hrvatska i Slovenija u odnosu na njih ipak su ostvarile nešto bolje rezultate. Van Europe,

Kina je čak uspjela ostvariti pozitivan rezultat gledajući realne stope rasta BDP-a, dok je SAD rekorder što se tiče negativnog kretanja istog pokazatelja.

2.1.2. Robna razmjena

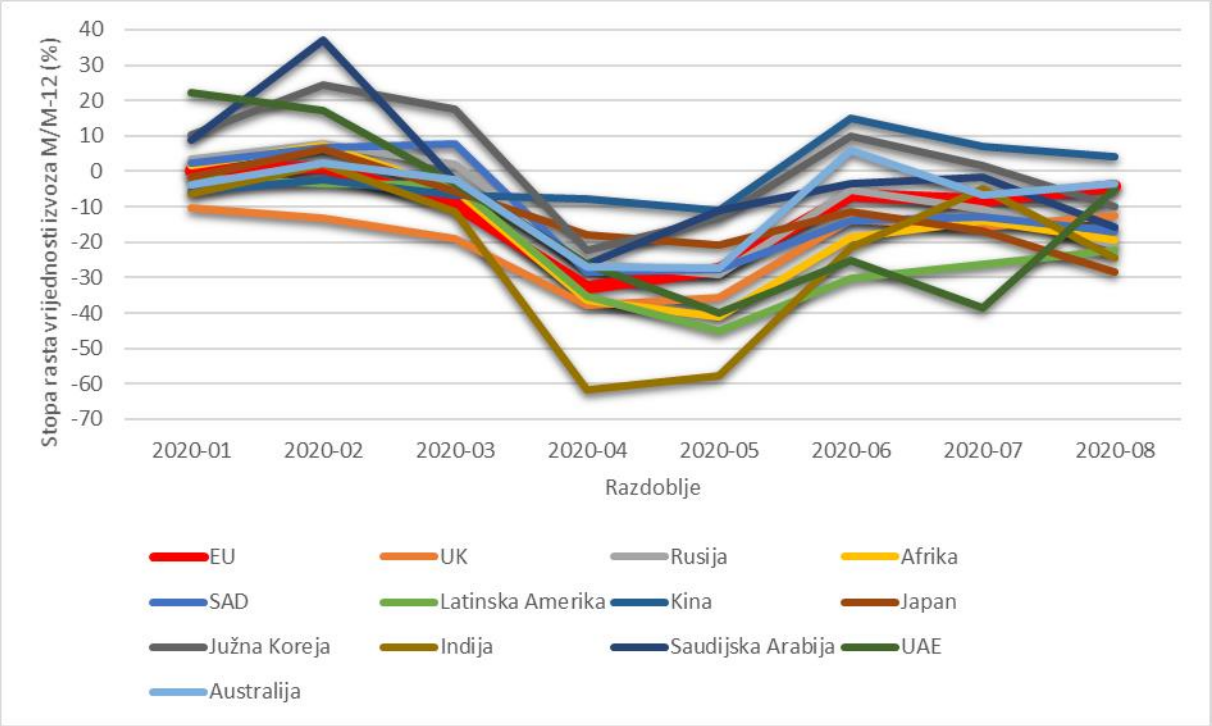
Uvoz i izvoz kategorije su koje su usko vezane i uz sami BDP, međutim ovdje će se sagledati zasebno. Uvedene mjere ograničile su kretanje ljudi, pa posljedično i kretanje robe i ostavile velike posljedice na vanjskotrgovinsku robnu razmjenu. Na Slici 14. prikazane su promjene uvoza pojedinih regija/zemalja po mjesecima u 2020. godini u odnosu na isto razdoblje prethodne godine.



Slika 14. Usporedba stopa promjene vrijednosti uvoza [13]

Kod većine zemalja uvoz je početkom godine bio otprilike jednak kao i u istom razdoblju 2019. godine (s iznimkom Saudijske Arabije zbog smanjenja uvoza) nakon čega ožujak donosi promjene u smislu pada uvoza. Saudijska Arabija i dalje nastavlja sa smanjenjem i predvodi navedene regije/zemlje s padom od 40,9 %. Slijedi ju susjedna zemlja Ujedinjeni Arapski Emirati, pa onda Rusija i Ujedinjeno Kraljevstvo. Uvoz nastavlja padati do svibnja kada dolazi do ukidanja uvedenih mjera u većini zemalja i umanjenja pada ako se gleda stopa mjeseci prije. Kod Ujedinjenih Arapskih Emirata u kolovozu dolazi do rasta od čak 80,8 % u odnosu na kolovoz 2019. godine, dok je kod Kine uvoz nakon ožujka (budući da je Kina

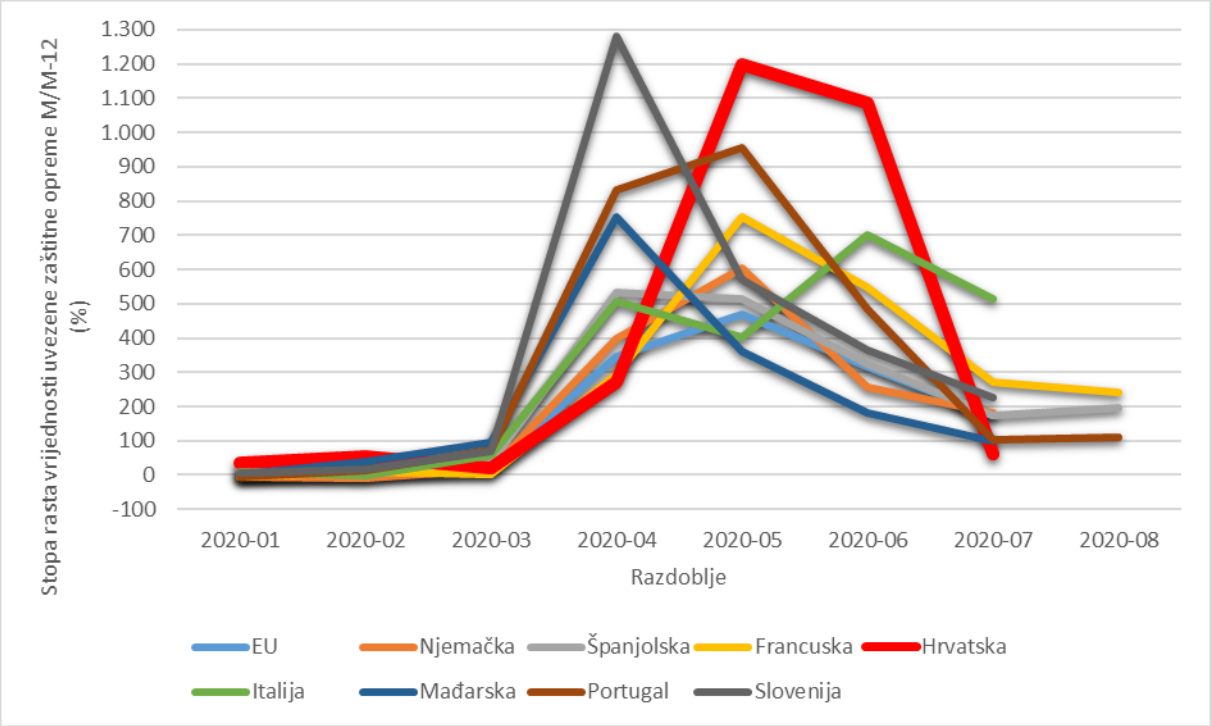
doživjela širenje bolesti ranije) kontinuirano veći u odnosu na prethodnu godinu. Nakon podataka vezanih uz uvoz, Slika 15. prikazuje iste regije/zemlje i njihov izvoz.



Slika 15. Usporedba stopa rasta vrijednosti izvoza [13]

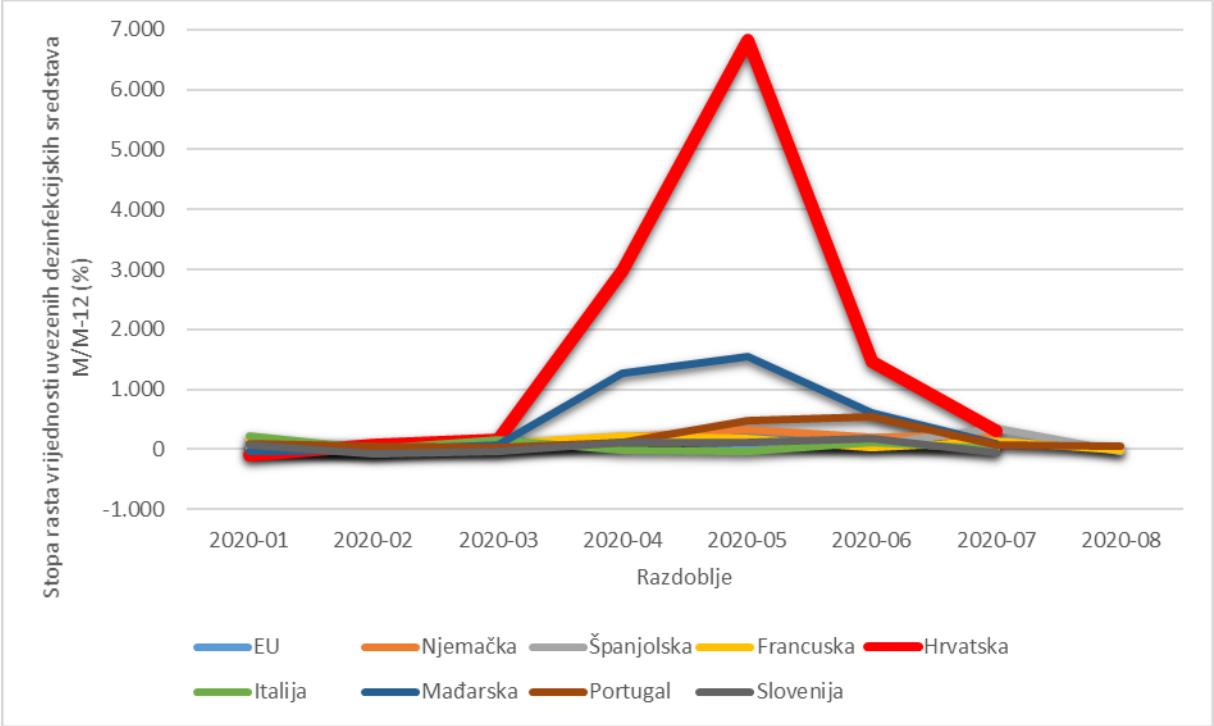
Trend je sličan kao i kod uvoza. Početak godine donosi manje promjene kod mnogih zemalja, a ističu se ponovno Saudijska Arabija, Ujedinjeni Arapski Emirati i Južna Koreja sa značajnijim rastom te Ujedinjeno Kraljevstvo sa značajnijim padom. Ožujak je ponovno prekretni mjesec nakon kojega sve zemlje doživljavaju pad izvoza koji je kulminirao u svibnju. Lipanj ponovno donosi manje padove i oni se nastavljaju smanjivati do kolovoza koji je kod dosta zemalja ponovno donio veće padove. Ističe se još jednom Kina koja nakon lipnja i ukidanja mjera u zemljama gdje izvozi robu bilježi kontinuirano veći izvoz u odnosu na 2019. godinu.

Jedna od glavnih preporuka, pa kasnije i obveza kako bi se spriječilo širenje zaraze je nošenje nekog oblika zaštitne opreme te učestalo pranje odnosno dezinficiranje ruku. Stoga će sljedeće dvije slike prikazati iznimno zanimljive podatke. Prvo, Slika 16. donosi uvid u promjenu vrijednosti uvezene zaštitne opreme, npr. zaštitnih maski, po mjesecima u odnosu na isto razdoblje prethodne godine za pojedine zemlje i Europsku uniju.



Slika 16. Usporedba stopa rasta vrijednosti uvezene zaštitne opreme [13]

Nakon relativno malih promjena početkom godine ožujak donosi prvi manji rast, da bi u travnju bio zabilježen enormni porast uvoza zaštitne opreme, a rekorder je Slovenija (1282,0 %). Žestoka reakcija zemalja i nagli porast uvoza zaštitne opreme stigao je nakon dolaska zaraze u Europu. Svibanj još karakterizira značajan rast uvoza, ali se nakon toga mjeseca količine ipak postepeno smanjuju. Hrvatska je najveću vrijednost uvezene robe imala u svibnju i lipnju u kojima je porast bio 1198,0 % i 1085,0 %. Slika 17. prikazuje iste podatke vezane uz uvoz dezinfekcijskih i sterilizacijskih sredstava.

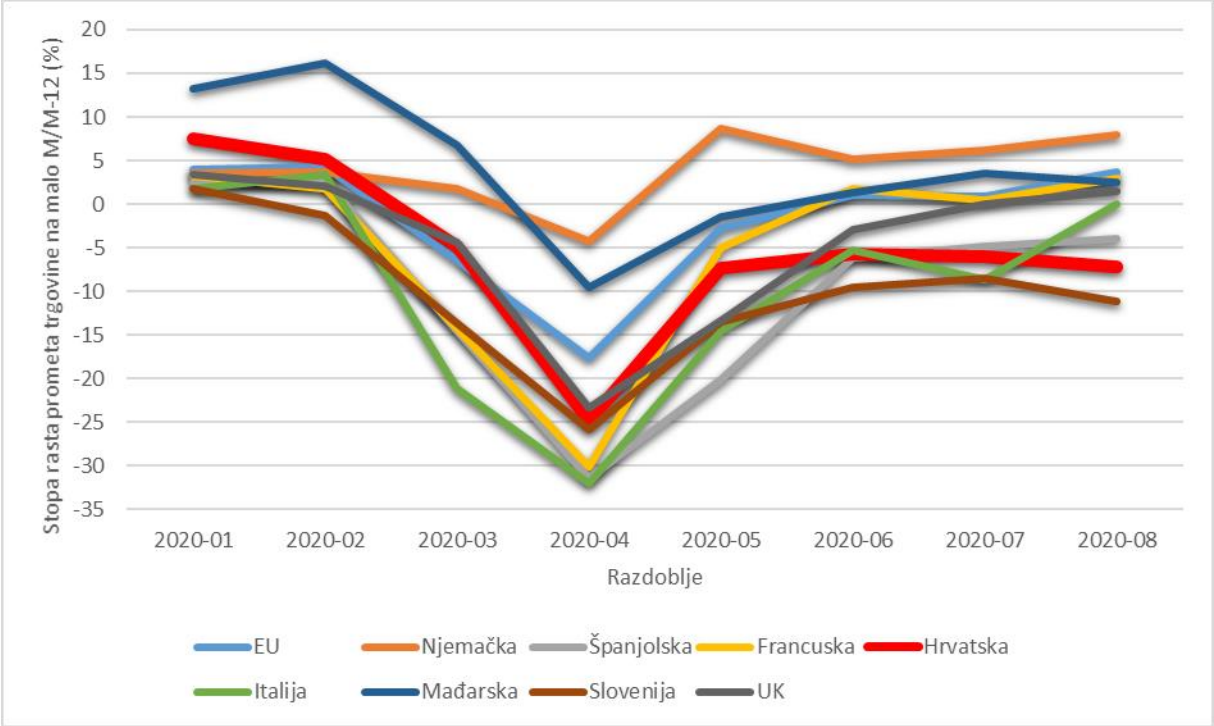


Slika 17. Usporedba stopa rasta vrijednosti uvezenih dezinfekcijskih sredstava [13]

Za razliku od značajnije promjene u uvozu zaštitne opreme, kod dezinfekcijskih sredstava prisutan je isti trend rasta međutim ne u tolikoj mjeri. No postoje iznimke i posebno se ističe upravo Hrvatska s najvećim rastom uvoza zabilježenim u svibnju od nevjerojatnih 6820,0 %. Osim Hrvatske ističu se i Mađarska, Portugal i Njemačka međutim ne u tolikoj mjeri. Zaključiti se može da je u Hrvatskoj naglo porasla potražnja za dezinfekcijskim sredstvima koji očito ne spadaju u navike lokalnog stanovništva, te da Hrvatska očito nema dovoljno domaćih proizvođača istih kako bi pokrila tu potražnju.

2.1.3. Trgovina na malo

Iz ranijeg poglavlja moguće je vidjeti kako je potrošnja kućanstava u prvom tromjesečju 2020. godine uspjela održati rast, međutim u drugom je došlo do primjetnog pada. Upravo je ta potrošnja usko vezana uz promet ostvaren u trgovini na malo. Slika 18. stoga prikazuje ukupnu mjesečnu promjenu prometa trgovine na malo (ne uključujući onu vezanu uz motorna vozila i motocikle) u 2020. godini u odnosu na isto razdoblje 2019. godine. Podaci kojima su dobivene promjene kalendarski su prilagođeni da bi se uzeo u obzir promjena broja radnih dana u istom mjesecu iz različite godine.

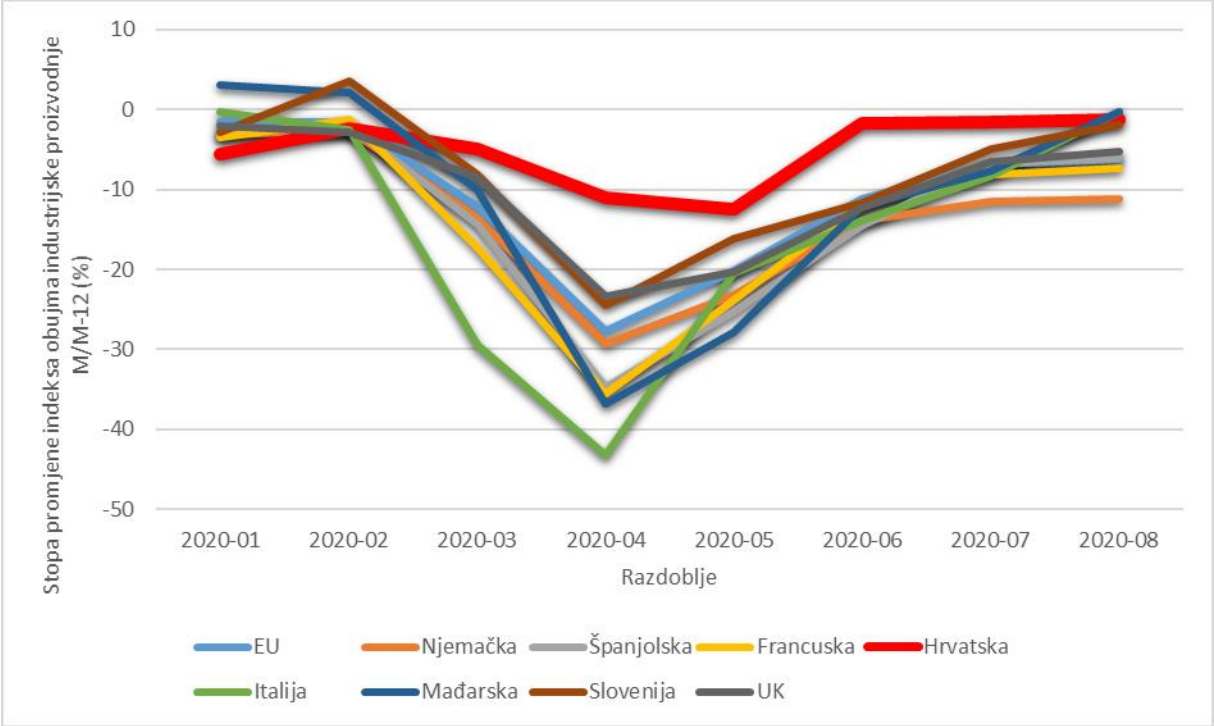


Slika 18. Usporedba stopa rasta prometa trgovine na malo [13]

Kao i kod većine dosadašnjih pokazatelja prva dva mjeseca do pojave pandemije u ožujku uglavnom obilježava rast da bi u ožujku došlo do promjene u negativnom smjeru. Gledajući promjene u mjesecima prvog tromjesečja za Hrvatsku, jasno je zašto je i potrošnja kućanstava zabilježila rast u tom periodu. Drugo tromjesečje i pripadni mjeseci oborili su pak rekorde u negativnom kretanju trgovine na malo. Najveći pad ostvaren je u travnju, nakon kojega promet počinje opet rasti, pa je kod pojedinih zemalja od lipnja zabilježena pozitivna promjena u odnosu na prethodnu godinu, dok je kod drugih još uvijek prisutan negativan trend. Naizgled su se upravo stvorile te dvije grupe zemalja, dok kumulativno gledajući ukupan prosjek na razini EU, promet od lipnja počinje rasti u odnosu na prethodnu godinu.

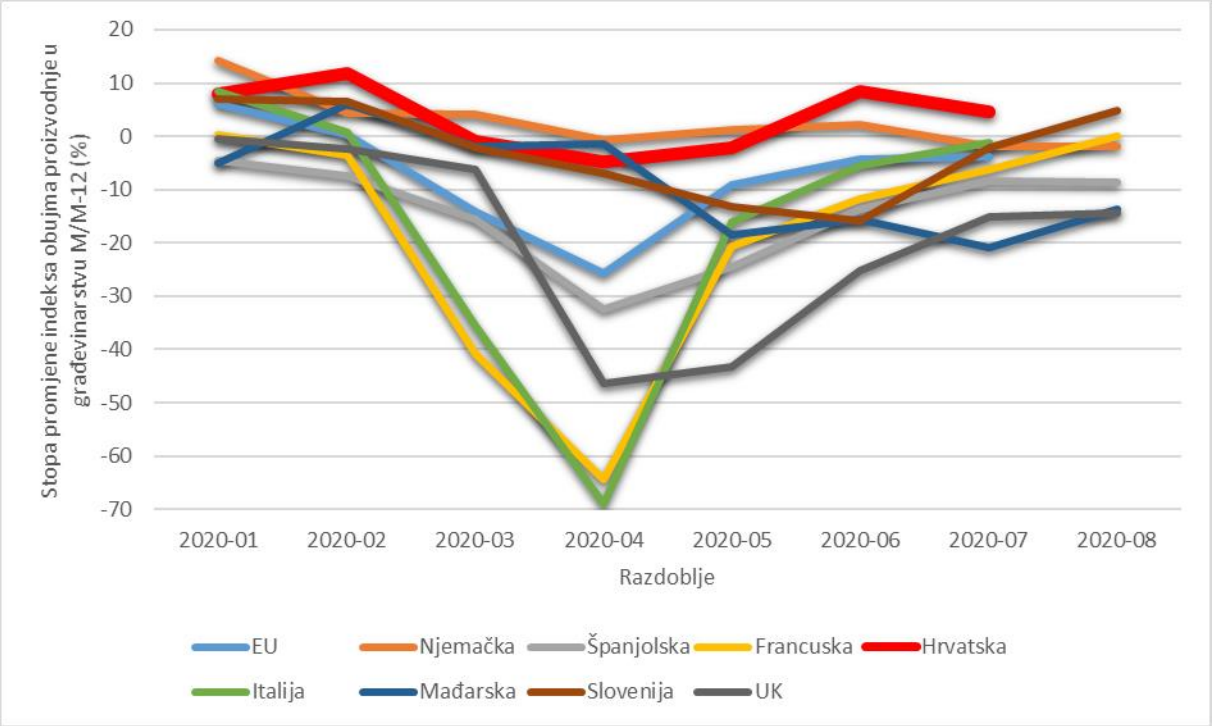
2.1.4. Industrijska proizvodnja i građevinarstvo

Vrlo bitan pokazatelj na kojega su uvedene mjere znatno utjecale su industrijska proizvodnja i građevinarstvo. Kao što je ranije navedeno mjere su spriječilo normalno obavljanje posla, pa je dobar dio poduzeća bio prisiljen prekinuti redovno poslovanje. Iz tog razloga ovdje će se prikazati promjene indeksa industrijske proizvodnje i proizvodnje u građevinarstvu po mjesecima u 2020. godini u odnosu na prethodnu godinu. Podaci su kao i u prethodnom poglavlju kalendarski prilagođeni iz istih razloga. Slika 19. prikazuje promjene vezane uz industrijsku proizvodnju.



Slika 19. Usporedba stopa promjene indeksa obujma industrijske proizvodnje [13]

Iako je cijelu godinu obilježio negativan trend kretanja promjene indeksa obujma industrijske proizvodnje, ipak ponovno postoje mjeseci koji se ističu. U ožujku dolazi do prve pojave većeg pada, da bi u travnju kod većine zemalja došlo do najvećeg pada. U tome smjeru kreće se i prosjek EU, koji nakon travnja postepeno smanjuje pad. Zanimljivo je da je Hrvatska prije pojave pandemije imala rezultate lošije od prosjeka na razini Europske unije, međutim za vrijeme trajanja pandemije ostvaruje rezultate bolje od prosjeka Europske unije. Promjena indeksa obujma proizvodnje vezane uz građevinarstvo prikazana je na Slici 20.

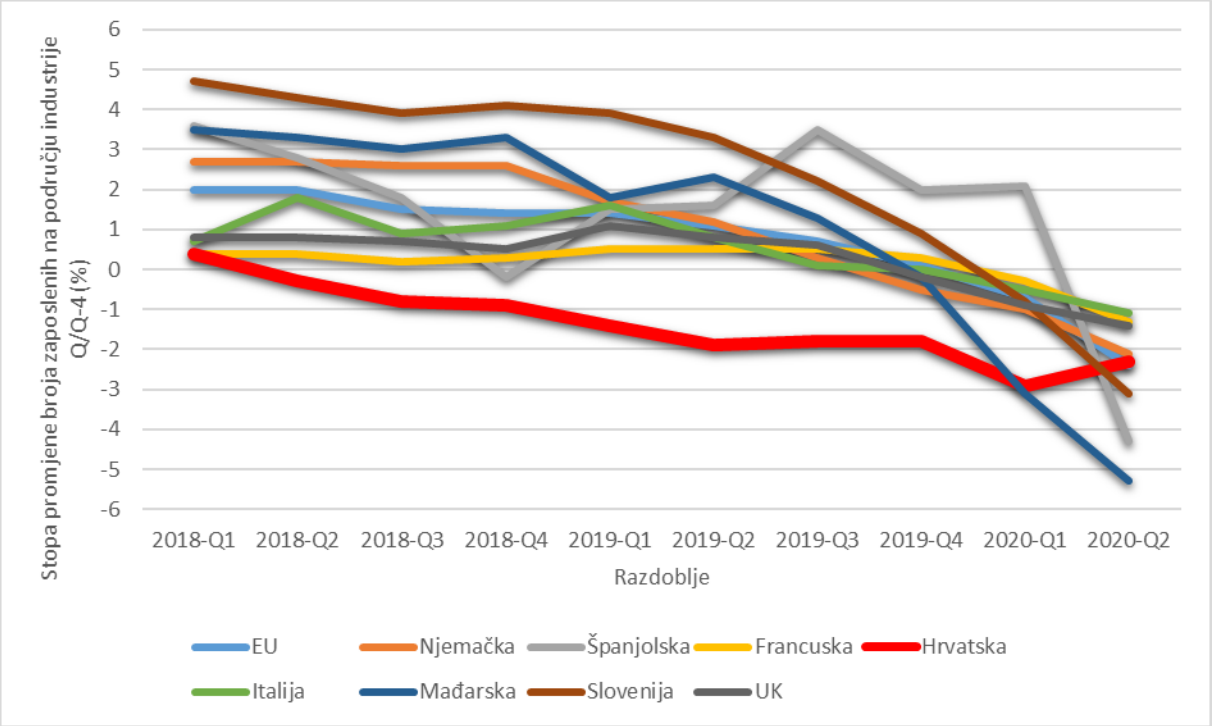


Slika 20. Usporedba stopa promjene indeksa obujma proizvodnje u građevinarstvu [13]

Kao i kod industrijske proizvodnje i ovdje su kroz siječanj i veljaču prisutne pozitivne promjene u odnosu na 2019. godinu. Međutim dolaskom ožujka stvaraju se dvije grupe zemalja. Jednu grupu s manje članova, u koju bi spadala i Hrvatska, karakterizira blaži pad i kasniji brži oporavak, dok je druga grupa zabilježila značajne padove u ožujku i travnju, pa je i oporavak nešto sporiji. Valja primijetiti kako je negativna stopa promjene indeksa proizvodnje u građevinarstvu dolaskom koronavirusa veća od one kod industrijske proizvodnje.

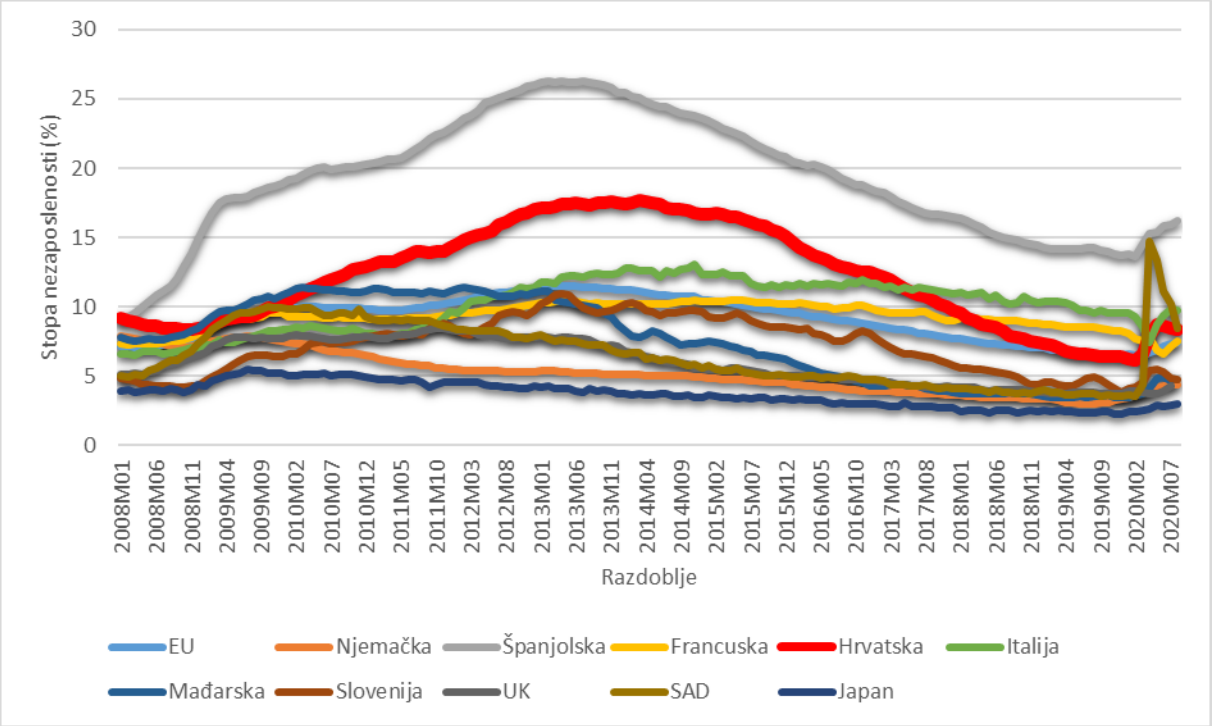
2.1.5. Zaposlenost

Pokazatelj koji izravno utječe na, ali je i posljedica promjena u svim granama gospodarstva, je zaposlenost. Uvedene mjere za suzbijanje zaraze zatvorile su mnoge gospodarske subjekte što je ostavilo značajan trag na razini zaposlenosti. Na Slici 21. prikazana je promjena u ukupnom broju zaposlenih u industriji na razini tromjesečja u odnosu na isto razdoblje prethodne godine.



Slika 21. Usporedba stopa promjene broja zaposlenih na području industrije [13]

Zaposlenost prati trend kretanja indeksa industrijske proizvodnje. 2018. i 2019. godina donose rast zaposlenosti u tom sektoru s iznimkom Hrvatske koja kroz obje godine bilježi pad zaposlenosti u svim tromjesečjima osim u prvom 2018. godine. Hrvatska nastavlja s negativnim kretanjem zaposlenosti i u 2020. godini međutim ovoga puta pridružuju joj se i ostale osim Španjolske koja u prvom kvartalu ostvaruje rast od 2,1 %. Od tri mjeseca prvog kvartala i pozitivnih promjena kroz prva dva, ožujak je ipak donio značajne promjene i uspio negativno promijeniti rezultat tog kvartala. U drugome kvartalu dolazi do većeg pada zaposlenosti uslijed uvedenih mjera koje su na snazi bile kroz travanj i svibanj. Osim zaposlenosti u sektoru industrije, zanimljivo je sagledati i kretanje stope nezaposlenosti prikazane na Slici 22.

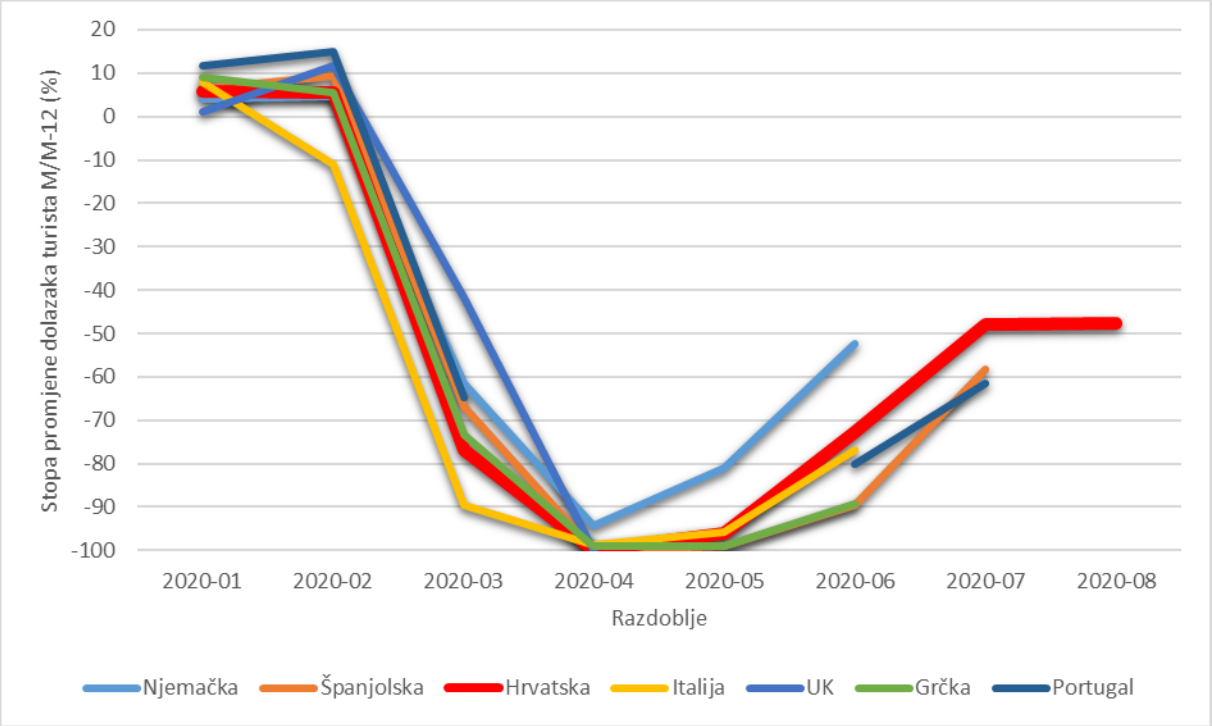


Slika 22. Usporedba stopa nezaposlenosti [13]

Nakon pojave ekonomske krize 2008./2009. godine stopa nezaposlenosti počela je rasti. Ovisno o potrebnim godinama za oporavak gospodarstava navedenih zemalja, neke su počele nezaposlenost smanjivati ranije međutim krajem 2013. godine kod svih navedenih zemalja ona je počela padati. Trend smanjivanja nastavio se do pojave COVID-a koji je ponovno započeo trend rasta najprimjetniji kod SAD-a i Španjolske.

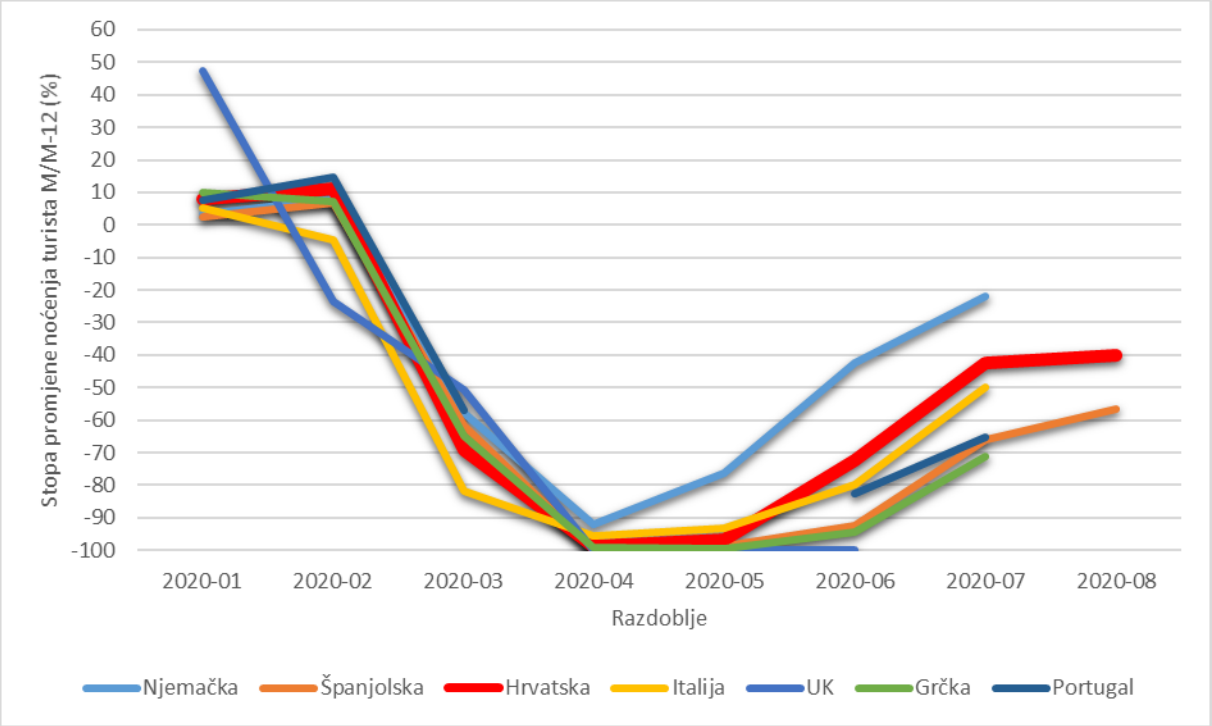
2.1.6. Turizam

Turizam je grana gospodarstva koja je pandemijom i uvedenim mjerama najviše pogođena. Turistička predsezona počinje upravo u drugome kvartalu u kojemu se zaraza proširila svijetom, pa su uvedene već navedene mjere. Kretanje stanovništva uvelike je ograničeno ne samo unutar zemalja, već i među njima, a većina turista koja posjećuje zemlje dolaze upravo iz inozemstva. Pokazatelji koji će dati uvid u stanje turizma u 2020. godini su dolasci i noćenja turista po mjesecima u tekućoj godini u odnosu na prethodnu. Promjena u dolascima prikazana je na Slici 23. za nekolicinu zemalja od kojih je većina izabrana zbog sličnosti s kretanjem turističke sezone Hrvatske.



Slika 23. Usporedba stopa promjene dolazaka turista [13]

Kod većine zemalja i dalje je prisutan trend rasta u prva dva mjeseca 2020. godine u odnosu na prethodnu godinu. Iznimka je Italija s blagim padom koja je ranije pogođena pandemijom u velikim razmjerima. U ožujku je prisutan značajan pad u usporedbi s 2019. godinom, a najveći je prisutan kod Italije (-89,5 %) koja je kao što je rečeno doživjela naglo širenje zaraze. Najveći pad ostvaren je u travnju u kojem su na snazi bile mjere i kod svih zemalja bio je blizu 100,0 %. U svibnju je došlo do neprimjetnog poboljšanja rezultata, da bi s lipnjem i ukidanjem mjera došlo do značajnijih poboljšanja. Svejedno i dalje je u svim zemljama za koje su dostupni podaci prisutan znatan pad u odnosu na prethodnu godinu kroz ljetne mjesece. Slika 24. prikazuje promjenu noćenja u odnosu na 2019. godinu.

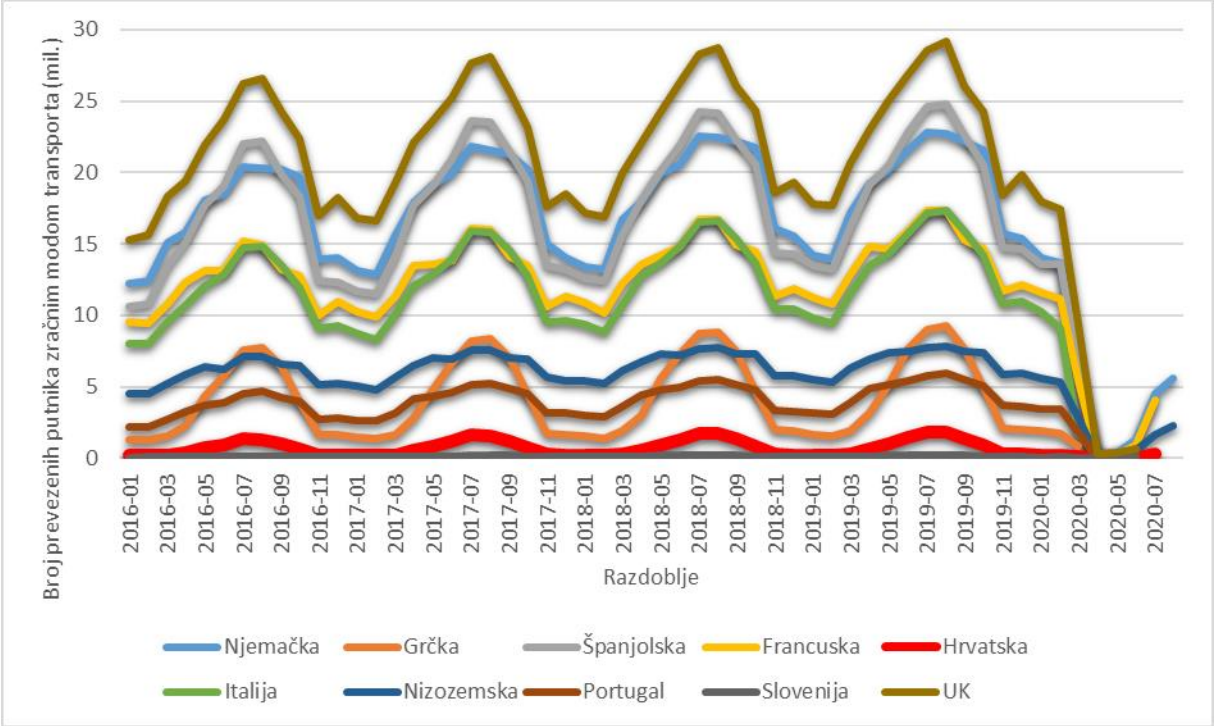


Slika 24. Usporedba stopa promjene noćenja turista [13]

Kretanje noćenja otprilike je identično kao i kretanje dolazaka. Razlika je u veljači u kojoj je pad osim kod Italije ostvaren i kod Ujedinjenog Kraljevstva koje je početkom godine izašlo iz EU, pa se može pretpostaviti da je i taj potez utjecao na ovakav rezultat. U ožujku je pad prisutan kod svih kao i kod dolazaka i ponovno je Italija zemlja s najvećim padom. Ukidanjem mjera pad se počinje smanjivati, ali je i dalje prisutan kroz ljetne mjesece odnosno glavni dio turističke sezone.

2.1.7. Transport

Unatoč uvođenjem mjera i ograničavanja kretanje transport dobara nužnih za osiguranje osnovnih životnih potreba je nastavljen. Naravno, kao što je moguće vidjeti u ranijem poglavlju vezanom uz robnu razmjenu došlo je do smanjenja obujma razmjene, pa samim time i transporta. Transport nije nužan samo za razmjenu dobara već je usko vezan i s turizmom, pa će Slika 25. prikazati trend kretanja prevezenih putnika zračnim modom transporta od 2016. do 2020. godine po mjesecima za nekoliko zemalja.



Slika 25. Broj prevezenih putnika zračnim modom transporta [13]

Prva pravilnost koja zapada za oko kod gledanja vremenske serije kretanja broja putnika je sezonalnost. Očito je da ljetni mjeseci predstavljaju vrhunac turističke sezone, pa je samim time i broj prevezenih putnika u tom periodu najveći. Osim sezonalnosti jasno je vidljiv i trend rasta odnosno iz godine u godinu broj prevezenih putnika sve je veći u odnosu na prethodnu godinu. I zadnja stvar koja upada u oko je posljedica pandemija novog koronavirusa. U 2020. godini broj prevezenih putnika je u siječnju i veljači nastavio trendom prethodnih godina, da bi u ožujku došlo do prve promjene i blagog odmaka u odnosu na trend. U mjesecima koji slijede broj prevezenih putnika gotovo je zanemariv kada se usporedi s rezultatima iz 2019. godine. Primjera radi u Grčkoj je u kolovozu 2020. godine prevezeno 71,5 % manje putnika u odnosu na 2019., a u Njemačkoj 75,3 %.

2.2. Utjecaj na gospodarske subjekte – usporedba uspješnosti poslovanja

Nakon dobivenog uvida u stanje gospodarstva na pretežno makro razini analizirat će se stanje pojedenih grana gospodarstva detaljnije. Za pojedine grane predstavit će se podaci iz privremenih tromjesečnih financijskih izvješća kako bi se prikazao utjecaj pandemije na različite grane i gospodarske subjekte vezane uz njih.

2.2.1. Trgovina, prijevoz i skladištenje, smještaj, priprema i usluživanje hrane

U prvoj skupini koja će se obraditi navest će se hrvatska i strana poduzeća čija je glavna djelatnost pružanje usluge prijevoza te smještaja, pripreme i usluživanja hrane. Za primjer prijevoza navest će se poduzeća vezana uz zračni mod transporta, dok će za smještaj, pripremu i usluživanje hrane biti navedena poduzeća koja vezana uz hotelijerski posao.

2.2.1.1. Zračni prijevoz

Iz ranijeg poglavlja u kojem je naveden broj putnika prevezenih zračnim transportom moguće je naslutiti da će poslovni rezultat poduzeća koja pružaju navedenu uslugu biti znatno slabiji u usporedbi s prethodnim razdobljima. Hrvatski predstavnik čiji će se poslovni rezultat proučiti je najveći na tom tržištu, grupa Croatia Airlines, dok će se za usporedbu prikazati rezultati grčkog predstavnika, grupe Aegean Airlines. Usporedba uspješnosti poslovanja po tromjesečjima prikazana je u Tablici 3.

Tablica 3. Usporedba uspješnosti poslovanja grupa Croatia Airlines i Aegean Airlines [16][17][18][19][20]

	2019.				**2020.**							
	Q1	Q2	Q3	**Q1-Q3**	Q1		Q2		Q3		**Q1-Q3**	
	CROATIA AIRLINES (mil. kn)											
Poslovni prihodi	256,4	499,3	580,9	**1.336,5**	231,7	*-10%*	108,1	*-78%*	209,0	*-64%*	**548,9**	***-59%***
Poslovni rashodi	346,5	487,9	530,9	**1.365,3**	327,9	*-5%*	169,0	*-65%*	276,7	*-48%*	**773,6**	***-43%***
Dobit ili gubitak razdoblja	-98,4	9,7	41,6	**-47,2**	-111,0	*-13%*	-63,9	*-761%*	-71,0	*-271%*	**-246,0**	***-421%***
	AEGEAN AIRLINES (mil. €)											
Poslovni prihodi	177,1	351,1	-	**528,2**	153,3	*-13%*	41,6	*-88%*	-	-	**194,9**	***-63%***
Poslovni rashodi	185,4	279,2	-	**464,6**	186,3	*0%*	56,2	*-80%*	-	-	**242,5**	***-48%***
Dobit ili gubitak razdoblja	-35,2	72,0	-	**36,8**	-85,4	*-143%*	-14,7	*-120%*	-	-	**-100,1**	***-372%***

Kao što je moguće primijetiti još iz poglavlja u kojem je prikazan broj prevezenih putnika, ovaj mod transporta karakterizira sezonalnost poslovanja. Stoga nije čudno kada se gledaju rezultati iz 2019. godine kod obje grupe da je poslovanje najslabije u prvom tromjesečju, u drugom dolazi do značajnog rasta i vrhunca poslovanja u trećem. U 2020. godini kod hrvatskog predstavnika je u prvom tromjesečju poslovni rezultat bio je na tragu onoga iz

prethodne godine. Dolaskom novog koronavirusa pred kraj tromjesečja, rezultati su ipak bili lošiji nego 2019. godine. Trend pada nastavljen je u tromjesečjima koji slijede, a pogotovo je izražen u drugom u kojem su na snazi bile mjere ograničavanja kretanja stanovništva. Loši rezultati kroz sva tromjesečja na kraju su rezultirali padom poslovnih prihoda kod obje grupacije za oko 60 % koje je pratio i pad rashoda za oko 45 %. Ukupan poslovni rezultat (dobit ili gubitak razdoblja) hrvatskog predstavnika u tekućoj godini ostvario je dodatan pad od 421 %. Grčki predstavnik je u istom periodu ostvario je pad od 372 %.

2.2.1.2. Smještaj, priprema i usluživanje hrane

Djelatnosti smještaja, pripreme i usluživanja hrane među najpogođenijima su pandemijom. Uslijed širenja zaraze sve se manje turista odlučuje na putovanja, a to pogotovo vrijedi za strane turiste. Ulogu ovdje igra i povezanost s djelatnosti prijevoza koja je veoma snažna budući da porastom potražnje za dolaskom na neku lokaciju (u neki smještaj) raste i potražnja za prijevozom na istu. Nakon spoznaje iz prethodnog poglavlja o značajnom negativnom utjecaju COVID-a na poslovanje prijevoznih poduzeća, proučit će se jesu li posljedice na poslovanje poduzeća koje pružaju usluge smještaja, pripreme i usluživanja hrane iste. Usporedit će se rezultati hrvatskog predstavnika grupe Maistra, i španjolske grupe NH Hotel Group. Usporedba uspješnosti poslovanja po tromjesečjima prikazana je u Tablici 4.

Tablica 4. Usporedba uspješnosti poslovanja grupa Maistra i NH Hotel Group [21][22][23][24][25]

	2019.				**2020.**							
	Q1	Q2	Q3	**Q1-Q3**	Q1		Q2		Q3		**Q1-Q3**	
	MAISTRA (mil. kn)											
Poslovni prihodi	92,9	319,0	790,1	**1.201,3**	76,6	*-18%*	42,0	*-87%*	427,9	*-46%*	**546,4**	***-55%***
Poslovni rashodi	141,4	260,7	399,9	**801,3**	152,5	*8%*	112,9	*-57%*	281,3	*-30%*	**546,7**	***-32%***
Dobit ili gubitak razdoblja	-50,2	44,4	379,0	**373,2**	-91,4	*-82%*	-79,2	*-278%*	138,1	*-64%*	**-32,5**	***-109%***
	NH HOTEL GROUP (mil. €)											
Poslovni prihodi	352,7	468,9	-	**821,6**	279,4	*-21%*	*29,9*	*-94%*	-	-	**309,3**	***-62%***
Poslovni rashodi	247,7	272,2	-	**519,9**	226,3	*-9%*	*82,9*	*-70%*	-	-	**309,2**	***-41%***
Dobit ili gubitak razdoblja	-14,7	54,6	-	**39,9**	-57,2	*-289%*	*-161,3*	*-395%*	-	-	**-218,5**	***-648%***

Kod obje grupe može se primijetiti isti trend poslovanja kroz tromjesečja koji je sličan kao i kod prethodne grupe zračnog prijevoza. Naime, vrhunac poslovanja ostvaruje se u trećem tromjesečju kada je turistička sezona na svom vrhuncu. U prvom je, kao što se može vidjeti kod obje grupe u 2019. godini, poslovni rezultat uglavnom negativan i dolaskom toplijeg vremena u drugom tromjesečju prelazi u pozitivan. U 2020. godini su ostvareni lošiji rezultati u svim tromjesečjima. U prvom je došlo je do pada poslovnog rezultat kod obje grupe. U drugom tromjesečju koje inače karakterizira pozitivan poslovni rezultat, ostvaren je negativan kod obje grupe. Kod grupe Maistra u trećem tromjesečju ipak je ostvarena dobit uslijed vrhunca znatno slabije turističke sezone, međutim gledano kumulativno kroz sva tri tromjesečja ipak je ostvaren gubitak od 32,5 milijuna kuna. Grupa NH Hotel Group kroz prva dva tromjesečja zabilježila je znatne promjene u odnosu na poslovni rezultati u tom kumulativnom razdoblju 2019. godine. Nakon dobiti prethodne godine, tekuće je ostvaren gubitak od 218,5 milijuna eura.

2.2.2. Prerađivačka industrija

Druga skupina djelatnosti vezana je uz prerađivačku industriju koja će se obraditi nešto detaljnije odnosno prikazat će se rezultati većeg broja poduzeća. Područja koja će se proučiti, pa onda usporediti rezultati poduzeća predstavnika su vezana uz proizvodnju mliječnih proizvoda, proizvoda od gume i plastike, osnovnih farmaceutskih proizvoda i farmaceutskih pripravaka, koksa i rafiniranih naftnih proizvoda te računala i elektroničkih i optičkih proizvoda.

2.2.2.1. Proizvodnja mliječnih proizvoda

Mliječni proizvodi za većinu ljudi spadaju u osnovne proizvode koji se kupuju gotovo svakodnevno. Također nastavkom rada trgovina tijekom pandemije i razdoblja u kojem su na snazi bile mjere omogućen je donekle normalan nastavak prodaje tih proizvoda. Međutim poslovanje poduzeća vezano uz proizvodnju mliječnih proizvoda velik dio svojeg poslovanja veže i uz uslužne djelatnosti vezane uz pripremu hrane i pića. Kroz prethodne dvije skupine djelatnosti jasno je vidljivo da se dolazak turista značajno smanjio što je ostavilo loše posljedice na poduzeća koja pružaju smještaj odnosno uslugu pripreme hrane. Poslovanje ovih poduzeća često nije ni ograničeno samo na domaće tržište već dobar dio čini izvoz koji je također bio smanjen kao što je moguće vidjeti u poglavlju vezanom uz robnu razmjenu. Na kraju svega rečenog zanimljivo će biti vidjeti u kojoj mjeri je ova djelatnost pogođena

koronavirusom prilikom usporedbe hrvatskog poduzeća Dukat d.d. i grčkog Kri-Kri Milk Industry S.A. Usporedba uspješnosti poslovanja po tromjesečjima prikazana je u Tablici 5.

Tablica 5. Usporedba uspješnosti poslovanja poduzeća Dukat d.d. i Kri-Kri Milk Industry S.A. [26][27][28][29][30]

	2019.				**2020.**							
	Q1	Q2	Q3	**Q1-Q3**	Q1		Q2		Q3		**Q1-Q3**	
	DUKAT d.d. (mil. kn)											
Poslovni prihodi	410,6	477,2	537,4	**1425,1**	427,9	*4%*	404,2	*-15%*	469,4	*-13%*	**1301,2**	***-9%***
Poslovni rashodi	409,6	465,3	503,7	**1378,4**	426,3	*4%*	407,7	*-12%*	458,8	*-9%*	**1292,6**	***-6%***
Dobit ili gubitak razdoblja	1,4	10,0	28,2	**39,7**	2,8	*95%*	-2,8	*-128%*	9,0	*-68%*	**9,1**	***-77%***
	KRI-KRI MILK INDUSTRY S.A. (mil. €)											
Poslovni prihodi	22,1	35,7	-	**57,8**	27,7	*26%*	38,7	*75%*	-	-	**66,4**	***15%***
Poslovni rashodi	18,9	28,3	-	**47,2**	24,1	*28%*	30,3	*60%*	-	-	**54,4**	***15%***
Dobit ili gubitak razdoblja	2,3	5,3	-	**7,6**	2,7	*16%*	6,4	*180%*	-	-	**9,1**	***19%***

Kod poduzeća Dukat d.d. moguće je primijetiti rast poslovanja kroz sva tri tromjesečja u prethodnoj godini. Vrhunac je ponovno ostvaren u trećem kvartalu zbog povećanja prihoda ostvarenog u HoReCA kanalu odnosno s hotelima, restoranima i kafićima. U tekućoj godini u prvom tromjesečju COVID je stigao krajem razdoblja, pa je i njegov utjecaj na poslovanje bio znatno manji i iz tog razloga je ostvareno povećanje poslovnog rezultata. U dva tromjesečja koja su uslijedila utjecaj je ipak došao do izražaja, pa je ostvaren slabiji poslovni rezultat u odnosu na ista razdoblja prethodne godine. Drugo i treće tromjesečje prevagnuli su svojim rezultatima i na kumulativnoj razini, pa je u odnosu na 2019. dobit pala za 77 %. Kod grčkog predstavnika s druge strane kroz prva dva tromjesečja dolazi do boljeg poslovanja i ostvarenja veće dobiti nego u prethodnoj godini. Naime, kroz nekoliko zadnjih godina došlo je do popularizacije jednog od glavnih proizvoda ovog poduzeća. Samim time poduzeće u svojem izvješću kao razlog rastu poslovanja i ostvarivanju boljeg poslovnog rezultat u odnosu na prethodno kumulativno razdoblje za 19 % navodi upravo porast prodaje tog proizvoda na stranim tržištima[30].

2.2.2.2. Proizvodnja proizvoda od gume i plastike

Iduća djelatnosti iz skupine prerađivačke industrije bavi se proizvodnjom proizvoda od gume i plastike. Proizvodi iz ove skupine veoma su traženi u moderno doba i prisutni su doslovno svuda oko nas. U nastavku će se usporediti poslovni rezultat hrvatske grupe AD Plastik i poljske Sanok Rubber. Usporedba uspješnosti poslovanja po tromjesečjima prikazana je u Tablici 6.

Tablica 6. Usporedba uspješnosti poslovanja grupa AD Plastik i Sanok Rubber [31][32][33][34][35]

	2019.				**2020.**							
	Q1	Q2	Q3	**Q1-Q3**	Q1		Q2		Q3		**Q1-Q3**	
	AD PLASTIK (mil. kn)											
Poslovni prihodi	348,3	365,3	381,7	**1095,3**	362,6	*4%*	186,2	*-49%*	292,9	*-23%*	**841,7**	***-23%***
Poslovni rashodi	328,5	335,4	379,6	**1043,5**	324,8	*-1%*	196,7	*-41%*	283,2	*-25%*	**804,7**	***-23%***
Dobit ili gubitak razdoblja	27,9	29,1	6,9	**63,9**	28,2	*1%*	-10,9	*-137%*	6,5	*-6%*	**23,8**	***-63%***
	SANOK RUBBER (mil. zł)											
Poslovni prihodi	281,3	261,7	-	**542,9**	264,9	*-6%*	190,9	*-32%*	-	-	**455,8**	***-16%***
Poslovni rashodi	266,1	254,9	-	**521,0**	253,0	*-5%*	194,8	*-27%*	-	-	**447,8**	***-14%***
Dobit ili gubitak razdoblja	18,1	8,9	-	**26,9**	9,0	*-50%*	1,9	*-89%*	-	-	**10,9**	***-59%***

U 2019. godini je u svim navedenim tromjesečjima ostvarena dobit kod obje grupe. AD Plastik grupa je u prvom tromjesečju 2020. godini nastavila trend rasta i ostvarila bolji rezultat u odnosu na isto razdoblje prethodne godine. U drugom tromjesečju utjecaj COVID-a je najizraženiji i u odnosu na dobit od 29,1 milijuna kuna iz prethodne godine, u tekućoj je ostvaren gubitak od 10,9 milijuna kuna. U trećem tromjesečju poslovanje je ostvarilo pozitivan poslovni rezultat, međutim u odnosu na prethodnu godinu slabiji je za 6 %. Kumulativno razdoblje od sva tri tromjesečja također karakterizira pad poslovnog rezultata, koji je i u tekućoj godini pozitivan, za 63 %. Sanok Rubber grupa već je u prvom tromjesečju tekuće godine ostvarila pad poslovnih prihoda i poslovnog rezultata koji je ipak bio pozitivan. Takav je ostao i u drugom tromjesečju u kojem je ostvaren veći pad nego u prvom i sve je konačno rezultiralo smanjenjem prihoda i poslovnog rezultata i na kumulativnoj razini.

2.2.2.3. Proizvodnja osnovnih farmaceutskih proizvoda i farmaceutskih pripravaka

Možda industrija za koju će biti najzanimljivije vidjeti poslovne rezultate uslijed pandemija novog koronavirusa je farmaceutska. Na prvu bi se moglo pretpostaviti kako će rezultati biti, ako ne u rangu prošlogodišnjih, onda još i bolji. Potražnja za lijekovima kojima se liječi bolest koronavirusa je povećana, a potražnja za ostalima zasigurno se nije smanjila. Za usporedbu će se prikazati poslovni rezultati hrvatske grupe JGL i slovenske Krka. Usporedba uspješnosti poslovanja po tromjesečjima prikazana je u Tablici 7.

Tablica 7. Usporedba uspješnosti poslovanja grupa JGL i Krka [36][37][38]

	2019.				**2020.**							
	Q1-Q2				**Q1-Q2**							
	JGL (mil. kn)											
Poslovni prihodi	391,4				453,3				*16%*			
Poslovni rashodi	368,3				406,2				*10%*			
Dobit ili gubitak razdoblja	26,0				29,8				*15%*			
	KRKA (mil. €)											
	Q1	Q2	Q3	**Q1-Q3**	Q1		Q2		Q3		**Q1-Q3**	
Poslovni prihodi	382,1	385,3	-	**767,4**	466,1	*22%*	344,1	*-10%*	-	-	**810,2**	***6%***
Poslovni rashodi	309,9	303,0	-	**612,9**	332,2	*7%*	261,3	*-16%*	-	-	**593,5**	***-3%***
Dobit ili gubitak razdoblja	70,3	69,6	-	**139,9**	85,2	*21%*	75,1	*7%*	-	-	**160,3**	***15%***

Kao što je i pretpostavljeno kod obje grupe u 2020. godini je došlo do ostvarenja boljeg poslovnog rezultata u odnosu na prethodnu godinu. U prvoj polovici godine grupa JGL ostvarila je porast poslovnih prihoda i rashoda u odnosu na isto razdoblje prethodne godine koji je rezultirao porastom dobiti za 15 %. Kod grupe Krka u prvom tromjesečju zabilježen je rast poslovnih prihoda i rashoda, te dobiti, dok je u drugom ipak došlo do smanjenja poslovnih prihoda i rashoda. Veće smanjenje ostvareno je na području rashoda, pa je i dobit u drugom tromjesečju porasla u odnosu na isto razdoblje 2019. godine. Kumulativno je došlo do porasta poslovnih prihoda i dobiti, te smanjenja poslovnih rashoda.

2.2.2.4. Proizvodnja koksa i rafiniranih naftnih proizvoda

Naftna industrija vjerojatno je jedna od najpovezanijih na globalnoj razini. Poznato je da postoje zemlje koje su najveći izvoznici rafiniranih naftnih proizvoda i vode glavnu riječ na tom tržištu. Osim samog stanja na globalnom tržištu, velik utjecaj na naftnu industriju imale su i mjere ograničavanja kretanja tijekom kojih su ljudi većinom ostajali kod kuće i sve su manje koristili svoje automobile. Osim osobnih prijevoznih sredstava, ranije je dan uvid u značajno smanjenje i zračnog prijevoza. Kako bi se vidjele posljedice na ovu industriju usporedit će se rezultati poslovanja hrvatskog poduzeća INA d.d. i slovenskog Petrol d.d. Usporedba uspješnosti poslovanja po tromjesečjima prikazana je u Tablici 8.

Tablica 8. Usporedba uspješnosti poslovanja poduzeća INA d.d. i Petrol d.d. [39][40][41][42][43]

	2019.				**2020.**							
	Q1	Q2	Q3	**Q1-Q3**	Q1		Q2		Q3		**Q1-Q3**	
	INA d.d. (mil. kn)											
Poslovni prihodi	3991,0	5237,0	6423,0	**15651,0**	3754,0	*-6%*	2951,0	*-44%*	3920,0	*-39%*	**10625,0**	***-32%***
Poslovni rashodi	3890,0	5120,0	5860,0	**14870,0**	4671,0	*20%*	2955,0	*-42%*	4169,0	*-29%*	**11795,0**	***-21%***
Dobit ili gubitak razdoblja	43,0	159,0	428,0	**630,0**	-800,0	*-1960%*	-69,0	*-143%*	-146,0	*-134%*	**-1015,0**	***-261%***
	PETROL d.d. (mil. €)											
Poslovni prihodi	889,5	875,7	-	**1765,2**	746,7	*-16%*	485,9	*-45%*	-	-	**1232,6**	***-30%***
Poslovni rashodi	878,8	862,0	-	**1740,8**	731,9	*-17%*	492,0	*-43%*	-	-	**1223,9**	***-30%***
Dobit ili gubitak razdoblja	7,2	19,1	-	**26,3**	11,0	*53%*	6,0	*-68%*	-	-	**17,1**	***-35%***

Pandemija je na naftnu industriju ostavila značajan utjecaj i stanje na globalnom tržištu utjecalo je na poslovni rezultat poduzeća. U 2019. godini kod oba poduzeća poslovni rezultat raste iz tromjesečja u tromjesečje. U 2020. godini stanje je drugačije, a pogotovo je utjecaj značajan na hrvatsko poduzeće. INA d.d. je u 2020. godini u sva tri tromjesečja u odnosu na prethodnu godinu ostvarila značajan pad poslovnih prihoda i lošiji poslovni rezultat. U prvom tromjesečju ostvaren je gubitak od 800 milijuna kuna dok je u istom razdoblju 2019. godine ostvarena dobit od 43 milijuna kuna. I u ostala dva tromjesečja zabilježen je gubitak u poslovanju, ali ne u mjeri prvog. Kumulativno je stoga došlo do pada poslovnih prihoda i rashoda, i na kraju je ostvaren gubitak od 1,015 milijardi kuna. Iako je i kod Petrol d.d.-a u

2020. godini na kumulativnoj razini ostvaren lošiji poslovni rezultat, ipak je u svim tromjesečjima, pa onda i kumulativno, ostvarena dobit. U prvom tromjesečju je čak uslijed pada poslovnih prihoda i nešto većeg pada poslovnih rashoda ostvarena dobit veća od istog razdoblja prethodne godine za 53 %.

2.2.2.5. Proizvodnja računala te elektroničkih i optičkih proizvoda

Za predstavnike ove grupe djelatnosti izabrana su dvije grupe čije je poslovanje, između ostalog, vezano i uz koncept Industrije 4.0 odnosno digitalizacije raznih aspekata poslovanja. Radi se o hrvatskoj grupi Ericsson Nikola Tesla i švedskoj HMS Networks. Usporedba uspješnosti poslovanja po tromjesečjima prikazana je u Tablici 9.

Tablica 9. Usporedba uspješnosti poslovanja grupa Ericsson Nikola Tesla i HMS Networks [44][45][46][47][48][49]

	2019.				**2020.**							
	Q1	Q2	Q3	**Q1-Q3**	Q1		Q2		Q3		**Q1-Q3**	
	ERICSSON NIKOLA TESLA (mil. kn)											
Poslovni prihodi	394,2	438,8	436,5	**1269,5**	492,5	*25%*	483,5	*10%*	481,5	*10%*	**1457,4**	***15%***
Poslovni rashodi	353,5	395,8	430,9	**1180,2**	459,0	*30%*	474,2	*20%*	447,9	*4%*	**1381,2**	***17%***
Dobit ili gubitak razdoblja	32,9	38,1	9,7	**80,8**	29,6	*-10%*	5,4	*-86%*	32,2	*232%*	**67,2**	***-17%***
	HMS NETWORKS (mil. kr)											
Poslovni prihodi	380,0	416,0	377,0	**1173,0**	362,0	*-5%*	366,0	*-12%*	345,0	*-8%*	**1073,0**	***-9%***
Poslovni rashodi	320,0	345,0	320,0	**985,0**	296,0	*-8%*	297,0	*-14%*	268,0	*-16%*	**861,0**	***-13%***
Dobit ili gubitak razdoblja	41,0	51,0	46,0	**138,0**	48,0	*17%*	54,0	*6%*	61,0	*33%*	**163,0**	***18%***

U 2019. godini oba poduzeća posluju s dobiti u sva tri tromjesečja, pa posljedično i kumulativno za ta tri razdoblja. U 2020. godini taj se trend nastavlja međutim u usporedbi s prethodnom godinom grupa Ericsson Nikola Tesla ostvarila je pad dobiti na kumulativnoj razini za 17 %. Poslovni prihodi su porasli za 15 % međutim došlo je do većeg povećanja poslovnih rashoda. Kod grupe HMS Networks u 2020. godini na kumulativnoj razini došlo je do povećanja dobiti za 18 % nakon povećanja dobiti u svakom od tri tromjesečja pojedinačno. Poslovni prihodi i poslovni rashodi s druge strane su na kumulativnoj razini i u svakom tromjesečju zabilježili pad, s time da je pad poslovnih rashoda bio veći.

2.2.3. Opskrba električnom energijom, plinom, parom i klimatizacija

Dok se potrošnja električne energije smanjila u uredima i raznim industrijskim pogonima koji nisu mogli nastaviti s redovnim poslovanjem dolaskom pandemije, s druge se strane u kućanstvima zasigurno potrošnja povećala. Ljudi su sve više vremena provodili u svojim domovima vezano uz posao, a i slobodno vrijeme. Kako je to utjecalo na poduzeća čija je djelatnost vezana uz opskrbu električnom energijom, plinom, parom i klimatizacijom pokušat će se vidjeti kroz usporedbu grupe iz hrvatske, HEP, i španjolske, ENDESA. Usporedba uspješnosti poslovanja po tromjesečjima prikazana je u Tablici 10.

Tablica 10. Usporedba uspješnosti poslovanja grupa HEP i ENDESA [50][51][52]

	2019.				**2020.**							
	Q1-Q2				**Q1-Q2**							
	HEP (mil. kn)											
Poslovni prihodi	7845,2				7139,7				-9%			
Poslovni rashodi	6812,5				5950,1				-13%			
Dobit ili gubitak razdoblja	859,3				959,9				12%			
	ENDESA (mil. €)											
	Q1	Q2	Q3	**Q1-Q3**	Q1		Q2		Q3		**Q1-Q3**	
Poslovni prihodi	5123,0	4767,0	-	9890,0	5116,0	*0%*	3864,0	*-25%*	-	-	8980,0	*-9%*
Poslovni rashodi	4195,0	3801,0	-	7996,0	3640,0	*-13%*	3025,0	*-28%*	-	-	6665,0	*-17%*
Dobit ili gubitak razdoblja	366,0	416,0	-	782,0	846,0	*131%*	285,0	*-22%*	-	-	1131,0	*45%*

Kod obje grupe moguće je zapaziti iste karakteristike poslovanja u 2020. godini. Uslijed pandemije, na kumulativnoj razini je došlo pada poslovnih prihoda i poslovnih rashoda u odnosu na prethodnu godinu, te je pad poslovnih rashoda bio je veći nego pad prihoda. Također nakon ostvarivanja dobiti u svih navedenim razdobljima prethodne godine, u tekućoj godini je ta dobit na kumulativnoj razini povećana. Ipak, na podacima vezanim uz grupu ENDESA moguće je vidjeti kako je u drugom tromjesečju zabilježen pad dobiti. Može se pretpostaviti kako je upravo zatvaranje dijela industrije uslijed provođenja mjera imalo utjecaj na smanjenje prihoda pa samim time i dobiti budući da potrošnja industrije donosi veći dio prihoda od potrošnje kućanstava.

2.2.4. Informacije i komunikacije

Pojavom i širenjem novog koronavirusa velik broj poduzeća bio je prisiljen prekinuti svoje poslovanje ili normalan način poslovanja. Kao što je vidljivo iz ranije navedenih mjera Vlade Republike Hrvatske, dok su bile na snazi, a i nakon popuštanja/ukidanja za sva poduzeća koja mogu organizirati rad od kuće to je bilo preporučeno. U tom trenutku za osiguranje nastavka poslovanja ključne su bile informacijske i komunikacijske tehnologije. Potražnja za njima tijekom ove pandemije uvelike je porasla, pa će biti zanimljivo vidjeti kakve su poslovne rezultate ostvarila poduzeća Hrvatski Telekom d.d. i Telekom Slovenije d.d. Usporedba uspješnosti poslovanja po tromjesečjima prikazana je u Tablici 11.

Tablica 11. Usporedba uspješnosti poslovanja poduzeća Hrvatski Telekom d.d. i Telekom Slovenije d.d. [53][54][55][56][57]

	2019.				**2020.**							
	Q1	Q2	Q3	**Q1-Q3**	Q1		Q2		Q3		**Q1-Q3**	
	HRVATSKI TELEKOM d.d. (mil. kn)											
Poslovni prihodi	1470,8	1482,8	1588,3	**4541,9**	1374,8	*-7%*	1368,9	*-8%*	1513,0	*-5%*	**4256,7**	***-6%***
Poslovni rashodi	1213,7	1149,8	1292,4	**3655,9**	1182,8	*-3%*	1145,9	*0%*	1204,0	*-7%*	**3532,6**	***-3%***
Dobit ili gubitak razdoblja	200,0	252,9	231,2	**684,0**	156,1	*-22%*	167,1	*-34%*	237,3	*3%*	**560,5**	***-18%***
	TELEKOM SLOVENIJE d.d. (mil. €)											
Poslovni prihodi	157,5	151,7	-	**309,2**	157,6	*0%*	147,4	*-3%*	-	-	**305,0**	***-1%***
Poslovni rashodi	144,2	139,6	-	**283,8**	142,7	*-1%*	134,1	*-4%*	-	-	**276,8**	***-2%***
Dobit ili gubitak razdoblja	12,6	10,6	-	**23,2**	12,6	*-1%*	2,7	*-75%*	-	-	**15,2**	***-34%***

Oba poduzeća u 2019. godini poslovala su s dobiti i taj se trend nastavio u tekućoj godini. Uslijed pandemije je ta dobit ipak manja nego ona iz prethodne godine u skoro svim tromjesečjima i na kumulativnoj razini. Posebno se ističe drugo tromjesečje u kojem je ostvaren znatno slabiji poslovni rezultat kod oba poduzeća u odnosu na isto razdoblje prethodne godine. Na to su zasigurno utjecale i već prije spomenute mjere za suzbijanje širenja virusa. Hrvatski Telekom d.d. je nakon ukidanja mjera u trećem tromjesečju uslijed pada prihoda i nešto većeg pada rashoda u odnosu na 2019. godinu ostvario rast dobiti za 3 %.

Nakon svih usporedba moguće je primijetiti kako je većinom kod oba predstavnika u kumulativnom razdoblju sva tri tromjesečja ostvaren poslovni rezultat s istim predznakom. Iznimka je djelatnost Proizvodnja koksa i rafiniranih naftnih proizvoda gdje je hrvatski predstavnik poslovao s gubitkom i značajno slabijim poslovnim rezultatom u odnosu na isto razdoblje prethodne godine, a strani predstavnik s dobiti, ali manjom od prethodne godine. Kod djelatnosti Zračni prijevoz, Proizvodnja proizvoda od gume i plastike, Proizvodnja osnovnih farmaceutskih proizvoda i farmaceutskih pripravaka te Informacije i komunikacije kod oba predstavnika je ostvarena otprilike ista postotna promjena poslovnog rezultata, bilo pozitivna ili negativna, u odnosu na prethodnu godinu. Kod djelatnosti Smještaj, priprema i usluživanje hrane te Opskrba električnom energijom, plinom, parom i klimatizacija ostvarene su promjene istog predznaka kod oba predstavnika u odnosu na prethodnu godinu, ali je kod stranog ostvaren veći pad odnosno veći rast nego kod hrvatskog. Za preostale dvije djelatnosti Proizvodnja mliječnih proizvoda i Proizvodnja računala te elektroničkih i optičkih proizvoda ostvaren je poslovni rezultat istog predznaka, ali promjena nije istog predznaka u odnosu na prethodnu godinu. U obje djelatnosti je strani predstavnik ostvario bolji rezultat, dok je hrvatski predstavnik ostvario lošiji.

2.3. Mjere za pomoć gospodarstvu

Nakon uvida u ozbiljnost posljedica koje je pandemija koronavirusa ostavila na velik dio gospodarskih djelatnosti osim mjera za suzbijanje širenja zaraze, vlade zemalja morale su uvesti i određene mjere za pomoć gospodarstvu. U nastavku će se navesti neke mjere koje je uvela Vlada Republike Hrvatske. Jedan od ciljeva bio je osiguranje likvidnosti poslovanja na koje se reagiralo predlaganjem beskamatne odgode plaćanja i/ili obročnom otplatom poreznih obveza koje su nastupile uslijed posebnih okolnosti. Nadalje, HBOR je uveo moratorij na kreditne obveze klijenata po postojećim plasmanima i reprogram postojećih kredita uz uvođenje počeka na otplatu glavnice. Također u suradnji s poslovnim bankama ugovoreno je odobravanje novih kredita za financiranje „hladnog pogona tvrtki“. Predloženo je i uvođenje *stand still* aranžmana od strane poslovnih banaka kojima bi se obustavile mjere prisilne naplate prema dužnicima u određenom razdoblju. Uspostavljen je i novi financijski instrument „COVID-19 zajmovi“ za obrtna sredstva za male i srednje poduzetnike. Možda mjera koja je u najvećoj mjeri iskorištena je državna potpora za očuvanje radnih mjesta kojoj je cilj kao što sami naziv kaže očuvanje radnih mjesta uslijed nemogućnosti redovnog obavljanja posla[58].

3. KORELACIJSKA ANALIZA

U prethodnom poglavlju prikazano je stanje poslovanja gospodarskih subjekata raznih grana u tekućoj godini kako bi se sagledao utjecaj COVID-a na poslovanje. Jasno je utvrđeno kako su posljedice značajne, za neke industriju više, a za neku manje, pa će se u ovome poglavlju povući poveznica između raznih pokazatelja vezanih uz novi koronavirus i cijene dionica navedenih hrvatskih gospodarskih subjekata. Postoji jedan aspekt vezan uz koronavirusnu bolest kojeg je teško kvantificirati, a to je ozbiljnost odnosno utjecaj mjera sprečavanja širenja zaraze, pa će se razdoblje tekuće godine podijeliti na dva dijela. Svi navedeni podaci bit će prikazani na tjednoj bazi. Prvo razdoblje obuhvaćat će period do 22. tjedna, uključujući i taj, kada je došlo do pojave koronavirusa i uvođenja mjera koje su postepeno popuštane do navedenog tjedna. Drugo razdoblje dakle kreće od 23. tjedna, i završava s 44. tjednom. Mjera kojom će se opisati povezanost navedenih varijabli, odnosno utvrditi ako među pokazateljima/varijablama postoji funkcionalna ovisnost je korelacija. Korelacija će se opisati preko Pearsonovog koeficijenta koji ovisno o jačini veze može poprimiti vrijednost između -1,00 i +1,00. Korištenjem metode izračuna korelacije preko Pearsonovog koeficijenta, pretpostavlja se kako je veza između varijabli linearna[59]. Za provođenje korelacijske analize koristit će se statistički alat Minitab tj. njegova besplatna 30-dnevna probna verzija. Varijable za koje će se izvršiti analiza su sljedeće:

- → HR_nsluc_SUM – ukupan broj novih slučajeva zaraze u tjednu u Hrvatskoj
- → HR_nsluc_AVG – prosječan broj novih slučajeva zaraze u tjednu u Hrvatskoj
- → HR_nprem_SUM – ukupan broj preminulih od bolesti koronavirusa u tjednu u Hrvatskoj
- → HR_nprem_AVG – prosječan broj preminulih od bolesti koronavirusa u tjednu u Hrvatskoj
- → HR_nslucmil_SUM – ukupan broj novih slučajeva zaraze na milijun stanovnika u tjednu u Hrvatskoj
- → HR_nslucmil_AVG – prosječan broj novih slučajeva zaraze na milijun stanovnika u tjednu u Hrvatskoj
- → HR_npremmil_SUM – ukupan broj preminulih od bolesti koronavirusa na milijun stanovnika u tjednu u Hrvatskoj

- → HR_npremmil_AVG – prosječan broj preminulih od bolesti koronavirusa na milijun stanovnika u tjednu u Hrvatskoj
- → HR_hosppac_AVG – prosječan broj hospitaliziranih pacijenata u tjednu u Hrvatskoj
- → HR_hosppacmil_AVG – prosječan broj hospitaliziranih pacijenata na milijun stanovnika u tjednu u Hrvatskoj
- → HR_tjprimbol – broj novo hospitaliziranih pacijenata u tjednu u Hrvatskoj
- → HR_tjprimbolmil – broj novo hospitaliziranih pacijenata na milijun stanovnika u tjednu u Hrvatskoj
- → HR_ntest_SUM – ukupan broj novo napravljenih testova u tjednu u Hrvatskoj
- → HR_ntest_AVG – prosječan broj novo napravljenih testova u tjednu u Hrvatskoj
- → HR_ntesttis_SUM – ukupan broj novo napravljenih testova na tisuću stanovnika u tjednu u Hrvatskoj
- → HR_ntesttis_AVG – prosječan broj novo napravljenih testova na tisuću stanovnika u tjednu u Hrvatskoj
- → HR_testposluc_AVG – prosječan broj napravljenih testova po slučaju zaraze u tjednu u Hrvatskoj
- → HR_stoppoztest_AVG – prosječna stopa pozitivnih testova u tjednu u Republici Hrvatskoj
- → SVJ_nsluc_SUM – ukupan broj novih slučajeva zaraze u tjednu u svijetu
- → SVJ_nsluc_AVG – prosječan broj novih slučajeva zaraze u tjednu u svijetu
- → SVJ_nprem_SUM – ukupan broj preminulih od bolesti koronavirusa u tjednu u svijetu
- → SVJ_nprem_AVG – prosječan broj preminulih od bolesti koronavirusa u tjednu u svijetu
- → SVJ_nslucmil_SUM – ukupan broj novih slučajeva zaraze na milijun stanovnika u tjednu u svijetu
- → SVJ_nslucmil_AVG – prosječan broj novih slučajeva zaraze na milijun stanovnika u tjednu u svijetu
- → SVJ_npremmil_SUM – ukupan broj preminulih od bolesti koronavirusa na milijun stanovnika u tjednu u svijetu
- → SVJ_npremmil_AVG – prosječan broj preminulih od bolesti koronavirusa na milijun stanovnika u tjednu u svijetu
- → MAIS – prosječna cijena dionica poduzeća Maistra d.d. u tjednu

→ DUK – prosječna cijena dionica poduzeća Dukat d.d. u tjednu

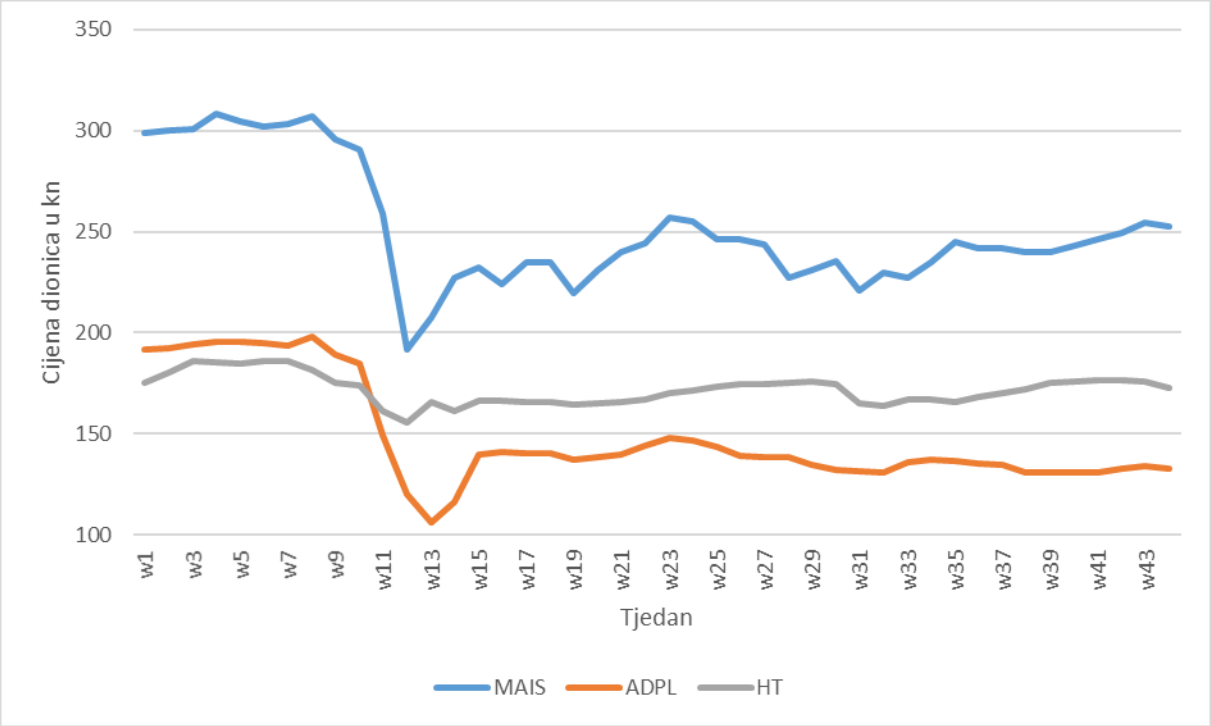
→ ADPL – prosječna cijena dionica poduzeća AD Plastik d.d. u tjednu

→ INA – prosječna cijena dionica poduzeća INA d.d. u tjednu

→ ERNT – prosječna cijena dionica poduzeća Ericsson Nikola Tesla d.d. u tjednu

→ HT – prosječna cijena dionica poduzeća Hrvatski Telekom d.d. u tjednu

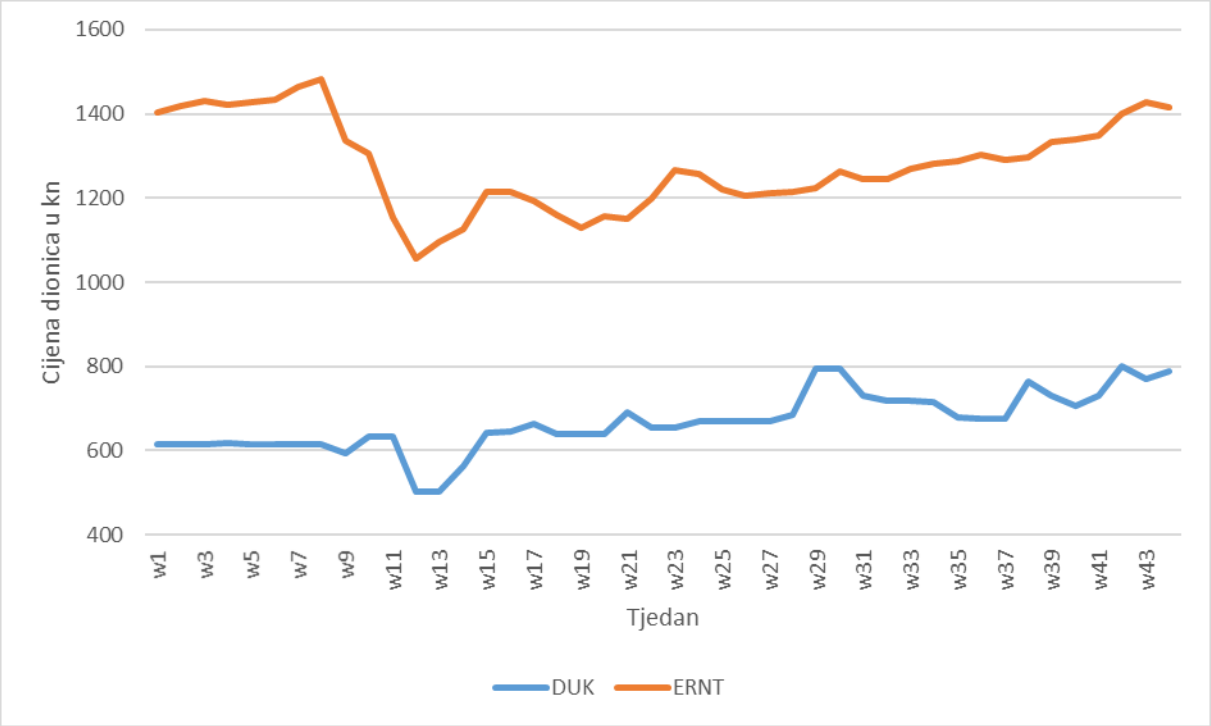
Prije samog provođenja korelacijske analize zanimljivo je promotriti kako izgledaju vremenske serije kretanja cijena dionica navedenih poduzeća. U jednom od prethodnih poglavlja prikazano je kretanje broja zaraženih i preminulih na tjednom bazi pa će se ovim putem moći u grubo povući poveznica između tih pokazatelja i cijena dionica. Zbog bolje preglednosti prvo će se na Slici 26. prikazati vremenske serije poduzeća Maistra d.d., AD Plastik d.d. i Hrvatski Telekom d.d.



Slika 26. Vremenske serije kretanja prosječnih tjednih cijena dionica poduzeća Maistra d.d., AD Plastik d.d. i Hrvatski telekom d.d. u 2020. godini [60]

Kod sva tri poduzeća moguće je primijetiti značajan pad cijena dionica u 11., 12. i 13. tjednu kada je nakon pojave koronavirusa u Hrvatskoj došlo do uvođenja mjera za sprječavanje širenja zaraze. U 15. tjednu došlo je do oporavka cijena, međutim one se nisu vratile u stanje prije pojave zaraze. Kod poduzeća Maistra d.d. cijena dionica je nastavila rasti do 23. tjedna i od tada varira oko tog iznosa od 250 kn. Dionica poduzeća AD Plastik d.d. također je oko 15.

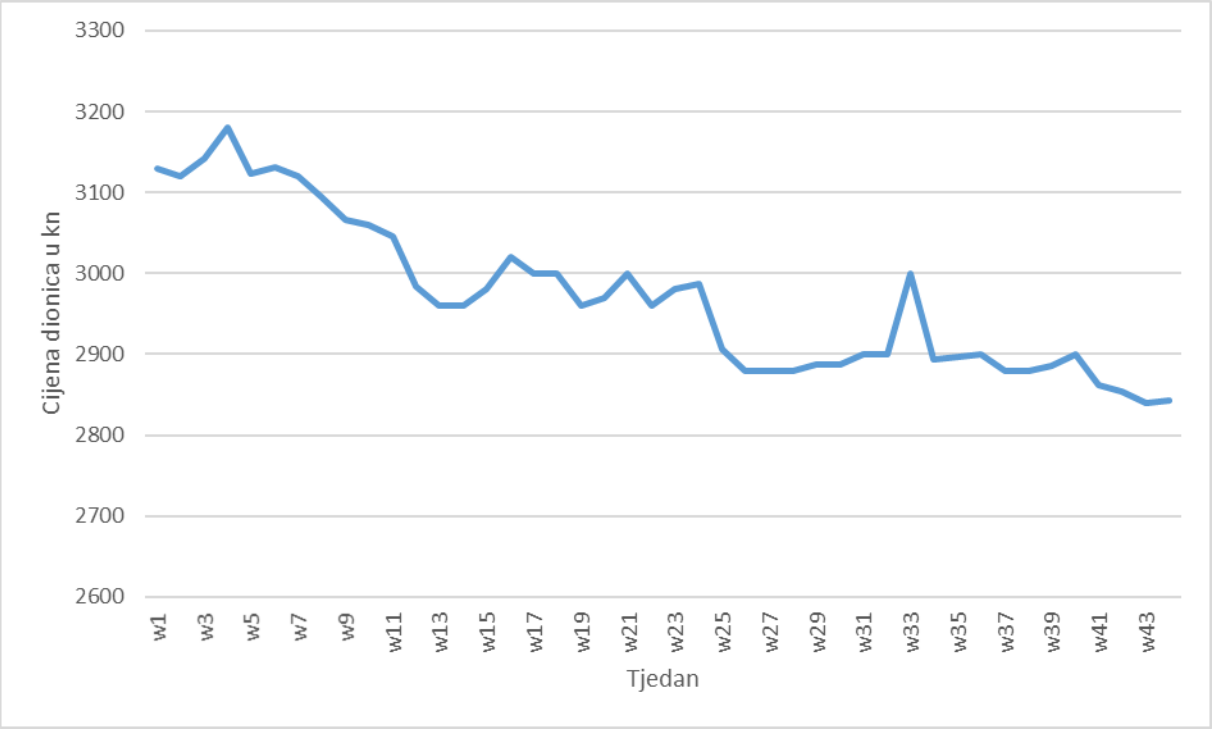
tjedna doživjela oporavak i nastavila rasti do 23. tjedna nakon kojeg je uslijedio blagi pad cijena. S druge strane dionica poduzeća Hrvatski Telekom d.d. doživjela je prvotno najmanji pad nakon kojega je uslijedio rast cijene kojim je skoro dostignut početni iznos od 180 kn. Moglo bi se reći kako je pad cijena dionica proporcionalan padu poslovnih rashoda, prihoda i neto financijskog rezultata. Maistra d.d. ima najveći postotni pad poslovnih rezultata u odnosu na prethodnu godinu, a isto tako i najveći pad cijene dionica. Isto pravilo slijede prvo AD Plastik d.d., pa onda i Hrvatski Telekom d.d. s najmanjim padom cijene dionice i poslovnog rezultata. Cijene dionica za iduća dva poduzeća, Dukat d.d. i Ericsson Nikola Tesla d.d. prikazane su na Slici 27.



Slika 27. Vremenske serije kretanja prosječnih tjednih cijena dionica poduzeća Dukat d.d. i Ericsson Nikola Tesla d.d. u 2020. godini [60]

Generalno je kod ova dva poduzeća prisutan trend isti kao i kod prethodnih, a on uključuje pad cijena dionica u odnosu na iznos s početka godine i nakon toga postepen rast. Razlika koja je prisutna kod poduzeća Ericsson Nikola Tesla d.d. je raniji pad cijene dionica, već u 8. tjednu, te druga možda bitnija, dostizanje cijene dionica s početka godine. Dukat d.d. ima jednu drugu razliku, a to je rast cijene dionica u odnosu na početak godine nakon pada kroz 11., 12 .i 13. tjedan. Ponovno se može povući određena poveznica s poslovnim rezultatima. Iako su oba poduzeća ostvarila slabiji neto financijski rezultat u odnosu na prethodnu godinu, Dukat d.d. je ostvario manje padove poslovnih prihoda i rashoda, a sami financijski rezultat je

i dalje pozitivan. Kod poduzeća Ericsson Nikola Tesla d.d. došlo je do porasta poslovnih prihoda i rashoda što je zasigurno znak dobrog poslovanja u tekućoj godini. Posljednje poduzeće za koje će se prikazati kretanje cijene dionica je INA d.d.



Slika 28. Vremenska serija kretanja prosječne tjedne cijene dionice poduzeća INA d.d. u 2020. godini [60]

Za razliku od prethodnih poduzeća jedina karakteristika kretanja koja je jednaka ostalima je početni pad cijene dionica. Međutim on se dogodio ranije i od pada kod poduzeća Ericsson Nikola Tesla d.d., tj. već početkom godine u 5. tjednu. Samim time moglo bi se zaključiti kako je globalno stanje uslijed pojave virusa imalo veći utjecaj na poduzeće početkom godine. Nakon početnog pada, taj isti trend nastavljen je kroz godinu, jedino je u drugoj polovici prikazanog razdoblja malo usporen. Financijski rezultat ovog poduzeća lošiji je od rezultata ostalih poduzeća, pa je ponovno moguće primijetiti vezu između ta dva pokazatelja.

Osim same usporedbe cijena dionica i financijskog rezultata, moguće je vidjeti i utjecaj pandemije na cijene. Veći utjecaj pandemija je imala u prvoj polovici prikazanog razdoblja kada su mjere, kao posljedica pojave virusa, imale značajan utjecaj na nagli pad cijena. Nakon toga utjecaj pandemije je i dalje prisutan u vidu sporijeg rasta cijena, zadržavanja cijena na određenom iznosu ili nastavka pada.

3.1. Razdoblje uz mjere za suzbijanje širenja zaraze

Kao što je već navedeno, ovaj period obuhvatit će prva 22 tjedna tekuće godine za koje će se proučiti veza između pokazatelja vezanih uz koronavirus na razini Hrvatske i svijeta, te kretanja cijena dionica hrvatskih poduzeća. Zbog nedostupnosti podataka za sve prethodno navedene varijable (nepotpunost podataka vezanih uz hospitalizaciju i testiranje pacijenata) kod izračuna Pearsonovog korelacijskog koeficijenta (r) u ovom razdoblju razmatrat će se samo dio varijabli za koje su dostupni cjelokupni podaci po tjednima i prikazani su u Tablici 12.

Tablica 12. Podaci cijene dionica i razmjera pandemije za korelacijsku analizu prvog razdoblja [60][61][62]

tjedan	w1	w2	w3	w4	w5	w6	w7	w8	w9	w10	w11
MAIS	299,000	299,928	300,792	308,325	304,583	302,215	303,540	307,150	295,845	290,466	259,179
DUK	615,000	615,000	615,000	617,500	615,000	615,000	615,000	615,000	593,642	634,300	634,300
ADPL	191,781	192,209	194,403	195,866	195,613	195,155	193,421	198,323	188,979	184,880	148,949
INA	3129,630	3120,000	3141,667	3180,000	3124,000	3131,667	3120,000	3095,192	3066,630	3060,000	3046,405
ERNT	1402,016	1419,297	1432,168	1422,313	1427,038	1434,920	1463,188	1482,000	1335,286	1307,548	1153,275
HT	175,207	180,537	185,939	185,444	184,840	186,346	185,875	181,373	175,318	173,682	161,340
HR_nsluc_SUM	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	5,000	7,000	25,000
HR_nsluc_AVG	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,714	1,000	3,571
HR_nprem_SUM	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
HR_nprem_AVG	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
HR_nslucmil_SUM	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	1,219	1,707	6,091
HR_nslucmil_AVG	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,174	0,244	0,870
HR_npremmil_SUM	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
HR_npremmil_AVG	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
SVJ_nsluc_SUM	59,000	0,000	161,000	1804,000	12532,000	22998,000	31715,000	9549,000	8273,000	19756,000	54166,000
SVJ_nsluc_AVG	9,833	0,000	23,000	257,714	1790,286	3285,429	4530,714	1364,143	1181,857	2822,286	7738,000
SVJ_nprem_SUM	0,000	1,000	2,000	53,000	249,000	508,000	856,000	794,000	516,000	606,000	2208,000
SVJ_nprem_AVG	0,000	0,143	0,286	7,571	35,571	72,571	122,286	113,429	73,714	86,571	315,429
SVJ_nslucmil_SUM	0,007	0,000	0,020	0,231	1,608	2,951	4,069	1,225	1,061	2,534	6,948
SVJ_nslucmil_AVG	0,001	0,000	0,003	0,033	0,230	0,422	0,581	0,175	0,152	0,362	0,993
SVJ_npremmil_SUM	0,000	0,000	0,000	0,006	0,032	0,063	0,109	0,102	0,065	0,077	0,283
SVJ_npremmil_AVG	0,000	0,000	0,000	0,001	0,005	0,009	0,016	0,015	0,009	0,011	0,040

tjedan	w12	w13	w14	w15	w16	w17	w18	w19	w20	w21	w22
MAIS	191,791	207,804	227,341	232,120	223,860	235,145	235,145	219,500	230,814	240,000	244,569
DUK	503,607	503,607	564,497	642,572	645,750	665,069	640,000	640,000	640,000	690,000	655,000
ADPL	120,053	105,857	116,524	139,813	141,002	140,275	140,487	137,170	138,205	139,563	144,179
INA	2983,333	2960,000	2960,000	2980,000	3020,706	3000,000	3000,000	2960,417	2970,000	3000,000	2960,000
ERNT	1056,464	1096,686	1127,553	1216,056	1215,901	1193,035	1161,388	1128,696	1157,032	1152,217	1198,440
HT	155,424	165,538	161,613	166,531	166,653	165,677	165,975	164,439	165,368	165,881	166,818
HR_nsluc_SUM	169,000	451,000	469,000	408,000	298,000	184,000	72,000	88,000	48,000	19,000	3,000
HR_nsluc_AVG	24,143	64,429	67,000	58,286	42,571	26,286	10,286	12,571	6,857	2,714	0,429
HR_nprem_SUM	0,000	5,000	7,000	9,000	18,000	15,000	23,000	10,000	8,000	4,000	4,000
HR_nprem_AVG	0,000	0,714	1,000	1,286	2,571	2,143	3,286	1,429	1,143	0,571	0,571
HR_nslucmil_SUM	41,167	109,859	114,243	99,385	72,590	44,821	17,538	21,436	11,692	4,628	0,732
HR_nslucmil_AVG	5,881	15,694	16,320	14,198	10,370	6,403	2,505	3,062	1,670	0,661	0,105
HR_npremmil_SUM	0,000	1,219	1,706	2,194	4,386	3,655	5,602	2,437	1,950	0,975	0,976
HR_npremmil_AVG	0,000	0,174	0,244	0,313	0,627	0,522	0,800	0,348	0,279	0,139	0,139
SVJ_nsluc_SUM	161516,00	364359,00	519478,00	554398,00	535970,00	550868,00	555780,00	593423,00	608903,00	682895,00	751940,00
SVJ_nsluc_AVG	23073,714	52051,286	74211,143	79199,714	76567,143	78695,429	79397,143	84774,714	86986,143	97556,429	107420,00
SVJ_nprem_SUM	7309,000	18401,000	35026,000	44766,000	52198,000	42470,000	37975,000	34933,000	32330,000	30050,000	26795,000
SVJ_nprem_AVG	1044,143	2628,714	5003,714	6395,143	7456,857	6067,143	5425,000	4990,429	4618,571	4292,857	3827,857
SVJ_nslucmil_SUM	20,722	46,746	66,643	71,125	68,760	70,671	71,301	76,129	78,117	87,609	96,466
SVJ_nslucmil_AVG	2,960	6,678	9,520	10,161	9,823	10,096	10,186	10,876	11,160	12,516	13,781
SVJ_npremmil_SUM	0,938	2,361	4,494	5,743	6,696	5,448	4,871	4,481	4,149	3,854	3,439
SVJ_npremmil_AVG	0,134	0,337	0,642	0,820	0,957	0,778	0,696	0,640	0,593	0,551	0,491

Provođenjem korelacijske analize pomoću Minitab-a dobivena je matrica korelacija prikazana u Tablici 13.

Tablica 13. Matrica korelacija cijene dionica i pokazatelja razmjera pandemije za prvo razdoblje

	MAIS	DUK	ADPL	INA	ERNT	HT
HR_nsluc_SUM	-0,676	-0,407	-0,728	-0,608	-0,574	-0,545
HR_nsluc_AVG	-0,676	-0,407	-0,728	-0,608	-0,574	-0,545
HR_nprem_SUM	-0,599	0,305	-0,563	-0,564	-0,518	-0,489
HR_nprem_AVG	-0,599	0,305	-0,563	-0,564	-0,518	-0,489
HR_nslucmil_SUM	-0,676	-0,407	-0,728	-0,608	-0,574	-0,545
HR_nslucmil_AVG	-0,676	-0,407	-0,728	-0,608	-0,574	-0,545
HR_npremmil_SUM	-0,599	0,305	-0,563	-0,564	-0,518	-0,489
HR_npremmil_AVG	-0,599	0,305	-0,563	-0,564	-0,518	-0,489
SVJ_nsluc_SUM	-0,775	0,329	-0,778	-0,846	-0,734	-0,681
SVJ_nsluc_AVG	-0,775	0,329	-0,778	-0,846	-0,734	-0,681
SVJ_nprem_SUM	-0,758	0,319	-0,738	-0,765	-0,669	-0,645
SVJ_nprem_AVG	-0,758	0,319	-0,738	-0,765	-0,669	-0,645
SVJ_nslucmil_SUM	-0,775	0,329	-0,778	-0,846	-0,735	-0,681
SVJ_nslucmil_AVG	-0,775	0,329	-0,778	-0,846	-0,735	-0,681
SVJ_npremmil_SUM	-0,758	0,319	-0,738	-0,765	-0,669	-0,646
SVJ_npremmil_AVG	-0,758	0,319	-0,738	-0,765	-0,669	-0,646

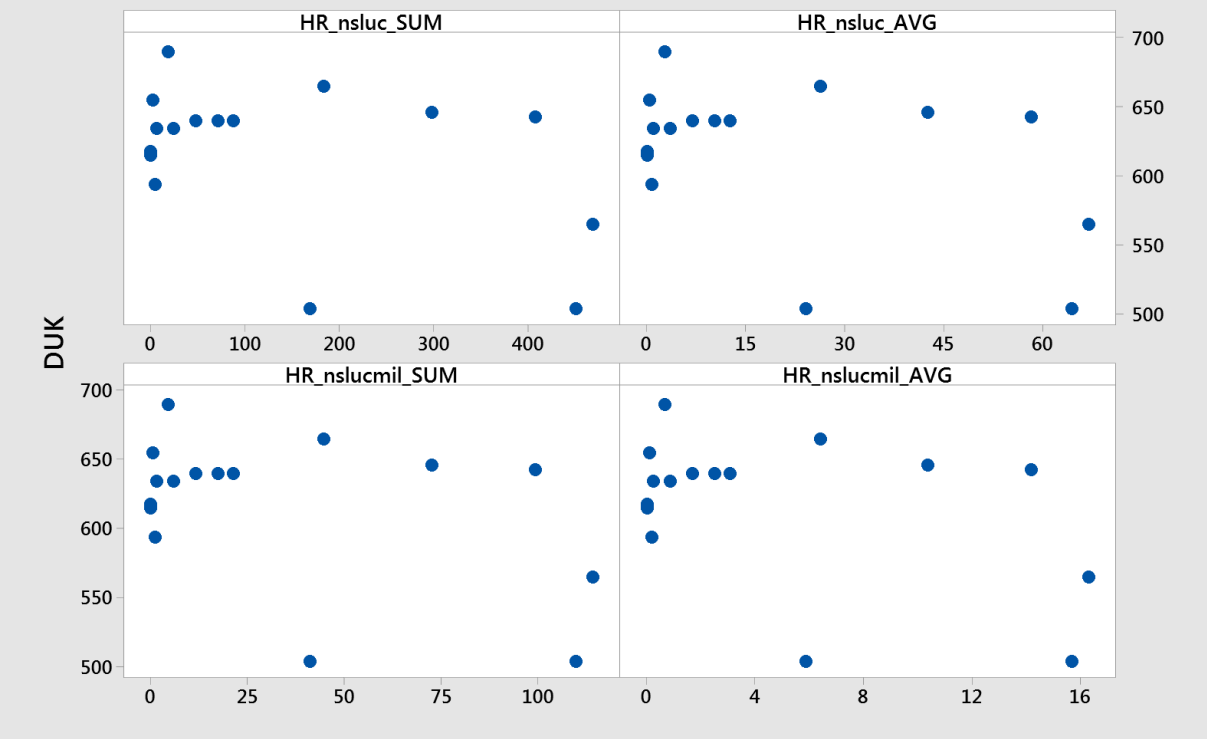
Za opis jakosti veze između varijabli koristit će se kriterij prikazan u Tablici 14.

Tablica 14. Jakost korelacije

Apsolutna vrijednost koeficijenta korelacije	Jakost veze
$\|r\| = 1$	Potpuna korelacija
$0{,}8 \leq \|r\| < 1$	Jaka korelacija
$0{,}5 \leq \|r\| < 0{,}8$	Srednje jaka korelacija
$0{,}2 \leq \|r\| < 0{,}5$	Relativno slaba korelacija
$0 < \|r\| < 0{,}2$	Neznatna korelacija
$\|r\| = 0$	Odsutnost korelacije

Na prvu je moguće primijetiti kako je cijena dionica svih poduzeća osim Dukat d.d. uglavnom negativno korelirana s drugim varijablama što bi značilo da pozitivna odnosno negativna promjena jedne varijable za posljedicu ima negativnu odnosno pozitivnu promjenu druge varijable. Također jakost veze među varijablama je uglavnom srednje jaka i statistički značajna na razini pogreške prve vrste od 5 %.

Veza cijene dionica DUK s ostalim varijablama može se okarakterizirati kao relativno slaba. Najjača veza prisutna je između cijene dionica i broja novih slučajeva i novih slučajeva na milijun stanovnika u Hrvatskoj te iznosi -0,407. Na Slici 29. prikazani su dijagrami rasipanja s navedenim varijablama.

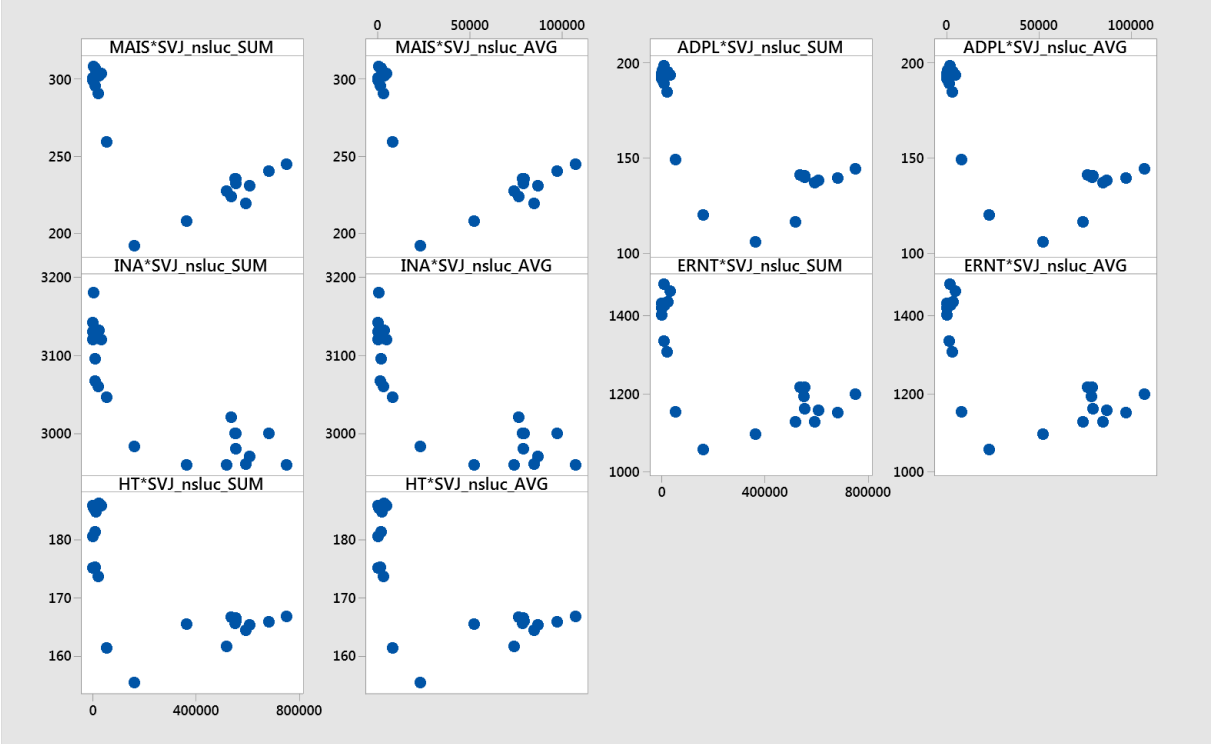


Slika 29. Dijagrami rasipanja - cijena dionica DUK, broj novih slučajeva i novih slučajeva na milijun stanovnika u Hrvatskoj

Na dijagramima se može uočiti da ne postoji neka jasna povezanost između varijabli. Na početku kod manje vrijednosti indeksa strogosti postoje veće varijacije kod cijene dionica, a također porastom indeksa strogosti ne postoji jasan trend pada cijene dionica.

U odnosu na cijenu dionica DUK koja najveću povezanost u prvom razdoblju ima s pokazateljima vezanim uz Hrvatsku, kod svih ostalih je ta povezanost najveća s pokazateljima vezanim uz svijet. Kao i kod cijene dionica DUK, najjača veza postoji s varijablama novih

slučajeva i novih slučajeva na milijun stanovnika, ali vezanim uz svijet. Na Slici 30. prikazani su dijagrami rasipanja vezani uz cijene dionica navedenih poduzeća i broja novih slučajeva zaraze u svijetu.



Slika 30. Dijagrami rasipanja - cijene dionica MAIS, ADPL, INA, ERNT i HT i broj novih slučajeva zaraze u svijetu

Veza je ponovno negativna, što je bilo za očekivati poznavajući kretanje vremenskih serija varijabli odnosno znajući da je došlo do pada cijena dionica u prvom razdoblju uz paralelan rast broja zaraženih. Također, vidi se i izraženiji trend kretanja kod dijagrama s cijenama dionica INA, MAIS i ADPL. Odstupanja od trenda su posebno primjetna kod cijena dionica ERNT i HT koja posljedično imaju i manji koeficijent korelacija s brojem novih slučajeva u odnosu na ostale navedene dionice.

3.2. Razdoblje nakon popuštanja/ukidanja mjera

Nakon analize korelacija za prvih 22 tjedna obilježena prisutnosti strogih mjera slijedi razdoblje od iduća 22 tjedna u kojem su mjere počele popuštati ili su čak ukinute. Ovoga puta dostupni su svi podaci, pa će se u obzir uzeti i varijable vezane uz hospitalizaciju i testiranje. Podaci prema kojima će se izvršiti korelacijska analiza prikazani u Tablici 15.

Tablica 15. Podaci cijene dionica i razmjera pandemije za korelacijsku analizu drugog razdoblja [60][61][62]

tjedan	w23	w24	w25	w26	w27	w28	w29	w30	w31	w32	w33
MAIS	256,786	255,260	246,118	246,118	243,714	227,000	231,037	235,333	221,217	230,000	227,522
DUK	655,000	670,000	670,000	670,000	670,000	685,701	794,342	794,342	730,289	719,371	719,371
ADPL	148,253	146,725	143,585	139,168	138,437	138,718	134,810	132,259	131,324	131,033	135,724
INA	2980,000	2986,667	2906,786	2880,000	2880,000	2880,000	2886,626	2886,667	2900,000	2900,000	3000,000
ERNT	1266,506	1258,517	1219,451	1204,611	1212,687	1213,948	1224,165	1262,393	1243,956	1246,355	1270,074
HT	170,162	171,384	173,524	174,526	174,544	175,006	175,822	174,511	165,118	164,027	167,036
HR_nsluc_SUM	1,000	4,000	48,000	325,000	470,000	578,000	563,000	557,000	432,000	319,000	877,000
HR_nsluc_AVG	0,143	0,571	6,857	46,429	67,143	82,571	80,429	79,571	61,714	45,571	125,286
HR_nprem_SUM	1,000	3,000	0,000	0,000	6,000	5,000	2,000	13,000	12,000	12,000	8,000
HR_nprem_AVG	0,143	0,429	0,000	0,000	0,857	0,714	0,286	1,857	1,714	1,714	1,143
HR_nslucmil_SUM	0,244	0,974	11,692	79,167	114,488	140,796	137,141	135,679	105,230	77,705	213,629
HR_nslucmil_AVG	0,035	0,139	1,670	11,310	16,355	20,114	19,592	19,383	15,033	11,101	30,518
HR_npremmil_SUM	0,244	0,731	0,000	0,000	1,462	1,219	0,488	3,167	2,925	2,923	1,949
HR_npremmil_AVG	0,035	0,104	0,000	0,000	0,209	0,174	0,070	0,452	0,418	0,418	0,278
HR_hosppac_AVG	14,714	7,000	7,143	35,714	81,429	104,286	136,857	139,286	130,857	118,714	117,286
HR_hosppacmil_AVG	3,584	1,705	1,740	8,700	19,835	25,403	33,337	33,929	31,875	28,918	28,570
HR_tjprimbol	0,000	3,021	6,043	57,406	67,477	95,676	100,712	82,584	76,541	64,456	70,498
HR_tjprimbolmil	0,000	0,736	1,472	13,983	16,437	23,306	24,532	20,117	18,645	15,701	17,173
HR_ntest_SUM	2335,000	1370,000	2368,000	3008,000	7957,000	8161,000	9533,000	8899,000	9317,000	6812,000	9525,000
HR_ntest_AVG	333,571	195,714	338,286	601,600	1136,714	1165,857	1361,857	1271,286	1331,000	973,143	1360,714
HR_ntesttis_SUM	0,570	0,335	0,576	0,733	1,938	1,987	2,322	2,169	2,270	1,659	2,321
HR_ntesttis_AVG	0,081	0,048	0,082	0,147	0,277	0,284	0,332	0,310	0,324	0,237	0,332

HR_testposluc_AVG	1724,500	1122,667	147,114	25,051	15,942	16,125	15,798	15,297	19,703	21,911	16,097
HR_stoppoztest_AVG	0,000	0,003	0,020	0,065	0,059	0,071	0,059	0,063	0,046	0,047	0,092
SVJ_nsluc_SUM	83420,000	899538,00	1041787,0	1152593,0	1319377,0	1450534,0	1578086,0	1760808,0	1818881,0	1790362,0	1831351,0
SVJ_nsluc_AVG	119245,71	128505,43	148826,71	164656,14	188482,43	207219,14	225440,86	251544,00	259840,14	255766,00	261621,57
SVJ_nprem_SUM	29675,000	30190,000	33775,000	33655,000	31664,000	33945,000	36762,000	42795,000	39683,000	41283,000	44484,000
SVJ_nprem_AVG	4239,286	4312,857	4825,000	4807,857	4523,429	4849,286	5251,714	6113,571	5669,000	5897,571	6354,857
SVJ_nslucmil_SUM	107,088	115,404	133,652	147,866	169,263	186,090	202,454	225,894	233,345	229,686	234,945
SVJ_nslucmil_AVG	15,298	16,486	19,093	21,124	24,180	26,584	28,922	32,271	33,335	32,812	33,564
SVJ_npremmil_SUM	3,807	3,872	4,333	4,318	4,062	4,355	4,718	5,491	5,090	5,297	5,707
SVJ_npremmil_AVG	0,544	0,553	0,619	0,617	0,580	0,622	0,674	0,784	0,727	0,757	0,815
tjedan	**w34**	**w35**	**w36**	**w37**	**w38**	**w39**	**w40**	**w41**	**w42**	**w43**	**w44**
MAIS	235,179	244,865	242,000	241,751	240,000	240,000	243,000	245,972	249,562	254,720	252,695
DUK	715,000	680,000	675,000	675,000	765,000	730,483	705,000	732,151	800,025	770,000	788,864
ADPL	137,253	136,361	135,545	134,575	130,917	131,079	130,763	130,885	132,567	133,946	132,494
INA	2893,333	2897,000	2900,000	2880,000	2880,000	2885,000	2900,000	2861,250	2853,333	2840,000	2843,333
ERNT	1280,300	1286,370	1301,713	1290,839	1297,524	1333,216	1338,038	1349,047	1399,964	1428,525	1415,026
HT	166,930	165,537	168,301	170,052	172,047	175,273	175,842	176,774	176,403	175,686	172,947
HR_nsluc_SUM	1480,000	1961,000	1878,000	1629,000	1357,000	1282,000	1394,000	2531,000	4829,000	9198,000	15357,000
HR_nsluc_AVG	211,429	280,143	268,286	232,714	193,857	183,143	199,143	361,571	689,857	1314,000	2193,857
HR_nprem_SUM	5,000	13,000	14,000	21,000	26,000	25,000	24,000	24,000	38,000	74,000	117,000
HR_nprem_AVG	0,714	1,857	2,000	3,000	3,714	3,571	3,429	3,429	5,429	10,571	16,714
HR_nslucmil_SUM	360,511	477,678	457,460	396,808	330,550	312,281	339,564	616,523	1176,293	2240,537	3740,803
HR_nslucmil_AVG	51,502	68,240	65,351	56,687	47,221	44,612	48,509	88,075	168,042	320,077	534,400
HR_npremmil_SUM	1,219	3,167	3,411	5,116	6,335	6,089	5,846	5,846	9,257	18,025	28,502
HR_npremmil_AVG	0,174	0,452	0,487	0,731	0,905	0,870	0,835	0,835	1,322	2,575	4,072

HR_hosppac_AVG	132,571	192,857	271,429	311,143	293,000	277,571	288,714	359,429	470,143	671,429	978,714
HR_hosppacmil_AVG	32,293	46,978	66,117	75,791	71,372	67,614	70,328	87,553	114,522	163,553	238,404
HR_tjprimbol	98,698	190,346	235,666	220,559	172,217	206,460	233,652	341,414	526,724	826,845	1084,000
HR_tjprimbolmil	24,042	46,366	57,406	53,726	41,950	50,291	56,915	83,165	128,304	201,411	264,051
HR_ntest_SUM	12803,000	16178,000	24722,000	30474,000	37030,000	34105,000	24230,000	32356,000	38485,000	48568,000	56480,000
HR_ntest_AVG	1829,000	2311,143	3531,714	4353,429	5290,000	4872,143	4846,000	4622,286	5497,857	6938,286	8068,571
HR_ntesttis_SUM	3,118	3,941	6,022	7,424	9,021	8,307	5,903	7,882	9,374	11,830	13,758
HR_ntesttis_AVG	0,445	0,563	0,860	1,061	1,289	1,187	1,181	1,126	1,339	1,690	1,965
HR_testposluc_AVG	9,170	8,639	10,448	15,060	25,159	26,868	25,766	17,211	10,427	6,534	4,187
HR_stoppoztest_AVG	0,116	0,121	0,076	0,053	0,037	0,038	0,042	0,078	0,125	0,189	0,272
SVJ_nsluc_SUM	1760707,0	1798890,0	1891129,0	1884449,0	2032362,0	2079215,0	2072193,0	2293522,0	2478503,0	2979014,0	3395382,0
SVJ_nsluc_AVG	251529,57	256984,29	270161,29	269207,00	290337,43	297030,71	296027,57	327646,00	354071,86	425573,43	485054,57
SVJ_nprem_SUM	39603,000	37594,000	37157,000	40614,000	36854,000	37351,000	39105,000	39617,000	37081,000	40290,000	45310,000
SVJ_nprem_AVG	5657,571	5370,571	5308,143	5802,000	5264,857	5335,857	5586,429	5659,571	5297,286	5755,714	6472,857
SVJ_nslucmil_SUM	225,882	230,779	242,615	241,758	260,733	266,744	265,843	294,238	317,968	382,180	435,596
SVJ_nslucmil_AVG	32,269	32,968	34,659	34,537	37,248	38,106	37,978	42,034	45,424	54,597	62,228
SVJ_npremmil_SUM	5,080	4,822	4,767	5,211	4,728	4,791	5,016	5,083	4,757	5,169	5,814
SVJ_npremmil_AVG	0,726	0,689	0,681	0,744	0,675	0,684	0,717	0,726	0,680	0,738	0,831

Provođenjem korelacijske analize pomoću Minitab-a dobivena je matrica korelacija prikazana u Tablici 16.

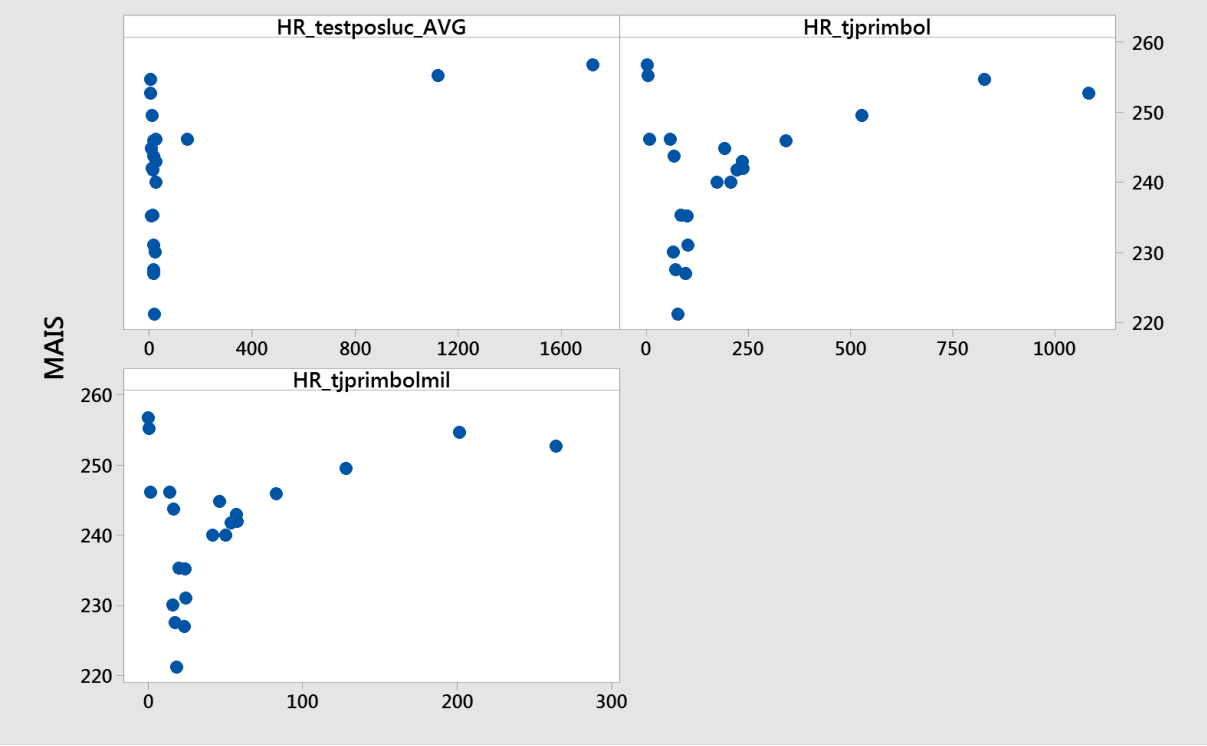
Tablica 16. Matrica korelacija cijene dionica i pokazatelja razmjera pandemije za drugo razdoblje

	MAIS	DUK	ADPL	INA	ERNT	HT
HR_nsluc_SUM	0,418	0,505	-0,298	-0,515	0,787	0,208
HR_nsluc_AVG	0,418	0,505	-0,298	-0,515	0,787	0,208
HR_nprem_SUM	0,385	0,550	-0,415	-0,536	0,830	0,230
HR_nprem_AVG	0,385	0,550	-0,415	-0,536	0,830	0,230
HR_nslucmil_SUM	0,418	0,505	-0,298	-0,515	0,787	0,208
HR_nslucmil_AVG	0,418	0,505	-0,298	-0,515	0,787	0,208
HR_npremmil_SUM	0,385	0,550	-0,415	-0,536	0,830	0,230
HR_npremmil_AVG	0,385	0,550	-0,415	-0,536	0,830	0,230
HR_hosppac_AVG	0,352	0,584	-0,511	-0,614	0,883	0,267
HR_hosppacmil_AVG	0,352	0,584	-0,511	-0,614	0,883	0,267
HR_tjprimbol	0,426	0,548	-0,401	-0,600	0,869	0,298
HR_tjprimbolmil	0,426	0,548	-0,401	-0,600	0,869	0,298
HR_ntest_SUM	0,342	0,553	-0,587	-0,630	0,905	0,313
HR_ntest_AVG	0,344	0,534	-0,605	-0,621	0,910	0,339
HR_ntesttis_SUM	0,342	0,553	-0,587	-0,630	0,905	0,313
HR_ntesttis_AVG	0,344	0,534	-0,605	-0,621	0,910	0,339
HR_testposluc_AVG	0,482	-0,400	0,762	0,659	-0,142	-0,089
HR_stoppoztest_AVG	0,205	0,500	-0,354	-0,537	0,664	0,075
SVJ_nsluc_SUM	0,106	0,686	-0,729	-0,635	0,866	0,171
SVJ_nsluc_AVG	0,106	0,686	-0,729	-0,635	0,866	0,171
SVJ_nprem_SUM	-0,350	0,586	-0,743	-0,296	0,467	-0,208
SVJ_nprem_AVG	-0,350	0,586	-0,743	-0,296	0,467	-0,208
SVJ_nslucmil_SUM	0,106	0,686	-0,729	-0,635	0,866	0,171
SVJ_nslucmil_AVG	0,106	0,686	-0,729	-0,635	0,866	0,171
SVJ_npremmil_SUM	-0,350	0,586	-0,743	-0,297	0,466	-0,207
SVJ_npremmil_AVG	-0,350	0,586	-0,743	-0,297	0,466	-0,207

Za razliku od prvog razdoblja u kojemu je koeficijent korelacije između cijene dionica i pokazatelja vezanih uz svijet uglavnom nosio veću vrijednost od onog vezanih uz Hrvatsku, raspodjela je u ovome razdoblju otprilike podijeljena. Također su i najveći iznosi

koeficijenata vezanih uz Hrvatsku i svijet puno bliži nego što su bili u prvom razdoblju. Nadalje, u drugom razdoblju postoji veća varijacija između pozitivnih i negativnih korelacija, dok je u prvom razdoblju prevladavala negativna.

Najveći iznos koeficijenta korelacije cijena dionica MAIS ima s prosječnim brojem napravljenih testova po slučaju, nakon toga s tjednim brojem novo hospitaliziranih pacijenata i istim pokazateljem na milijun stanovnika, a sve u Hrvatskoj. Dijagrami rasipanja između navedene tri varijable i cijene dionica prikazani su na Slici 31.

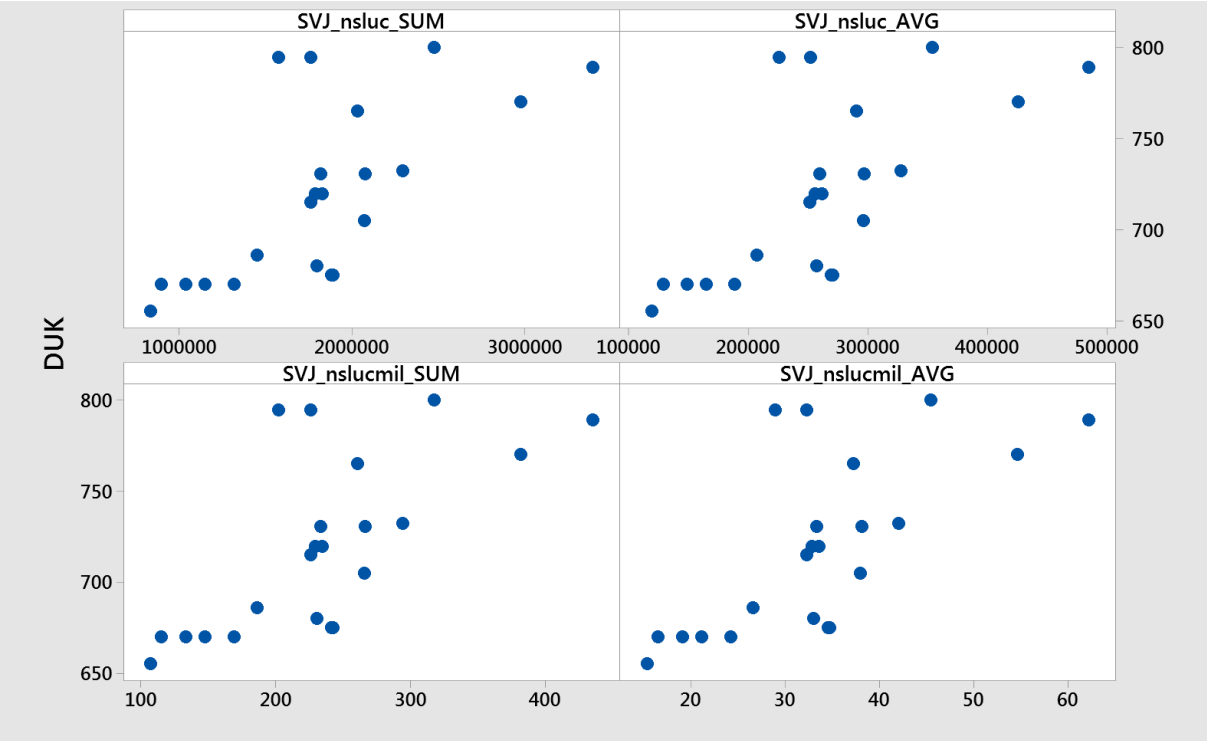


Slika 31. Dijagrami rasipanja - cijena dionica MAIS, broja testova po slučaju, broj novo hospitaliziranih i broj novo hospitaliziranih na milijun stanovnika u Hrvatskoj

Pozitivna relativno slaba veza prisutna između oba pokazatelja vezana uz broj novo hospitaliziranih pacijenata i cijene dionica vidljiva je i na dijagramu. Linearna veza nije jasno izražena i postoje znatne varijacije cijene dionica kod malog broja novo hospitaliziranih pacijenata. Kod broja testova po slučaju postoje 2 vrijednosti koje znatno odstupaju u odnosu na ostale i ukazuju na nagli pad broja testova koji se obavljaju u odnosu na broj novih slučajeva zaraze. Takav trend kretanja tog pokazatelja vrlo je zabrinjavajući kada se u obzir uzme porast broja novih slučajeva zaraze, što ukazuje na neproporcionalan porast testiranja u odnosu na porast broja novih slučajeva. Za ostalih 20 tjedana broj testova po slučaju kreće se

oko 15 čime se trend kretanja cijene dionica u ovisnosti o tom pokazatelju ne može jasno razlučiti.

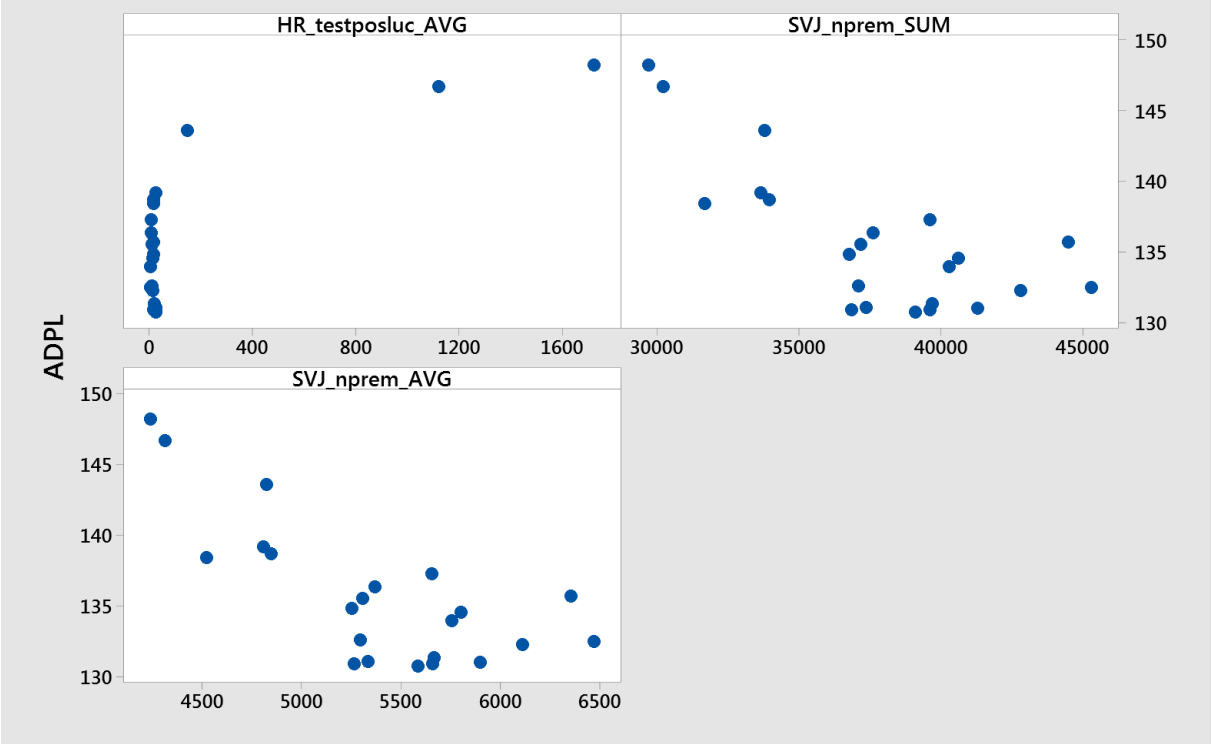
Nakon iznimno malih iznosa korelacijskih koeficijenata u prvom razdoblju, ovoga puta kod cijene dionica DUK iznosi su veći i kreću se u prosjeku oko iznosa 0,55-0,60. Također se može uočiti kako su uglavnom pozitivni. Najveći iznos koeficijenta korelacije postignut je kod broja novih slučajeva zaraze u svijetu i broja novih slučajeva zaraze na milijun stanovnika u svijetu. Dijagrami rasipanja za navedene korelacijske parove prikazani su na Slici 32.



Slika 32. Dijagrami rasipanja - cijena dionica DUK, broj novih slučajeva zaraze i novih slučajeva zaraze na milijun stanovnika u svijetu

U ovome primjeru može se uočiti linearan trend paralelnog rasta cijene dionica i broja novih slučajeva zaraze, pa je samim time i jasno zašto je veza među varijablama srednje jaka i pozitivna. Ono na što ukazuje obostran rast je da cijena dionica nije bila pod značajnim utjecajem većeg širenja zaraze, već je uslijed porasta broja novih slučajeva kroz vrijeme došlo do porasta cijena dionica. Moguće je zaključiti da su same mjere koje je koronavirus uzrokovao u prvoj polovici godine ostavile veće posljedice na cijenu dionica nego širenje zaraze u drugoj polovici tekuće godine.

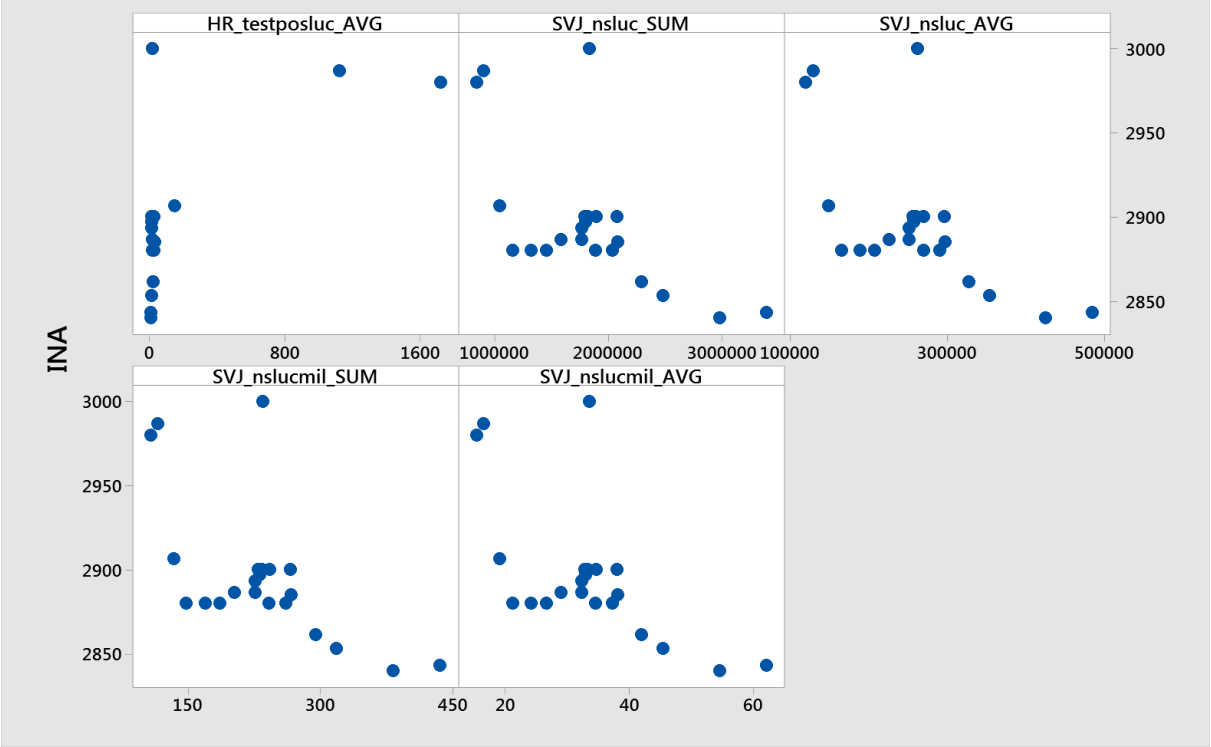
Najveća korelacija cijene dionica ADPL je u drugom razdoblju s brojem testova po slučaju zaraze (srednje jaka i pozitivna) u Hrvatskoj, a nakon toga s brojem preminulih u svijetu. Dijagrami rasipanja za navedene parove pokazatelja prikazani su na Slici 33.



Slika 33. Dijagrami rasipanja - cijena dionica ADPL, broj testiranja po slučaju zaraze u Hrvatskoj i broj preminulih u svijetu

Prvo što se može primijetiti je pozitivna korelacija cijene dionica ADPL s brojem testiranih po slučaju i negativna korelacija u preostala dva dijagrama. Drugim riječima, porastom broja testova po slučaju dolazi do porasta cijene dionica, pa i pad jedne varijable uzrokuje pad druge varijable. Upravo je takav slučaj u stvarnosti, gdje je u vremenskim serijama jasno vidljivo kako u drugoj polovici dolazi do smanjenja broja testova po slučaju što je rezultiralo smanjenjem cijene dionica. Veza s brojem preminulih je negativna, a iz dijagrama je vidljivo da porastom broja preminulih dolazi do pada cijena dionica. Linearan trend je ovdje lakše uočljiv unatoč nešto manjem iznosu koeficijenta korelacije.

Najveći koeficijent korelacije kod cijene dionica INA vezan je ponovno uz broj testova po slučaju u Hrvatskoj, a nakon toga uz broj novih slučajeva i broj novih slučajeva na milijun stanovnika u svijetu. Dijagrami rasipanja prikazani su na Slici 34.



Slika 34. Dijagrami rasipanja - cijena dionica INA, broj testiranja po slučaju zaraze u Hrvatskoj, broj novih slučajeva i broj novih slučajeva na milijun stanovnika u svijetu

Korelacija je ponovno pozitivna između cijene dionica INA i broja testova, dok je u ostalim dijagramima negativna. Povećanjem broja testova po slučaju dolazi do povećanja cijena dionica, dok povećanjem broja novih slučajeva dolazi do smanjenja cijene dionica. Kod dijagrama vezanog uz broj testova po slučaju još je jednom lako primijetiti velika odstupanja za podatke 3 tjedna u odnosu na grupiranost i malu varijaciju ostalih tjedana.

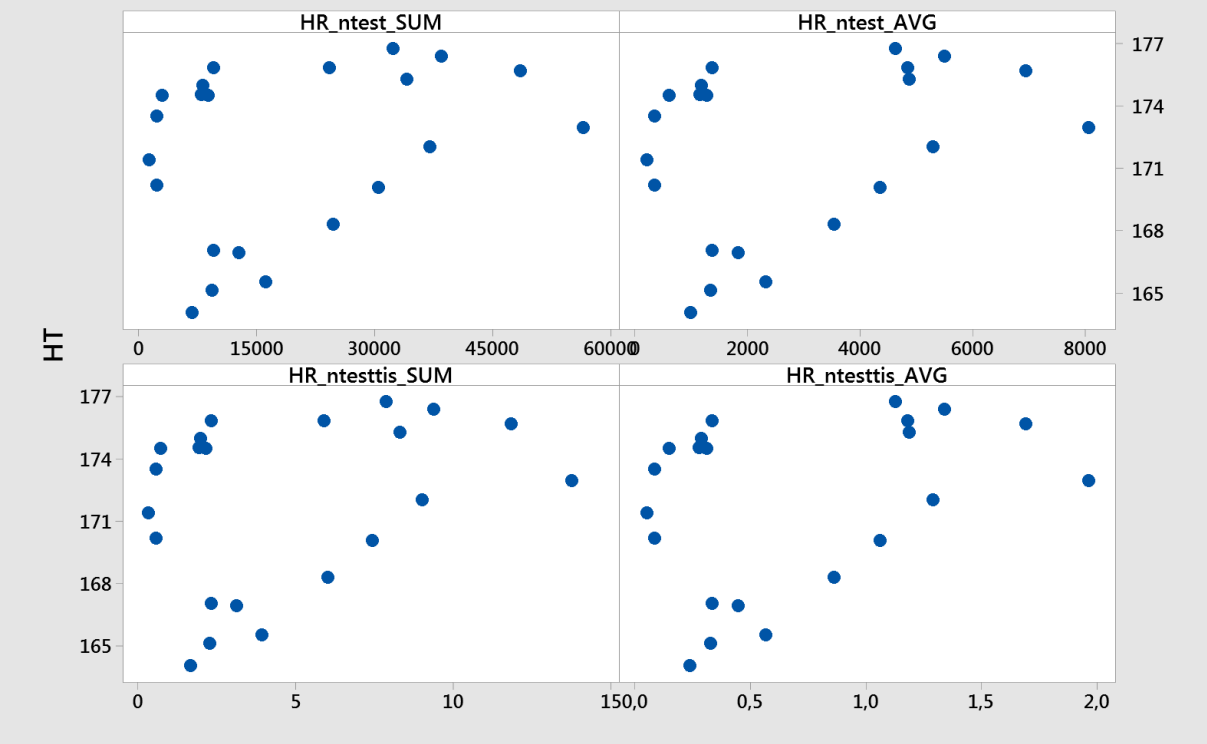
U ovome razdoblju najveći koeficijenti korelacije prisutni su kod cijene dionica ERNT. Zapravo jedino u ovom slučaju postoje jake korelacijske veze, a najveći iznos vezan je uz prosječan broj novo napravljenih testova i testova na tisuću stanovnika u Hrvatskoj, a nakon toga uz iste varijable samo ukupan broj. Dijagrami rasipanja za navedene varijable prikazani su na Slici 35.



Slika 35. Dijagrami rasipanja – cijena dionica ERNT, broj novo napravljenih testova i broj novo napravljenih testova na tisuću stanovnika u Hrvatskoj

Samim pogledom na dijagrame rasipanja jasno je zašto je u ovim slučajevima korelacija jaka između varijabli. Pozitivan linearan trend je izražen što je indikator porasta cijene dionica uz porast broja novo napravljenih testova i novo napravljenih testova na tisuću stanovnika. Unatoč većem širenju zaraze u drugoj polovici godine i porastom broja novo napravljenih testova, cijena dionica ERNT kontinuirano raste što je znak oporavka nakon utjecaja kojeg su mjere ostavile u prvom razdoblju.

Posljednji dio matrice korelacija je onaj vezan uz cijenu dionica HT. Koeficijenti korelacije su ovdje mali, odnosno korelacije među varijablama su uglavnom relativno slabe. Najveći iznosi vezani su uz prosječan broj novo napravljenih testova i testova na tisuću stanovnika, a nakon toga uz iste varijable samo ukupan iznos. Dijagrami rasipanja prikazani su na Slici 36.



Slika 36. Dijagrami rasipanja – cijena dionica HT, broj novo napravljenih testova i broj novo napravljenih testova na tisuću stanovnika u Hrvatskoj

Iz dijagrama rasipanja jasno je vidljivo zašto su koeficijenti korelacija toliko mali. Odstupanja podataka od zajedničkog pozitivnog linearnog trenda na koji sugerira iznos korelacijskog koeficijenta iznimno su velika.

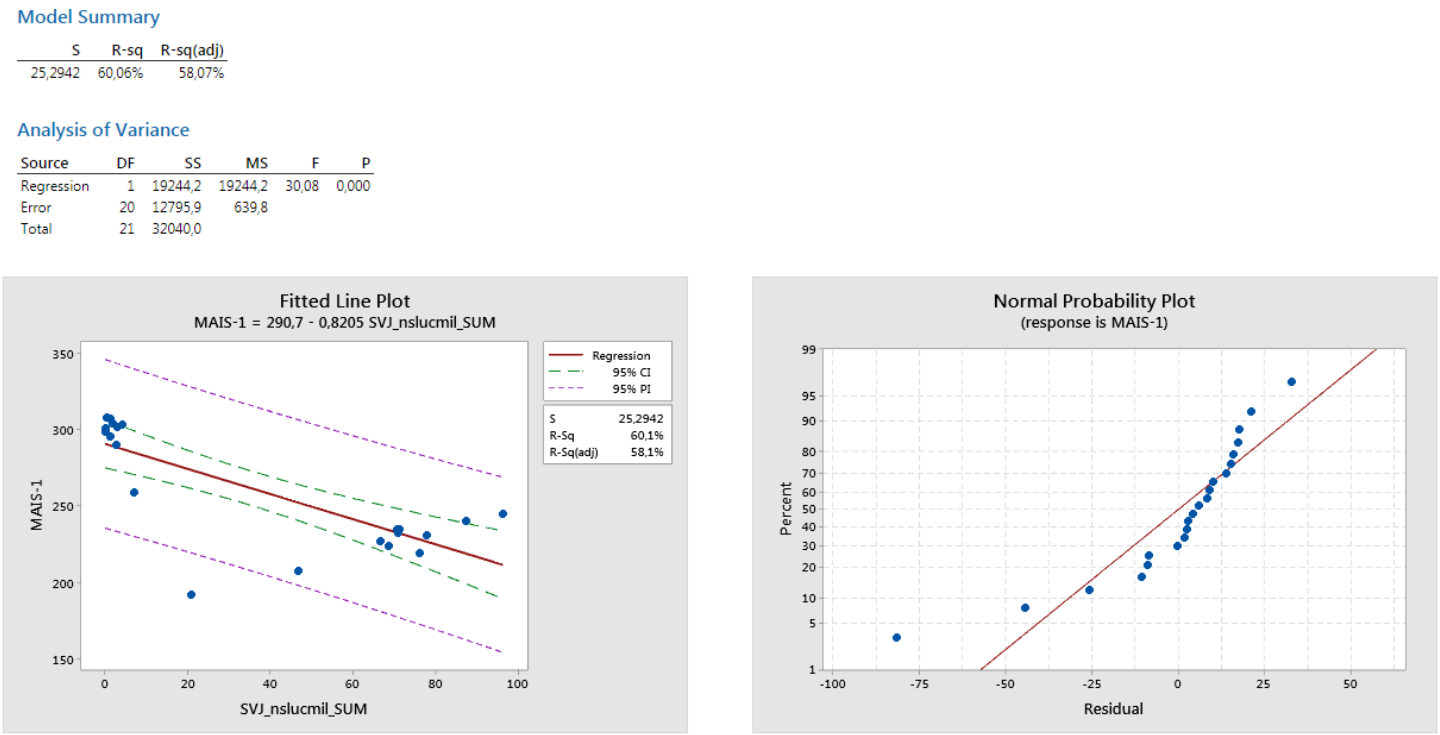
Gledajući sve koeficijente korelacije vezane uz cijene dionica u drugome razdoblju moguće je jasno razdijeliti dvije skupine. U prvoj je u drugom razdoblju došlo do rasta cijene dionica i iznosi koeficijenata korelacija su za tu skupinu pozitivni. Kod onih cijena dionica koje su ostvarile veći rast koeficijenti su veći budući da su i pokazatelji vezani uz širenje zaraze ostvarili veći rast. Smanjenjem rasta cijene dionica smanjili su se i koeficijenti korelacija. Drugu skupinu karakterizira pad cijena dionica i negativni iznosi koeficijenata korelacija. Ponovno vrijedi isto pravilo, ako je pad bio veći i iznos koeficijenta je veći.

4. REGRESIJSKA ANALIZA

Nakon provedene korelacijske analize i otkrića varijabli koje imaju s cijenom dionica najjaču povezanost, u ovome poglavlju za te parove varijabli pronaći će se regresijski modeli kojima bi se mogla modelirati uzročno posljedična veza. Za dobivanje tih modela ponovno će se koristiti isti alat, Minitab.

4.1. Razdoblje uz mjere za suzbijanje širenja zaraze

Iz korelacijske analize vezane uz cijenu dionica MAIS otkriveno je kako je u prvome razdoblju povezanost s varijablama broj novih slučajeva zaraze u svijetu najveća, pa će se za regresijsku analizu konkretno izabrati ukupan broj novih slučajeva zaraze na milijun stanovnika u svijetu. Dobiven jednostavan linearan regresijski model prikazan je na Slici 37.



Slika 37. Jednostavan linearan regresijski model – MAIS, prvo razdoblje

Prvi parametar koji će se promotriti prilikom analize dobivenog modela je p-vrijednost. U svim regresijskim modelima koji će biti prikazani uzeta je razina pouzdanosti od 95 %. Ta se razina odražava na interval povjerenja za koji se u tom slučaju pretpostavlja da će u 95 % slučajeva on sadržavati očekivanu vrijednost odzivne varijable. Također odražava se i na interval predviđenih vrijednosti za koji se pretpostavlja da će u 95 % slučajeva sadržavati

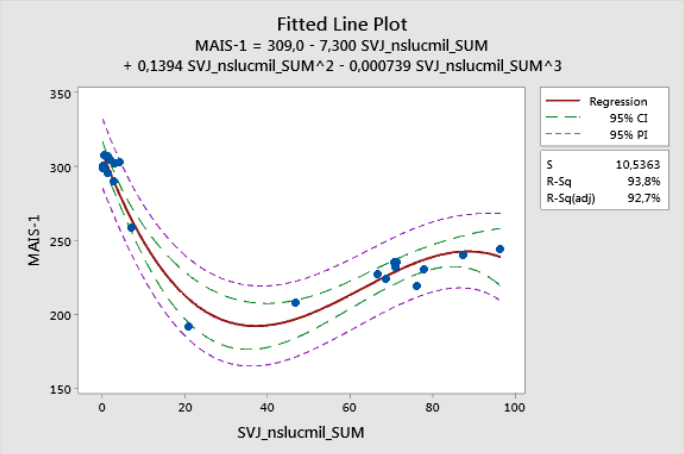
pojedinačnu vrijednost odzivne varijable. Samim time jasno je zašto interval povjerenja predviđenih vrijednosti pokriva šire područje od intervala povjerenja očekivane vrijednosti. Odabrana razina povjerenja odražava se na razinu pogreške (α) koja se dobiva oduzimanjem vjerojatnosti od 1, odnosno u ovome slučaju iznosi 0,05. Ako je p-vrijednost manja ili jednaka vrijednosti razine značajnosti (α) tada se može reći da postoji značajna statistička povezanost između odzivne varijable (cijena dionice) i prediktorske varijable. Dobivena p-vrijednost iz modela je 0,000 što je manje od 0,05, pa se time može zaključiti kako je povezanost među varijablama značajna. To nužno ne znači da je sami model adekvatan, pa se nastavlja s analizom koeficijenta determinacije (R^2). On označava postotak varijacije u odzivu koji je objašnjen modelom. Povezan je s vrijednostima sume kvadrata odstupanja (*SS*), koja se izračunava za regresijski model (dio varijacije koji je opisan modelom) i za grešku (dio varijacije koji nije opisan prediktorskom varijablom). Stavljanjem u omjer sume kvadrata odstupanja modela (*SS Regression*) i ukupne sume kvadrata odstupanja (*SS Total*). Dobivena je vrijednost koeficijenta determinacije od 60,06 %, što znači da je samo toliki postotak varijacije objašnjen modelom. To se može vidjeti i iz grafičkog prikaza modela u kojem postoje vrijednosti s većim odstupanjima od modela (engl. *outlieri*) te iz prikaza normalnosti ostataka na desnom grafu. Jasno je vidljivo da oni ne prate pravac, pa se samim time ni ne može zaključiti normalnost raspodjele ostataka i ponovno su prisutni outlieri. Iz tog razloga model nije adekvatan za primjenu. U podacima se može primijetiti zakrivljenost i oblik doline, pa će se pokušati bolje opisati podatke kubnim regresijskim modelom prikazanim na Slici 38.

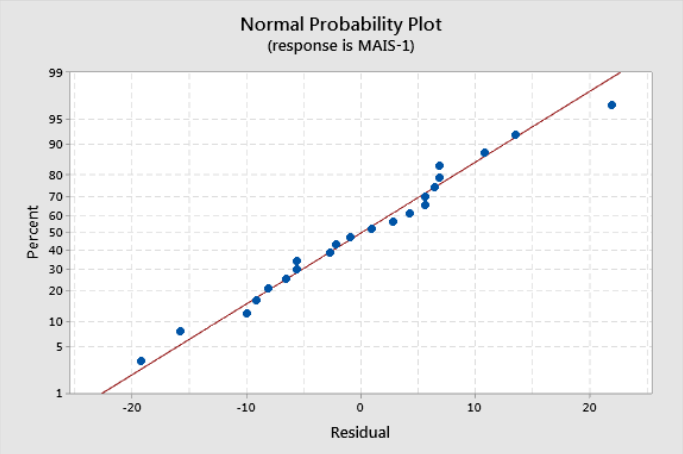
Model Summary

S	R-sq	R-sq(adj)
10,5363	93,76%	92,72%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	3	30041,8	10013,9	90,20	0,000
Error	18	1998,3	111,0		
Total	21	32040,0			





Slika 38. Kubni regresijski model – MAIS, prvo razdoblje

Prvi dio analize, p-vrijednost, ponovno je 0,000 i manja od 0,05 što znači da je povezanost među varijablama statistički značajna i može se nastaviti s daljnjom analizom. Koeficijent determinacije ovoga puta znatno je veći i iznosi 93,76 % (prilagođeni iznosi 92,72 %). Potvrda ovog izračuna je i način na koji krivulja pokriva kretanje podataka na grafu. Stvarne vrijednosti puno su bliže onima aproksimiranima modelom što prate i interval povjerenja i interval predviđenih vrijednosti. Potvrda je i prikaz normalnosti ostataka na desnom grafu gdje se može jasno uočiti kako podaci prate pravac. Ovaj model prikladan je za korištenje uz jednu napomenu, a to je nedostatak podataka u rasponu ukupnog broja novih slučajeva na milijun stanovnika u svijetu od 10 do 60.

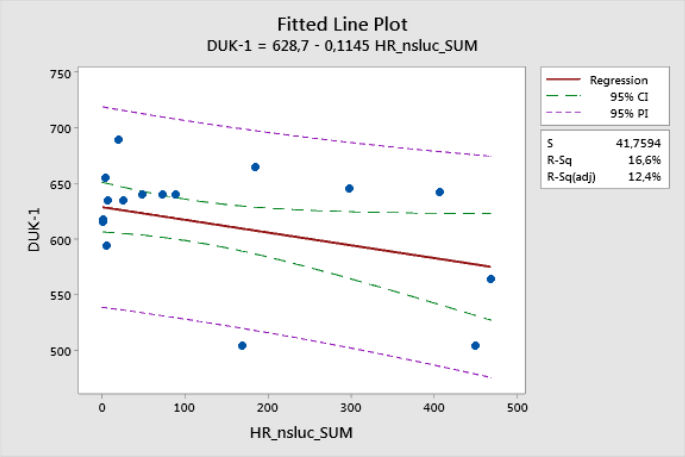
Za cijenu dionica DUK u prvom razdoblju uočena je najznačajnija povezanost s varijablama vezanim uz broj novih slučajeva u Hrvatskoj, a za izradu modela odabran je ukupan broj novih slučajeva zaraze u Hrvatskoj. Dobiveni model prikazan je na Slici 39.

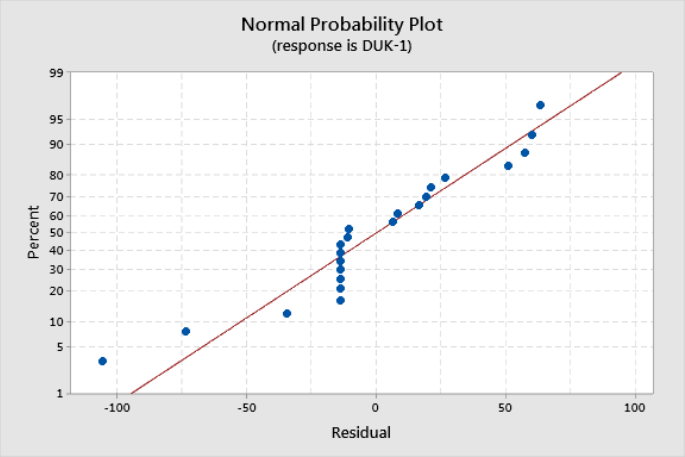
Model Summary

S	R-sq	R-sq(adj)
41,7594	16,55%	12,38%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	1	6919,3	6919,33	3,97	0,060
Error	20	34876,9	1743,84		
Total	21	41796,2			





Slika 39. Jednostavan linearan regresijski model – DUK, prvo razdoblje

Provodeći prvi korak analize dobivenog modela, odnosno usporedbom p-vrijednosti s razinom značajnosti dolazi se do zaključka kako ne postoji značajna statistička povezanost među varijablama. Naime, p-vrijednost iznosi 0,06 i veća je od 0,05. Model postaje neadekvatan za uporabu već na prvom koraku provjere, ali i ostali koraci ukazuju na isti problem. Koeficijent determinacije iznosi 16,55 % i također ukazuje na malu pokrivenost odstupanja dobivenim modelom. Moguće je zaključiti kako je izrada regresijskog modela za cijene dionica koje s varijablama razmjera pandemije nisu imale barem srednje jake korelacije nepotrebna jer dobiveni modeli nisu primjenjivi.

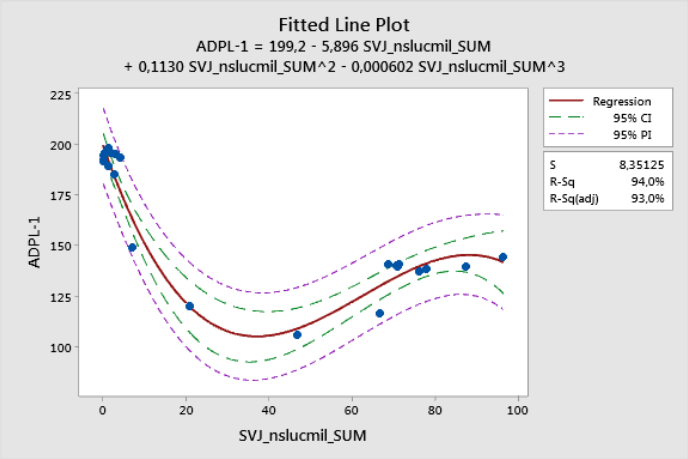
Budući da su sve preostale cijene u prvom razdoblju ostvarile najveću povezanost s varijablama vezanim uz broj novih slučajeva zaraze u svijetu i da je iz dijagrama rasipanja moguće vidjeti kako je kretanje dviju varijabli slično obliku kubne krivulje, preskočit će se korak izrade jednostavnog linearnog regresijskog modela i odmah započeti s kubnim. Varijabla ukupnog broja novih slučajeva zaraze na milijun stanovnika u svijetu odabrana je za izradu dobivenog modela vezanog uz cijenu dionica ADPL prikazanog na Slici 40.

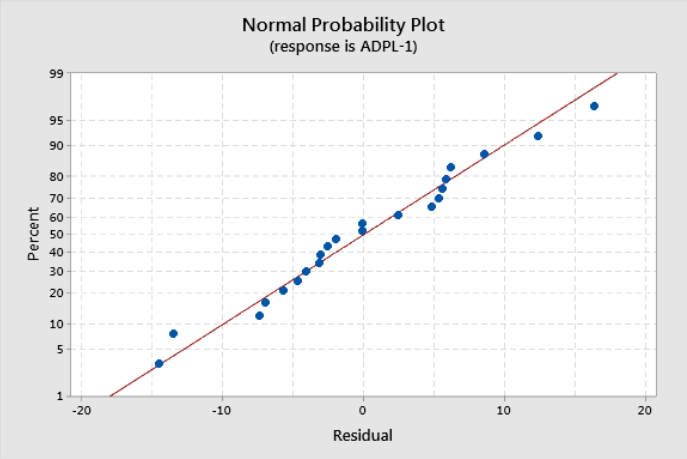
Model Summary

S	R-sq	R-sq(adj)
8,35125	93,96%	92,95%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	3	19529,1	6509,71	93,34	0,000
Error	18	1255,4	69,74		
Total	21	20784,5			





Slika 40. Kubni regresijski model – ADPL, prvo razdoblje

Pretpostavka se pokazala točnom i dobiveni model na prvu izgleda kao prikladan. Uz potvrdu statistički značajne veze među varijablama preko p-vrijednosti i koeficijent determinacije ukazuje na pokrivenost varijacija modelom od 93,96 % (prilagođeni iznosi 92,95 %). Za primijetiti je da je raspodjela ostataka normalna zbog pobližeg praćenje pravca. Samim time ovaj model je adekvatan za uporabu uz ponovnu napomenu o manjem broju podataka prisutnih za broj novih slučajeva zaraze od 10 do 60.

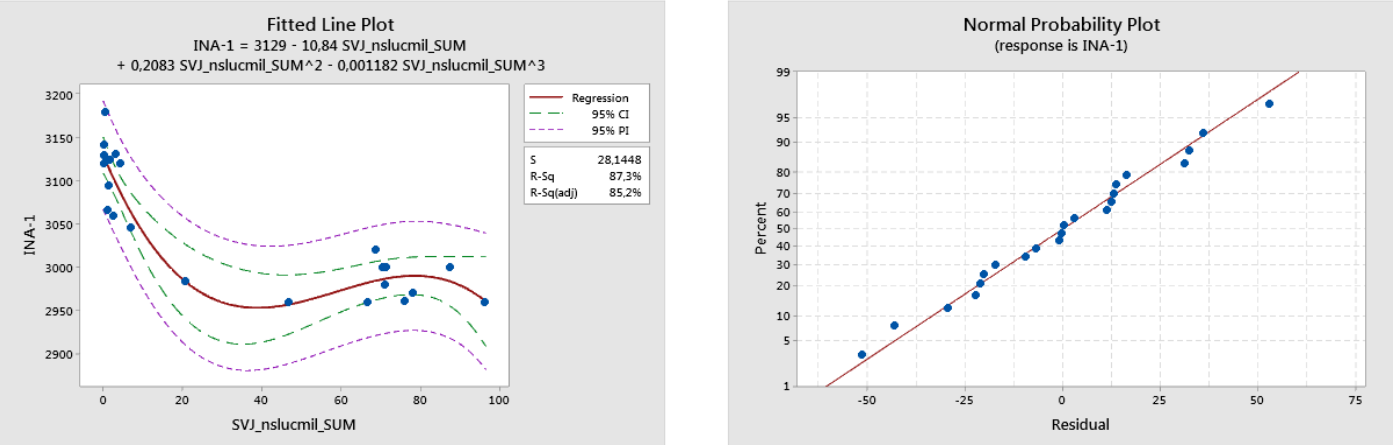
Što se tiče cijene dionica INA, za izradu regresijskog modela prikazanog na Slici 41. kao prediktorska varijabla korištena je varijabla ukupnog broja novih slučajeva zaraze na milijun stanovnika u svijetu.

Model Summary

S	R-sq	R-sq(adj)
28,1448	87,28%	85,16%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	3	97819	32606,4	41,16	0,000
Error	18	14258	792,1		
Total	21	112078			



Slika 41. Kubni regresijski model – INA, prvo razdoblje

Pretpostavka o korištenju kubnog modela ponovno se pokazala ispravnom. P-vrijednost ukazuje na postojanje statistički značajne veze između prediktorske i odzivne varijable. Uz to primjećuje se velika pokrivenost varijacija modelom zbog iznosom koeficijenta determinacije od 87,28 % (prilagođeni iznosi 85,16%). Na desnom grafu moguće je primijetiti kako i ostaci bolje prate pravac što je naznaka njihove normalne raspodjele. Jedina napomena je ponovno kako postoji manji broj podataka za raspon ukupnog broja novih slučajeva zaraze na milijun stanovnika od 10 do 60.

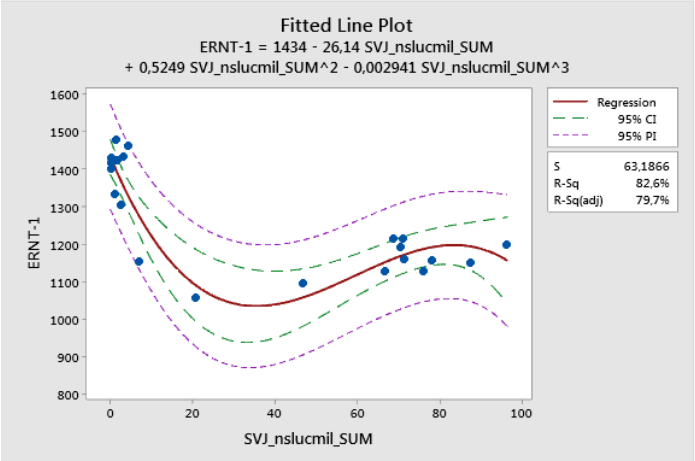
Kod cijene dionica ERNT najjača korelacijska veza utvrđena je s varijablama ukupni i prosječni broj novih slučajeva zaraze na milijun stanovnika. Za izradu regresijskog modela prikazanog na Slici 42. korištena je varijabla ukupni broj novih slučajeva zaraze na milijun stanovnika.

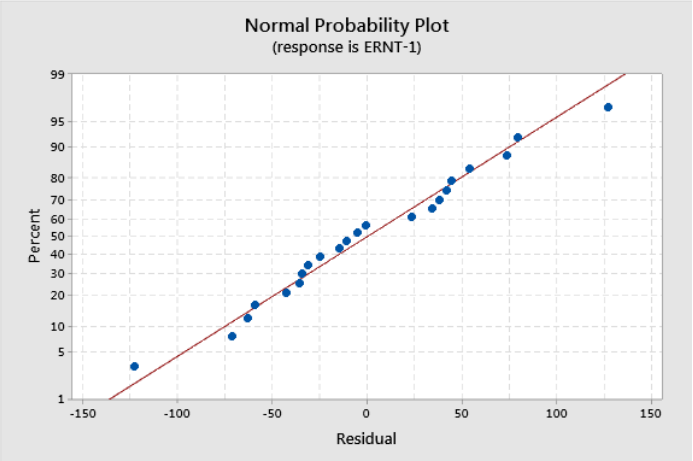
Model Summary

S	R-sq	R-sq(adj)
63,1866	82,63%	79,74%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	3	341895	113965	28,54	0,000
Error	18	71866	3993		
Total	21	413760			





Slika 42. Kubni regresijski model – ERNT, prvo razdoblje

Uz odgovarajuću p-vrijednost i iznos koeficijenta determinacije ukazuje na dobru pokrivenost varijacija modelom s iznosom od 82,63 % (prilagođeni iznosi 79,74 %). Na desnome grafu moguće je primijetiti kako je i raspodjela ostataka normalna zbog bolje sljedivosti podataka i pravca. Samim time model je adekvatan za uporabu uz ponovno napomenu o manjem broju podataka koji opisuju razdoblje od 10 do 60 ukupnih novih slučajeva zaraze na milijun stanovnika u svijetu.

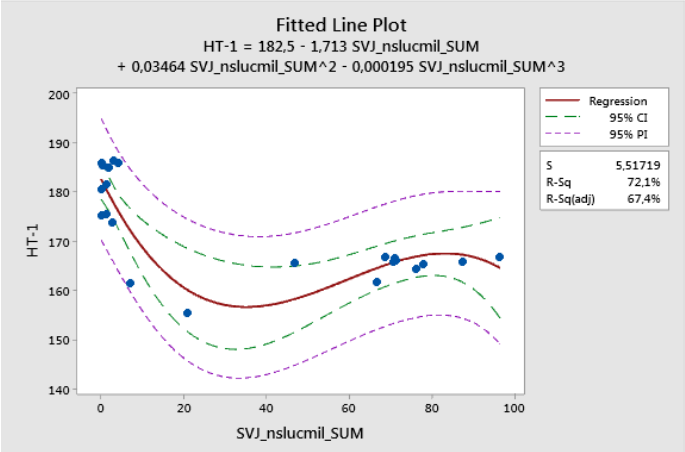
Posljednja cijena dionica je HT, a na Slici 43. prikazan je regresijski model dobiven korištenjem varijable ukupan broj novih slučajeva zaraze na milijun stanovnika u svijetu kao prediktorske.

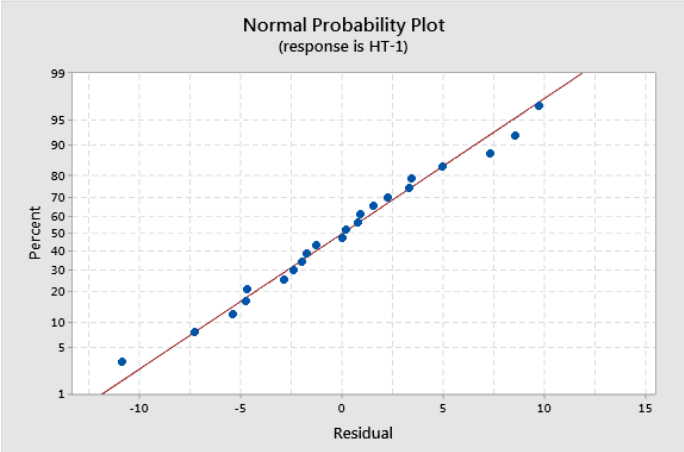
Model Summary

S	R-sq	R-sq(adj)
5,51719	72,06%	67,41%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	3	1413,31	471,103	15,48	0,000
Error	18	547,91	30,439		
Total	21	1961,22			





Slika 43. Kubni regresijski model – HT, prvo razdoblje

Uz zadovoljavajuću p-vrijednost, dobiveni model dobro opisuje varijaciju s iznosom koeficijenta determinacije od 72,06 % (prilagođeni iznosi 67,41 %). Iznos tog koeficijenta nije izrazito velik, ali je adekvatan za približno određivanje kretanja cijene dionica HT. Također su i ostaci normalno raspodijeljeni što je moguće zaključiti iz visoke podudarnosti podataka s pravcem na desnom grafu.

U promatranom razdoblju postoji logičnost povezanosti među varijablama koja je prikazana u svim modelima prikladnim za uporabu. Naime, moguće je primijetiti kako su dobiveni kubni modeli preslike načina na koji se kreću cijene dionica i broj novih slučajeva zaraze. Vremenske serije kretanja cijene dionica izgledaju otprilike identično kao i dobiveni modeli dok kretanje broja novih slučajeva zaraze prati isti oblik krivulje samo zrcaljen oko apscise. Korelacijska veza među varijablama iz toga razloga i je negativna te predstavlja logičnost koja se odražava padom cijene dionica uslijed porasta broja novih slučajeva zaraze. Ta uzročno posljedična veza može se uzeti kao model pada ključnih pokazatelja za prvo razdoblje.

4.2. Razdoblje nakon popuštanja/ukidanja mjera

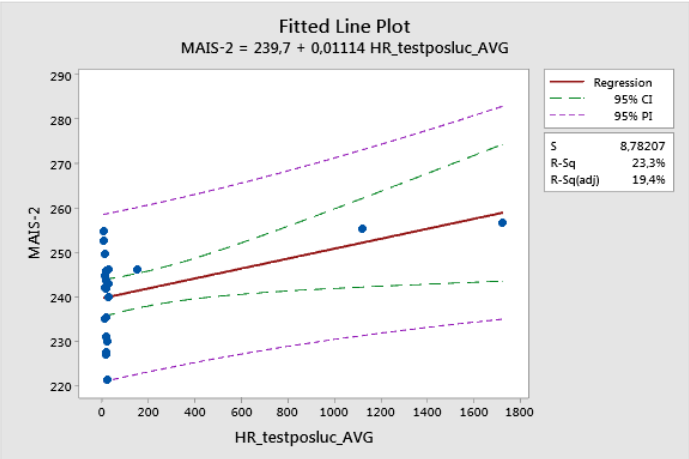
Regresijski modeli kojima bi se mogla utvrditi uzročno posljedična veza te time i predikcija bit će razvijeni i za drugo razdoblje. Time će se dobiti odgovor na pitanje jesu li isti trendovi poslovanja u prvom i drugom razdoblju te što je moguće očekivati u narednim mjesecima. U drugom razdoblju najznačajnija korelacija cijene dionica MAIS utvrđena je s prosječnim brojem testova po slučaju u Hrvatskoj, pa je dobiveni jednostavan linearan regresijski model prikazan na Slici 44.

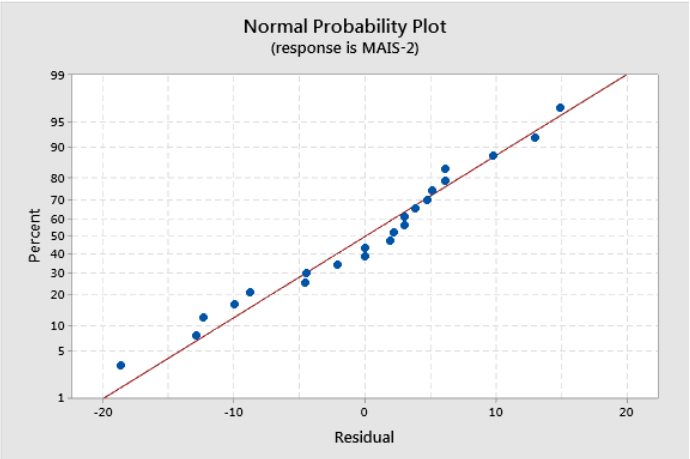
Model Summary

S	R-sq	R-sq(adj)
8,78207	23,27%	19,43%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	1	467,77	467,772	6,07	0,023
Error	20	1542,50	77,125		
Total	21	2010,27			





Slika 44. Jednostavan linearan regresijski model – MAIS, drugo razdoblje

Dobivena p-vrijednost iznosi 0,023 što ponovno ukazuje na statistički značajnu povezanost varijabli. Pokrivenost varijacije podataka modelom iznosi tek 23,27 % što ukazuje na slabu pokrivenost varijacija. Isto je jasno vidljivo i iz prikaza regresijskog modela gdje se vidi velika grupiranost različitih cijena dionica pri malom broju testova po slučaju. Osim te grupe podataka postoje 3 *outliera*, od kojih se dva krajnje desno posebno ističu. Samim time model nije prikladan za opisivanje veze među varijablama i ne može se koristiti za predviđanje kretanja cijene dionica uslijed nepostojanja mjera.

Kod cijene dionica DUK za drugo razdoblje je utvrđeno kako postoji povezanost s varijablama vezanim uz broj novim slučajeva zaraze u svijetu, a za provedbu regresijske

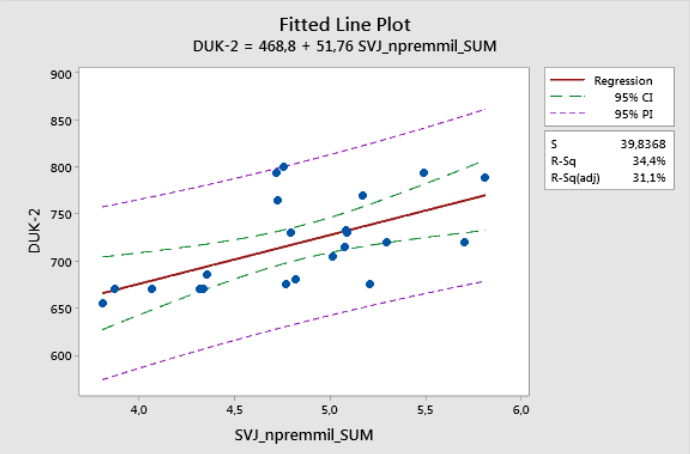
analize odabrana je varijabla ukupan broj novih slučajeva zaraze na milijun stanovnika u svijetu. Dobiveni model prikazan je na Slici 45.

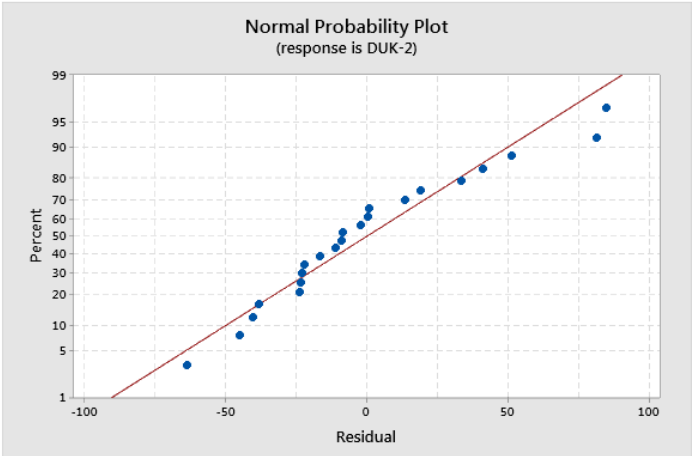
Model Summary

S	R-sq	R-sq(adj)
39,8368	34,37%	31,09%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	1	16622,4	16622,4	10,47	0,004
Error	20	31739,4	1587,0		
Total	21	48361,7			





Slika 45. Jednostavan linearan regresijski model – DUK, drugo razdoblje

Za razliku od prvog razdoblja gdje je p-vrijednosti bila nezadovoljavajuća, u ovome razdoblju ipak ukazuje na statistički značajnu vezu među varijablama sa svojim iznosom od 0,004. Iznos koeficijenta determinacije s druge strane ipak ukazuje na lošu pokrivenost odstupanja modelom s vrijednosti od 34,37 %. Pogledom na graf regresijskog modela jasno je vidljivo kako postoje značajna odstupanja od dobivenog linearnog modela što dokazuje desni graf s većim odstupanjem ostataka od pravca. Zaključno se može reći kako ovaj model nije adekvatan za predviđanje kretanja cijene dionica s velikom sigurnošću, ali pokriva trend rasta cijene dionica prisutan u drugom razdoblju.

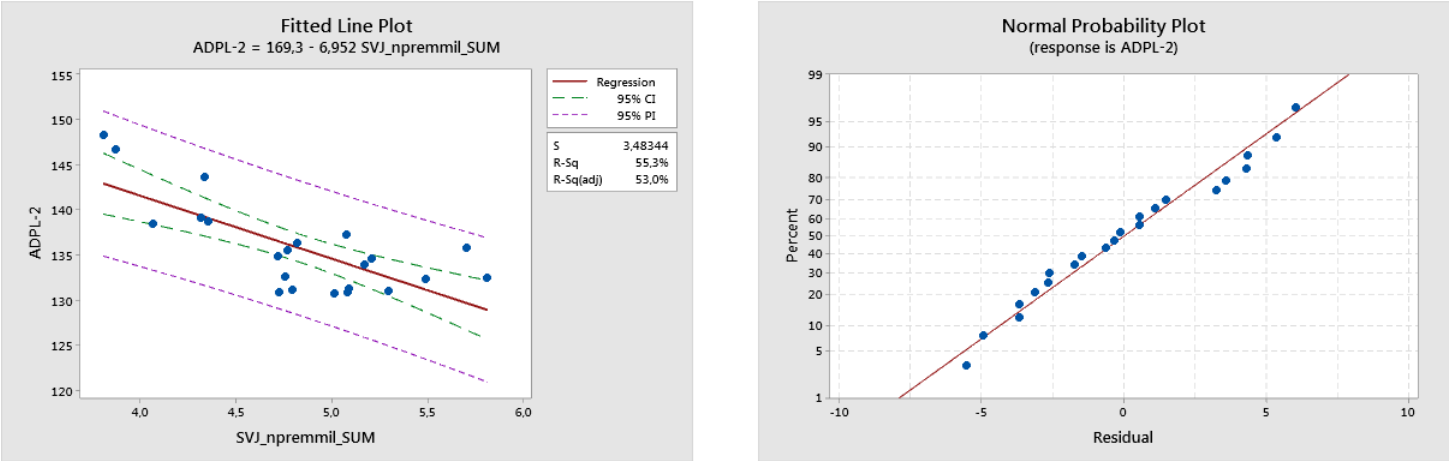
Za drugo razdoblje kod cijene dionica ADPL, najjača povezanost utvrđena je s varijablom prosječnog broja testova po slučaju u Hrvatskoj, ali je iz jednog od prethodnih primjera već utvrđeno kako model dobiven korištenjem te varijable kao prediktorske rezultira lošim modelom. Stoga je regresijska analiza prikazana na Slici 46. provedena korištenjem druge po redu najprikladnije varijable gledajući koeficijent korelacije, ukupnim brojem preminulih na milijun slučajeva u svijetu.

Model Summary

S	R-sq	R-sq(adj)
3,48344	55,27%	53,03%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	1	299,864	299,864	24,71	0,000
Error	20	242,686	12,134		
Total	21	542,551			



Slika 46. Jednostavan linearan regresijski model – ADPL, drugo razdoblje

Iako p-vrijednost još jednom ukazuje na postojanje veze među varijablama, pokrivenost varijacija modelom nije toliko značajna s iznosom od 55,27 %. Pokrivenost varijacija je nešto veća nego kod modela dobivenog za prethodno spomenutu cijenu dionica što je vidljivo i uz bolju sljedivost ostataka s pravcem. Ponovno je predviđanje cijene dionica s većom sigurnošću nemoguće, ali je negativan trend kretanja cijene dionica dobro pokriven modelom.

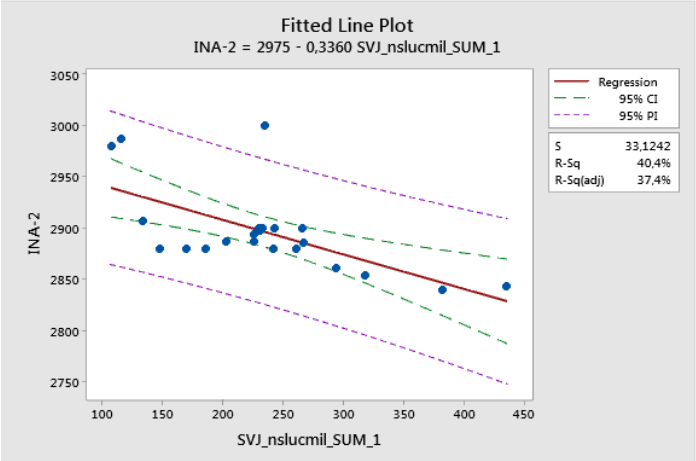
U drugom razdoblju varijabla prosječan broj testova po slučaju u Hrvatskoj imala je najveći koeficijent korelacije s cijenom dionica INA. Iz istog razloga kao i kod prethodne cijene dionica uzet će se iduća najbolja varijabla prema iznosu koeficijenta. Radi se o ukupnom broju novih slučajeva zaraze na milijun stanovnika u svijetu, a dobiveni model prikazan je na Slici 47.

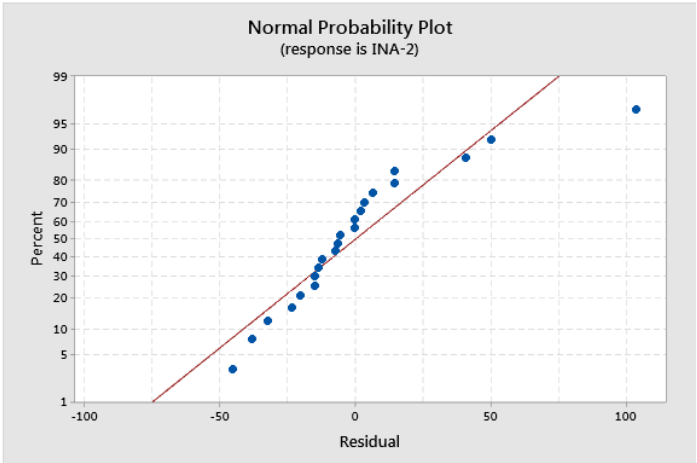
Model Summary

S	R-sq	R-sq(adj)
33,1242	40,36%	37,37%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	1	14847,5	14847,5	13,53	0,001
Error	20	21944,2	1097,2		
Total	21	36791,8			





Slika 47. Jednostavan linearan regresijski model – INA, drugo razdoblje

Iako p-vrijednost ponovno zadovoljava, koeficijent determinacije s iznosom od 40,36 % zajedno s većom nepodudarnosti ostataka na desnom grafu s pravcem ukazuje na prisutnost većih odstupanja stvarnih podataka od modela. Negativan trend kretanja cijene dionica još je jednom pokriven modelom iako je teže predvidjeti samu cijenu s većom sigurnošću.

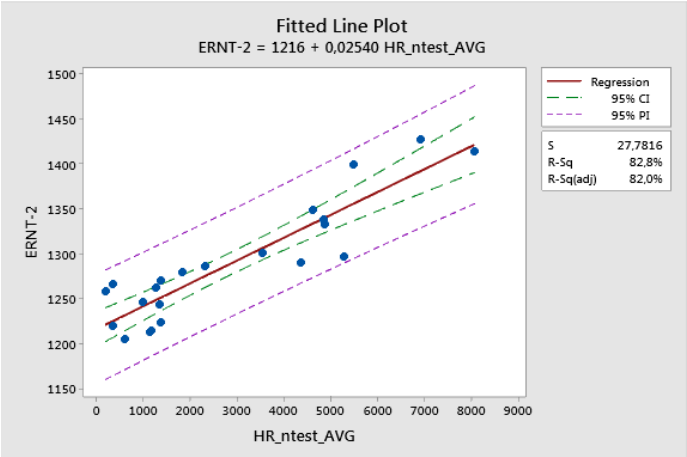
Kod cijene dionica ERNT u drugome razdoblju je korelacija bila najjača s varijablom prosječan broj novo napravljenih testova u Hrvatskoj, a dobiveni regresijski model prikazan je na Slici 48.

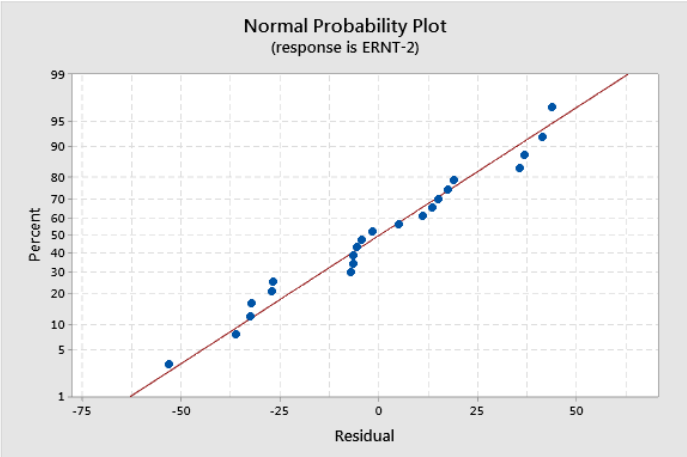
Model Summary

S	R-sq	R-sq(adj)
27,7816	82,83%	81,97%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	1	74469,8	74469,8	96,49	0,000
Error	20	15436,3	771,8		
Total	21	89906,1			





Slika 48. Jednostavan linearan regresijski model – ERNT, drugo razdoblje

Dobivena p-vrijednost ukazuje na prisutnost statistički značajne veze, a iznos koeficijenta determinacije od 82,83 % označava dobru pokrivenost varijacija modelom. Radi se o dosad najvećem iznosu koeficijenta determinacije za drugo razdoblje što se može primijetiti i na desnome grafu gdje ostaci pobliže prate pravac u odnosu na prethodne modele. Od svih dobivenih modela za drugo razdoblje ovaj je najadekvatniji za uporabu iako je moguće primijetiti neka malo veća odstupanja stvarnih podataka od modela.

Kod cijene dionica HT, u drugom razdoblju su iznosi koeficijenata korelacije iznimno mali. Uzimajući u obzir izglede dijagrama rasipanja iz poglavlja vezanog uz korelacijsku analizu te lošeg regresijskog modela dobivenog kod cijene dionica DUK uslijed relativno slabe korelacije u prvom razdoblju, za drugo se neće izrađivati regresijski model.

Dok i u drugom razdoblju postoje neke logične veze kod kojih se može primijetiti pad cijena dionica s porastom broja zaraženih, pojavljuju se i one koje nisu toliko logične. Naime, porastom svih pokazatelja razmjera pandemije u drugome razdoblju dolazi do paralelnog rasta cijene dionica. Iz toga se mogu zaključiti dvije stvari:

→ Prva je kako su korišteni pokazatelji razmjera pandemije zapravo aliasi za neke subjektivne karakteristike koje se ne mogu kvantificirati, a radi se najvjerojatnije o

strahu ljudi kao reakciji na nešto novo i nepoznato. Postepenim privikavanjem ljudi na novonastalu situaciju i upoznavanjem s nečim novim pokazatelji razmjera pandemije zapravo se više ne mogu dosljedno koristiti.

→ Time se dolazi do druge stvari koju se može zaključiti, a radi se o tome da je vremenska domena prediktor koji igra najveću ulogu u drugome razdoblju gdje samim prolaskom vremena uglavnom dolazi do oporavka gospodarstva vidljivog preko porasta cijene dionica.

5. ZAKLJUČAK

Posljedice koje je pandemija ostavila na gospodarstvo cijeloga svijeta, pa onda naravno i Hrvatske vrlo su ozbiljne. Na razini država došlo je do rekordnih padova u realnim stopama rasta BDP-a praćenim smanjenjem potrošnje, uvoza i izvoza, broja zaposlenih i industrijske odnosno proizvodnje u građevinskoj industriji. Za zemlje koje su kao Hrvatska orijentirane turizmu najalarmantniji pokazatelji su izraziti padovi dolazaka i noćenja turista. Migracije stanovništva evidentno su manje u odnosu na prethodne godine što najbolje pokazuje enorman pad broja prevezenih putnika zračnim modom transporta. Koliko je uslužni sektor pogođen pandemijom najbolje se vidi u analizi poslovanja djelatnosti Trgovina, prijevoz i skladištenje, smještaj, priprema i usluživanje hrane gdje su navedena poduzeća u usporedbi s ostalim djelatnostima ostvarila najveće padove. Kod prerađivačke industrije u većini djelatnosti moguće je primijetiti manje padove. Postoje dvije iznimke, naftna industrija osjetila je veće posljedice dok je farmaceutska nastavila s rastom poslovanja. Iz analize kretanja cijene dionica usporedno s pokazateljima o širenju zaraze moguće je primijetiti postojanje jačih i slabijih korelacija ovisno o djelatnosti. Generalno je najprimjetniji značajan utjecaj mjera u razdoblju kada su one bile na snazi. Također je u tom periodu primjetna jača povezanost kretanja cijena dionica s globalnim pokazateljima. Ukidanjem mjera i veza s pokazateljima se mijenja te sada do izražaja dolaze i oni vezani uz Hrvatsku. Dok su u prvom razdoblju vezanom uz mjere korelacije uglavnom bile negativne, što je označavalo povećanje pokazatelja vezanog uz pandemiju i paralelan pad cijena dionica, u drugome se i to promijenilo. Upravo zato moguće je primijetiti rast cijena dionica u nekim djelatnostima praćen paralelnim rastom pokazatelja vezanih uz pandemiju zbog čega je zaključeno kako je došlo do oporavka gospodarstva uslijed samog prolaska vremena i navikavanja ljudi na situaciju nastalu oko pandemije. Trendovi uočeni provođenjem korelacijske analize potkrijepljeni su izradom regresijskih modela. Regresijski modeli kao modeli uzročno posljedičnih veza ključnih pokazatelja i dinamike razmjera pandemije, se teško mogu koristiti za predviđanje budućih vrijednosti. Kao i u slučaju predviđanja širenja pandemije tako i u slučaju izloženom u ovom radu predviđanja bi imala smisla samo za vrlo kratki vremenski period kada nema značajnijih promjena u društvenim i gospodarskim aktivnostima.

LITERATURA

[1] Zhu N, Zhang D, Wang W, et al. A Novel Coronavirus from Patients with Pneumonia in China, 2019. The New England Journal of Medicine. February 2020. DOI: 10.1056/NEJMoa2001017

[2] https://phil.cdc.gov/default.aspx (zadnji pristup: 4.10.2020.)

[3] https://www.who.int/health-topics/severe-acute-respiratory-syndrome (zadnji pristup: 4.10.2020.)

[4] https://www.who.int/emergencies/mers-cov/en/ (zadnji pristup: 5.10.2020.)

[5] Guan W, Ni Z, et al. Clinical Characteristics of Coronavirus Disease 2019 in China. The New England Journal od Medicine. April 2020. DOI: 10.1056/NEJMoa2002032

[6] https://www.who.int/emergencies/diseases/novel-coronavirus-2019/advice-for-public (zadnji pristup: 7.10.2020.)

[7] https://www.who.int/emergencies/diseases/novel-coronavirus-2019/interactive-timeline (zadnji pristup: 7.10.2020.)

[8] https://covid19.who.int/ (zadnji pristup: 7.10.2020)

[9] https://www.ecdc.europa.eu/en/covid-19/situation-updates (zadnji pristup: 7.10.2020.)

[10] https://www.koronavirus.hr/vladine-mjere/101 (zadnji pristup 10.10.2020.)

[11] Krueger D. Intermediate Macroeconomics (Teaching Manuscripts). University of Pennsylvania. (preveli i prilagodili: Bićanić I, Kukavčić J, Nikšić G, Spajić V. Kolovoz 2009.)

[12] Državni zavod za statistiku: https://www.dzs.hr/ (zadnji pristup 30.10.2020.)

[13] Eurostat: https://ec.europa.eu/eurostat/home (zadnji pristup 30.10.2020.)

[14] Bureau of Economic Analysis. Gross Domestic Product (Third Estimate), Corporate Profits (Revised), and GDP by Industry, Second Quarter 2020.

[15] http://www.stats.gov.cn/english/PressRelease/202007/t20200717_1776596.html (zadnji pristup: 30.10.2020)

[16] Croatia Airlines d.d. – Prvi kvartal 1Q., nerevidirano, konsolidirano, 2020.

[17] Croatia Airlines d.d. – Polugodišnji izvještaj 1H., nerevidirano, konsolidirano, 2020.

[18] Croatia Airlines d.d. – Treći kvartal 3Q., nerevidirano, konsolidirano, 2020.

[19] Aegean Airlines – First Quarter 2020 Financial Results

[20] Aegean Airlines – Second Quarter & First Half 2020 Financial Results

[21] Maistra d.d. – Prvi kvartal 1Q., nerevidirano, konsolidirano, 2020.

[22] Maistra d.d. – Polugodišnji izvještaj 1H., nerevidirano, konsolidirano, 2020.

[23] Maistra d.d. – Treći kvartal 3Q., nerevidirano, konsolidirano, 2020.

[24] NH Hotel Group – Q1 2020 Sales and Results

[25] NH Hotel Group – Sales and Results 1st Half 2020

[26] Dukat d.d. – Prvi kvartal 1Q., nerevidirano, nekonsolidirano, 2020.

[27] Dukat d.d. – Polugodišnji izvještaj 1H., nerevidirano, nekonsolidirano, 2020.

[28] Dukat d.d. – Treći kvartal 3Q., nerevidirano, nekonsolidirano, 2020.

[29] Kri-Kri Milk Industry S.A. – Interim Financial Statements for the Period 1.1.2020 - 31.3.2020

[30] Kri-Kri Milk Industry S.A. – Interim Financial Statements for the Period 1.1.2020 - 30.6.2020

[31] AD Plastik d.d. – Prvi kvartal 1Q., nerevidirano, konsolidirano, 2020.

[32] AD Plastik d.d. – Polugodišnji izvještaj 1H., nerevidirano, konsolidirano, 2020.

[33] AD Plastik d.d. – Treći kvartal 3Q., nerevidirano, konsolidirano, 2020.

[34] Sanok Rubber – Extended report for the 1st quarter of 2020

[35] Sanok Rubber – Extended report for the 1st half-year quarter of 2020

[36] JGL d.d. – Polugodišnji izvještaj 1H., nerevidirano, konsolidirano, 2020.

[37] Q1 2020 Unaudited Interim Report of the Krka Group and Krka, d.d.

[38] Unaudited Interim Report of the Krka Group and Krka, d.d. for the Hals Year Ended 30 June 2020

[39] INA d.d. – Prvi kvartal 1Q., nerevidirano, nekonsolidirano, 2020.

[40] INA d.d. – Polugodišnji izvještaj 1H., nerevidirano, nekonsolidirano, 2020.

[41] INA d.d. – Treći kvartal 3Q., nerevidirano, nekonsolidirano, 2020.

[42] Report on the operations of the Petrol Group and the company Petrol d.d., Ljubljana in the first three months of 2020

[43] Report on the operations of the Petrol Group and Petrol d.d., Ljubljana in the first six months of 2020

[44] ERICSSON NIKOLA TESLA d.d. – Prvi kvartal 1Q., nerevidirano, konsolidirano, 2020.

[45] ERICSSON NIKOLA TESLA d.d. – Polugodišnji izvještaj 1H., nerevidirano, konsolidirano, 2020.

[46] ERICSSON NIKOLA TESLA d.d. – Treći kvartal 3Q., nerevidirano, konsolidirano, 2020.

[47] HMS Networks Interim report 2020 January – March

[48] HMS Networks Interim report 2020 January – June

[49] HMS Networks Interim report 2020 January – September

[50] HRVATSKA ELEKTROPRIVREDA d.d. Zagreb Skraćeni konsolidirani financijski izvještaji za razdoblje završeno 30. lipnja 2020. godine

[51] ENDESA, S.A. and Subsidiaries Consolidated Management Report for the three-month period ended 31 March 2020

[52] ENDESA, S.A. and Subsidiaries Consolidated Management Report for the six-month period ended 30 June 2020

[53] Hrvatski Telekom d.d. – Prvi kvartal 1Q., nerevidirano, nekonsolidirano, 2020.

[54] Hrvatski Telekom d.d. – Polugodišnji izvještaj 1H., nerevidirano, nekonsolidirano, 2020.

[55] Hrvatski Telekom d.d. – Treći kvartal 3Q., nerevidirano, nekonsolidirano, 2020.

[56] Unaudited Business Report Telekom Slovenije Group and Telekom Slovenije, d. d., for period January to March 2020

[57] Unaudited Business Report Telekom Slovenije Group and Telekom Slovenije, d. d., for the period January to June 2020

[58] https://vlada.gov.hr/ (zadnji pristup: 30.10.2020.)

[59] Cajner H. Inženjerska statistika (materijali s predavanja)

[60] https://zse.hr/ (zadnji pristup: 8.11.2020.)

[61] https://www.hzjz.hr/ (zadnji pristup: 8.11.2020.)

[62] https://ourworldindata.org/ (zadnji pristup: 8.11.2020.)

PRILOZI

I. CD-R disc