

## PRETHODNO PRIOPĆENJE

UDK: 343

Primljeno: prosinac 2018.

NIKOLA PROTRKA\*

# Računalna prijevara – analiza djelotvornosti otkrivačke djelatnosti

## Sažetak

*Smisao je ovoga rada dati čitatelju uvid u pravnu normiranost kaznenog djela računalne prijevara opisanog u članku 271. Kaznenog zakona Republike Hrvatske. U radu se prikazuje i opis kaznenog djela iz Kaznenog zakona koji je bio na snazi do 2013. godine, zato što se podaci za analitičku obradu temelje na desetogodišnjem razdoblju koje pokriva činjenični opis iz oba navedena zakona.*

*U prvoj dijelu rada daje se prikaz i pojašnjenje opisa kaznenog djela po Kaznenom zakonu koji je bio na snazi do 2011. godine, te novog Kaznenog zakona koji je usvojen 2011. godine, a krenuo je s primjenom 2013. godine za analizirano kazneno djelo računalne prijevare.*

*U drugome dijelu rada provedeno je istraživanje djelotvornost rada hrvatskih institucija koje razrješavaju kaznena djela računalnih prijevara. Istraživanje obuhvaća i detaljniju kvalitativnu analizu broja prijavljenih te broja razriješenih slučajeva računalne prijevare u Republici Hrvatskoj zadnjih 10 godina. Izvor podataka nad kojima je provedeno cijekupno istraživanje za potrebe izrade ovog rada je Državni zavod za statistiku i Ministarstvo unutarnjih poslova..*

**Ključne riječi:** računalna prijevara, kazneno djelo, analitička obrada, kvalitativna analiza.

## 1. UVOD

U Republici Hrvatskoj, ali i izvan nje, javnost smatra da je rad hrvatskog pravosuđa nedovoljno djelotvoran. Primjerice, u članku *Hrvati od svih u EU najmanje vjeruju pravosuđu*, objavljenom 28. 5. 2018. na internetskom portalu Index.hr, navode se rezultati istraživanja *Eurobarometra* koje je naručila *Europska komisija*. Od 1000 anketiranih, samo je 23 % is-

---

\* dr. sc. Nikola Protrka, MUP RH, Zagreb, Hrvatska.

pitanika iz Hrvatske ocijenilo da je stanje u hrvatskom pravosuđu dobro, što je najmanji postotak u cijeloj EU. Nadalje, 35 % ispitanika iz Hrvatske smatra da hrvatsko pravosuđe nije neovisno niti dobro funkcioniра.<sup>1</sup>

Istraživački problem ovog rada jest djelotvornost rada institucija za provođenje zakona u odnosu na kazneno djelo računalne prijevare. Osim subjektivne ocjene šire javnosti, rad navedenih institucija može se analizirati i objektivno. Moguće je odrediti kriterije analize njegove djelotvornosti, postaviti hipoteze čija će se dokazivost kvantitativno analizirati kako bi se izveli nedvojbeni zaključci postoje li statističke značajnosti promatranih varijabli u promatranim pojавama koje pripadaju u opseg rada.

Predmet su hrvatska tijela za provođenje zakona koja razrješavaju kaznena djela računalnih prijevara. Promatrane su varijable prijavljeni i razriješeni slučajevi kaznenih djela računalnih prijevara u Republici Hrvatskoj u razdoblju 2008. – 2017. godine. U ovom se radu analizira pitanje postoji li statistički značajna razlika između dviju promatranih varijabli. U slučaju da ne postoji, rad hrvatskih institucija koje razrješavaju kaznena djela računalnih prijevara mogao bi se nedvojbeno smatrati djelotvornim. Naime, to bi značilo da broj razriješenih slučajeva u cijelokupnom promatranoj razdoblju slijedi broj prijavljenih slučajeva.

Kazneno pravo Republike Hrvatske sve do 2000-ih godina nije prepoznavalo oblik prijevare koji je uključivao uporabu računalnog sustava kao posebno kazneno djelo. Do tada su prema Vuletić i Nedić (2014) sudovi prepoznavali ovo djelo kao djelo teške krađe.

Računalna prijevara prvi je put normirana Kaznenim zakonom iz 2003. godine pod glavom XVII. – kaznena djela protiv imovine. Nalazila se pod člankom 224.a, stavkom 1. u prvotno drukčijem sadržaju negoli je danas, a glasila je: „*Tko s ciljem da sebi ili drugome pribavi protupravnu imovinsku korist, izmjeni tuđe računalne podatke ili računalne programe ili na drugi način utječe na njihovo korištenje i na taj način prouzroči štetu drugome...*“<sup>2</sup>. Sadržaj sličan današnjem članak je dobio s dopunom iz 2004. godine<sup>3</sup>, da bi novim Kaznenim zakonom iz 2011. godine s identičnim sadržajem bio premješten u zasebnu glavu Kaznenog zakona XXV. – kaznena djela protiv računalnih sustava, programa i podataka, gdje je i danas.<sup>4</sup>

Smisleno je da je kazneno djelo računalne prijevare smješteno pod računalna kaznena djela jer se ipak radi o nešto drukčijem kaznenom djelu, nego što su to kaznena djela protiv imovine, najviše zbog toga što se radnja ovoga djela odvija u kibernetičkom prostoru (Protrka 2018).

Sadašnji Kazneni zakon računalnu prijevaru propisuje člankom 271.: „*Tko s ciljem da sebi ili drugome pribavi protupravnu imovinsku korist unese, izmjeni, izbriše, ošteti, učini neuporabljivim ili nedostupnim računalne podatke ili ometa rad računalnog sustava i na taj način prouzroči štetu drugome, kaznit će se...*“.

---

<sup>1</sup> Hrvati od svih u EU-u najmanje vjeruju pravosuđu. (28. 5. 2018.) Preuzeto 26. 11. 2018. iz Index.hr: <https://www.index.hr/vijesti/clanak/hrvati-od-svih-u-eu-najmanje-vjeruju-pravosudju/2000769.aspx>

<sup>2</sup> Kazneni zakon RH, NN 111/03.

<sup>3</sup> Ibid, NN 105/04.

<sup>4</sup> Ibid, NN 125/11.

Osim što je moguće da ovim kaznenim djelom osoba pribavlja sebi odnosno drugome imovinsku korist, propisano je da se kažnjava i samo ako svojim postupcima nanese štetu drugoj osobi. Modaliteti počinjenja djela računalne prijevare su mnogi, stoga su ovakvim sadržajem članka obuhvaćene razne mogućnosti počinjenja.

Prema Vuletiću i Nediću (2014) postoje dvije vrste računalnih prijevara. To su izravna računalna prijevara i neizravna računalna prijevara. Razlika između ovih pojordova jest u objektu prijevare, odnosno, pokušava li se prevariti računalo ili fizička osoba.

Pod *izravnom računalnom prijevarom* smatra se prijevara fizičke osobe putem računalnog sustava. Takvo djelo je u ovom radu razmatrani način prijevare – *phishing*, kod kojega kibernetički kriminalac obmanjuje žrtvu uporabom računalnog sustava. Ovakav oblik kaznenog djela moguće je počiniti putem elektroničke pošte (u dalnjem tekstu: e-mail), ali i putem drugih sredstava komunikacije – *smishing, vishing*. Najjednostavniji oblik *phishinga* bio bi lažno predstavljanje kibernetičkog kriminalaca koji putem e-maila zatraži od buduće žrtve podatke bankovnog računa i pristupne lozinke zbog npr. hitne bankovne provjere vlasništva nad računom. Žrtva u ovom slučaju smatra da je pošiljatelj e-maila institucija (njezina banka) koja podatke traži iz opravdanih razloga. Iako se ovakav način prijevare možda čini smiješnim i nevjerojatnim on predstavlja ozbiljnu prijetnju jer, statistički gledajući, što više osoba dobije ovakvu poruku, veće su mogućnosti da neka od njih odgovori i postane žrtva prijevare. (Protrka i Jovanovski 2018)

Pod *neizravnom računalnom prijevarom* smatra se varanje samog računalnog sustava. Primjer neizravne prijevare, odnosno varanja računalnog sustava, slučaj je kada osoba s tuđom bankovnom karticom podigne određeni novčani iznos na bankomatu. Ovo se smatra varanjem računalnog sustava jer računalo smatra da mu pristupa ovlašteni korisnik. Možemo reći da je u ovom slučaju računalni sustav u zabludi jer on putem četveroznamenkastog koda (PIN-a) provjerava pravo pristupa određenom bankovnom računu.

Problem ovakvih vrsta prijevara (izravne računalne prijevare) sastoji se u činjenici da one imaju međunarodni karakter. Iako kriminalci mogu biti iz zemlje iz koje je i žrtva, ove prijevare teže se otkrivaju ako se počinitelj nalazi u drugoj državi. Takvom je kriminalcu bez međunarodne pravne pomoći nemoguće ući u trag. To čini ovakva kaznena djela primamljiva počiniteljima; tim više što su kriminalci sa samo nekoliko klikova mišem u mogućnosti poslati milijune e-mailova i onda čekati da im se žrtva sama javi. S obzirom na to da se novčano poslovanje sve više premješta u virtualni prostor, može se pretpostaviti da će ovakvih prijevara u budućnosti biti sve više, ali i da će s razvojem tehnologije prijevare biti sve sofisticiranije (Badovinac 2018). Takve vrste prijevara poznate su pod nazivom *phishing*, a sam pojam koristi se u Sjedinjenim Američkim Državama još od devedesetih godina prošlog stoljeća.

## 2. ANALIZA DJELOTVORNOSTI RAZRJEŠAVANJA KAZNENOG DJELA RAČUNALNE PRIJEVARE

### 2.1. Ciljevi istraživanja

Više je ciljeva istraživanja u ovome znanstvenom radu. Primarni je cilj istražiti djelotvornost rada hrvatskih institucija koje razrješavaju kaznena djela računalnih prijevara. Za potrebe provođenja te analize u radu se postavlja hipoteza H: *Institucije zadužene za razrješavanje kaznenih djela računalne prijevare u Republici Hrvatskoj rade djelotvorno.* Istraživanje obuhvaća i detaljniju kvalitativnu analizu broja prijavljenih te broja razriješenih slučajeva računalne prijevare u Republici Hrvatskoj u razdoblju zadnjih 10 godina, odnosno između 2008. godine i 2017. godine. Te analize predstavljaju sekundarne ciljeve rada.

### 2.2. Izvor podataka

Izvor podataka nad kojima je provedeno cijelokupno istraživanje za potrebe izrade ovo-ga rada jesu *Državni zavod za statistiku i Ministarstvo unutarnjih poslova*. Opis kaznenih djela računalne prijevare i sankcije za takvo kazneno navedeni su u članku 224.a *Kaznenog zakona* koji je vrijedio do 2013. Od 2013. godine nadalje za takvo djelo je mjerodavan članak 271. *Kaznenog zakona*. Podaci o brojevima prijavljenih i razriješenih slučajeva kaznenog djela računalne prijevare preuzeti su od Ministarstva unutarnjih poslova<sup>5</sup> i prikazani su u tablici 1.

Tablica 1: Broj prijavljenih i broj razriješenih slučajeva kaznenih djela računalne prijevare u Republici Hrvatskoj u razdoblju 2008. – 2017. godine

Godina	Broj prijavljenih slučajeva	Broj razriješenih slučajeva
2008.	346	320
2009.	305	278
2010.	903	886
2011.	684	638
2012.	505	459
2013.	583	525
2014.	960	864
2015.	1361	1215
2016.	1365	1238
2017.	1114	915

Izvor: Obradio autor prema podacima iz *Ministarstva unutarnjih poslova*

<sup>5</sup> Statistika Ministarstva unutarnjih poslova – <https://www.mup.hr/ministarstvo/dokumenti/statistika>, preuzeto 30. studenoga 2018.

## 2.3. Metodologije istraživanja

Istraživanje broja prijavljenih i broja razriješenih slučajeva računalne prijevare u Republici Hrvatskoj u razdoblju između 2008. godine i 2017. godine obuhvaća izračun i interpretaciju najvažnijih pokazatelja *deskriptivne statistike*. Vrijednosti odabralih pokazatelja prikazane su tablično za obje promatrane pojave. Ključne su vrijednosti tekstualno interpretirane.

Nadalje, istraživanje obuhvaća i izrade prognostičkih trend modela pojавa prijava i razrješenja slučajeva kaznenog djela računalne prijevare uporabom metoda *linearne* i *eksponencijalne regresije*. Izračuni prognostičkih trend modela prikazani su u radu tablično. Interpretacija podrazumijeva tekstualno objašnjenje ključnih pokazatelja trendova.

Treća se komponenta istraživanja odnosi na primarni cilj rada hrvatskih institucija zaduženih za razrješavanje kaznenih djela računalne prijevare. Djelotvornost rada hrvatskih institucija zaduženih za razrješavanje kaznenih djela računalne prijevare istraživana je testiranjem dokazivosti u radu postavljene hipoteze. Dokazivost hipoteze testirana je provođenjem statističkog testa kojim je analizirano eventualno postojanje statistički značajne razlike između medijana ranga pojave prijavljivanja kaznenih djela računalnih prijevara i medijana ranga pojave razrješavanja kaznenih djela računalnih prijevara u promatranom razdoblju. U slučaju nepostojanja statistički značajne razlike, u radu bi se postavljena hipoteza mogla smatrati nedvojbeno potvrđenom. To bi značilo da hrvatske institucije zadužene za razrješavanje kaznenih djela računalne prijevare rade djelotvorno, odnosno da dinamika pojave razrješavanja kaznenih djela računalne prijevare slijedi dinamiku pojave prijavljivanja kaznenih djela računalne prijevare, odnosno da se broj nerazriješenih slučajeva kaznenih djela računalne prijevare godišnje ne povećava.

Izračuni provedeni uporabom svih u radu primjenjivanih metoda obavljeni su uporabom informatičkog programa MS Excel. Za potrebe testiranja postavljene hipoteze u radu je rabljena u Excel dopunski ugrađena funkcija iz informatičkog programa XLST. (Papić 2014)

## 3. ANALIZA I INTERPRETACIJA REZULTATA ISTRAŽIVANJA

U ovom se poglavlju prikazuju i interpretiraju rezultati istraživanja provedenog za potrebe izrade ovog znanstvenog rada.

### 3.1. Analiza broja prijavljenih i razriješenih slučajeva

U tablici 2 prikazani su brojevi prijavljenih slučajeva kaznenih djela računalne prijevare u Republici Hrvatskoj u razdoblju 2008. – 2017. s pripadajućim verižnim indeksima i stopama rasta te vrijednosti aritmetičke i geometrijske sredine verižnih indeksa i stopa rasta. Aritmetička sredina verižnih indeksa pojave prijave kaznenih djela računalne prijevare iznosi 126,40 što znači da je prosječni godišnji rast broja prijava 26,40 %. Geometrijska sredina verižnih indeksa predmetne pojave iznosi 113,87 što znači da je prosječni godišnji rast broja prijava, odnosno stopa rasta 13,87 %. Za potrebe ovog rada, odnosno promatranja pojave prijave kaznenih djela računalne prijevare relevantna je geometrijska sredina jer se promatrana pojava prati u vremenu. Vidljivo je da je vrijednost geometrijske sredine manja od vrijednosti aritmetičke sredine. Vrijednost geometrijske sredine kasnije će se u radu uspoređivati

s vrijednosti koja se odnosi na prosječnu godišnju stopu rasta broja prijava kaznenih djela računalne prijevare u eksponencijalnom trend modelu. (Šošić 2006)

Tablica 2: Verižni indeksi i stope rasta prijavljenih kaznenih djela računalne prijevare

Prijavljena kaznena djela računalne prijevare				
Godina	Relativna godina	Broj	Verižni indeks	Stopa rasta
2008.	0	346	–	–
2009.	1	305	88,15 %	-11,85 %
2010.	2	903	296,07 %	196,07 %
2011.	3	684	75,75 %	-24,25 %
2012.	4	505	73,83 %	-26,17 %
2013.	5	583	115,45 %	15,45 %
2014.	6	960	164,67 %	64,67 %
2015.	7	1361	141,77 %	41,77 %
2016.	8	1365	100,29 %	0,29 %
2017.	9	1114	81,61 %	-18,39 %
Aritmetička sredina			126,40	26,40 %
Geometrijska sredina			113,87	13,87 %

Izvor: Obradio autor prema podacima iz *Ministarstva unutarnjih poslova*

U tablici 3 prikazani su brojevi razriješenih slučajeva kaznenih djela računalne prijevare u Republici Hrvatskoj u razdoblju 2008. – 2017. s pripadajućim verižnim indeksima i stopama rasta te vrijednosti aritmetičke i geometrijske sredine verižnih indeksa i stopa rasta. Aritmetička sredina verižnih indeksa pojave razriješenih kaznenih djela računalne prijevare iznosi 127,21 što znači da je prosječni godišnji rast broja prijava 27,21 %. Geometrijska sredina verižnih indeksa predmetne pojave iznosi 112,38 što znači da je prosječni godišnji rast broja prijava 12,38 %. Za promatranje pojave razriješenih kaznenih djela računalne prijevare relevantna je geometrijska sredina jer se pojava prati u vremenu. I u ovom slučaju, i za ovu je pojavu vidljivo da je vrijednost geometrijske sredine manja od vrijednosti aritmetičke sredine. Vrijednost geometrijske sredine kasnije će se u radu uspoređivati s vrijednostima u eksponencijalnom trend modelu koja se odnosi na prosječnu godišnju stopu rasta broja razriješenih kaznenih djela računalne prijevare.

Tablica 3: Verižni indeksi i stope rasta razriješenih kaznenih djela računalne prijevare

Razriješena kaznena djela računalne prijevare				
Godina	Relativna godina	Broj	Verižni indeks	Stopa rasta
2008.	0	320	–	–
2009.	1	278	86,88 %	-13,13 %
2010.	2	886	318,71 %	218,71 %
2011.	3	638	72,01 %	-27,99 %
2012.	4	459	71,94 %	-28,06 %
2013.	5	525	114,38 %	14,38 %
2014.	6	864	164,57 %	64,57 %
2015.	7	1215	140,63 %	40,63 %
2016.	8	1238	101,89 %	1,89 %
2017.	9	915	73,91 %	-26,09 %
Aritmetička sredina			127,21	27,21 %
Geometrijska sredina			112,38	12,38 %

Izvor: Obradio autor prema podacima iz Ministarstva unutarnjih poslova

Vrijednosti verižnih indeksa, odnosno pripadajućih stopa rasta pokazuju da je u razdoblju 2008.–2017. velika varijabilnost brojeva prijavljenih, a i brojeva razriješenih slučajeva kaznenih djela računalne prijevare. Tijekom promatranog razdoblja dolazilo je do velikog povećanja brojeva prijava i razriješenja kaznenih djela računalne prijevare, ali i do pada tih brojeva. Primjerice, broj prijavljenih slučajeva kaznenih djela računalne prijevare u 2010. godini bio je gotovo 3 puta veći od broja prijava u 2009. godini. Stopa porasta bila je 196,07 %. Iste je godine broj razriješenih slučajeva kaznenih djela računalne prijevare bio više od 3 puta veći negoli u 2009. godini. Stopa porasta bila je 218,71 %.

U 2016. godini stopa porasta prijavljenih slučajeva kaznenih djela računalne prijevare bila je veća u odnosu na 2015. godinu manje od 1 %, odnosno tek 0,29 %. Iste je godine stopa porasta razriješenih slučajeva kaznenih djela računalne prijevare bila veća u odnosu na 2015. godinu tek nešto više od 1 %, odnosno tek 1,89 %.

U tablici 4 prikazane su vrijednosti najvažnijih pokazatelja deskriptivne statistike za pojave prijava i razriješenja kaznenih djela računalne prijevare u Republici Hrvatskoj u razdoblju između 2008. – 2017. godine. Na temelju vrijednosti prikazanih u tablici 4 može se zaključiti da su vrijednosti varijanci i standardne varijacije prilično velike u odnosu na pripadajuće aritmetičke sredine zbog čega su koeficijenti varijacije neuobičajeno visoki, gotovo 50 % što ukazuje na veliku varijabilnost podataka o broju prijavljenih i razriješenih slučajeva kaznenih djela računalne prijevare u Republici Hrvatskoj u razdoblju 2008. – 2017. godine.

*Tablica 4: Odabrani pokazatelji deskriptivne statistike za pojave prijava i razrješenja kaznenih djela računalne prijevare u Republici Hrvatskoj u razdoblju između 2008. – 2017. godine*

Odabrani pokazatelji deskriptivne statistike	Prijavljeni slučajevi	Razriješeni slučajevi
Minimalna vrijednost	305	278
Maksimalna vrijednost	1365	1238
Raspon	1060	960
Medijan	793,50	751
Aritmetička sredina	812,60	733,80
Geometrijska sredina	721,31	654,43
Varijanca	151763,82	118443,96
Standardna devijacija	389,57	344,16
Koeficijent varijacije	47,94 %	46,90 %

*Izvor: Obradio autor prema podacima iz Ministarstva unutarnjih poslova*

U tablici 5 prikazane su vrijednosti parametara linearnog trend modela za pojavu prijavljenih kaznenih djela računalne prijevare u Republici Hrvatskoj u razdoblju 2008. – 2017.

*Tablica 5: Parametri linearnog trend modela za pojavu prijavljenih kaznenih djela računalne prijevare u Republici Hrvatskoj u razdoblju 2008. – 2017.*

<i>Regression Statistics</i>	
Multiple R	0,8256006
R Square	0,6816163
Adjusted R Square	0,6418184
Standard Error	233,1501727
Observations	10

<i>ANOVA</i>					
	<i>df</i>	<i>SS</i>	<i>MS</i>	<i>F</i>	<i>Significance F</i>
Regression	1	931002,375	931002,37	17,12692	0,00326024
Residual	8	434872,024	54359,00		
Total	9	1365874,4			

	Coefficients	Standard Error	t Stat	P-value	Lower 95%	Upper 95%
Intercept	334,56363	137,034903	2,4414483	0,0404729	18,5605830	650,5666
X Variable 1	106,23030	25,6689892	4,1384684	0,0032602	47,0375077	165,4230

Izvor: Obradio autor prema podacima iz *Ministarstva unutarnjih poslova*

Interpretacija ključnih parametara ukazuje na to da je vrijednost konstante *Intercept* = 334. Ta vrijednost ukazuje na početnu vrijednost linearog trend modela pojave razriješenja kaznenih djela računalne prijevare u Republici Hrvatskoj. Budući da je stvarna 346 postoji odstupanje od 3,46 % što se može smatrati malim odstupanjem od stvarnog broja prijava kaznenih djela računalne prijevare u 2008. godini, odnosno početnoj godini promatranog razdoblja.

Vrijednost konstante *X Variable 1* = 106,23 ukazuje na to da je prosječni godišnji porast broja prijava kaznenih djela računalne prijevare 106. Dakle, jednadžba linearog trend modela pojave prijava kaznenih djela računalne prijevare u Republici Hrvatskoj u razdoblju 2008. – 2017. godine jest  $y = 106,23x + 334,56$ .

Vrijednost koeficijenta determinacije, odnosno konstante *R Square* = 0,6816 ukazuje na nisku reprezentativnost linearog trend modela pojave, odnosno da linearni trend model točno opisuje 68,16 % pojave broja prijava kaznenih djela računalne prijevare u Republici Hrvatskoj u promatranom razdoblju 2008. – 2017. godine.

U tablici 6 prikazane su vrijednosti parametara linearog trend modela za pojavu razriješenih kaznenih djela računalne prijevare u Republici Hrvatskoj u razdoblju 2008. – 2017.

*Tablica 6: Parametri linearog trend modela za pojavu razriješenih kaznenih djela računalne prijevare u Republici Hrvatskoj u razdoblju 2008. – 2017.*

Regression Statistics	
Multiple R	0,7711764
R Square	0,5947130
Adjusted R Square	0,5440521
Standard Error	232,3881712
Observations	10

## ANOVA

	<i>df</i>	<i>SS</i>	<i>MS</i>	<i>F</i>	<i>Significance F</i>
Regression	1	633961,503	633961,50	11,73910	0,00900468
Residual	8	432034,097	54004,26		
Total	9	1065995,6			

	<i>Coefficients</i>	<i>Standard Error</i>	<i>t Stat</i>	<i>P-value</i>	<i>Lower 95%</i>	<i>Upper 95%</i>
Intercept	339,32727	136,587033	2,4843300	0,0378552	24,3570077	654,2975
X Variable 1	87,66060	25,585095	3,4262371	0,0090046	28,6612698	146,6599

Izvor: Obradio autor prema podacima iz *Ministarstva unutarnjih poslova*

Interpretacija ključnih parametara ukazuje na to da je vrijednost konstante *Intercept* = 334. Ta vrijednost ukazuje na početnu vrijednost linearog trend modela pojave razrješenja kaznenih djela računalne prijevare u Republici Hrvatskoj. Budući da je stvarna 320, postoji odstupanje od 4,37 % što se može smatrati malim odstupanjem od stvarnog broja razrješenih kaznenih djela računalne prijevare u 2008. godini, odnosno početnoj godini promatranog razdoblja.

Vrijednost konstante *X Variable 1* = 87,66 ukazuje na to da je prosječni godišnji porast broja razrješenih kaznenih djela računalne prijevare 88. Dakle, jednadžba linearog trend modela pojave prijava kaznenih djela računalne prijevare u Republici Hrvatskoj u razdoblju 2008. – 2017. godine jest  $y = 87,66x + 339,32$ .

Vrijednost koeficijenta determinacije, odnosno konstante *R Square* = 0,5947 ukazuje na nisku reprezentativnost linearog trend modela pojave, odnosno da linearni trend model točno opisuje 59,47 % pojave broja razrješenih kaznenih djela računalne prijevare u Republici Hrvatskoj u promatranom razdoblju 2008. – 2017. godine.

U radu je postavljena hipoteza H: *Institucije zadužene za razrješavanje kaznenih djela računalne prijevare u Republici Hrvatskoj rade djelotvorno*. Dokazivost hipoteze testirana je provođenjem testa kojim se utvrđuje postoji li statistički značajna razlika između medijana rangiranih pojava prijava kaznenih djela računalne prijevare i pojave razrješavanja kaznenih djela računalne prijevare u Republici Hrvatskoj u promatranom razdoblju. Rezultati testiranja njezine dokazivosti prikazani su u tablici 7. Analiza je provedena uporabom Mann - Whitneyeva testa.

U slučaju da statistički značajna razlika ne postoji, rad hrvatskih institucija zaduženih za razrješavanje kaznenih djela računalne prijevare mogao bi se nedvojbeno smatrati djelotvornim. Za potrebe testiranja dokazivosti u radu postavljene hipoteze, ključna je vrijednost parametra *p* koja ukazuje na to postoji li statistički značajna razlika medijana rangova pojave prijevare kaznenih djela računalne prijevare i pojave razrješenja kaznenih djela računalne

prijevare u Republici Hrvatskoj u razdoblju 2008. – 2017. Budući da je vrijednost parametra  $p = 0,579$ , što je znatno više od granične vrijednosti 0,05, promatrane pojave nemaju statistički značajnu razliku medijana rangova može se izvesti zaključak da se hipoteza H: *Institucije zadužene za razrješavanje kaznenih djela računalne prijevare u Republici Hrvatskoj rade djelotvorno* može smatrati nedvojbeno potvrđenom.

Tablica 7: Izračun Mann - Whitneyeva testa

Variable	Number	Observations						Std. deviation
		With missing data	Without missing data	Minim-um	Maxi-mum	Mean		
Prijavljeno	10	0	10	305,000	1365,000	812,600	389,569	
Razriješeno	10	0	10	278,000	1238,000	733,800	344,157	

Mann – Whitneyev test

Two-tailed test:

U	58
U (standardized)	0,000
Expected value	50,000
Variance (U)	175,000
p-value (Two-tailed)	0,579
alpha	0,05

The p-value is computed using an exact method. Time elapsed: 0s.

Test interpretation:

H0: The difference of location between the samples is equal to 0.

Ha: The difference of location between the samples is different from 0.

As the computed p-value is greater than the significance level alpha=0,05, one cannot reject the null hypothesis H0.

Izvor: Obradio autor prema podacima iz *Ministarstva unutarnjih poslova*

### 3.2. Prikaz vrsta odluka u strukturi prijavljenih počinitelja

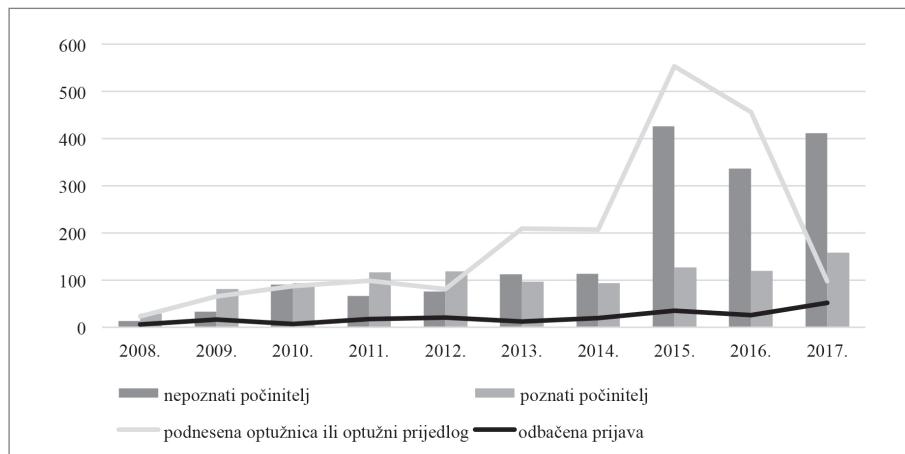
Za prikaz podataka o broju prijavljenih osoba za kazneno djelo računalne prijevare rabljeni su podaci *Državnog zavoda za statistiku Republike Hrvatske*<sup>6</sup>, iz kojih je vidljiv broj prijavljenih osoba, po strukturi i vrsti odluke, za promatrano razdoblje.

Tablica 8: Prikaz po strukturi

Računalna prijevara (članak 271.)	čl. 224.a										čl. 271.		
	GODINA	2008.	2009.	2010.	2011.	2012.	2013.	2014.	2015.	2016.	2008.	2009.	
Podnesena optužnica ili optužni prijedlog		23	65	87	99	81	209	207	553	456	98	13	33
Nepoznati počinitelj		13	33	90	66	76	112	113	426	336	411	29	81
Poznati počinitelj		29	81	94	116	119	97	94	127	120	158	6	16
Odbačena prijava		7	17	21	12	19	35	26	52				

Izvor: Obradio autor prema podacima iz *Državnog zavoda za statistiku*

Grafikon 1 daje uvid u podatke koji se odnose na broj podnesenih optužnica ili optužnih prijedloga, odbačenih prijava, kao i podatke o broju nepoznatih i poznatih počinitelja za sve stavke kaznenog djela računalne prijevare Kaznenog zakona u vremenskom razdoblju 2008. do 2017., koje predstavlja najveći udio u ukupnom broju kaznenih djela iz domene kaznenih djela protiv računalnih sustava, programa i podataka, a drugo je po broju počinjenja kaznenih djela iz glave gospodarskog kriminaliteta gdje pripadaju i računalna kaznena djela.



Grafikon 1: Struktura podataka  
Izvor: Obradio autor prema podacima iz *Državnog zavoda za statistiku*

<sup>6</sup> Državni zavod za statistiku Republike Hrvatske - <https://www.dzs.hr/>, datum pristupa 30. 11. 2018.

#### 4. ZAKLJUČAK

Istraživački dio rada odnosi se na provođenje izračuna osnovnih pokazatelja deskriptivne statistike za pojavu prijave kaznenih djela računalne prijevare i pojavu razrješenja kaznenih djela računalne prijevare u Republici Hrvatskoj u razdoblju 2008. – 2017., izrade trend modela za obje promatrane pojave te testiranje dokazivosti u radu postavljene hipoteze.

Vrijednosti odabralih pokazatelja deskriptivne statistike za obje promatrane pojave prikazane su tablici 4. Koeficijenti varijacije za obje pojave neuobičajeno su visoki, gotovo 50 % što ukazuje na veliku varijabilnost podataka u brojevima prijavljenih i razrješenih slučajeva kaznenih djela računalne prijevare u Republici Hrvatskoj u razdoblju 2008. – 2017. godine.

Za svaku od promatranih pojava izrađen je linearni i eksponencijalni trend model. Početne vrijednosti u tri od četiri modela ne odstupaju znatno od stvarnih, što se može smatrati dobrim. Međutim, koeficijenti determinacije u svim su modelima prilično niži od prihvatljivih što ukazuje na nisku reprezentativnost trend modela za obje promatrane pojave, odnosno za sva četiri u radu predstavljena trend modela.

U radu je postavljena hipoteza H: *Institucije zadužene za razrješavanje kaznenih djela računalne prijevare u Republici Hrvatskoj rade djelotvorno.* Testiranje njezine dokazivosti provedeno je provođenjem Mann - Whitneyeva testa. Ključna vrijednost izračuna jest vrijednost parametra  $p = 0,579$ , što je znatno više od granične vrijednosti 0,05; stoga promatrane pojave nemaju statistički značajnu razliku medijana rangova. Budući da ne postoji statistički značajna razlika medijana rangova pojave prijavljivanja i pojave razrješavanja kaznenog djela računalne prijevare, može se izvesti nedvojbeni zaključak da hrvatske institucije zadužene za razrješavanje kaznenih djela računalne prijevare rade djelotvorno. Otkrivačka djelatnost i učinkovitost kriminalističkog istraživanja ove vrste kaznenog djela više je nego dvostruko veća u 2015. i 2016. godini, vjerojatno zato što je ova domena suzbijanja kriminala ojačana novim kadrovskim i tehničkim resursima.

#### LITERATURA

1. Vuletić, I., i Nedić, T. (2014). Računalna prijevara u hrvatskom kaznenom pravu, *Zbornik Pravnog fakulteta Sveučilišta u Rijeci*, 35(2), str. 679.-692.
2. Badovinac, Ž., (2018). Kriminalističko istraživanje računalnih prijevara – phishing, diplomski rad, Visoka policijska škola, Zagreb.
3. Papić, M. (2014). Primijenjena statistika u MS Excelu. Zagreb: Zoro.
4. Šošić, I. (2006). Primijenjena statistika. Zagreb: Školska knjiga.
5. Protrka, N. (2018). Međunarodna suradnja i sigurnost u suzbijanju kriminaliteta u kibernetičkom prostoru 2018., doktorska disertacija, Odjel za informacijske znanosti, Zadar.
6. Protrka, N.; Jovanovski, G. (2018). Using Security Intelligence in Corporations // Journal of Forensic Sciences & Criminal Investigation (JFSCI), 9 (2018), 5; 555775, 11 doi:10.19080/JFSCI.2018.09.555775

7. *Kazneni zakon RH*, NN 125/11., 144/12., 56/15., 61/15., 101/17.
8. *Kazneni zakon RH*, NN 111/03., 105/04.
9. Statistička izvješća Državnog zavoda za statistiku Republike Hrvatske (2008. – 2017.). Objavljeni podaci, Publikacije, Kazneno pravosude i socijalna zaštita (metodologija ESSPROS). Dohvaćeno iz Punoljetni počinitelji kaznenih djela, prijave, optužbe i osude. Dostupno na: [https://www.dzs.hr/Hrv\\_Eng/publication/](https://www.dzs.hr/Hrv_Eng/publication/), datum pristupa 30. listopada 2018.
10. Statistika Ministarstva unutarnjih poslova (2008. –2017.). Statistički pregled te-meljnih sigurnosnih pokazatelja i rezultata rada. Dohvaćeno iz Statistika MUP-a - Pregled sigurnosnih pokazatelja: <https://www.mup.hr/UserDocsImages/statisti-ka/>, datum pristupa 30. listopada 2018.

## Summary

---

### Nikola Protrka

#### Computer Fraud – Analysis of Effectiveness of Discovery Activity

The purpose of this paper is to give the reader an insight into the legal standardization of the criminal offence of computer fraud described in Article 271. of the Criminal Code of the Republic of Croatia. The paper also outlines a description of the computer fraud from the Criminal Code that was valid until 2013, because the data for analytical processing are based on a ten-year period covering the factual description of both laws.

The first part of the paper reviews and clarifies the description of the criminal offence under the Criminal Code that came into force until 2011 and the new Criminal Code passed in 2011, and started with the 2013 application for the analysed criminal offence of Computer Fraud.

In the second part of the paper, a study was carried out on the effectiveness of the work of Croatian institutions that relieve criminal offences of computer fraud. The research also includes a more detailed qualitative analysis of the number of reported cases and the number of cases of computer fraud in the Republic of Croatia over the last 10 years. The source of data on which the entire research conducted for the purpose of this work is the Croatian Bureau of Statistics and the Ministry of the Interior.

**Keywords:** computer fraud, criminal offense, analytical processing, qualitative analysis.