



Creative Commons Attribution –
NonCommercial 4.0 International License

Izvorni znanstveni rad

<https://doi.org/10.31784/zvr.14.1.8>

Datum primitka rada: 6. 2. 2025.

Datum prihvaćanja rada: 9. 9. 2025.

UČINKOVITOST PREDVIĐANJA POMOĆU STROJNOG UČENJA ZA POTREBE KONTROLINGA U PROCESU DONOŠENJA ODLUKA

Uwe Lebefromm

Dr. sc., predavač, Kooperativno državno sveučilište Mannheim, Fakultet poslovne informatike,
Coblitzallee 1-9, 68163 Mannheim, Njemačka; e-mail: lebefrommuwe@outlook.de

Neda Vitezić

Dr. sc., redovita profesorica u trajnom zvanju, Sveučilište u Rijeci, Ekonomski fakultet, Ivana Filipovića 4,
51 000 Rijeka, Hrvatska; e-mail: neda.vitezic@efri.uniri.hr

Antonija Petrić

Dr. sc., docentica, Sveučilište u Rijeci, Ekonomski fakultet, Ivana Filipovića 4, 51 000 Rijeka, Hrvatska;
e-mail: antonija.petric@efri.uniri.hr

SAŽETAK

Predmet su ovog istraživanja razvoj i primjena prediktivnih modela dobivenih uporabom matematičko statističkih metoda i umjetnom inteligencijom, tj. strojnim učenjem. Cilj je rada razvijanje modela za implementaciju digitalne transformacije u procese operativnog odlučivanja za potrebe kontrolinga i upravljanja. Kontroling je kao disciplina i funkcija u poduzeću zadužen za analizu postojećeg i predviđanje budućeg poslovanja te u tu svrhu i uporabe sofisticiranih metoda i alata. Ovim radom dokazuje se da je poslovno predviđanje temeljeno na povijesnim činjenicama evoluiralo u poslovno predviđanje procijenjeno na temelju strojnog učenja. U radu je prikazan inovativni stohastički model predviđanja na primjeru pružanja usluga u jednoj marini u Hrvatskoj. Rezultati istraživanja su četiri prikazana modela za ugovaranje i pridobivanje klijenata koji se koriste uslugama marine. Dobiveni rezultati potvrđuju visoku razinu pouzdanosti modela predviđanja uporabom digitalnih alata za potrebe kontrolinga u procesu donošenja odluka. Kroz razvijene metode pretvaranja manualnih procesa u izbornu automatizirane procese odlučivanja, ovaj rad pridonosi inovativnosti kontrolinga u digitalnom okruženju.

Ključne riječi: predviđanje, strojno učenje, kontroling, odlučivanje

1. UVOD

Odlučujuću ulogu s aspekta konkurentnosti poduzeća u budućnosti će imati digitalizirani poslovni modeli. Poslovni model definicija je logične strukture kako bi se postigla konkurentna prednost i pozitivan ekonomski rezultat, a poslovni model bit će uspješan ako je inovativan. To je područje u kojem kontroleri imaju središnju ulogu inovatora, u kojem pridonose digitalizaciji postojećih ili razvoju novih poslovnih procesa. Put do digitalnoga poslovnog modela uključuje fleksibilnost lanaca vrijednosti, korištenje potencijalima optimizacije, decentraliziranom kontrolom i korištenje informacijama u stvarnom vremenu za podršku odlučivanju (Gassmann, Sutter, 2019). Ovo istraživanje polazi od informacija potrebnih u stvarnom vremenu za podršku odlučivanju, prvenstveno kroz mogućnosti pojednostavljenja podatkovnih modela suvremenih poslovnih aplikacija u informacijskoj tehnologiji. Odnosno, ovo istraživanje ima za svrhu razviti model za implementaciju digitalne transformacije u procese operativnog odlučivanja za potrebe kontrolinga i upravljanja. Cilj je rada istražiti preferencije pružatelja usluga te uporabom prediktivne analitike i teorije vjerojatnosti razviti stohastičke modele odlučivanja temeljene na znanosti o podacima.

Dakle, ključna uloga u kreiranju poslovnih modala predviđanja pripada kontroleru koji nije više samo sakupljač podataka i statističar nego daleko više — analitičar i savjetnik menadžmentu, stručnjak koji se pozicionira između podatkovnog znanstvenika i menadžmenta. Digitalno doba mijenja poziciju kontrolera u poduzeću, a time i odnos između njega i menadžmenta. Odgovornost je kontrolera izbjeći pogrešno tumačenje podataka i pronaći ključne podatke relevantne za donošenje odluka (Vitezić, Lebefromm, 2018). Generiranje goleme količine podataka i izračuni ključnih pokazatelja nedovoljni su za učinkovito korporativno upravljanje. U dinamičnom okruženju razni su nepredvidivi utjecaji svih aktera, a ne samo kupaca, dobavljača i konkurenata. Zato je nužan kontroling, analitičko-planska-informativna i savjetodavna funkcija kao potpora učinkovitu upravljanju. Kontroler postaje partner (Oesterreich, Teuteberg, 2019; Schäffer, 2019), ne samo menadžmentu nego i partner u dijalogu sa stručnjacima u podatkovnoj znanosti. Raspon jučerašnjeg znanja i iskustva kontrolera bio je od upravljanja troškovima do dizajniranja ključnih pokazatelja učinka. Danas kontroler treba matematičko-statističko znanje i iskustvo u rasponu od dizajniranja podatkovnih modela, poslovnih procesa do poslovnih modela koji zahtijevaju stalno testiranje, kako iz kritičkog ugla, tako i metodički.

Razvoj informacijske tehnologije omogućio je dizajniranje modela predviđanja temeljenih na matematičko-statističkim metodama i uporabi strojnog učenja. Odnosno, iskustveni podaci iz algoritama učenja koji se temelje na teoriji statističkog učenja rabe se za generiranje modela predviđanja kojima se koristi kao da čine osnovu za donošenje odluka kontrolera i menadžmenta. Tako se npr. rezultati procjene podataka o kupcima mogu iskoristiti za kreiranje ponuda i marketinških kampanja usmjerenih na kupca. Ako kontroler računalne aplikacije rabi na takav način koji omogućava da se generiraju pouzdana predviđanja i donose odluke usmjerene prema budućnosti, onda će se unutar svoje tvrtke kontroler razviti u digitalnog vođu koji stvara povjerenje u digitalnu transformaciju (Weber, 2019). Uporabom računalnih aplikacija, kao npr. SAP Predictive Analytics, može se jamčiti brzo ažuriranje podataka u fazi

učenja. To je osnova za agilni i pouzdani kontroling koji se transformira u kompetentni centar za analize usmjerene prema budućnosti.

Donošenje odluka sve će se više temeljiti na robusnim predviđanjima koja su izračunata na temelju suvremene informacijske tehnologije i zadatak je kontrolinga identificirati odgovarajuće metode predviđanja, odrediti odgovarajuće ciljne varijable te iz njih izvući održive zaključke. Dakle, proces digitalizacije u poduzeću kontroleri podržavaju putem svojih metodoloških kompetencija (Tschandl, Kogleck, 2018), a u ovom je istraživanju fokus na razvoju i primjeni prediktivnih modela u svrhu pružanja usluga u jednoj od najvećih marina u Hrvatskoj. Poslovanje marina karakterizira kompleksnost i agilnost (Gračan i sur., 2016; Kovačić, Dundović, 2009; Luković, 2013; Peović, 2018) jer podliježe brojnim zakonima i propisima, sezonalnosti, velikim investicijskim zahvatima, ekostandardizaciji i zahtjevima održivosti. Ovladavanje njima zahtijeva uporabu tehnologije i metodologije usmjerene na budućnost kako bi se održao korak s ubrzanim razvojem digitalizacije. Upravljanje digitalnim podacima karakterizira jednostavnost, fleksibilnost, integracija te usmjerenost na interese primatelja i njihovu uključenost. Važnost kontrolinga ključna je zbog predviđanja izračunatih iz simulacijskih modela te njihove interpretacije u kontekstu poslovanja poduzeća i korporativnog okruženja. Podaci postaju transparentni tek procjenama kontrolera, a što se tiče rizika digitalizacije, kontroleri su nezaobilazni kao koordinirajuća tijela, pokretači inovacija te konzultanti ili poslovni partneri uprave. Ovim se radom želi dati odgovor na sljedeće istraživačko pitanje: Omogućuju li razvoj i primjena prediktivne analitike i teorije vjerojatnosti i razvoj stohastičkih modela odlučivanja temeljenih na znanosti o podacima, a koji omogućuju digitalnu transformaciju procesa operativnog odlučivanja za potrebe kontrolinga i upravljanja?

Ovaj rad strukturiran je u četiri poglavlja. Prvo poglavlje čini uvod. U drugom poglavlju prikazana je teorijska osnova za predikciju i proces poslovnog odlučivanja te metodologija provedena istraživanja. Treće poglavlje prikazuje rezultate istraživanja, dok četvrto predstavlja zaključak rada.

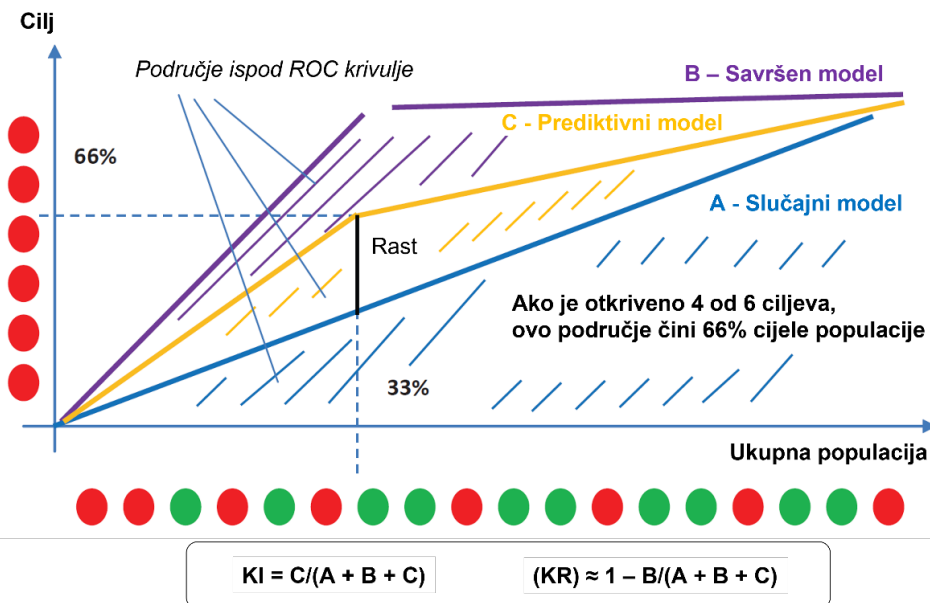
2. TEORIJSKA OSNOVA I METODOLOGIJA ISTRAŽIVANJA

Ovim radom istražuje se način donošenja odluka na primjeru nautičkog turizma, tj. konkretno pružanja usluga jedne od najvećih marina u Hrvatskoj, te se na temelju mogućnosti koje pruža znanost o podacima (engl. *data science*) povezana s digitalnom transformacijom razvijaju modeli predviđanja kao osnova za donošenje odluka. Odluke u pravilu trebaju biti racionalne i jedna je od središnjih zadaća kontrolinga uporabom informacijskog sustava utemeljenog u digitalnoj tehnologiji i analitičkim metodama pomoći menadžmentu u donošenju racionalnih odluka (Weber i sur., 1999). Sustavno istraživanje ponašanja pojedinaca i grupa u donošenju odluka područje je teorije odlučivanja pa je temeljno pitanje istraživanje o razumijevanju i predviđanju odluka. Riječ je o pristupu koji stavlja poseban naglasak na ulogu informacija u procesu donošenja odluka, tj. kako dostupnost, kvaliteta i obrada informacija utječu na donošenje racionalnih ili uvjetno racionalnih odluka. U ovom se kontekstu odluka promatra kao proces koji nije samo rezultat preferencija i ciljeva nego i funkcija informacijske strukture

kojom raspolaže donositelj odluke. Stoga je u ovom radu fokus na informacijski orijentiranoj teoriji odlučivanja, tj. logičkoj i empirijskoj analizi ponašanja pri donošenju odluka (Bamberg i sur., 2012). Informacijski orijentirana teorija uključuje analizu vrijednosti informacije – primjerice u kojoj mjeri dodatna informacija može promijeniti ishod odluke ili smanjiti rizik od pogreške. S poslovnoga gledišta, kad postoji velik utjecaj na učinak i razvoj poduzeća, odluka se definira s velikom važnošću (Laux i sur., 2014). Kako je cilj ovog istraživanja razviti prediktivne modele za donošenje odluka, treba istaknuti da se one mogu donijeti sigurno i uz rizik. Sigurne odluke donose se kad su dostupne potpune informacije, što se u praksi rijetko događa. U tom smislu, modeli odlučivanja samo bi predstavljali drastično pojednostavljene slike stvarnosti bez rizika. Slučaj relevantan za praksu odluke su koje mogu biti rizične i kad se ti rizici razmatraju kao vjerojatnosti (Bamber i sur., 2012). Rizik se može izračunati i pozitivno je ako ga nema. No, ako postoji vjerojatnost da će se rizik pojaviti, u procesu donošenja odluka treba ga uključiti. Takav rizik u poslovanju marina je, primjerice, kreditna sposobnost kupca ili raskid ugovora.

Da bi se mogli razviti prediktivni modeli, u ovom istraživanju rabljeno je 38 000 skupova podataka jedne od marina u Hrvatskoj koji su se statistički obradili strojnim učenjem, odnosno na temelju teorije statističkog učenja razvijene od Vladimira N. Vapnika (Vapnik, Chevronenkis, 1991; Vapnik, 2018), a matematički modelirane i implementirane u strojno učenje preko vektorskoga stroja podrške s podrijetlom Bayesova klasifikatora (Shi-fei i sur., 2011; Fischer, 2007; Hurwitz, Kirsch, 2018; Kellerher i sur., 2015; Krzanowski, Hand, 2009; Kuhn, Johnson, 2013; Runkler, 2015; Russel, Norvig, 2012). Strojno učenje rabi se za prepoznavanje uzoraka u velikom broju podataka i omogućuje prepoznavanje skrivenih informacija u podacima jer kombinira operacijsko istraživanje i strojno učenje. Operacijska istraživanja simuliraju i optimiziraju poslovne procese pomoću algoritama i kvantitativnih metoda, a strojno učenje koristi se takozvanim algoritmima učenja za generalizaciju prepoznatih uzoraka u podacima. Generalizacija dovodi do činjenice da se prepoznati obrasci mogu prenijeti i na buduće podatke, na temelju čega se mogu dati pouzdane izjave o budućim događajima. Primijenjeno kvantitativno istraživanje provedeno je pomoću računalne aplikacije pod nazivom SAP Predictive Analytics (SAP PA). Modeli predviđanja kreirani su uz postavljanje parametara koji su se odnosili na ciljne varijable, istovremeno isključujući nebitne varijable (npr. broj ugovora, registracija plovila i sl.) koje bi mogle ugroziti rezultat. Da bi se to izbjeglo, izračunata je kvaliteta modela predviđanja putem evaluacije ključnih pokazatelja, i to „prediktivne snage” (KI) koja ukazuje na točnost modela, i „pouzdanosti predviđanja” (KR) koja ukazuje na statističku robusnost (Busemeyer, Townsend, 1993; Butsmann i sur., 2019; Charbert i sur., 2017). Točnost se mjeri korelacijom između ulaznih ili eksplanatornih varijabli u odnosu na ciljnu varijablu. KI ima raspon od 0,0 do gotovo 1,0, obično 0,998. Što je veća vrijednost KI-ja, to su eksplanatorne varijable značajnije, kao i KR koji također ima raspon od 0,0 do 1,0. (Slika 1). Samo vrijednost iznad 0,95 pokazuje da se radi o robusnom modelu (Chabert i sur., 2017; Hurwitz, Kirsch, 2018) Robusnost mjeri točnost predviđanja kad se koristi podacima čiji su rezultati poznati i stoga se predviđanje može usporediti sa stvarnim razvojem.

Slika 1. Prediktivni i savršeni model



Legenda:

ROC — krivulja odnosa osjetljivosti i specifičnosti (engl. Receiver Operating Characteristic)

Izvor: Autori

Dakle, 38 000 skupova podataka rabljeno je za pronalaženje eksplanatornih varijabli, što je omogućilo razvoj modela predviđanja s optimalnom snagom i pouzdanošću predviđanja. Autori ovog rada postavili su ciljne varijable za razvoj prediktivnih modela. Podaci su prikupljeni od zaposlenika marine slučajnim odabirom (Borschardt, Göthlich, 2007; Schnell i sur., 2018; Stier, 1999). Podaci se odnose na ugovore sklopljene između marine i kupaca o najmu vezova. To uključuje podatke o kupcu (dob, starosna skupina, državljanstvo), brodici (godina proizvodnje, starost, duljina brodice) i ugovorima (prodaja, vrsta ugovora). Interes je marine popuniti kapacitete ugovaranjem na duži rok s korisnicima marine, što se odražava na prihode i dobit.

Postavljena je osnovna **hipoteza** rada koja glasi da je primjenom skupa podataka u djelatnosti marina moguće izraditi model predviđanja čija se značajnost može dokazati visokim vrijednostima (0,995 do 0,998) prediktivne snage i pouzdanosti predviđanja. Za potvrđivanje ove hipoteze postavila su se četiri modela (Tablica 1).

Tablica 1. Modeli istraživanja

Model	Varijable	Metode
A	Godišnji ugovor s privatnim osobama, a koji ovisi o vrsti i starosti plovila, dobi klijenta, načinu plaćanja.	metoda klastera i klasifikacije
B	Godišnji ugovor s poduzećem koji ovisi o vrsti i starosti plovila, duljini plovila, vrsti ugovora (novi ili obnovljeni ugovor).	metoda klastera i klasifikacije
C	Klijenti koji kasne s plaćanjem. Varijable od utjecaja su vrsta klijenta, državljanstvo, starost plovila, vrsta ugovora.	metoda klasifikacije i linearne regresije
D	Klijenti od kojih se može očekivati veća prodaja. Ciljna varijabla u zadanu skupu podataka jest iznos ugovora.	metoda linearne regresije

Izvor: Autori

Klasifikacija i klasteriranje su dvije osnovne metode koje se koriste u prediktivnim modelima kada se rabi strojno učenje. Primjenom matematičko-statističkih metoda za klasteriranje, izračun regresije i klasifikaciju (Auer, 2016; Georgi, 2015) identificirani su značajni faktori koji utječu na ponašanje u odlučivanju i posljedično poslovne rezultate klijenata. Rabljena je regresijska analiza kontinuiranih eksplanatornih varijabli, a grupiranje i klasifikacija odabrani su kao metodologija za diskretne eksplanatorne varijable (Auer, 2016; Hyndman, Athanasopoulos, 2014; Lawrence, Klimberg, 2018; Stier, 1999). Točnije, koristilo se podacima o godišnjim i obnovljivim ugovorima na temelju popisa teorijski utemeljenih obilježja razlikovanja između modela poslovnog ugovaranja. Grupe se razlikuju primjenom matematičko-statističke metode klasteriranja koja se odnosi na karakteristike korisnika i podnositelja zahtjeva. Grupe korisnika koji će kasniti s plaćanjem identificirane su pomoću broja dana u kojima nisu izvršile plaćanje. Rezultat je dizajniran tako da postavlja granicu za ovu grupu korisnika. U vezi s kontinuiranom varijablom „dani neizvršenog plaćanja” primjenjuje se matematičko-statistička metoda višestruke linearne regresije. Identificirani su i klijenti od kojih se može očekivati veća prodaja, a vezano uz vrijednost ugovora koji se ne produljuje, nego obnavlja.

3. REZULTATI ISTRAŽIVANJA

U intervjuima s kontrolerima poduzeća definirane su ciljne ili objektivne varijable od značaja za poslovanje, kao i dodatne varijable koje objašnjavaju ciljnu varijablu (u daljnjem tekstu objašnjavajuće). Računalna aplikacija je strojnim učenjem prepoznala objašnjavajuće varijable u procesu izrade modela predviđanja kao one koje najviše koreliraju s odgovarajućom ciljnom varijablom.

Po modelima su rezultati sljedeći:

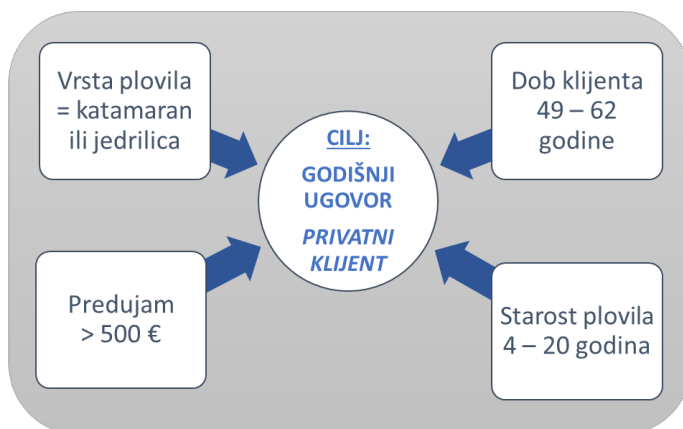
Model A:

- ciljna varijabla: godišnji ugovor

- objašnjavajuće varijable:
 - x1 = vrsta plovila
 - x2 = starost plovila
 - x3 = dob klijenta
 - x4 = strani gost
 - x5 = preplata
- filter: vrsta klijenta = privatni

U modelu A Identificirane su četiri objašnjavajuće varijable (vrsta plovila, starost plovila, dob klijenta i predujam) koje imaju pozitivan utjecaj na ciljanu varijablu GODIŠNJI UGOVOR (Slika 2).

Slika 2. Rezultat modela A — objašnjavajuće varijable s pozitivnim utjecajem na ciljnu varijablu „Godišnji ugovor” – vrsta klijenta: PRIVATNI



Izvor: Autori

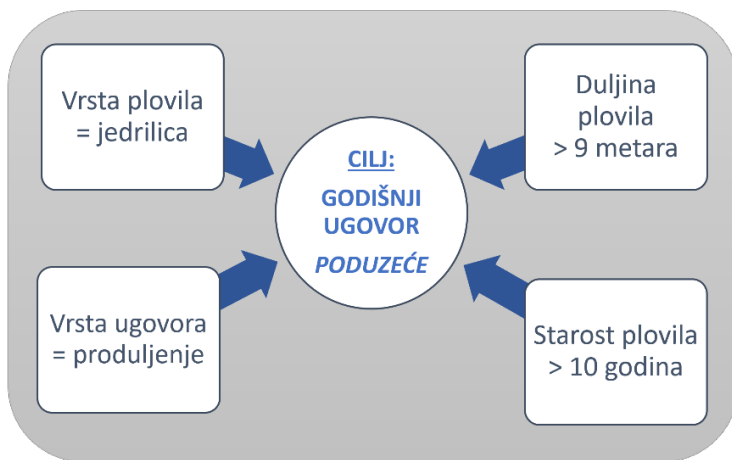
Zaključuje se da su privatni kupci skloniji sklapanju godišnjeg ugovora ako su u dobnoj skupini od 49 do 62 godine, posjeduju jedrilicu ili katamaran starosti od četiri do 20 godina, te ako su uplatili predujam u iznosu većem od 500 EUR.

Model B:

- ciljna varijabla: godišnji ugovor
- objašnjavajuće varijable:
 - x1 = vrsta plovila
 - x2 = starost plovila
 - x3 = duljina plovila
 - x4 = vrsta ugovora (novi ili obnovljeni ugovor)
- filter: vrsta klijenta = poduzeće

Najvažnije objašnjavajuće varijable za sklapanje godišnjih ugovora s vrstom klijenta „**PODUZEĆE**” ovise o karakteristikama plovila. Prednost ne bi imali ni najmlađi ni najmanji brodovi poput jedrilice. Najbolja je opcija za godišnji ugovor obnova postojećeg ugovora (Slika 3).

Slika 3. Rezultat modela B — objašnjavajuće varijable s pozitivnim utjecajem na ciljnu varijablu „Godišnji ugovor” – vrsta klijenta: **PODUZEĆE**



Izvor: Autori

Zaključuje se da, kad su klijenti poduzeća koja rabe jedrilicu stariju od deset godina i dužu od devet metara s namjerom obnove ugovora, očekuje se da će ti klijenti sklopiti godišnji ugovor.

Model C:

- ciljna varijabla: kašnjenje s plaćanjem
- objašnjavajuće varijable:
 - x_1 = vrsta ugovora
 - x_2 = vrsta plovila
 - x_3 = dob privatnih klijenata
- filtar: broj dana veći ili jednak 100

Cilj je modela C upoznavanje s karakteristikama korisnika koji kasne s plaćanjem. S datumom dospjeća od nula dana, plaćanje je u dospjeću već nakon primitka računa. Komercijalnim standardima obično se dopušta rok plaćanja od 60 dana. No, filtar je postavljen na broj dana koji je veći ili jednak 100 dana u modelu. Budući da je ciljna varijabla kontinuirana, koristi se metodom regresije. Obrazac višestruke linearne regresije primijenjen u ovom predviđanju za model C jest sljedeći (Auer, 2016):

$$y_{i,j} = \alpha_i x_i + \beta_j x_i + \gamma_j x_i + \delta_i x_i \text{ sa } i = 1 \dots n \text{ i ograničenjem } y_i < 0$$

y_i = broj dana neplaćanja, račun, i , klijent, j

α = klijent građanin, i

β = vrsta klijenta, j

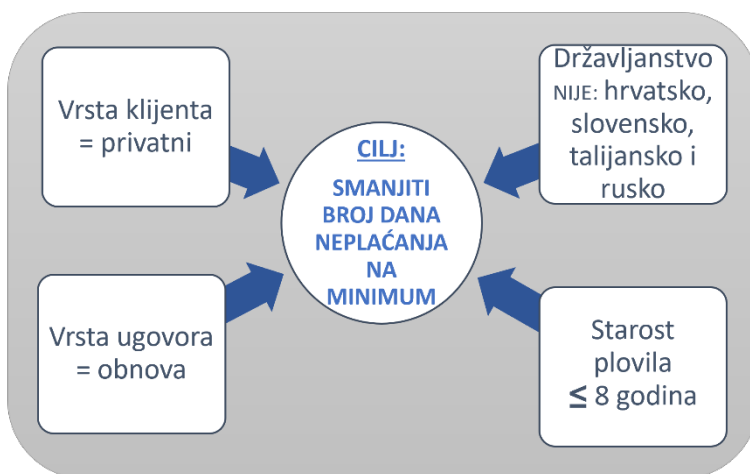
γ = starost plovila klijenta, j

δ = vrsta ugovora klijenta, i

x_j = klijent, j

Ograničenje u smislu dana neizvršenja plaćanja u modelu je iznad nule ako je okviru odobrenih dana, a ostaje ispod nule ako je klijent platio unaprijed. Rezultati modela prikazani su u slici 4.

Slika 4. Rezultat modela C — objašnjavajuće varijable s pozitivnim utjecajem na zakašnjelo plaćanje



Izvor: Autori

S obzirom na značajan utjecaj eksplanatornih varijabli, pouzdanost modela predviđanja je do 150 dana kašnjenja u plaćanju. Kašnjenje plaćanja uglavnom se očekuje od poduzeća s brodovima starijima od osam godina i koji imaju sjedišta u Hrvatskoj, Sloveniji, Italiji ili Rusiji te koji obnavljaju ugovor. Rezultati su pokazali da 82,7 % onih koji kasne s plaćanjima posjeduje plovilo staro osam ili više godina pa se može zaključiti da su vlasnici mlađih plovila platežno sposobniji.

Model D:

- ciljna varijabla: iznos ugovora
- objašnjavajuće varijable:
 - x_1 = datum proizvodnje plovila
 - x_2 = duljina plovila
- filter: klijenti s najvišom vrijednosti obnovljenih ugovora

Cilj je ovog modela identificirati klijente od kojih se može očekivati veći prihod od prodaje usluge, pa je ciljna varijabla u zadanu skupu podataka iznos ugovora. Iznos fakture i iznos duga prirodno imaju visoku korelaciju s iznosom ugovora. Međutim, za objašnjenje je korisna samo vrsta ugovora, tj. ugovor koji se ne produljuje, nego obnavlja. Rezultati su pokazali da je gotovo 60 % količine prodaje ostvareno obnovom ugovora. Stoga izračun prodaje po kupcu zahtijeva kumulaciju iznosa ugovora po identifikacijskoj oznaci klijenta. Novi ugovori obično sadrže manji iznos od obnovljenih ugovora. U ovom se istraživanju ispituju samo klijenti s najvišim vrijednostima ugovora. Oblik višestruke linearne regresije uporabljen u ovom predviđanju za model jest sljedeći (Auer, 2016):

$$y_{i,j} = \alpha_i x_i + \beta_i x_i + \gamma_i x_i + \delta_i x_i \text{ sa } i = 1, \dots, n \text{ i } j = 1, \dots, n$$

$y_{i,j}$ = iznos ugovora, ugovor_i s klijentom_j

α_j = vrsta plovila klijent_j

β_j = duljina plovila klijent_j

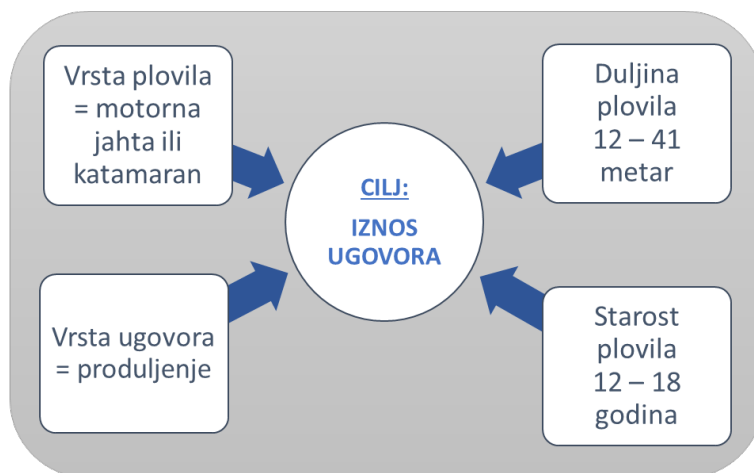
γ_j = starost plovila klijent_j

δ_j = vrsta ugovora klijent_j

Ispitni postupak provodi se za obje vrste klijenata. Iznos ugovora postavljen je kao ciljna varijabla u ovom modelu. Jedan klijent može imati nekoliko ugovora. Cilj je modela klasificirati korisnike u različite skupine korisnika:

- manji opseg narudžbe kratkog trajanja od nekoliko dana
- srednji opseg narudžbe prosječnog trajanja od nekoliko tjedana
- veći opseg narudžbe s prilično dugotrajnim trajanjem od jedne do nekoliko godina.

Slika 5. Rezultat modela D — objašnjavajuće varijable s pozitivnim utjecajem na iznos ugovora



Izvor: Autori

Zaključuje se da se zbog određenih karakteristika može predvidjeti sklapanje ugovora većeg opsega s vlasnicima motornih jahti i katamarana. Vlasnici motornih čamaca i katamarana dužine između 12 i 41 metra i starosti između 12 i 18 godina trebali bi imati prednost pri potpisivanju obnovljena ugovora

Rezultati prikazanih modela predviđanja primijenjeni su kao sastavni dio procesa odlučivanja. Grupiranje podnositelja zahtjeva i klijenata tvrtke u različite klastere na temelju rezultata modela predviđanja dovodi do određivanja prioriteta u procesu odlučivanja. Prednost imaju podnositelji zahtjeva i klijenti čija obilježja imaju višu korelaciju s ciljnom varijablom. S obzirom na to da su parametri predviđanja poznati, modeli se mogu rabiti ako se cilj jasno definira, što u konačnici rezultira statistički pouzdanim donošenjem odluka.

Svi modeli predviđanja dokumentirani su izračunom vrijednosti za prediktivnu snagu (KI) i robusnost predviđanja (KR). Kako je već prethodno navedeno, KI i KR poprimaju vrijednost od 0,0 do 1,0, pri čemu veća vrijednost KI-ja upućuje na veću prediktivnu snagu, dok vrijednost KR-a iznad 0,95 pokazuje da se radi o robusnu modelu (Chabert i sur., 2017; Hurwitz, Kirsch, 2018). U ovom su istraživanju visoke vrijednosti potvrđene u svim modelima korelacijom najvažnijih objašnjavajućih varijabli s ciljnim varijablama (KI). Istodobno su postojale i visoke vrijednosti u podudaranju rezultata predviđanja i poznatih rezultata u ispitivanju modela predviđanja s validacijskim podacima (KR) (Tablica 2).

Tablica 2. Pregled KI-ja i KR-a za sve modele predviđanja

Model	KI	KR
A	0,9798	0,9910
B	0,9977	0,9993
C	0,,9849	0,9960
D	0,9908	0,9985

Izvor: Autori

U svim modelima predviđanja izračunate su adekvatne vrijednosti KI-ja i KR-a. To znači da se modeli mogu promatrati kao smisleni i robusni.

4. ZAKLJUČAK

Osnovna je svrha ovog istraživanja bila razviti model predviđanja za potrebe donošenja odluka u jednoj od hrvatskih marina. Odnosno, radom je potvrđeno da razvoj i primjena prediktivne analitike i teorije vjerojatnosti omogućuje razvoj stohastičkih modela odlučivanja temeljenih na znanosti o podacima, a koji omogućuju digitalnu transformaciju procesa operativnog odlučivanja za potrebe kontrolinga i upravljanja. Kontroleri kao poslovni analitičari i savjetnici menadžmentu mogu rabiti ovaj model za potrebe predviđanja poslovnih rezultata i donošenje odluka od menadžmenta. Ovo istraživanje potvrđuje korisnost sofisticiranih računalnih alata (strojno učenje, prediktivna analitika) koji se mogu rabiti za izradu točnih i pouzdanih predviđanja, a za potrebe bilo koje vrste djelatnosti. Također je ovim istraživanjem potvrđeno

da se uporabom operativnih varijabli specifičnih za konkretnu djelatnost, u ovom primjeru marine, mogu izračunati pouzdana predviđanja za potrebe kontrolinga i menadžmenta o događajima relevantnim za odlučivanje u budućnosti. Rezultati strojnog učenja s visokom vrijednosti prediktivne moći i pouzdanosti predviđanja pomažu kontroleru u donošenju zaključaka i prijedloga za poslovno odlučivanje.

Rezultati prikazani u ovom radu mogu se rabiti kao temelj za uvođenje novih procesa donošenja odluka koji više ne odražavaju tradicionalne stilove odlučivanja. Stoga je doprinos ovoga znanstvenog istraživanja u primjeni suvremenoga metodološkog pristupa donošenju odluka. Potvrđuje se korisnost sofisticiranih računalnih alata (strojno učenje, analiza predviđanja) kojima bi se trebalo koristiti za izradu točnih i pouzdanih predviđanja u konkretnoj djelatnosti. Prediktivna analiza rabljena u ovom istraživanju dio je znanosti o podacima (engl. *data science*), a metode koje se rabe temelje se na matematici (strukturirana minimalizacija rizika) i računalnoj znanosti (stroj potpornih vektora). Rezultat dobivenih modela predviđanja testiran je s ključnim pokazateljima učinka — prediktivna snaga i prediktivna robusnost, koji predstavljaju programirani algoritam i svoju znanstvenu osnovu imaju u teoriji statističkog učenja.

Ovo istraživanje potvrđuje trend ka modernizaciji kontrolinga i rukovođenja u doba digitalne transformacije. Primjena metodologije znanosti o podacima za prepoznavanje uzoraka dovodi do bolje identifikacije ciljnih skupina tvrtke, a time i do racionalnih odluka vezanih uz ciljne skupine. U ovome istraživanju razvijeni su višerazinski stohastički modeli odlučivanja, što proces odlučivanja čini transparentnijim i samim time razumljivijim. Mogućnosti odlučivanja razvijene u modelima odlučivanja povećavaju fleksibilnost i prilagodljivost koje su potrebne kontrolingu u doba digitalne transformacije. Ovo istraživanje ima važnost za konkretno poduzeće na kojem je izvršeno istraživanje s obzirom na to da je razvojem stohastičkih modela moguće donijeti pravovaljane odluke, a vezano uz ugovaranje, plaćanje, itd. Moguće ograničenje u ovom istraživanju leži u činjenici što je model razvijen na primjeru jednog poduzeća koje se bavi uslugama marine pa bi ubuduće trebalo model testirati na drugim poduzećima u istoj djelatnosti. Doprinos ovog istraživanje svakako je činjenica da se model može primijeniti i na druge djelatnosti. Automatizacija procesa donošenja odluka uporabom strojnog učenja kao faktora odlučivanja skraćuje procese donošenja odluka i potiče agilnost i fleksibilnost poslovanja.

NAPOMENA

Ovaj rad financiralo/sufinanciralo je Sveučilište u Rijeci projektom uniri-mladi-drustv-23-17.

LITERATURA

- Auer von, L (2016) *Ökonometrie — Eine Einführung*. Heidelberg: Springer Verlag, 7. izdanje
- Bamberg, G., Coenenberg, A., Krapp, M. (2012) *Betriebswirtschaftliche Entscheidungslehre*. München: Vahlens, 15. izdanje

- Borchardt, A., Göthlich, St. (2007) Erkenntnisgewinnung durch Fallstudien. U: Söhnke, A. i sur.: *Methodik der empirischen Forschung*, Gabler Verlag
- Busemeyer, J. R., Townsend, J. T. (1993) „Decision field theory: A dynamic cognitive approach to decision-making in an uncertain environment” *Psychological Review*, Jul;100(3), str. 432–459.
- Butsmann, J., Crumbach, M., Franke, J., Köhler, B., Morgenthaler, J. (2019) *SAP S/4HANA Embedded Analytics – Architektur, Funktionen, Anwendungen*. Bonn: Rheinwerk
- Charbert, A., Forster, A., Tessier, L., Vezzosi, P. (2017) *SAP Predictive Analytics – The Comprehensive Guide*. Boston: SAP Press, Rheinwerk Publishing
- Fischer, J. (2007) Support Vector Machines (SVM). Seminar „Statistische Lerntheorie und ihre Anwendungen”. Ulm: Universität Ulm.
- Gassmann, O., Sutter, Ph. (2019) *Digitale Transformation gestalten: Geschäftsmodelle — Erfolgsfaktoren – Checklisten*. München: Hanser Verlag, 2. izdanje
- Georgii, H.-O. (2015) *STOCHASTIK. Einführung in die Wahrscheinlichkeitstheorie und Statistik*. Berlin i Boston: De Gruyter, 5. izdanje
- Gračan, D., Gregorić, M., Martinić, T. (2016) „Nautical tourism in Croatia: current situation and outlook”, *Conference: 23rd Biennial International Congress, Tourism and Hospitality Industry 2016, Trends and Challenges*, Opatija, Hrvatska, 28. — 29. 4. 2016
- Hurwitz, J., Kirsch, D. (2018) *Machine Learning for Dummies. Understanding Machine learning fundamentals. Make sense of machine learning algorithms. Build your data science team*. New Jersey: Jon Wiley & Sons Inc.
- Hyndman, R. J., Athanasopoulos, G. (2014) *Forecasting – Principles and Practice. A comprehensive introduction to the latest Forecasting methods using R. Learn to improve Your forecast accuracy using dozens of real data Examples*. Melbourne: OTEX.
- Kelleher, J. D., Mac Namee, B., D’Arcy, A. (2015) *Machine Learning for Predictive Data Analytics, Algorithms, Worked Examples and Case Studies*. London: Cambridge.
- Kovačić, M., Dundović, Č. (2009) „Criteria for selecting a location for a port of nautical tourism” *Pomorstvo*, 23(1), str. 41–65
- Krzanowski, W. J., Hand, D. J. (2009) ROC Curves for Continuous Data. U: *Monographs on Statistics and Applied Probability 111*. London, New York: CRC Press Taylor & Francis Group.
- Kuhn, M., Johnson, K. (2013) *Applied Predictive Modeling*. Heidelberg: Springer
- Laux, H., Gellenkirsch, R. M., Schlenk-Mathes, H. (2014) *Bildung eines Wahrscheinlichkeitsurteils und Bewertung von Informationen*. Heidelberg: Springer Verlag, 9. izdanje
- Lawrence, K. D., Klimberg, R. K. (2018) *Advances in Business and Management Forecasting*. United Kingdom, North America, Japan, India, Malaysia, China: Emerald Publishing, 12. izdanje
- Luković, T (2013) *Nautical Tourism*. Dubronik: CABI
- Oesterreich, T. D., Teuteberg, F. (2019) „The role of business analytics in the controllers and management accountants’ competence profiles: An exploratory study on individual-level data” *Journal of Accounting and Organizational Change*, 15(2), str. 330–356.
- Peović, K. (2018) „Die politische und wirtschaftliche Situation Kroatiens – die Peripherie Europas heute”. <https://transform-network.net/de/blog/artikel/die-politische-und-wirtschaftliche-situation-kroatiens-die-peripherie-europas-heute/> (5. 2. 2025.)
- Runkler, A. (2015) *Data Mining – Modelle und Algorithmen intelligenter Datenanalyse*. Wiesbaden: Springer-Vieweg, 2. izdanje
- Russell, St., Norvig, P. (2012) *Künstliche Intelligenz. Ein moderner Ansatz*. München: Pearson DE, 3. izdanje

- Schnell, R., Hill, P. B., Esser, E. (2018) *Methoden der empirischen Sozial-Forschung*. De Gruyter Oldenbourg, 11. izdanje
- Schäffer, U. (2019). *Behavioral Controlling: Anniversary Volume in Honor of Jürgen Weber*, Wiesbaden: Springer Gabler
- Shi-fei, D., Bing-juan, QI., Hong-yan, T. (2011) „An Overview on Theory and Algorithm of Support Vector Machines“. *Journal of University of Electronic Science and Technology of China*, 40(1), str. 2—10.
- Stier, W. (1999) *Empirische Forschungsmethoden*. Berlin, Heidelberg; Springer Verlag 2. izdanje
- Tschandl, M., Kogleck, R. (2018) Controller als Innovatoren: Von der Digitalisierungs-Roadmap zum neuen Geschäftsmodell. U: Gleich, R. et al.: *Digitalisierung und Controlling – Technologien – Instrumente – Praxisbeispiele*. Haufe
- Vapnik, V. N. (2018) *Statistical Learning Theory. A Volume in the Wiley Series on Adaptive and Learning Systems for Signal Processing, Communications, and Control*. London. New Delhi: Wiley, Reprint from 1998.
- Vapnik, V. N., Chevronenkis, A. Ya. (1991) *The necessary and sufficient conditions for consistency of the method of empirical risk minimization*. Yearbook of the Academy of Science of the USSR on Recognition, Classification and Forecasting. Nauka, Moscow: 2. Izdanje
- Vitezić, N., Lebefromm, U. (2018) *Production Controlling in the Digital Age*. Rijeka: Sveučilište u Rijeci, Ekonomski fakultet
- Weber (2019) Digitalization: Eight Challenges for Controllers – How digitalization will change controlling and what controllers should do about it. U: WHU on Controlling, Academic insights for professionals in controlling & finance.
- Weber, J., Schäffer, U., Langenbach, W. (1999) *Gedanken zur Rationalitätskonzeption des Controlling*. Wiesbaden: Dt. Univ.-Verl



Creative Commons Attribution –
NonCommercial 4.0 International License

Original scientific paper

<https://doi.org/10.31784/zvr.14.1.8>

Received: 6. 2. 2025.

Accepted: 9. 9. 2025.

EFFECTIVENESS OF FORECASTING USING MACHINE LEARNING FOR CONTROLLING NEEDS IN THE DECISION-MAKING PROCESS

Uwe Lebefromm

PhD, Lecturer, Cooperative State University Mannheim, Faculty of Business Informatics, Coblitzallee 1-9,
68163 Mannheim. Germany; email: lebefrommuwe@outlook.de

Neda Vitezić

PhD, Full Professor, University of Rijeka, Faculty of Economics and Business, Ivana Filipovića 4, 51000 Rijeka,
Croatia; email: neda.vitezic@efri.uniri.hr

Antonija Petrić

PhD, Assistant Professor, University of Rijeka, Faculty of Economics and Business, Ivana Filipovića 4, 51000
Rijeka, Croatia; email: antonija.petrlic@efri.uniri.hr

ABSTRACT

The subject of this research is the development and application of prediction models that are created with the help of mathematical and statistical methods and artificial intelligence, i.e. machine learning. The aim of the work is to develop a model for the implementation of digital transformation in operational decision-making processes and controlling and management requirements. Controlling as a discipline and function in a company is responsible for analysing existing and predicting future business using sophisticated methods and tools. This paper shows that business forecasting based on historical facts has evolved into business forecasting estimated on the basis of machine learning. The paper presents an innovative stochastic forecasting model using the example of the provision of services in a marina in Croatia. The results of the study are four presented models for contracting and acquisition of customers using the services of a marina. The results obtained confirm the high reliability of the forecasting model for the use of digital tools for controlling needs in the decision-making process. Through the developed methods of converting manual processes into optionally automated decision-making processes, this work contributes to the innovation of controlling in a digital environment.

Keywords: forecasting, machine learning, controlling, decision-making

