Uloga CRM sustava u poslovnoj analitici osiguravajućih društava

Pipinić, Krunoslav

Undergraduate thesis / Završni rad

2021

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **The University of Applied Sciences Baltazar Zaprešić / Veleučilište s pravom javnosti Baltazar Zaprešić**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:129:930941

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

Digital Repository of the University of Applied Sciences Baltazar Zaprešić - The aim of Digital Repository is to collect and publish diploma works, dissertations, scientific and professional publications





VELEUČILIŠTE

s pravom javnosti

BALTAZAR ZAPREŠIĆ

Zaprešić

Preddiplomski stručni studij

Poslovanje i upravljanje

KRUNOSLAV PIPINIĆ

ULOGA CRM SUSTAVA U POSLOVNOJ ANALITICI OSIGURAVAJUĆIH DRUŠTAVA

PREDDIPLOMSKI ZAVRŠNI RAD

Zaprešić, 2021. godine

VELEUČILIŠTE

s pravom javnosti

BALTAZAR ZAPREŠIĆ

Zaprešić

Preddiplomski stručni studij

Poslovanje i upravljanje

PREDDIPLOMSKI ZAVRŠNI RAD

ULOGA CRM SUSTAVA U POSLOVNOJ ANALITICI OSIGURAVAJUĆIH DRUŠTAVA

Mentor:

Krešimir Jurina, struč. spec. ing. techn. inf. i struč. spec. oec., Viši predavač

Student:

Krunoslav Pipinić

JMBAG:

0067181862

Naziv kolegija:

E-KOMUNIKACIJSKI KANALI

SADRŽAJ

SAŽETAK 1
ABSTRACT 2
1. UVOD 3
1.1. Problem i predmet istraživanja 3
1.2. Svrha i ciljevi rada 5
1.3. Doprinos rada 5
2. PREGLED TEORETSKIH POSTAVKI O CRM-U U VREMENSKOJ PERSPEKTIVI 6
2.1. Opća teorija sustava kao konceptualna preteča CRM-u 7
2.2. Nastanak i razvoj CRM-a 8
2.2.1. Povijesni narativ o CRM-u 8
2.2.2. Definicija pojma CRM 10
2.2.3. Odnos CRM-a i kritičnih čimbenika uspjeha 11
2.3. Operativne definicije koje se vezuju uz CRM 13
2.4. Pitanje uspješnosti implementacije CRM sustava 14
2.5. Kategorizacija CRM sustava 15
2.6. Pogled na benefite i nedostatke uvođenja CRM-a 20
3. SPECIFIČNOSTI PRIMJENE CRM-A U SEKTORU OSIGURANJA 27
3.1. Potreba za CRM-om u industriji osiguranja 27
3.2. Važnost CRM-a u industriji osiguranja 28
3.3. Osobitosti CRM-a u osiguranju 29
3.3.1. Usluge povezane s premijom osiguranja koje pruža CRM 29
3.3.2. Premium usluge koje pruža CRM 30
3.3.2.3. Prijenos politike i promjena adrese 31
3.3.2.4. Održavanje zapisa 31
3.3.2.5. Oživljavanje politike 31
3.4. Usluge vezane uz nagodbu 32
3.4.1. Predaja police 32
3.4.3 Namirenje potraživanja 33
3.5. Rezultati CRM-a u osiguravateljnoj industriji 33
3.5.1. Prednosti CRM-a za osiguravajuće kuće 33

3.5.2. Čimbenici odgovorni za neuspjeh CRM-a u osiguranju 34
4. VAŽNOST PODATAKA U INDUSTRIJI OSIGURANJA 36
4.1. Definicija i područje primjene 36
4.2. Proces otkrivanja znanja iz baza podataka 36
4.3. Razlikovne pojmovne konotacije otkrivanja znanja iz baza podataka 41
4.4. Najčešće greške prilikom rudarenja podataka 42
4.5. Formuliranje ciljeva i zadataka kod rudarenja podataka 43
4.6. Izvedene funkcije rudarenja podataka 45
4.7. Prednosti korištenja podataka u sektoru osiguranja 47
5. ZAKLJUČAK 49
POPIS KRATICA 51
LITERATURA 52

IZJAVA O AUTORSTVU I JAVNOJ OBJAVI RADA

Pod punom odgovornošću potvrđujem da je ovo moj autorski rad čiji niti jedan dio nije nastao kopiranjem ili plagiranjem tuđeg sadržaja. Prilikom izrade rada koristio sam tuđe materijale navedene u popisu literature, ali nisam kopirao niti jedan njihov dio, osim citata za koje sam naveo autora i izvor te ih jasno označio znakovima navodnika. U slučaju da se u bilo kojem trenutku dokaže suprotno, spreman sam snositi sve posljedice uključivo i poništenje javne isprave stečene dijelom i na temelju ovog rada.

Potvrđujem da je elektronička verzija rada identična onoj tiskanoj te da je to verzija rada koju je odobrio mentor

U Zaprešiću 19.11.2021.

Krunoslav Pipinić

SAŽETAK

Tema ovog završnog rada je objašnjenje funkcionalnosti CRM sustava koji se koristi u prodajnom i analitičkom sektoru osiguravajućih društva.

Kroz teorijski dio prikazat će se podaci potrebni za ostvarenje funkcionalnosti koju pruža CRM sustav, uz naglasak na permanentno prikupljanje i obradu podataka s ciljem unaprjeđenja poslovanja u cijelosti. Analize podataka o klijentima nemaju samo reperkusiju na prodaju i financije poduzeća, već mogu imati važnu ulogu u stvaranju predikcija budućih događaja koje određuju snagu poslovnog modela i njegovu konkurentsku prednost. Snaga alata za analizu i obradu predmet je i fokus ovoga rada te će najveća usmjerenost upravo biti na njima i promatranja tog segmenta u ukupnom radu poduzeća.

Cilj komparativnog pregleda uloge CRM-a i njegovih performansi je prikazati i objasniti na koji način obrada podataka i korištenje istih može utjecati na veću efikasnost prodaje, a samim time i na ukupne rezultate tvrtke

Ključne riječi: *CRM sustav, prodajni sektor, analitički sektor, obrada podataka, efikasnost prodaje*

ABSTRACT

The topic of this final paper is an explanation of the functionality of the CRM system used in the sales and analytical sector of insurance companies.

Through the theoretical part, the data necessary for the realization of the functionality provided by the CRM system will be presented, with an emphasis on the permanent collection and processing of data with the aim of improving the business as a whole.

Analyzes of customer data not only have a repercussion on the sales and finances of the company but can also play an important role in creating predictions of future events that determine the strength of the business model and its competitive advantage. The power of tools for analysis and processing is the subject and focus of this paper, and the greatest focus will be on them and the observation of this segment in the overall work of the company.

The aim of a comparative review of the role of CRM and its performance is to show and explain how data processing and use can affect greater sales efficiency, and thus the overall results of the company.

Keywords: *CRM system, sales sector, analytical sector, data processing, sales efficiency*

1. UVOD

1.1. Problem i predmet istraživanja

Mnoge tvrtke puno ulažu u sustav upravljanja odnosima s klijentima (CRM), kao i provedbu, te očekuju povećanje njihove profitabilnosti. Međutim, potrebno je implementirati strategije koje provode CRM menadžeri, kako bi se postigla CRM učinkovitost sustava.
Kako bi CRM sustav tržio uspjeh u poslovanju potrebni su organizacijski fokus, relevantno rukovodstvo, tehnička sposobnost, razvoj vođen korisnicima i tim za implementaciju (Foss et al., 2008:71). Sadašnji i budući CRM menadžeri mogu primijeniti ove spoznaje u uspostavljanju strategija za poboljšanje učinkovitosti CRM sustava.

Uspješni CRM sustavi u osiguravajućim društvima mogu dovesti do povećanja profitabilnosti, a poslovni lideri mogu poboljšati profitabilnost svojih organizacija kada učinkovito upravljaju odnosima s kupcima. Ako se baza kupaca smanjuje, osiguravajuća društva se kontinuirano suočavaju s konkurencijom drugih osiguravajućih kuća (Kulpa, 2017). Može se zaključiti da kada menadžeri osiguravajućih društva grade i održavaju odnose s klijentima, kupci ponavljaju kupnju proizvoda ili usluga. Promjene uključuju povećanu poslovnu odgovornost za osmišljavanje mehanizama u smjeru držanja koraka na konkurentnom tržištu.

Informacijska tehnologija (IT) je alat za prikupljanje i analizu informacija o klijentima. Lideri u industriji osiguranja dobro koriste IT u svom poslovanju i troše resurse i vrijeme na poboljšanje njihove IT infrastrukture, no i dalje postoje mogućnosti poboljšanja. Sagledavajući navedeno na razini Hrvatske, vidljivo je kako pojedine osiguravajuće kuće nude mogućnosti ugovaranja online polica, dok druge osiguravajuće kuće kreiraju svoje tržišne podidentitete, kako bi uspješnije konvergirale ka uvelike digitaliziranim tržišnim segmentima, kako je to vidljivo na primjeru Croatia i Laqo osiguranja.

Upravljanje odnosima s klijentima (CRM) je način poboljšanja lojalnosti i performansi kupaca, ali je vrlo skup i može ne ispuniti očekivanja menadžera. Visoke stope neuspjeha od preko 70% implementacija CRM-a, koje ne dovode do poslovnih koristi, dovodi u pitanje opravdanost uvođenja CRM sustava u poslovanje (Farhan et al., 2018:402).

Pod pojmom CRM-a podrazumijeva se takav poslovni koncept poduzeća, koji predstavlja ključni alat, kojim se značajno može poboljšati vrijednost kupaca, pri čemu se može koristiti ne samo za zadržavanje kupaca, već i za privlačenje novih kupaca (Ahani et al., 2017:562). CRM može biti IT-temeljen sustav, kojim se poslovni menadžeri koriste za upravljanje dugoročnim odnosima s kupcima, s krajnjom svrhom stvaranja vrijednosti za kupca dijeljenjem sažetih, pouzdanih i pravovremenih informacija (Garrido-Moreno et al., 2015:402).

CRM je kombinacija sustava, procesa i ljudi koji postižu zadovoljstvo kupaca, a kada menadžeri ne vide ovu kombinaciju i smatraju CRM samo alatom, CRM-ove implementacije ne pružaju nikakvu vrijednost za ulaganje (Ledingham i Rigby, 2014).

Postoji nekoliko strategija implementacije CRM sustava, ali odabrana strategija implementacije nije uvijek uspješna, obzirom da svaka organizacija ima različite situacije i identificira jedan ispravan pristup, kao izazovan za menadžere. CRM program bi trebao pokrivati poslovnu strategiju organizacije. CRM je moćan alat, ali potrebno je znati ga koristiti. Kada je riječ o osiguravajućim kućama, u praksi je poznato da su menadžeri za prikupljanje podataka koristili CRM sustave, međutim, opisano se pokazalo kao neučinkovito i skupo u situacijama kada se informacije nisu obradile dostatno učinkovito, zbog previše ili premalo informacija (Matis i Ilies, 2014: 1141).

Menadžeri u osiguranju imaju tendenciju tretirati CRM podatke jedinstvenima za odnose s klijentima i često ne uspijevaju holistički analizirati informacije po tržišnim segmentima i kategorijama kupaca, te donijeti smislene zaključke za poslovne odluke (Andrersson i Stekovic, 2011: 29).

Nepoznavanje CRM sustava moglo bi i nadalje pridonositi neuspjehu cjelokupne implementacije, ukoliko bi organizacije promatrale ove sustave sa sužene tehnološke perspektive i posljedično pristupale rješavanju problema na fragmentiran način. Tvrtke diljem svijeta uložile su nekoliko milijardi dolara u CRM softver od 2000. godine, pri čemu razina ulaganja raste, međutim, stopa neuspjeha za projekte implementacije CRM-a kreće se od 60% do 80% (Edinger, 2018).

Opći poslovni problem i neuspjesi menadžera u implementaciji CRM-a dovode do loše interakcije s klijentima i gubitka profitabilnost za tvrtke. Specifičan poslovni problem u okviru industrije osiguranja pokazao se taj što nekim CRM menadžerima u osiguravajućim društvima nedostaju strategije za postizanje efikasnosti CRM sustava.

Na osnovi uvida u spoznaje primarnih autora, u radu su detektirane bitne odrednice uloge CRM sustava u poslovnoj analitici osiguravajućih društava. Teorijska znanja potvrdit će se empirijskom valorizacijom kroz samo istraživanje.

1.2. Svrha i ciljevi rada

Svrha ovog rada bila je istražiti strategije koje CRM menadžeri u osiguravateljnom sektoru koriste za postizanje učinkovitosti CRM sustava. Ciljana populacija za ovo istraživanje bili su menadžeri u osiguranju, koji su implementirali, tj koji se koriste CRM sustavom u svom radu.

Ovaj rad se bavi implementacijom upravljanja odnosima s klijentima (CRM) u osiguravajućim društvima. Stoga su pregledane publikacije, koje se bave regionalnim i međunarodnim rješenjima za upravljanje odnosima s klijentima. U ovom radu je fokus na strategije koje se koriste u upravljanju prodajom s obzirom na standarde korisničke usluge i modele koji se koriste u upravljanju odnosima s kupcima.

Cilj je rada prikazati prednosti koje proizlaze iz primjene novih tehnologija, procjenjujući na taj način tempo promjena, nove mogućnosti i potrebu za fleksibilnošću u odnosu s kupcima, pri čemu se uočava da je uz tehnološku komponentu prisutna je i ljudska komponenta kako bi se osigurala uspješna implementacija CRM-a.

1.3. Doprinos rada

Znanstveni i stručni doprinos rada „Uloga CRM sustava u poslovnoj analitici osiguravajućih društava“ podrazumijeva pronalaženje ključnih elemenata upravljanja CRM sustavom u vremenskom presjeku začetka iste na ovamo, na temelju longitudinalnog istraživanja, tj analize sekundarnih podataka i provedenog istraživanja na određenom uzorku i u skladu s time definiranje smjernica za revalorizaciju postojećih strategija upravljanja CRM sustavom u sektoru osiguranja, te mogućnost korištenja rezultata istraživanja, kao poticaj i podloga za buduća istraživanja.

2. PREGLED TEORETSKIH POSTAVKI O CRM-U U VREMENSKOJ PERSPEKTIVI

Najveći izazov upravljanja u novom vremenu liberalizacije i globalizacije za poslovanje je služiti i održavati dobar odnos s kraljem, a to je u svakoj situaciji bez iznimke kupac. U prošlosti su proizvođači svoje kupce uzimali zdravo za gotovo, jer u to vrijeme kupci nisu bili zahtjevni, niti su imali alternativni izvor opskrbe ili dobavljača, ali danas dolazi do radikalne transformacije (Ejara et al., 2011). Promjenjivo poslovno okruženje karakterizira ekonomska liberalizacija, sve veća konkurencija, veliki izbor potrošača, zahtjevan kupac, veći naglasak na kvaliteti i vrijednosti kupnje itd. Sve su te promjene dovele do pomaka današnjeg proizvođača s tradicionalnog marketinga na moderni marketing (Levitt, 1983). Suvremeni marketing zahtijeva više od razvoja proizvoda, utvrđivanja cijene, promocije i pristupanja ciljanom kupcu. Zahtijeva izgradnju povjerenja, obvezujuću snagu i odnos s dodanom vrijednošću s kupcima. Proces razvoja kooperativnog i suradničkog odnosa između kupca i prodavača naziva se upravljanje odnosima s kupcima, skraćeno CRM (Agwu i Onwuegbuzie, 2018).

Danas, s konkurentnom poslovnom atmosferom, poduzećima je izazov zadržati svoje kupce. Upravljanje učinkovitim i dobrim odnosima s kupcima zauzima značajno mjesto za sve tvrtke, bez obzira na veličinu i vrstu. Tako značajna pozicija brzo se razvila kao odgovor na mnoge zahtjeve poslovnog okruženja kao što je integracija sofisticiranih tehnologija u području informacijskih sustava (Kulpa, 2017).

Upravljanje odnosima s kupcima smatra se jednim od integriranih koncepata u području informacijske tehnologije i poslovanja, čiji su ključni ciljevi izgrađeni dugovječni odnosi između organizacija i kupaca. CRM je poslovna strategija orijentirana na kupca, koja se usredotočuje na poboljšanje zadovoljstva kupaca i stope lojalnosti kupaca pružanjem personaliziranijih i prilagođenih usluga korisnicima (Feiz et al., 2011). CRM tehnološke inicijative obično se provode u funkcionalnim odjelima; korisničke usluge i podrška, prodaja i marketing, kako bi se maksimizirao profit organizacije. Stoga organizacije puno ulažu u CRM projekte, kako bi bolje razumjeli kupce i brzo odgovorili na njihove zahtjeve i potrebe (Ledingham i Rigby, 2004).

Iako se obećavajuće prednosti i očekivanja mogu postići implementacijom ovakvih projekata unutar mnogih organizacija, značajan i velik broj CRM projekata je propao ili su rezultirali razočaravajućim rezultatima koji su daleko ispod očekivanja (Srivastava, 2012).

Osim toga, mnogi su autori izvijestili da organizacije ignoriraju važnost kritičnih čimbenika uspjeha potrebnih za implementaciju CRM-a, što je rezultiralo ovim velikim neuspjesima i gubicima u CRM projektima. To je motiviralo istraživače i akademike da se usredotoče na proučavanje razloga neuspjeha i istaknu vitalne uloge kritičnih čimbenika uspjeha u implementaciji CRM-a. Mnoge publikacije i radovi potvrdili su da "da bi organizacije implementirale CRM projekte zahtijevaju određene aktivnosti ili čimbenike" kojima se ispravno upravlja i kontrolira kako bi se jamčio učinkovit proces implementacije (Lund, 2021).

2.1. Opća teorija sustava kao konceptualna preteča CRM-u

Opća teorija sustava (GST) je osnova za rad sustava u stvarnom vremenu. Autor Bertalanffy je još 1960'ih godina prošlog stoljeća pokrenuo GST. CRM menadžeri mogu koristiti GST kao objektiv za gledanje nekoliko disciplina i sustava i s njima povezanih problema. GST je skup koncepata koji se kombiniraju radi razumijevanja različitih sustava, daju objašnjenja i identificiraju stvarne utjecaje na sustav implementatora. Koristeći GST, istraživači također mogu razumjeti i interpretirati složene adaptivne sustave, koji su u interakciji na hijerarhijski način (Ray, 2000).

Sustavno razmišljanje je kolektivan pristup za poslovne menadžere, koji mogu koristiti nekoliko složenih podsustava ljudi, procesa i tehnologija za postizanje zajedničkih ciljeva. Budući da je GST više komplementaran nego konkurentan, istraživači mogu odabrati opće pojave u različitim disciplinama i stvoriti konceptualne okvire (Kozlowski i Klein, 2012).

Koristeći GST, istraživači mogu istražiti strategije koje CRM menadžeri u bilo kojem sektoru, pa tako i osiguravateljnom, koriste za postizanje učinkovitosti i djelotvornosti u svojim CRM praksama. Koristeći GST, istraživači mogu tražiti slične ideje, zakone i modele u različitim područjima i olakšati razmjenu među tim područjima (Turner i Baker, 2019).

GST može također doprinijeti smanjenju ponavljanja teorijskih napora i poboljšanju komunikacije među zaposlenicima, koji su sudjelovali u dizajnu, razvoju i implementaciji CRM sustava. Korištenje GST-a može pružiti uvid za istraživanje i razumijevanje sustava u stvarnom svijetu, kao i višestrukih složenih sustava (Yurtseven i Buchananb, 2016).

2.2. Nastanak i razvoj CRM-a

Od 1990-ih, upravljanje odnosima s klijentima (CRM) pojavilo se i brzo raslo u poslovnom okruženju. Zapravo, CRM je evoluirao iz tržišta automatizacije prodajne snage (SFA), koje je nastalo iz upravljanja kontaktima (Xu et al., 2002). Bez obzira na njihovu vrstu i veličinu, tvrtke su motivirane implementirati CRM kako bi razvile i učinkovitije upravljale jakim odnosom s kupcima u pokušaju da steknu komparativnu prednost. Poboljšana kvaliteta odnosa s kupcima može u konačnici dovesti do povećanja zadovoljstva kupaca i profitabilnosti organizacije (Pohludka i Stverkova, 2019). Osim toga, brzi rast interneta i njegovih naprednih tehnologija uvelike su povećali mogućnosti za marketing i promijenili način na koji se upravlja odnosima između organizacija i kupaca (Saarijärvi et al., 2013).

2.2.1. Povijesni narativ o CRM-u

Mnogi ljudi vjeruju da je CRM počeo s uvođenjem tehnologija o bazama podataka u većim razmjerima. Iako je tehnologija baze podataka nesumnjivo omogućila rast CRM-a, počeci CRM-a počeli su u poslovnim disciplinama marketinga, strategije i upravljanja opskrbnim upravljanje lancem. Točnije, znanstvenici mogu pratiti CRM korijene unazad sve do marketinga, koji se temelji na odnosima. Međutim, CRM također ima jake veze s orijentacijom na kupca i upravljanje bazom podataka (Buttle, 2008).

Zapravo, ranije implementacije CRM-a bile su usredotočene gotovo isključivo na tehnologiju. Pogled na CRM kao jedino tehnološko rješenje može biti ključni razlog za zakazivanje mnogih sustava. Mnoge tvrtke izgubile su fokus na kupca jer su tražile novu tehnologiju. Početna veza s tehnologijom baze podataka natjerala je mnoge korisnike da se više koncentriraju na tehnologiju, a ne kako omogućiti poboljšane odnose s kupcima (Simmons, 2015).

Tehnološki fokus prvih CRM napora, zajedno sa željom tvrtki da dođu do uspjeha, doveli su do značajnih ulaganja u CRM platforme. Između 2000. i 2005. godine, tvrtke su zajedno potrošile 220 milijardi dolara na CRM rješenja. Istraživanja međutim sugeriraju da to nije bio dobro potrošen novac. Znanstvenici su otkrili da je 22% CRM sustava implementirano prije 2008. dalo razočaravajuće rezultate, a 20% čak i narušene odnose s kupcima (Becker et al., 2009).
Pogrešan fokus na tehnologiju, naspram uravnoteženog pristupa, uključujući ljude i procese može biti temeljni razlog zašto CRM sustavi ne uspijevaju (Maklan et al., 2011).

Povijest CRM sustava počinje u području marketinga. Istraživači su pratili najranije podrijetlo CRM sustava u području marketinga odnosa još iz 1983. godine. Prisutne su međutim tvrdnje da je CRM počeo mnogo ranije s korištenjem telefonskih anketa nasumičnog biranja broja sedamdesetih godina prošlog stoljeća. Ipak treba imati u vidu da prve telefonske ankete malo nalikuju sadašnjoj definiciji CRM-a (Christopoulos i Agoes, 2018).

Međutim, stvarni rast CRM-a započeo je početkom 1990-ih uvođenjem aplikacija za automatizaciju prodaje i širenje pozivnih centara. Standardne softverske aplikacije, ili platforme, potaknule su prvo rast CRM tržišta. Izdavanje komercijalnih hardverskih i softverskih rješenja od strane dobavljača kao što je Siebel Systems potaknulo je rast uočen u kasnim 1990-ima (https://www.vtiger.com/crm/evolution-of-crm/, pristup 08.09.2021).

Komercijalni CRM sustavi isporučuju se s unaprijed zapakiranim aplikacijama, kao što su automatizacija prodajnih snaga i korisnička podrška. Prethodno zapakirane aplikacije su tvrtkama pružile najbolju praksu, temeljenu na sustavu poboljšanja u upravljanju prodajom i uslugama za korisnike. Uz implementacije komercijalnih CRM aplikacija, tvrtke su uspjele prikupiti goleme količine podataka o preferencijama i kupovnim navikama njihovih kupaca (Hargrave i Anderson, 2020). S velikim količinama novodobivenih podataka o kupcima, trgovci su brzo tražili nove načine korištenja podataka za stratešku prednost. Dostupnost velikih količina podataka o kupcima iznjedrila je ideju marketinga jedan-na-jedan i masovne prilagodbe još od vremena ranih 1990-im godinama (Hargrave i Anderson, 2020).

2.2.2. Definicija pojma CRM

Često se ističe da postoji nedostatak konsenzusa o definiciji CRM-a. Usko utemeljena definicija CRM-a često doprinosi neuspjehu CRM projekata, kada organizacija promatra CRM iz perspektive ograničene tehnologije ili kada implementira CRM kao fragmentirani put. CRM sustav je alat za upravljanje poslovanjem temeljen na tehnologiji za razvoj i iskorištavanje znanja kupaca za njegovanje, održavanje i jačanje profitabilnih odnosa s kupcima. Stoga je CRM sustav bitan dio globalne CRM strategije koja naglašava stvaranje vrijednosti za dioničare kroz razvoj odgovarajućeg odnosa s ključnim kupcima i segmentima kupaca (Thejaswarup, 2017).

Temeljna premisa CRM-a je da tvrtke stvaraju znanje kupaca kako bi mogle učinkovito segmentirati kupce, razviti i održavati dugoročne odnose s profitabilnim kupcima, odrediti kako postupati s neprofitabilnim kupcima i prilagoditi tržišne ponude i promotivne napore. Kroz stvaranje i bolje korištenje znanja kupaca, odnos s kupcima i lojalnost kupaca bi se trebali poboljšati (Farhan et al., 2018).

CRM se smatra značajnim poslovnim strateškim alatom, koji može pomoći organizacijama u postizanju puno ciljeva i zadataka. Iz perspektive industrije, CRM se sastoji od omogućavanja organizaciji da identificira i cilja vrijedne kupce, učinkovito integrira poslovne procese, razvije konkurentsku prednost, te upravlja marketinškim kampanjama s jasno planiranim ciljevima (Chai et al., 2018). Nadalje, omogućuje udovoljavanje zahtjevima kupaca u pravom trenutku s pravom uslugom ili proizvodom, tretirajući svakog kupca jedinstveno, pomaže organizaciji da poboljša teleprodaju, računovodstvo i upravljanje prodajom, optimiziranjem informacija koje dijeli više zaposlenika, omogućava uspostavljanje individualiziranih odnosa s kupcima, kao i pružanje sigurnih usluga i praćenje potreba i ponašanja kupaca cijelo vrijeme (Feiz et al., 2011).

Kada poduzeća ostvare ove ciljeve, ostvarit će se povećanje dobiti i koristi. Studija autora Tarasija izvijestila je da prednosti CRM-a uključuju povećanje sposobnosti organizacija da zadrže i pridobiju nove kupce, maksimiziraju životni vijek kupaca i poboljšaju kvalitetu usluge uz niže troškove (Tarasi, 2007).

Iako je upravljanje odnosima s klijentima (CRM) široko prihvaćen poslovni pristup, on znači različite stvari za različite ljude, te stoga ne postoji univerzalno zajednička i prihvaćena definicija za CRM.

Studija autora Kankam Boadu definira CRM kao „pristup tvrtke razumijevanju i utjecaju na ponašanje kupaca kroz smislenu komunikaciju kako bi se poboljšalo stjecanje kupaca, zadržavanje kupaca, lojalnost kupaca i profitabilnost kupaca" (Kankam Boadu, 2019).

Studija autora Buttlea promatra CRM kao „integracijski okvir, poduzetničku strategiju i proces koji pruža usluge korisnicima i ima za cilj održavanje dugoročne veze i ispunjavanje različitih i stalnih potreba kupaca" (Buttle, 2008).

U studiji autora Parvatiyara i Shetha uvedena je još jedna definicija CRM-a kao: "Sveobuhvatna strategija i proces stjecanja, zadržavanja i partnerstva sa selektivnim kupcima za stvaranje vrhunske vrijednosti za tvrtku i kupca. Uključuje integraciju marketinga, prodaje, te usluga kupcima, kao i funkciju lanca nabave u organizaciji, kako bi se postigla veća učinkovitost i djelotvornost u isporuci vrijednosti za kupce" (Parvatiyara i Sheth, 2001).

U osnovi, ove razlike u definiciji CRM-a mogu biti rezultat pojave CRM koncepta marketinga u području informacijske tehnologije. Stopa neuspjeha implementacije CRM-a je visoka, što onemogućuje ishode ovih implementacija. Stoga je učinjeno mnogo radova na otkrivanju razloga, koji dovode do neuspjeha CRM projekata. Ove studije identificirale su razloge, koji mogu uzrokovati neuspjeh CRM-a. Općenito, razlozi neuspjeha CRM-a, kako je prikazano u postojećim studijama, povezani su s različitim aspektima elemenata, komponenti i procesa CRM-a (Foss et al., 2008).

2.2.3. Odnos CRM-a i kritičnih čimbenika uspjeha

S druge strane, kritični čimbenici uspjeha (CSF) je metoda koja se koncentrira na identificiranje čimbenika koji imaju ključnu ulogu za uspjeh organizacije, jer bi nedostatak takvih čimbenika mogao dovesti do neuspjeha. Razvoj ove metodologije temeljio se na radu autora, ali malo je zanimanja za ovaj koncept u ovom trenutku. Identificiranje čimbenika uspjeha važna je aktivnost, u kojoj se tvrtkama omogućuje da usmjere svoje resurse prilikom implementacije svojih sustava, kako bi postigle te čimbenike uspjeha (Caralli, 2004).

Autor u svojoj studiji definira CSF-ove kao „fiksne varijable koje pomažu u razvoju granica poboljšanja procesa; ako razmotre svaki korak provedbe na temelju važnosti, imat će veći učinak." Osim toga, istoimeni autor nadalje ističe da su ključni čimbenici uspjeha "minimalni kapacitet koji bi tvrtka trebala imati da uđe u konkurenciju". Međutim, ove se gornje definicije više usredotočuju na upravljanje općenito, no također je moguće integrirati koncept CSF-a u projekte implementacije CRM-a (Fryer et al., 2007).

Bez sumnje, uspješna implementacija CRM-a zahtijeva integraciju tri ključne komponente CRM procesa, ljudi i tehnologije. U prirodi, svaki kritični čimbenik uspjeha ima izravan ili neizravan učinak na ove elemente kombinacije CRM-a. Stoga su pojedini i istraživači definirali ove CSF-ove iz gledišta CRM-a (Shabani Shojaei, 2015).
Autor Farhan definira CRM CSF-ove kao "generički sastojak koji mora biti bitan dio svake uspješne implementacije CRM-a". Također, autor ističe da su ovi CSF-ovi definirani kao "ograničeni broj područja u kojima će rezultati, ako su zadovoljavajući, osigurati uspješnu konkurentsku izvedbu za organizaciju" (Farhan et al., 2018:395). Istoimeni autori su pretpostavili da se faktor može smatrati CSF-om samo kada njegova prisutnost jamči uspješnu implementaciju CRM-a. Također, CSF su definirani kao "problemi koji utječu na uspjeh intervencije omogućene IT-om, a koje su osmišljene da utječu na poslovnu promjenu" (Farhan et al., 2018: 395).

Konačno, autor u svojoj studiji navodi da su ti CSF-ovi „aktivnosti koje se provode kako bi se zajamčila uspješna implementacija CRM-a" i mogu uzrokovati neuspjeh u projektima ako se zanemare. Međutim, ne mogu svi CSF biti kritični čimbenici neusojeha CRM-a. Iako veliki broj svih gore navedenih definicija koje se odnose na čimbenike uspjeha, autor navodi da ne postoji standardna metoda za prikupljanje i analizu tih čimbenika uspjeha. To je razlog što je bilo mnogo studija, te su istraživači koristili različite metode za identifikaciju CSF-a, kao što su: upitnici, intervjui i pregled literature prethodnih studija, kako bi se spoznalo što je točno potrebno za uspješne projekte implementacije CRM-a (Zahedi et al., 2011).

Uspješna implementacija upravljanja odnosima s klijentima (CRM) nije laka i čini se složenim zadatkom. Gotovo oko 70% svih projekata implementacije CRM-a ne uspijeva postići svoje očekivane ciljeve. Stoga se većina istraživača i programera informacijskih sustava usredotočuje na pristup kritičnim čimbenicima uspjeha koji mogu poboljšati uspjeh

implementacije CRM-a i pretvoriti neuspjeh i nedostatke s kojima se CRM suočava u uspješno usvajanje i implementaciju CRM sustava (https://www.salesforce.com/ap/hub/crm/why-do-crm-projects-fail/, pristup 12.09.2021).

U ovom je poglavlju pregledan broj prethodnih studija kako bi se pokazale prepreke iza ove visoke stope neuspjeha. Osim toga, provodi se opsežna revizija kako bi se identificirali i odredili prioriteti kritični čimbenici uspjeha (CSF-ovi) kojih su organizacije svjesne i pravilno poznaju; postići će uspjeh i ostvariti očekivane prednosti svoje CRM inicijative. Zatim se predlaže opsežna klasifikacija CSF-a. Konačno, rad predlaže opsežan popis metrike kao sredstva za pomoć u mjerenju ovih kritičnih čimbenika uspjeha (Farhan et al., 2018: 396).

2.3. Operativne definicije koje se vezuju uz CRM

Sljedeći izrazi i izrazi uključuju definicije uobičajenih pojmova, koje bi mogle imati različita značenja u svakodnevnoj upotrebi: (Chai et al., 2018)

- CRM implementator

CRM implementatori su tehnički menadžeri, voditelji projekata, softverski arhitekti i softverski administratori koji prakticiraju CRM u svojim organizacijama, koristeći bilo koji CRM alat (Hargrave i Anderson, 2020).

- CRM alat

CRM alat je softverska aplikacija. CRM alati koje su neki razvili neki od vodećih proizvođača softvera su Oracle CRM, SAP CRM, PeopleSoft CRM i Microsoft CRM.

- Upravljanje odnosima s klijentima (CRM)

CRM uključuje mjere, tehnologije i strategije koje organizacije prakticiraju kako bi održale dobar odnos sa svojim kupcima.

- Elektronsko upravljanje odnosima s klijentima (eCRM)

eCRM je integracija aplikacija za CRM i e-poslovanje, a usredotočuje se na korištenje elektronike za olakšavanje CRM-strategije.

- Društveni CRM

Društveni CRM odnosi se na proces, u okviru kojega velike tvrtke analiziraju veće količine podataka o kupcima, dostupnim putem društvenih medija (Hargrave i Anderson, 2020).

2.4. Pitanje uspješnosti implementacije CRM sustava

Foss i suradnici tvrde da uspješna implementacija CRM programa ovisi o četiri kritična čimbenika: procjeni spremnosti CRM-a, upravljanju promjenama CRM-a, upravljanju CRM projektom i angažmanu zaposlenika (Foss et al., 2008).

Procjena spremnosti CRM-a je pregledna revizija, koja pomaže menadžerima da procijene ukupnu poziciju u smislu spremnosti za napredak u implementaciji CRM-a i da identificiraju koliko je njihova organizacija razvijena u odnosu na druge tvrtke (Foss et al., 2008).
Upravljanje promjenama CRM-a uključuje strateške organizacijske promjene i kulturološke promjene. Razumijevanje na višim razinama, sponzorstvo, vodstvo i međufunkcionalna integracija očito su ključni u složenoj implementaciji CRM-a (Faed et al., 2010).

Upravljanje CRM projektima zahtijeva formiranje među funkcionalnih timova stručnjaka, koji upravljaju programom implementacije CRM-a poduzeća. Uspješni CRM projekti ispunjavaju CRM ciljeve koji proizlaze iz korporativnih ciljeva i podržavaju cjelokupnu poslovnu strategiju. Konačno, angažman zaposlenika uključuje podršku i predanost zaposlenika CRM projektima. Poduzeća sve više prepoznaju značajnu vrijednost koju njihovi zaposlenici pridonose poslovanju, koja se proteže i dalje od osnovnog ispunjavanja temeljnih dužnosti. Tvrtke ne mogu razviti i upravljati na odgovarajući način CRM sustave i procese usmjerene na kupca bez motiviranih i obučenih zaposlenika (Faed et al., 2010).

Isto tako iznose se različiti argumenti za neuspjeh CRM sustava. Grisham sugerira da je glavni razlog neuspjeha CRM projekta nedostatak strateškog planiranja prije implementacije CRM-a, te dalje otkriva da su razlozi neuspjeha mnogih CRM inicijativa varirali od tehnoloških problema implementacije do nedostatka organizacijske integracije i orijentacije na kupca (Grisham, 2016).

Schaeffer navodi da se većina takvih neuspjeha pripisuje lošem dizajnu, planiranju i mjerenju CRM projekata, te dalje u svom članku komentira da su hvatanje pogrešnih informacija o klijentima, nejasni ciljevi, neprikladan odabir i korištenje tehnologije, nemogućnost integracije ljudi i procesa, te korištenje obmanjujućih metričkih podataka ili neprikladnih pristupa mjerenju glavne prepreke u implementaciji i upravljanju CRM projektima (Schaeffer, 2017).

U literaturi se nadalje ističu razlozi za nezadovoljavajući ishod CRM-a u smislu promatranja CRM inicijative kao tehnološke inicijative; nedostatak vizije usmjerene na kupca; nedovoljno uvažavanje životne vrijednosti kupaca; neadekvatna podrška najvišeg menadžmenta; podcjenjivanje važnosti upravljanja promjenama; neuspjeh reinženjeringa poslovnih procesa; i podcjenjivanje poteškoća povezanih s rudarenjem podataka i integracijom podataka (https://www.salesforce.com/ap/hub/crm/why-do-crm-projects-fail/, pristup 22.09.2021).

Navodi se nadalje da većina rukovoditelja nije ni svjesna ovih problema, iako bi to moglo predstavljati katastrofu za njihovu karijeru i tvrtku. Drugi tvrde da je na neuspjehe CRM-a u velikoj mjeri utjecao nedostatak sposobnosti tvrtki da integriraju CRM tehnologije u svoje funkcionalne procese (Schwager i Meyer, 2007).

2.5. Kategorizacija CRM sustava

Aplikacije CRM sustava mogu se kategorizirati u operativne ili analitičke. Operativni CRM ima za cilj smanjenje operativnih troškova, a istovremeno omogućuje tim funkcionalnim područjima da korisnicima pruže višu razinu vrijednosti. Sadrži sve aplikacije u izravnom kontaktu s kupcem (npr. predstavništava) (https://www.nextiva.com/blog/operational-crm.html, pristup 24.09.2021).

Operativni CRM uključuje automatizaciju prodajnih snaga (SFA), marketing i korisničku podršku s ciljem da ove funkcije budu učinkovitije i učinkovitije. Na primjer, CRM sustav može voditi prodavača kroz identifikaciju informacija, koje se odnose na kupca prilikom obavljanja prodajnog poziva. Te se informacije mogu odmah povezati s pozadinskim uredima ili prenijeti u druge funkcionalne odjele, kao što su proizvodnja, financije i logistika, te komunikacijske kanale kako bi se identificirala i pružila kupcu tržišna ponuda koja pruža vrijednost (Iriana i Buttle, 2006).

Tvrtke su brzo naučile da bi im prikupljanje i djelovanje na temelju podataka o kupcima moglo pomoći da steknu i zadrže profitabilne kupce. Ova potreba stvorila je novu granu CRM-a poznatu kao analitički CRM. Obećanje analitičkog CRM-a je da može pomoći u prenošenju prave ponude do pravih kupaca u pravo vrijeme. Korištenje analitičkog CRM-a od strane menadžera, omogućio im je da podatke o kupcima pretvore u informacije, koje bi

mogli koristiti za pronalaženje novih kupaca ili poboljšanje odnosa s postojećim kupcima (Hicks, 2020).

Analitički CRM odnosi se na tehnologije koje agregiraju informacije o klijentima i pružaju analizu podataka o klijentima, kako bi se poboljšalo donošenje odluka i djelovanje u upravljanju. Temelji se na tehnologijama kao što su skladištenje podataka i rudarenje podataka. U idealnom slučaju, baza podataka kupaca bi trebala biti dostupna iz svih relevantnih odjela kao što su prodaja, služba za korisnike i marketing (Iriana i Buttle, 2006).

Analitički CRM čini osnovu za planiranje i evaluaciju marketinških kampanja, te pomaže unakrsnim i prodajnim funkcijama. Za uspješnu implementaciju CRM-a, tvrtke moraju kombinirati fizičke resurse (npr. računala i tehnološku infrastrukturu), informacijske resurse (npr. baze podataka kupaca, evidenciju poziva prodavača, interakcije s korisničkom službom) i organizacijske resurse (npr. kultura orijentirana na kupca, rutine dijeljenja informacija) kako bi poboljšale relacijski resursi (tj. odnosi s kupcima) kako bi se poboljšala konkurentska pozicija tvrtke (Kulpa, 2017).

Uspjeh implementacije CRM-a može se definirati kao događaj kada CRM sustav pomaže tvrtki da isplativo isporuči tržišne ponude kupcima koje pružaju vrijednost kupcima, moguće po nižoj cijeni u odnosu na konkurenciju, pružaju veću vrijednost u isto vrijeme relativni trošak u odnosu na konkurenciju ili pružaju veću vrijednost uz nižu cijenu u odnosu na konkurenciju (https://techonestop.com/types-of-crm-operational-analytical-collaborative, pristup 27.09.2021).

Početkom do sredine 2000-ih počela se pojavljivati nova generacija CRM-a poznata kao društveni CRM ili CRM 2.0. Pojava popularnih društvenih mreža kao što su Facebook, MySpace, Twitter i drugi pomogli su u razvoju novih metoda za tvrtke za komunikaciju i prikupljanje informacija od svojih kupaca (Newberry, 2021). Svrha društvenog CRM-a je uključivanje kupaca u suradnju kroz razgovore i poboljšanje odnosa s kupcima. Društveni CRM proširuje dostupne podatke na CRM aplikacije i omogućuje trgovcima novi kanal za učinkovitije komuniciranje s kupcima (Faese et al., 2011).

Postoji jaka veza između CRM aplikacija i disciplina marketinga. U literaturi je usuglašeno da je sposobnost CRM aplikacija za profiliranje kupaca jednako važno kao i proizvod, cijena,

promocija i mjesto, poznatije kao 4P marketing. Izgradnja i upravljanje odnosima s kupcima bitni su za marketing. CRM tehnologija omogućuje tvrtkama da razvijaju bolje marketinške strategije i omogućuje izvođenje ciljanih kampanja, koje su učinkovitije zbog integriranih podataka o kupcima (Ghavami i Olyaei, 2006).

Dodatno, CRM tehnologija omogućuje tvrtkama da poboljšaju svoje marketinške sposobnosti, dopuštajući zaposlenicima da brže i temeljitije postižu ciljeve. Tradicionalno upravljanje marketingom usredotočeno je na proizvedene i pakirane potrošačke proizvode za masovnu distribuciju. Međutim, marketinški trend se promijenio ranih 2000-ih od modela usmjerenog na proizvod do modela usmjerenog na kupca (Xu et al.,2002).

Model usmjeren na kupca prisilio je tvrtke da se više usredotoče na usluge koje su njihovi kupci željeli, a ne na puke proizvode. Promjena u ekonomijama do baza usluga prouzročila je pomak sličan marketingu usluga. Servisni marketing je sličan marketingu odnosa i fokusira se na interakciju između kupaca i dobavljača. Osim toga, marketing usluga naglašava važnost osobnih odnosa s kupcima i važnost izvršenja usluge (Xu et al.,2002).

Suradnički CRM je pojavnost CRM-a *per se*. Jedna od primarnih prednosti CRM-a je način na koji omogućuje komunikacija. Komunikacija među dionicima bitan je element stvaranja suradničkog radnog okruženja. Učinkovit CRM sustav omogućuje organizaciji da poveća suradnju među internim funkcijama kao što su prodaja i druge interne grupe (Rodriguez i Honeycutt, 2011.).

Kolaborativni CRM sustavi pružaju sredstva za sinkronizirati, upravljati i distribuirati komunikaciju između funkcija unutar jedne organizacije i izvana prema kupcu. Neki znanstvenici su proširili opseg suradničkog CRM-a na cijeli lanac opskrbe. Kada CRM za suradnju uključuje kompletan lanac opskrbe, tvrtke bolje vide odgovor na zahtjeve kupaca (Dyshkant, 2020).

Budući da suradnički CRM pruža sredstvo za priopćavanje informacija tolikom broju dionika, često se naziva i komunikativni CRM. Primarni cilj kolaborativnog CRM-a treba pružiti rezultate analize od analitičkog CRM sustava do operativnog CRM sustava u pravo vrijeme i putem odgovarajućeg kanala (Dyshkant, 2020).

Kolaborativni CRM sustavi uključuju informacijske tehnologije koje omogućuju učinkovitu komunikaciju u cijelom opskrbnom lancu. Komponente suradničkog CRM-a uobičajene su u radnoj snazi. Suradničke CRM tehnologije uključuju mnoge opće mehanizme, koje tvrtke koriste za internu i vanjsku komunikaciju kao što su e-pošta, telefonski sustavi, faks i web stranice (Rodriguez i Honeycutt, 2011.).

Kako sustavi i tehnologija napreduju u područjima upravljanja partnerskim odnosima i unutar centara za interakciju s korisnicima, znanstvenici su uključili dodatne alate u kategoriji suradničkog CRM-a. Na primjer, upravljanje projektima, projektna suradnja, softver za čavrljanje, sustavi za e-učenje, web prijenosi, web audio, web video, interaktivna korisnička podrška i interaktivna prodajna podrška su sustavi suradnje. Programeri integriraju konvencionalne komunikacijske alate u CRM platforme, kako bi se omogućio suradnički CRM. (Dyshkant, 2020).

Elektronički CRM je naredni pojavni oblik CRM-a. Uz jaku vezu između tehnologije i CRM-a, nije iznenađujuće da mnogi istraživači informacijsku tehnologiju vide kao najvažniji dio CRM-a. Znanstvenici koji podržavaju dominaciju tehnologije vide internet i druge informacije, kao tehnološka rješenja koja su ključni pokretači marketinga odnosa. Istraživači koji podržavaju tehnološku perspektivu razvili su pojam elektronički CRM (Peštek i Lalović, 2011).

Elektronički CRM usko je povezan s inicijativama e-poslovanja i uključuje niz koncepata, procesa i alata, koji pomažu poduzeću da maksimalno poveća svoj povrat ulaganja u tehnologiju. Koncept eCRM-a više prevladava na tržištima poslovnih korisnika, nego na tržištima između poduzeća. Elektronički CRM sustavi pružaju izravnije sredstvo komunikacije s kupcima, pa čak i stupanj samoposluživanja. Osnovna razlika između eCRM-a i druge vrste CRM-ova je izravan kontakt s kupcima putem internetskih tehnologija (Diksha, 2018).

U operativnom CRM-u, uslužni agenti u pozivnom centru komuniciraju s kupcima i bilježe podatke o interakciji u CRM sustavu. Elektronički CRM sustavi omogućuju korisnicima izravnu komunikaciju s poslovnim sustavima putem interneta alata bez potrebe za ljudskom interakcijom. Elektronički CRM bilježi potpuno online korisničko iskustvo od prije kupnje do post-kupnje (Oanh, 2021).

Elektronički CRM sustavi su u velikoj mjeri zamijenili aplikacije na prodajnim mjestima u mnogim slučajevima i omogućili kupcu da izvrši cjelokupnu transakciju kupnje, bez potrebe za serviserom. Napredni eCRM sustavi, poput onih koje koristi Amazon.com, čak će predložiti dodatne kupnje na temelju kupčeve povijesti kupnje (Diksha, 2018).

Postoje mnoge potencijalne prednosti eCRM-a, uključujući poboljšanu korisničku uslugu, poboljšanu lojalnost kupaca, personalizaciju proizvoda, uštede troškova, povećanje prodaje i povećanje profitabilnosti (Oanh, 2021).

Mettagarunagul i Pueng u svojoj tezi iz 2011., pronašli su snažnu vezu između eCRM-a i proizvodnje. Elektronički CRM omogućuje tvrtkama da pojednostave svoju proizvodnju poslovanja i pružanje prilagođenih proizvoda i usluga svakom kupcu. Mnoge prednosti eCRM-a mogu ponuditi izvor dugoročne konkurentske prednosti za organizacije. Međutim, eCRM je manje prihvaćen u poslovnom okruženju gdje profesionalci još uvijek preferiraju osobnu interakciju (Mettagarunagul i Pueng, 2011).

Društveni CRM je također pojavni oblik CRM-a. Širenje tehnologije daje ljudima mogućnost komunicirati brže i učinkovitije nego u bilo kojem drugom trenutku u povijesti. Društvene mreže postaju sve popularniji alati u osobnoj i profesionalnoj upotrebi. Društvene mreže dopuštaju klijentima komunicirati među sobom i s tvrtkama. Kupci očekuju sudjelovati u prilagodbi proizvoda koje kupuju i žele dati svoj doprinos budućim proizvodima (Yawised et al., 2013).

Društveni CRM je relativno nov razvoj na CRM tržištu, te je započeo s razvojem još 2007. godine, a pojavio se kao pomak u strategiji s odnosa samo transakcije na odnos usmjeren na interakciju s kupcima (Jalal et al., 2021).

Međutim, koncept društvenog CRM-a datira iz 1996. godine, kada su znanstvenici predviđali da će budući kupci uspjeti uspostaviti osobne odnose s tvrtkama. Bez obzira na točan početak društvenog CRM-a, još uvijek nije postignuta potrebna razina integracije i sofisticiranosti kao drugi aspekt CRM-a. Stručnjaci ne vide društveni CRM kao zamjenu za tradicionalni CRM, ali umjesto toga ga promatraju kao proširenje koje dodaje društvene funkcije, procese i interakcije s tradicionalnim CRM-om (Faese et al., 2011).

Društveni CRM je prirodno proširenje CRM platforme s integracijom novih komunikacijskih tehnologija (Mettagarunagul i Pueng, 2011).

Sveobuhvatna CRM definicija nešto je šira. Znanstvenici su naime proizveli veći broj definicija za CRM. Mnogi oblici CRM sustava korišteni u posljednjih 20 godina mogu pomoći objasniti kako su se razvile različite definicije CRM-a. Iako ne postoji jedinstvena definicija CRM-a, pregled literature ukazuje da sveobuhvatna definicija mora nadilaziti opis tehnologijom utemeljenih rješenja (Hargrave i Anderson, 2020).

CRM je široki poslovni koncept s korijenima u marketingu odnosa i vezama na informacijsku tehnologiju, koja uključuje kombinaciju ljudi i procesa u radu, kako bi maksimizirali koristi ostvarene iz poboljšanih odnosa s kupcima. U tom smislu, rukovoditelji gledaju na CRM kao na strategiju, koja omogućuje korištenje internih resursa, za upravljanje odnosima s kupcima, kako bi se omogućila poboljšana financijska izvedba i stvorila konkurentska prednost za organizaciju (https://crm.org/crmland/what-is-a-crm , pristup 28.09.2021).

Značajna stopa neuspjeha CRM implementacija, može utjecati na želja za kvantificiranjem financijskih koristi ulaganja u CRM. Novije definicije CRM-a naglašavaju stratešku prirodu procesa, više nego li sam aspect tehnologije. U novojim definicijama, autori su opisali CRM kao stratešku inicijativu, povezanu s tehnologijom, koja usredotočuje aktivnosti tvrtke oko kupca, s ciljem pružanja prilagođene usluge pri svakoj interakciji (Edinger, 2018). Zajednička tema, koja se pojavljuje u svim definicijama je pogled na CRM, kao na sveobuhvatnu skupine strategije za upravljanje odnosima s kupcima, a ne samostalnu inicijativu, koja nije povezana s cjelokupnom poslovnom strategijom (Pedron i Saccol, 2009).

2.6. Pogled na benefite i nedostatke uvođenja CRM-a

Tvrtke koriste CRM kako bi razvile čvršće odnose s kupcima. U studiji iz 2014. godine, autori su otkrili da tvrtke, koje imaju jake odnose s kupcima, rade bolje od onih koji to ne rade. Međutim, tvrtke mogu postići mnoge druge koristi od korištenja CRM praksi. Neki primjeri prednosti uključuju omogućavanje komunikacije, pružanje pravovremenih povratnih informacija, analizu informacija o kupcima i pružanje prilagođene ponude proizvoda (Avery et al., 2014.).

Neke od općih prednosti CRM-a uključuju zadržavanje kupaca, povećane mogućnosti unakrsne prodaje, povećanu akviziciju kupaca i pridobivanje profitabilnih kupaca (Rana, 2019).

Istraživači su otkrili da CRM u zdravstvenoj industriji poboljšava kvalitetu usluge, povećava zadovoljstvo pacijenata i povećava obostranu korist. Menadžeri u bankarskom sektoru koriste CRM sustave za ciljanje profitabilnih kupaca, integraciju preko digitalnih kanala, poboljšavanje korisničkih usluga, povećanje prodajne snage, kao i prodajne učinkovitosti, koordinaciju marketinške poruke, povećanje motivacije zaposlenika, poboljšanje u donošenju odluka i prilagođavanju proizvoda. Ukratko, CRM sustavi ojačavaju odnos između kupaca i prodavača (Baashar et al., 2020).

Međutim, tvrtke su pronašle prednosti korištenja CRM sustava izvan očitih prednosti u situacijama s klijentima. Jedna od ključnih prednosti korištenja CRM sustava je ta što su mnoge tvrtke počele shvaćati važnost ogromne količine podataka o kupcima, koje pohranjuje. CRM sustavi omogućuju poduzećima kako bi prikupili informacije o kupcima i zatim iskoristili stečeno znanje za poboljšavanje proizvode i usluga (Kuligowski, 2021).

Kako tvrtke, koje koriste podatke pohranjene u njihovom CRM sustavu često diktiraju percipirani uspjeh njihovog ulaganja, istraživači su otkrili da tvrtke koje generiraju veće količine podataka o kupcima nadmašuju one koji ne prikupljaju podatke (Krafft et al., 2021).

Međutim, prikupljanje podataka o klijentima samo po sebi sustav neće učiniti uspješnim. Stručnjaci dizajniraju najbolje CRM sustave za prikupljanje, obradu i korištenje podataka o korisnicima, što omogućuje agentima usluga da brzo rješavaju probleme kupaca. Nasuprot tome, tvrtke koje imaju djelomične ili netočne podatke o kupcima su u opasnosti od širenja frustracija kupaca i često imaju smanjenu profitabilnost (Krafft et al., 2021).

Nakon što CRM sustav prikupi informacije od kupca, menadžeri trebaju alat koji im omogućuje analizu podataka. Tehnologije analitičkog CRM-a (aCRM) obavljaju zadatak analize podataka u CRM sustavima. Analitički CRM omogućuje ciljani marketing, pruža analitiku tržišta, pomaže u otkrivanju prijevara i segmentira kupce na temelju unaprijed određenih kriterija (https://www.managementstudyguide.com/analytical-crm.htm, pristup 02.10.2021).

Analitički CRM pruža menadžerima potrebne analize podataka da izvuku vrijednost iz ulaganja u svoj CRM. Ključna prednost korištenja CRM-a je smanjenje stope napuštanja korisnika. CRM omogućuje tvrtkama da prate probleme korisnika, prate odgovor usluge i dodjeljuju upite kupaca odgovarajućem stručnjaku (Lin et al., 2002).

Na opisani način tvrtke mogu riješiti kupčeve probleme u bržem roku i poboljšati zadovoljstvo kupaca, dovodeći kupce do pravih stručnjaka, koji brzo mogu riješiti svoj problem (Lin et al., 2002).

Zadovoljstvo kupaca je bitno mjerilo poslovnog uspjeha. Zadovoljstvo kupaca jedan je od primarnih čimbenika, koji utječu na profitabilnost. Postoji nekoliko prednosti povećanog zadovoljstva kupaca uključujući višu razinu lojalnosti kupaca, preporuke kupaca i zadržavanje kupaca. Međutim, najvrjednija prednost zadovoljstva kupaca je povjerenje kupaca. Tvrtke žive i umiru na temelju povjerenja kupaca (Szyndlar, 2021).
Na primjer, u industriji financijskih usluga, banke su propale, jer im klijenti nisu vjerovali da će biti sposobne zaštititi njihov novac.

Pravilno dizajniran CRM sustav omogućuje uslužnim stručnjacima da brzo riješe probleme kupaca ili ih usmjer na stručnjake. Stručnjaci vjeruju da je vrijeme odgovora ključni čimbenik u poboljšanju zadovoljstva kupaca dugoročno. Potencijalne prednosti CRM-a su brojne, a popis se i dalje povećava kako tvrtke pronalaze nove i kreativne načine korištenja podataka o kupcima za isporuku proizvoda i usluga s dodanom vrijednošću (Plaksij, 2021).

Istraživači su grupirali ključne prednosti CRM-a u četiri kategorije, a to su poboljšani tržišni udio, smanjenje troškova, povećanje kupčeva zadovoljstva i integraciju operacija u cijelom opskrbnom lancu (Lin et al., 2002).

Implementacija i korištenje CRM-a u malim i srednjim poduzećima donosi izravne koristi u smislu financijskog učinka i dnevne poslovne aktivnosti. Drugim riječima, poboljšanja u cjelokupnom korisničkom iskustvu dovode do većeg zadovoljstva kupaca, što zauzvrat ima pozitivan učinak na profitabilnost tvrtke, sa posebnim dobicima kao što su povećana lojalnost kupaca; učinkovitija marketinška strategija; poboljšana korisnička usluga i podrška; veća učinkovitost; i smanjenje troškova (Pohludka i Stverkova, 2019).

Što se tiče lojalnosti kupaca, CRM omogućuje tvrtkama da centraliziraju i integriraju svoje evidencije o transakcijama i podatke o klijentima, čineći te informacije dostupnim i upravljivim svim ključnim dionicima kako bi se identificirali najlojalniji kupci i najučinkovitije marketinške aktivnosti (Pohludka i Stverkova, 2019).

Gil-Gomez i suradnici u svojoj studiji navode, kako softverske alate za personalizaciju smatraju jednim od ključnih elemenata za povećanu lojalnost kupaca. Definitivno, u današnjem visokokonkurentnom tržišnom ekosustavu postoji sve veća potreba za malim i srednjim poduzećima za diverzifikacijom rizika gubitka velikih kupaca (Gil-Gomez et al., 2020).

Marketing postaje učinkovitiji kada tvrtke implementiraju CRM zbog vrlo detaljnih informacija o klijentima prikupljenih interakcijom. Ove informacije omogućuju predviđanje donošenja odluka kupaca, što se prevodi u učinkovitije i personaliziranije marketinške kampanje za uspješne tvrtke, s većim utjecajem na njihovu prodaju i profitabilnost (Pohludka i Stverkova, 2019).

Camilieri u svojoj studiji iz 2017. godine tvrdi da informacije o kupcima mogu olakšati segmentaciju kupaca i na taj način učiniti marketinške napore učinkovitijima, jer grupiranje kupaca prema njihovim tržišnim potrebama omogućuje tvrtkama da dosegnu ciljne skupine kroz marketinške napore prilagođene segmentima (Camilieri, 2017).

Korisnička služba i podrška još je jedna tržišna značajka koja je podložna poboljšanju putem CRM-a, potičući temeljito razumijevanje potreba potrošača, a time i dovodeći do boljih načina za njihovo zadovoljenje (Plaksij, 2021).

Zapravo, CRM može pojednostaviti udaljene procese primanja, ažuriranja i plasiranja narudžbi tvrtke. S druge strane, CRM omogućuje vođenje tekućeg registra ulaganja u projekt, koji uključuje materijale, troškove i utrošak vremena. Konačno, daje pristup bazi podataka ugovora o korisničkoj službi. Sve ove poboljšane mogućnosti integrirane su kako bi klijente zadržali točno tamo gdje im je mjesto: u središtu strategije tvrtke (Lund, 2021).

CRM je dio šireg skupa softverskih alata i rješenja za upravljanje podacima za rudarenje podataka. Stoga olakšava analizu podataka kako bi se pronašle detaljne, tržišno relevantne informacije za uspješnije procese donošenja odluka (Gil-Gomez et al., 2020).

Osim toga, integriranje svih informacija u jedinstvenu bazu podataka omogućuje svim dionicima tvrtke da odbace zavaravajuće podatke, kao i da imaju dosljedan i jedinstven izvor informacija, što je ključna značajka za poboljšanje učinkovitosti, smanjenje troškova vezanih uz pristup podacima, analizu i eksploatacije, a time i donošenje boljih marketinških odluka (Srivastova, 2012).

CRM ne obuhvaća samo softver ili tehnologiju, već i strateško znanje, što ga čini globalnim rješenjem za točniju analizu podataka i bolje poslovne odluke (Anshari et al., 2019).

Čak i uz sve prednosti koje CRM sustavi nude, mnoge tvrtke koje su implementirale CRM sustave, njihovi čelnici i nadalje vide kao promašaje.

CRM sustavi pružaju mnoge prednosti tvrtkama, ali nema jamstva za uspjeh. Ogled tom primjeru je korporacija Hershey Corporation, koja je pretrpjela značajne gubitke nakon implementacije CRM sustava, a tvrtke u financijskom sektoru izvijestile su o značajnim poteškoćama u usklađivanju potreba kupaca s ponudom proizvoda (Simmons, 2015).

Istraživači imaju objavljene studije koje pokazuju stope neuspjeha CRM-a između 35% i 75%, dok je samo 44% ispitanih rukovoditelja izvijestilo o zadovoljavajućim rezultatima svojih novih CRM sustava (Farhan et al., 2001.).

Negativni ishodi neuspjeha CRM-a mogu se proširiti na zaposlenike i kupce na sličan način. U slučaju jedne određene australske telekomunikacijske tvrtke, problem s njihovom implementacijom CRM-a potaknulo je stvaranje Facebook stranice pod nazivom *Mrzim Siebel.* Novostvorena stranica privukla je preko 3000 članova, uključujući zaposlenike i kupaca (Hsieh et al., 2012).

Jasno je da loše implementiran CRM sustav uzrokuju značajnu frustraciju svim uključenim dionicima. Iako postoji mnogo razloga za neuspjehe CRM-a, istraživači su predložili sedam

ključne kategorije koje objašnjavaju zašto određeni CRM sustavi ne uspijevaju, uključujući tvrtke koje gledaju na CRM sustav uglavnom kao na ulaganje u tehnologiju: (Schaeffer, 2017)

- Tvrtki nedostaje vizija usmjerena na kupca,
- U poslovanju nema razumijevanja životne vrijednosti kupca,
- Nema dovoljno podrške višeg vodstva,
- Tvrtka nije rekonstruirala svoje poslovne procese kako bi odgovarala njihovim CRM strategijama,
- Tvrtka je podcijenila izazov integracije složenog sustava
- Tvrtka nije bila dorasla zadatku da izvrši potrebnu promjenu (Schaeffer, 2017)

Uravnotežen pristup implementaciji CRM-a, počevši s pravom količinom interakcije zaposlenika, može biti jedan od ključeva uspjeha CRM-a. Istraživači su na tom tragu predložili poboljšanu interakciju između ljudskih resursa i sposobnosti IT usluga, na ime dugog puta u borbi protiv visokih stopa neuspjeha (Foss et al., 2008).

Međutim, čak i ravnoteža između tehnologije i ljudi često nisu dovoljni. Implementacije CRM-a zahtijevaju uravnotežen pristup, koji integrira tehnologiju, procese i ljude, kako bi pružili duboko znanje i odgovor na potrebe kupaca. Kako bi se maksimizirale šanse za uspjeh implementacije CRM-a, tvrtke bi trebale ciljati poboljšanja, uz tri linije uključujući ljude, procese i tehnologiju (Feiz et al., 2011).

Čak i uz sve prednosti rada CRM sustava za tvrtke i njihove kupce, još uvijek ima mnogo negativnih aspekata. Jedna značajna negativna strana korištenja CRM-a je CRM paradoks. CRM paradoks opisuje nuspojave nekih kupaca, koje mogu imati kada prepoznaju različit tretman (Nguyen i Mutum, 2012).

Kada neki kupci percipiraju različit tretman, mogu reagirati tako da se uzrujaju, a zatim širiti negativne informacije koje mogu oštetiti tvrtku. Problemi kao što je CRM paradoks inherentni su dio onoga što neki autori nazivaju mračnom stranom CRM-a (Nguyen i Mutum, 2012).

Akademska literatura sadrži primjere tvrtki, koje su iskusile negativne posljedice jer su iste artikle prodavale kupcima različito na temelju statusa svakog kupca. Jedan od najpoznatijih primjera je korištenje Amazonovog dinamičkog određivanja cijena. Amazon je prodavao DVD-ove različitim kupcima po različitim cijenama, ovisno o njihovom statusu u tvrtki

(https://www.computerworld.com/article/2588337/amazon-apologizes-for-price-testing-program-that-angered-customers.html, pristup 05.10.2021).

Amazonovi kupci su saznavši za strategiju dinamičnog određivanja cijena, podigli pobunu velikih razmjera. Kupci su percipirali ovu praksu, kao neprikladnu upotrebu CRM podataka. Iako je Amazonova upotreba dinamičkog određivanja cijena često citirani primjer negativnog Ponašanja, povezano s korištenjem CRM-a, ona ipak ne odgovara tradicionalnoj definiciji tamne strane manifestacije CRM-a (Frow et al., 2011). Istoimeni autori su opisali ponašanje tamne strane kao izravnu namjeru. Kako bi se organizacije ostvarile obilježja istinskog ponašanja mračne strane, moraju namjerno prihvatiti nepoštenu prednost kupaca, korištenjem CRM podataka. Autori su nadalje utvrdili da i sami kupci mogu sudjelovati u negativnom CRM ponašanju. Autori su također opisali specifične negativne manifestacije ponašanja kupaca, kao pokušaj iskorištavanja prednosti pružatelja usluga prekomjernim pritužbama ili namjernim zlouporabama proizvoda (Frow et al., 2011).

Istoimeni autori su stoga predložili metodologiju za tvrtke, kako bi izbjegle negativno CRM ponašanje. Središnji dio Frowove metodologije je prosvijećena CRM strategija. U cilju spriječavanja štetnog ponašanja, tvrtke bi trebale nastojati razviti dugoročne odnose s kupcima, koji su obostrano korisni i progresivni. Preostali procesi u takvoj metodologiji bili bi: (Frow et al., 2011)

- Stvaranje vrijednosti, koje opisuje obostrano koristan proces koji nastoji ukloniti financijsko iskorištavanje, stigmatizaciju korisnika i nepoštenje;
- Višekanalna korisnička iskustva koja osiguravaju da kupac dobiva jedinstvenu dosljednu poruku iz svih dijelova poslovanja, što pomaže eliminirati zbunjenost kupaca;
- Informirano upravljanje, gdje pružatelj usluga okuplja kupčeve podatke uz puno znanje i suglasnost kupca koji je suglasan s time kako se podaci koriste, što pomaže eliminirati invazije na privatnost i zlouporabu informacija;
- Procjena učinka, gdje bi pružatelj usluga trebao pratiti i upravljati svim dodirnim točkama kako bi se osiguralo zajedničko stvaranje vrijednosti, što pomaže u izbjegavanju zanemarivanje odnosa; i
- Razvoj strategije koja usklađuje kupca i poslovnu strategiju, te osigurava da postoji podudaranje, što pomaže u sprječavanju favoriziranja kupaca i učinaka prelijevanja (Frow et al., 2011.).

3. SPECIFIČNOSTI PRIMJENE CRM-A U SEKTORU OSIGURANJA

Upravljanje odnosima s kupcima u osiguranju je sveobuhvatna strategija i proces stjecanja, zadržavanja i partnerstva sa selektivnim kupcima za stvaranje vrhunske vrijednosti za osiguravajuću kuću i kupca. To uključuje integraciju marketinga, prodaje, usluge kupcima i funkcija lanca nabave u osiguravajućoj kući, u cilju postizanja veće učinkovitosti i djelotvornosti u isporuci vrijednosti za kupca.

Također, CRM je marketinški orijentiran na jake i trajne odnose s pojedinačnim računima, te se na temelju dostupnog razumijevanja upravljanja odnosima s klijentima, može definirati kao: „Upravljanje odnosima s klijentima je kontinuirano ažuriran proces identificiranja relativne vrijednosti kupaca i dizajniranja prilagođene interakcije, kako bi ih oduševili. Puna uključenost i osnaživanje zaposlenika, te odgovarajuća tehnologija, osnove su za uspješan CRM" (Hargrave i Anderson, 2020).

3.1. Potreba za CRM-om u industriji osiguranja

Globalizacija je procvat u elektroničkom svijetu koji pomaže području CRM-a da izravno kontaktira korisnike, pri čemu osiguravajuća tvrtka može lako komunicirati sa svojim klijentima uz niske troškove. CRM je jedan na jedan, komunikacija osiguravajuće tvrtke i njezinih klijenata. Tržišni akteri u osiguranju se moraju prebaciti sa stare paradigme masovnog ugovaranja polica na novu paradigm kupacizacije, kako bi se zadovoljili točni zahtjevi klijenata (https://www.talisma.com/role-of-crm-in-insurance-industry/, pristup 08.10.2021).

Posljednjih desetljeća prisutna je eksplozija rasta mogućnosti za organizacije uslužnog sektora, tako da danas sve više tvrtki iz uslužnog sektora ima priliku ostvariti konkurentsku prednost i dokazati svoje sposobnosti na razini, ako ne i bolje od ostalih aktera na tržištu. Sadašnji trend počiva na dobrom upravljanju odnosima s kupcima. Uspjesi uslužnog sektora organizacija danas, ovise o njihovoj sposobnosti da služe klijentu na trajnoj osnovi, a također i o dostupnosti brojnih usluga kupcima, stoga postoji potreba za proučavanjem utjecaja CRM-a na poslovni prospekt. U ovom kontekstu, CRM postaje imperative (Joshi, 2020).

3.2. Važnost CRM-a u industriji osiguranja

Zadovoljan kupac za 10 godina u tvrtku će dovesti 100 kupaca više. Košta 7 puta više privući novog kupca nego poslužiti starog. 20% vjernih kupaca tvrtke čini 80% njezinih Prihoda, sukladno Paretovom principu. Šanse za prodaju postojećem kupcu su 1 prema 2, dok su šanse za prodaju novom kupcu 1 od 16 (Shanmugasundaram et al., 2017).

Istraživanja pokazuju da kupci informiraju svojih 8 prijatelja o zadovoljavajućem iskustvu i 20 prijatelja o negativnom iskustvu. Lakše je utjecati na postojeće kupce da kupe 10% više nego povećati kupcu osnovicu plaćanja za 10%. Osamdeset posto uspješnih ideja o novim proizvodima i uslugama dolazi od postojećih kupaca. Kupci koji ponavljaju kupnju koštaju petinu manje od novih kupaca i mogu značajno povećati profit (Matis i Ilies, 2014).

Načini zadržavanja kupaca mogući su na jedan od sljedećih načina: (Shanmugasundaram et al., 2017)

- Svaki dio marketinških napora osiguravajuće tvrtke trebao bi biti usmjeren na izgradnju doživotnih odnosa.
- Ljudi žele poslovati s prijateljskim ljudima. Za učinkovite odnose mora se prožimati prijateljski stav u organizaciji.
- Razvoj informacijske tehnologije trebao bi se pozitivno koristiti za pružanje usluga kupcima.
- Osiguravajuća tvrtka bi uvijek trebala biti fleksibilna da svoja pravila i procedure preokrene u korist klijenta.
- Osiguravajuća tvrtka bi trebala komunicirati sa svojim kupcima čak i kada ne pokušava nešto prodati.
- Osiguravajuća tvrtka može ujediniti i razviti jače povezivanje kupaca pružanjem financijskih i društvenih beneficija, kao primjerice bonus na auto osiguranje ili poklon osiguranje za dijete.
- Osiguravajuća tvrtka bi trebala pokušati upoznati sve svoje kupce uključujući njihov stil života, hobije, sviđanja i nesklonosti itd.
- Osiguravajuća tvrtka bi se trebala potruditi isporučiti više od onoga što je obećano.

3.3. Osobitosti CRM-a u osiguranju

S povećanjem broja osiguravajućih društava na tržištu, sve više potrošača je sve više svjesno različitih politika. Osiguravajuća društva su shvatila važnost CRM-a. Trošak privlačenja novih kupaca je pet puta veći, nego što je potrebno da bi se postojeći kupac usrećio. Stoga, u cilju preživljavanja na tržištu, osiguravajuća društva trebaju implementirati CRM u svoje organizacije. Ovo je ključ uspjeha u industriji. Organizacije mogu uspjeti, ukoliko su uspjele izgraditi bazu svojih vjernih kupaca, jer vjerni kupac puno bolje zagovara proizvode tvrtki, nego sama organizacija (https://www.softwaresuggest.com/blog/crm-in-insurance-sector/#, pristup 18.10.2021).

Osnovno postojanje organizacije leži u rukama njenih kupaca. Lako se može zaključiti da je za uspjeh potrebno implementirati CRM na pravi način. Proizlazi da je velika važnost CRM-a u sektoru osiguranja Mnogi klijenti osiguravajućih društava nisu upoznati s politikama i uslugama, koje će im pružati osiguravajuća tvrtka. Dakle, između kupca i osiguravajuće tvrtke treba postojati odnos. CRM pomaže organizaciji da upozna kupce u ime organizacije, te oni tek tada postaju odani organizaciji. Većina osiguravatelja razumije poslovnu ponudu CRM-a, te su poduzeli inicijative u značajnoj mjeri, no do danas je postignut ograničen uspjeh (https://www.talisma.com/role-of-crm-in-insurance-industry/, pristup 19.10.2021).

3.3.1. Usluge povezane s premijom osiguranja koje pruža CRM

Premiju životnog osiguranja ugovaratelj osiguranja plaća u razdoblju od 5 do 30 godina. Ovo razdoblje ovisi o trajanju police. Kako bi na vrijeme platila premiju, tvrtka slijedi neki CRM alati za pomoć kupcu. Služba za korisnike u osiguravajućim organizacijama ima čudna ograničenja, što možda nije vrlo relevantno u drugim područjima uslužnih organizacija. U nekim slučajevima može se odnositi i na cijeli životni vijek klijenta, ako on ili ona gleda na podržano pokriće rizika tijekom aktivnog rada životnog razdoblja, s razumnim i pristojnim mirovinskim paketom (Matis i Ilies, 2014).

3.3.1.1. Podsjetnici za plaćanje premije

Slanje podsjetnika kupcima putem pošte najstarija je metoda koju organizacija slijedi. Danas osiguravajuća društva šalju podsjetnike putem e-pošte, SMS-a ili regularne pošte, po želji korisnika. Osiguravajuće tvrtke pružaju mogućnost korisnicima da doznače premiju ne samo u svojim poslovnicama nego i putem novih načina plaćanja kao što su servisni centri, internet bankarstvo, mobilne aplikacije i bankovni računi. Pružanjem takve usluge prilagođene korisnicima, korisnici osjećaju bolje iskustvo usluge ((Matis i Ilies, 2014).

3.3.1.2. Razdoblje odgode

Razdoblje počeka za policu osiguranja znači davanje dodatnog vremena za plaćanje njihove premije, općenito, 30 dana za tromjesečni, polugodišnji i godišnji način plaćanja. Za način mjesečnog plaćanja, 15 dana daje se kao poček. Ako ugovaratelj osiguranja ne plati premiju u roku odgode, polica će automatski prestati, što znači da ugovaratelj police više nema životnu zaštitu police. Pružanje razdoblja odgode također je jedan od CRM-ovih alata (Matis i Ilies, 2014).

3.3.2. Premium usluge koje pruža CRM

Postoje i neke druge usluge, koje osiguravajuća društva također pružaju, koristeći CRM kao alat.

3.3.2.1. Duplicirana politika

Ako se izvorna polica izgubi, nije lako dobiti duplikat police. Budući da postoji mogućnost zlouporabe izvorne politike prema osiguravajućoj tvrtki, poduzima se nekoliko mjera opreza prije izdavanja duplicirane police. Duplicirana polica svom vlasniku daje ista prava i privilegije kao i izvorna polica.
Izdavanje dupliciranih pravila također je jedan od CRM alata (Matis i Ilies, 2014).

3.3.2.2. Promjene u politici

Danas se politika može tako lako promijeniti. Dostupni su objekti nadopune za osiguranu svotu. Ovako, također dolazi do dostupnog smanjenja osigurane svote. Način plaćanja premije

također je promjenjiv iz mjesečnog načina u tromjesečni ili godišnji način. Izmjene politike uključuju pretvaranje politike cijelog života u plan zadužbine, izmjena plana bez dobiti u plan s dobiti, ispravak naziva, mogućnost namire isplate iznosa osiguranog obrocima, dodjelom naknade za nezgodu itd. Međutim, nikakva promjena nije dopuštena unutar jedne godine od početka politike uz neke iznimke (Matis i Ilies, 2014).

3.3.2.3. Prijenos politike i promjena adrese

Ugovor o životnom osiguranju je dugotrajan proces. Dakle, promjena adrese ugovaratelja police je neizbježna. CRM pomaže kupcu da se prijavi i dobije promjenu adrese. Kao rezultat promjene adrese, politika bilježi prebacivanje iz jedne grupe kupaca u drugu. Danas su sve grane međusobno povezane kroz umrežavanje. Dakle, prijenos zapisa police iz jedne grane u drugu nije potreban (Matis i Ilies, 2014).

3.3.2.4. Održavanje zapisa

Imatelj police može izvršiti izmjene police u bilo kojem trenutku tijekom razdoblja police. Dakle, od vitalnog je značaja ažurirati i održavati evidenciju osiguranika. U prvim danima, osiguranici su morali kontaktirati svoje agente za svaki detalj koji žele. Ali danas, koristeći učinkovit CRM, lako je dobiti bilo koju informaciju koju žele (Matis i Ilies, 2014).

3.3.2.5. Oživljavanje politike

Sva društva za osiguranje života pružaju uslugu oživljavanja zastarjelih polica. Zaostale neplaćene obveze treba platiti premiju s kamatama za oživljavanje police. Ako se obnova police izvrši u roku od 6 mjeseci od dospijeća prve neplaćene premije, nije potrebna osobna izjava o zdravstvenom stanju i polica je oživljena naplatom odgođene premije s kamatama. Pružanje takve mogućnosti oživljavanja daje osiguraniku mogućnost da klijent ažurira svoju policu i iskoristi pogodnosti police osiguranja (Matis i Ilies, 2014).

3.3.2.6. Dodjela i imenovanje

Polica životnog osiguranja lako se može dodijeliti drugoj osobi. Ako vlasnik police želi darovati svoju policu osiguranja nekoj drugoj osobi, lako može prenijeti svoja vlasnička prava po toj polici. Police životnog osiguranja inzistiraju svoje klijente na nominaciji. Iako se nominacija vrši u vrijeme kupnje police, nominacija se također može izvršiti nakon toga putem indosamenta[1] na samoj polici (http://www.enciklopedija.hr/Natuknica.aspx?ID=27338, pristup 16.10.2021).

Promjena i poništenje nominacije može se izvršiti bilo koji broj puta tijekom razdoblja obuhvaćenog osiguranjem života.

3.4. Usluge vezane uz nagodbu

To su osnovne usluge koje osiguravatelji života pružaju svojim klijentima. Ugovaratelj osiguranja može raskinuti ugovor kad god to želi, iz bilo kojeg razloga.

3.4.1. ***Predaja police***

Osiguravajuća društva omogućuju osiguranicima mogućnost predaje polica osiguranja. Najmanje tri godine premija se mora plaćati, a ugovaratelj osiguranja može odustati od ugovora za zajamčenu otkupnu vrijednost. U slučaju predaje, polica se općenito mora otkazati.

3.4.2. ***Uplaćeno jamstvo***

Najmanje tri godine, premija se mora plaćati, a ukoliko se naknadne premije ne bi plaćale, polica neće prestati, ali će se pretvoriti u plaćeno jamstvo. Iznos potraživanja bit će dostupan ili po dospijeću ili ranije, ukoliko dođe do smrti osiguranika.

[1] indosament (njemački Indossament, od talijanski indossare: metnuti na se), pravni institut, posebna izjava, kojom prenositelj (indosant) prenosi na stjecatelja (indosatara) vrijednosni papir i njime indosatar stupa u pravni položaj indosanta. Indosament je pismena izjava na poleđini vrijednosnoga papira. Ako se indosatar ne označi, već se indosant samo potpiše, riječ je o bjanko-indosamentu. Indosamentom se najčešće prenose vrijednosni papiri po naredbi (mjenica).

3.4.3 Namirenje potraživanja

Namirenje potraživanja važan je aspekt usluge osiguranicima. Društva za životno osiguranje moraju staviti naglasak na ekspeditivno namirenje dospijeća, te bi oni trebali osigurati odgovarajuće upute svojim klijentima u postupku prijave potraživanja i prijevremenog podmirenja istog. IRDA regulatorne smjernice pomažu osiguravajućim društvima kod brzog rješavanja šteta. Uvođenje CRM sustava pomaže u web-baziranom podnošenju gubitaka i provjeri statusa zahtjeva (Matis i Ilies, 2014).

3.5. Rezultati CRM-a u osiguravateljnoj industriji

CRM pruža niz funkcionalnih alata temeljenih na procesima koji pomažu zaposlenicima da budu produktivniji oko prodaje, marketinga i servisiranja ključnih dionika. Prva razina utjecaja CRM-a je poboljšana brzina, točnost i učinkovitost internih procesa ili poboljšana produktivnost pojedinaca u kojima su radni i papirno intenzivni procesi racionalizirani (https://www.talisma.com/role-of-crm-in-insurance-industry/, pristup 19.10.2021).

Druga razina utjecaja mjeri se kada platitelju postane lakše voditi poslovanje iz, kako perspektive agenta, tako i iz perspektive potrošača. Treća i najdublja razina utjecaja je kada se otkrije tzv. slatka točka optimalne poslovne profitabilnosti. Kada je pravi spoj proizvoda, tržišta, prodajnih modela i agenata identificiran, tvrtka ima sve elemente potrebne da postane pametnija i donosi više strateški orijentiranih poslovnih odluka. CRM sustav bi trebao olakšati prilagodbu, olakšavajući promjenu načina rada, u kojem se organiziraju i koriste podaci o kupcima (https://www.talisma.com/role-of-crm-in-insurance-industry/, pristup 19.10.2021).

3.5.1. ***Prednosti CRM-a za osiguravajuće kuće***

CRM je proces stjecanja, zadržavanja i rasta profitabilnih kupaca. Zahtijeva jasan fokus na atribute usluge, koje predstavljaju vrijednost za kupca, koji stvaraju lojalnost. Upravljanje odnosima s kupcima u osiguranju ima nekoliko prednosti: (Joshi, 2020)

- Osiguravajuće društvo može lako pronaći potrebe kupaca.
- Može lako ciljati određene kupce usredotočujući se na njihove potrebe.
- I olakšavati praćenje učinkovitosti određene kampanje.
- Dati znanje o kupcu koji je odan proizvodu.
- Omogućiti izravan kontakt s kupcima, te stvoriti bazu postojanja potencijalnih kupaca.
- Marketing proizvoda temelji se na kupcu, a ne na cijeni.

- Proizvod se po želji kupaca proizvodi i plasira na tržište.
- Sprječava prekomjernu potrošnju na klijente male vrijednosti ili nedovoljnu potrošnju na klijente visoke vrijednosti.
- Ubrzava vrijeme za razvoj i plasiranje proizvoda.
- CRM smanjuje troškove oglašavanja.
- Kvalitetu proizvoda treba povećati.
- Obim prodaje treba povećati.
- Poboljšava korištenje kanala korisnika, čime se svaki kontakt s kupcem maksimalno iskorištava (Joshi, 2020).

3.5.2. Čimbenici odgovorni za neuspjeh CRM-a u osiguranju

Uprava u okviru osiguravajućih društava čvrsto vjeruje da je CRM jedini izvor za rješavanje svih njihovih problema na koje se odnose marketing. Nakon što se inicijative počnu razvijati i postati opipljive, menadžment uviđa nedostatke svojih očekivanja, kao i razloge neuspjeha (Joshi, 2020)

Jedan od čimbenika neuspjeha CRM-a u osiguranju leži u tome što se CRM gleda kao tehnologiju, a ne kao marketinšku praksu. Do navedenog dolazi zbog automatizacije zastarjelih procesa i ljudi koji vjeruju da tehnologija sama može promijeniti rezultate.
Većina neuspjeha CRM-a temelji se na politici tvrtke i pogrešnom tumačenju analize CRM-a. Preinačiti tvrtku tako da bude istinski usmjerena na kupca nov je i neistražen teritorij i kao u svemu novome, uvijek postoji otpor promjenama. Promjena često prisiljava ljude da se povuku prema onome što znaju i štite što im je uvijek bilo ugodno (https://www.talisma.com/role-of-crm-in-insurance-industry/, pristup 20.10.2021).

Ako tvrtka želi primijeniti CRM tehniku, onda se treba osloniti na njezinu analizu. Postoji neuspjeh u razumijevanju onoga što je CRM. Neki smatraju da je sve o tehnologiji i ne uspijevaju uskladiti tehnologiju sa strategijom. Neki misle da je sve u ciljanju kupaca i grupa kupaca za posebne ponude. Oni to vide kao jednostavno pitanje hvatanja imena i adresa i povezivanja toga s transakcijama kupaca i unakrsnom prodajom
(https://www.talisma.com/role-of-crm-in-insurance-industry/, pristup 19.10.2021).

Loše planiranje interakcije tvrtke s kupcima povećava šanse za pogrešno rješavanje pitanja. Loše razumijevanje CRM-a, ne može ispuniti svoj cilj. Mnoge tvrtke ne educiraju svoje osoblje za primjenu CRM tehnika i ne mogu educirati svoje kupce kako da koriste CRM. Važan čimbenik je i taj da osiguravajućim društvima često nedostaju CRM vještine. Mnoge tvrtke stvaraju sofisticirana istraživanja kupaca metodološkim tehnikama ne shvaćajući da takvi sofisticirani alati zahtijevaju sofisticirane korisnike, kao i da je korisnicima potrebna obuka. Isto tako, u većini slučajeva, CRM zahtijeva veliki proračun. Nedostatak interne integracije podataka u pojedinim osiguravajućim društvima, iznimno je otežao razvoj na sveobuhvatan pregled kupaca (Shanmugasundaram et al., 2017).

4. VAŽNOST PODATAKA U INDUSTRIJI OSIGURANJA

Sve je veća potražnja za većom transparentnosti, dosljednosti i više informacija, koje je potrebno uključiti u poslovanje. Uslijed takvih okolnosti dolazi do pojave Data Mining (DM), odnosno otkrivanja znanja iz baze podataka, kao iterativnog procesa, unutar kojeg je napredak otkrivanja znanja definiran otkrivanjem, bilo automatskim, bilo ručnim metodama.
Primjena Data Mininga je plodno područje istraživanja.

4.1. Definicija i područje primjene

Data mining se odnosi na otkrivanje znanja iz velike količine podataka. Postoji niz tehnika rudarenja podataka kao što su grupiranje, neuronske mreže, regresija, višestruki prediktivni modeli. Raspravljajući o tehnikama rudarenja podataka, to su u prvom redu Bayesova mreža, te stablo odlučivanja, za izradu opisnog modela svake skupine (Bhowmik, 2008).
Bayesova mreža je tehnika koja se koristi za klasifikaciju zadatka. Klasifikacija, s obzirom na skup unaprijed definiranih kategoričkih klasa, određuje kojoj od ovih klasa pripada određeni podatak, pri čemu se za stvaranje koriste deskriptivni modeli stabla odluka, dok se za opisivanje karakteristika izrađuju deskriptivni modeli (Bhowmik, 2008).
Autori Sonika i Sushil zaključili su da pristupi strojnog učenja mogu postići bolju preciznost klasifikacije, posebno kada je dostupnost uzoraka podataka niska. Nadalje, visoka klasifikacija preciznosti se može postići sa skupom podataka s mapiranjem 1:1 korištenjem pristupa klasifikaciji strojnog učenja (Sonika i Sushil, 2021).
Glavne tehnike rudarenja podataka, su logistički modeli, koji pružaju neposredna rješenja za probleme svojstvene otkrivanju i klasificiranju podataka.

4.2. Proces otkrivanja znanja iz baza podataka

Opća ideja otkrivanja znanja u velikim količinama podataka privlačna je i intuitivna, te obično svoju pozornost usmjerava na algoritme učenja, koji pružaju temeljnu sposobnost generaliziranja iz velikog broja malih, vrlo specifičnih činjenica do korisnih pravila visoke

razine, pri čini se da ove tehnike učenja sadrže možda najsadržajniji znanstveni sadržaj u otkrivanju znanja u bazama podataka poduzeća. Međutim, upuštanje u otkrivanje stvarnog svijeta zadataka, nalazi da isti mogu biti iznimno složeni, a da je indukcija pravila samo jedan mali dio cjelokupnog procesa (Fayyad et al., 1996).

Data Mining[2], koji se također naziva otkrivanje znanja u bazama podataka (KDD), područje je otkrivanja novih i potencijalno korisnih informacija iz velikih količina podataka. Data Mining se primjenjuje u velikom broju područja, uključujući maloprodaju, osiguravajuća društva, bioinformatiku, borbu protiv terorizma, spriječavanje financijskih prijevara, optimiziranje korisničkog iskustva i mnogih drugih (Baker, 2010).

Pojam rudarenja podataka pokriva širok raspon postupaka analize podataka s korijenima u brojnim domenama, uključujući statistiku, strojno učenje, prepoznavanje uzoraka, pronalaženje informacija i druge. Vjerojatno postoji onoliko definicija koliko i praktičara. Nekada je taj izraz imao pejorativnu konotaciju sličnu pronalaženju podataka, što znači dopuštanje podacima da definiraju hipoteze istraživanja, ili čak ponovnu analizu istih podataka sve dok neki test hipoteze ne postane značajan, bez obzira na izvorno istraživačko pitanje. Statističari tome prigovaraju jer se time krši određena paradigma znanstvene objektivnosti. U suvremenoj upotrebi, međutim, Data Mining je jednostavno metafora za određene vrste analiza i ne podrazumijeva se nikakav vrijednosni sud (Bunge i Judson, 2005).

Data Mining se bavi potragom za novim znanjem u podacima. Takvo se znanje obično dobiva u obliku pravila, koja su korisniku ranije bila nepoznata i koja bi se mogla pokazati korisnima u budućnosti. Ova pravila mogu imati oblik specifičnih pravila induciranih pomoću algoritma indukcije pravila ili mogu biti općenitija statistička pravila poput onih koja se nalaze u prediktivnom modeliranju. Izvođenje takvih pravila specificirano je u smislu zadataka Data Mininga, gdje tipični zadaci mogu uključivati klasificiranje ili grupiranje podataka (McClean, 2003).

Data Mining je nužan zbog sve veće dostupnosti vrlo velikih količina podataka i hitne potrebe za pretvaranjem takvih podataka u korisne informacije i znanje. Data Mining je u biti znanost izvlačenja informacija iz velikih skupova podataka i baza podataka (Coomand i Yang, 2009).

[2] Data Mining = Rudarenje podataka

Kao što Coomand i Yang ističu, izraz data mining je pogrešan naziv. Analogno tome, ako geolog govori o iskopavanju zlata, on traži zlato među stijenama i pijeskom. Stoga bi rudarenje podataka trebalo bolje nazvati *knowledge mining from data* ili jednostavno *knowledge mining*. Osim pronalaženja odgovarajućeg naziva za novu disciplinu, također je kontroverzan zadatak definirati disciplinu, budući da se istraživači obično ne slažu oko opsega i ograničenja određenog znanstvenog područja (Coomand i Yang, 2009).

U tom kontekstu, ovi autori dalje navode: „Razbijanje podataka je analiza (često velikih) skupova podataka promatranja kako bi se pronašli neslućeni odnosi i sažimali podaci na nove načine koji su razumljivi i korisni za vlasnika podataka." (Coomand i Yang, 2009:579).
Ovi odnosi i sažeci predstavljaju se kao modeli i obrasci kao što su linearni odnosi, strukture stabala, klasteri, ponavljajući obrasci na slikama i spektralni podaci. Jasno je da se ovdje radije misli na podatke promatranja, nego na eksperimentalne podatke, što znači da se u podacima traže dodatne ili „sekundarne informacije" koje nisu povezane s glavnom svrhom za koju su podaci prikupljeni.

Definicija se također odnosi na velike skupove podataka i u biti također na složene skupove podataka. Da je fokus zanimanja na samo malim skupovima podataka s nekoliko varijabli, tada bi rasprava počivala na tradicionalnoj istraživačkoj analizi podataka, što dovodi do točke da postoji jaka veza između tehnika istraživanja podataka i metoda rudarenja podataka (Coomand i Yang, 2009).

U suštini, tehnike istraživanja podataka pripadaju arsenalu alata za rudarenje podataka, ali ih ne treba potpuno poistovjetiti. Data mining velikih baza podataka uključuje više faza i složenije algoritame od jednostavnog istraživanja podataka. Kao takvo, rudarenje podataka zahtijeva integraciju tehnika iz više disciplina uključujući statistiku, matematiku, strojno učenje, tehnologiju baze podataka, vizualizaciju podataka, prepoznavanje uzoraka, obradu signala, pronalaženje informacija i računalstvo visokih performansi. Na temelju ovog gledišta, učinkovit sustav rudarenja podataka sastoji se od različitih komponenti (Colonna, 2013).

Potrebno je naglasiti da se, kada se radi o vrlo velikim i složenim skupovima podataka, pojavljuju dodatni problemi čak i kod tradicionalnih metoda regresijske analize i nadzirane klasifikacije. Vrlo veliki i složeni skupovi podataka zahtijevaju modele koji su u isto vrijeme dovoljno fleksibilni kako bi uhvatili raznovrsnost prisutnih informacija i dovoljno robusni na

ogromnu količinu suvišnosti koji su tipično prisutni u takvim vrstama podataka (Friedman i Popescu, 2008). Jedan novi način da se to postigne je kombiniranjem različitih modela u ansamblima koji proizlaze iz percepcije da jedan model vjerojatno neće obuhvatiti sve informacije svojstvene velikim skupovima podataka. Ove ideje su za regresiju i nadziranu klasifikaciju predložili Friedman i Popescu u svojoj studiji iz 2008. godine.

Vrlo poželjna značajka Data Mininga je da postoji neko korisničko sučelje na visokoj razini, koje omogućuje krajnjem korisniku da specificira probleme i dobije rezultate u što je moguće prijateljskijoj materiji. Iako je moguće, i zapravo uobičajeno, da Data Mining provede stručnjak, a rezultati se potom objasne korisniku, također je vrlo poželjno da korisnik bude ovlašten za provođenje vlastitog Data Mininga i crtanje vlastitog zaključke iz novih spoznaja. Stoga je odgovarajuće korisničko sučelje od velike važnosti (McClean, 2003).

Otkrivanje znanja u bazama podataka smatra se netrivijalnim izdvajanjem implicitnih, prethodno nepoznatih i potencijalno korisnih informacija iz podataka. No, iako je ovo razumna definicija za početak, ova vrsta definicije teži se usredotočiti samo na značajke rezultirajućih informacija. Nažalost, to ne odražava točno složenost procesa u stvarnom svijetu, koji prolazi kroz izdvajanje, organiziranje i predstavljanje otkrivenih informacija (Brown et al., 2018).

Nadalje, mnogi zagovornici su implicirali da sustavi za otkrivanje znanja u bazama podataka trebaju biti autonomni. Iako je možda dugoročno poželjan, ovaj pristup ima tendenciju nedovoljno naglašavaju apsolutno ključnu ulogu koju čovjek ima u cjelokupnom današnjem sustavu otkrića znanja. Općenito je vidljiva jasna potreba za većim naglaskom na proces otkrivanja znanja iz baza podataka, usmjerenoj na čovjeka, koji bi, ako se artikulira, mogao pomoći boljem razumijevanju kako otkriti znanje i kako najbolje podržati ljudske analitičare bez kojih ne bi bilo otkrivanja znanja iz baza podataka uopće (Brown et al., 2018).

S tehnološke strane, sustav otkrivanja znanja bio bi integrirano okruženje, koje je na neki način pomoglo korisniku u provođenju procesa otkrivanja složenog znanja. Sustav otkrića je jednostavno neki fragment znanja, dok bi rezultat znanja bio proces otkrivanja u komercijalnom okruženju, te bi tipično bio specifikacija za aplikaciju za otkrivanje znanja (Guarascio i Ritacco, 2019).

Takva bi se aplikacija tada mogla izraditi i instalirati u poslovnom okruženju za pružanje analiza i preporuka za djelovanje, koristeći, na primjer, dolazne poslovne podatke. Njegov bi korisnik bio poslovna osoba, primjerice voditelj životnih osiguranja, koji je posvećen praćenju važnih događaja u poslovnim podacima, a ne analitičar podataka koji traži duboke temeljne trendove i obrasce u domeni (Guarascio i Ritacco, 2019).

U tom smislu, program koji prati skup činjenica u bazi podataka i proizvodi obrasce više je aplikacija za otkrivanje znanja, nego opći sustav za otkrivanje znanja iz baza podataka. Istraživanje i razvoj u brzo rastućem području otkrivanja znanja iz baza podataka, doveli su do brojnih uspješnih primjena otkrivanja znanja. Proces razvoja za svaku od ovih primjena može se okarakterizirati početnim napornim otkrićem znanja nekoga tko je razumio domenu kao i specifične tehnike analize, njegovo kodiranje unutar specifične arhitekture rješavanja problema i konačno njezinu primjenu u kontekstu stvarnog zadatka od strane dobro shvaćene klase krajnjih korisnika (Norton, 1999).

Potrebno je imati u vidu da je u vrijeme kada se pojavila sistematika otkrivanja znanja iz baza podataka, u konačnici jedan zadatak bio podržan u svakoj od aplikacija, a krajnji korisnici su bili ne analitičari podataka, nego stručnjaci iz domene ili poslovni ljudi. Nasuprot tome, većina kasnijih sustava koji sebe označavaju kao sustavi za otkrivanje znanja, pružaju jednu ili više tehnika otkrivanja, kao što je indukcija stabla odluka, grupiranje, linearna regresija itd. Oni podržavaju otkrivanje znanja od strane korisnika koji ima razumjeti razne tehnike otkrivanja, elemente podataka unutar baza podataka, te zadatak za koji se traži znanje (Baker, 2010).

Proces otkrivanja znanja iz baza podataka uključuje sljedeće korake: (Olufemi Ogunleye, 2021)

- Zahtjevi za prikupljanje

Prikupljanje i razumijevanje zahtjeva, prvi je korak u bilo kojem projektu rudarenja podataka. S poslovnog stajališta dobavljača, analitičari ili korisnici rudarenja podataka određuju opseg zahtjeva.

- Istraživanje podataka

Ovaj potez podrazumijeva identificiranje i pretvaranje uzoraka podataka pomoću statistike rudarenja podataka. Zahtijeva prikupljanje, procjenu i istraživanje zahtjeva ili projekta. Stručnjaci shvaćaju probleme i izazove i prevode ih u metapodatke.

- Prikupljanje podataka i planiranje

Za fazu modeliranja, stručnjaci za rudarenje podataka prevode podatke u smislene informacije. Koriste ETL (Extract, Transform, and Load) metodu. Oni su također zaduženi za izmišljanje novih atributa podataka. Ovdje se koriste različite metode za prikaz podataka u strukturnom formatu uz očuvanje vrijednosti skupova podataka.

- Modeliranje

Stručnjaci za podatke koriste svoje najbolje alate za ovu fazu, jer je ona toliko važna u cjelokupnoj obradi podataka. Za filtriranje podataka na prihvatljiv način koriste se sve metode modeliranja. Modeliranje i procjena isprepleteni su koraci koji se moraju izvršiti u isto vrijeme kako bi se osiguralo da su kriteriji točni. Nakon što je konačno modeliranje završeno, može se provjeriti točnost konačnog rezultata.

- Procjena ili evaluacija

Nakon učinkovitog modeliranja, ovo je metoda filtriranja. Ako rezultat nije prihvatljiv, onda se vraća u model. Nakon zadovoljavajućeg rezultata, zahtjev se još jednom provjerava s davateljem kako bi se osiguralo da se nijedan detalj ne previdi. Na kraju procesa, stručnjaci za rudarenje podataka ocjenjuju cjelokupni rezultat.

- Razmještaj

Ovo je posljednja faza u cijelom procesu. Podatke dobavljačima prezentiraju stručnjaci u obliku proračunskih tablica ili grafikona (Olufemi Ogunleye, 2021)

4.3. Razlikovne pojmovne konotacije otkrivanja znanja iz baza podataka

Kako se data mining razvijao kao profesionalna djelatnost, bilo ga je potrebno razlikovati od dotadašnje djelatnosti statističkog modeliranja i šire djelatnosti otkrivanja znanja. Potrebno je razumijeti i sljedeće radne definicije: (Nisbet i Yale, 2018)

  - Statističko modeliranje: Upotreba parametarskih statističkih algoritama za grupiranje ili predviđanje ishoda ili događaja, na temelju prediktorskih varijabli.

- Data mining: Upotreba algoritama za strojno učenje za pronalaženje slabih obrazaca odnosa između elemenata podataka u velikim, bučnim i neurednim skupovima podataka, što može dovesti do radnji za povećanje koristi u nekom obliku (dijagnoza, profit, otkrivanje itd.)

- Otkrivanje znanja: cijeli proces pristupa podacima, istraživanje podataka, priprema podataka, modeliranje, implementacija modela i praćenje modela.

- Znanost o podacima: Proširenje otkrića znanja u podatkovnu arhitekturu analitičkih podatkovnih baza s jedne strane i složenu analizu slike, govora i teksta s druge strane s visoko razvijenim algoritmima za strojno učenje.

Kako se praksa rudarenja podataka dalje razvijala, fokus definicija pomaknuo se na specifične aspekte informacija i njihovih izvora. Definicija rudarenja podataka izvorno je bila ograničena samo na proces izgradnje modela. No kako je praksa sazrijevala, paketi alata za rudarenje podataka uključivali su i druge potrebne alate za olakšavanje pripreme podataka te za evaluaciju i prikaz modela (Nisbet i Yale, 2018).

4.4. Najčešće greške prilikom rudarenja podataka

Vađenje podataka za izdvajanje korisnih i trajnih obrazaca ostaje vještina i vjerojatno više umjetnost nego znanost. U tri desetljeća vađenja podataka iz različitih područja, čini se mnogo pogrešaka, što može dovesti do određenih zaključaka i lekcija za budućnost. Ovo poglavlje ukratko opisuje i ilustrira na primjerima “Top 10” pogrešaka rudarenja podataka, u smislu učestalosti i ozbiljnosti. Da bi se napredovalo u analizi, potrebno je imati označene slučajeve, tj. izlaznu varijablu (Nisbet et al., 2009).

Modeliranje služi za uvjerenje da velika većina ugovora gotovo sigurno nije lažna, što revizorima omogućuje da usredotoče svoj trud. Najvažniji način da se izbjegne prekomjerna oprema je rezerviranje podataka. Uz ponovno uzorkovanje, izvode se višestruki eksperimenti modeliranja, s različitim uzorcima podataka, kako bi se osvijetlila distribucija rezultata. Konvencionalna kvadratna pogreška često može dovesti model u područje performansi koje se može koristiti, a funkcija koja se optimizira ima temeljit učinak na prikladnost konačnog modela (Nisbet et al., 2009).

Analitičarima je potreban jak višedimenzionalni i po mogućnosti multimodalni algoritam optimizacije; ipak, korištenje čak i jednostavnog slučajnog pretraživanja s funkcijom prilagođenog rezultata obično je bolje, nego ne prilagođavati. Odstupanja i točke poluge mogu uvelike utjecati na zbirne rezultate i opće trendove oblaka (Nisbet et al., 2009).

4.5. Formuliranje ciljeva i zadataka kod rudarenja podataka

Proces otkrivanja znanja u bazama podataka kombinira matematiku, koja se koristi za otkrivanje zanimljivih obrazaca u podacima s cjelokupnim procesom izdvajanja podataka i korištenjem rezultirajućih modela za primjenu na druge skupove podataka kako bi se informacije iskoristile u neku svrhu (Fayyad, 1996).

Ovaj proces spaja inženjering poslovnog sustava, statističke metode i računalnu snagu industrijske snage kako bi se pronašla struktura (veze, obrasci, asocijacije i osnovne funkcije) umjesto statističkih parametara (srednje vrijednosti, težine, pragovi i čvorovi). No, istaknuto je zapravo prilično linearna organizacija procesa rudarenja podataka, dok iterativni sustav zatvorene petlje s povratnim informacijama, čini suvremeni pristup praksi rudarenja podataka (Baum et al., 2020).

Mukotrpnost razvoja realističnih aplikacija otkrivanja znanja iz baza podataka, prethodno prijavljeni primjeri otkrivanja znanja u literaturi, kao i samo iskustvo u znanju iz stvarnog svijeta, navode na zaključak da je otkrivanje znanja ljudski zadatak, koji zahtijeva znanje i sastoji se od složenih interakcija između čovjeka i velike baze podataka, možebitno podržane heterogenim skupom alata. Većina sustava otkrivanja znanja više su motivirani novom tehnikom otkrivanja, nego prvenstvenom brigom za korisnikov zadatak. Kao rezultat toga, oni su se susreli s mješovitim ili minimalnim komercijalnim uspjehom. Za uspješniji razvoj otkrivanja znanja iza baza podataka, ključno je razumjeti točnu prirodu interakcija između čovjeka i podataka, koji vodi do otkrića znanja (Baum et al., 2020).

Formuliranje ciljeva i zadataka rudarenja podataka može se činiti besmislenim, u odnosu na poslovni cilj, ali je ključno za uspjeh projekta rudarenja podataka. Primarni cilj vježbe rudarenja podataka nije uvježbavanje dobrog prediktivnog modela po sebi, već radije

implementacija dobrog prediktivnog modela kako bi se ispunio poslovni cilj (Nisbet et al., 2009).

Često rudari podataka to uzimaju zdravo za gotovo. No, to se ne događa automatski. Dobro raspoređeni modeli moraju biti projektirani, a ne zamišljeni. Mnogi modeli koji su bili zamišljeni zbog svoje korisnosti u tvrtki su gurnuti na policu takoreći, jer se nisu mogli učinkovito i djelotvorno implementirati. Jedan od prvih uspješnih manifestacija procesa otkrivanja znanja iz baza podataka 21. stoljeća, vidljiv je u jednoj implementaciji generaliziranog mehanizma za implementaciju pod nazivom Zementis ADAPA, koji je koristio Amazon.com Elastic Cloud za implementaciju modela preko Interneta. Ovaj proizvod bio je jedan od rijetkih ozbiljnih pokušaja da se naglasak prebaci s izgradnje modela na implementaciju modela (Nisbet et al., 2009).

Ciljevi rudarenja podataka mogu uključivati sljedeće: (Nisbet et al., 2009).

- Izgradnja (ili pomoć u izgradnji) prikladne baze podataka iz koje se skupovi podataka za modeliranje mogu lako izdvojiti
- Razvoj i implementacija modela koji generira značajnu poslovnu vrijednost
- Izgradnja baze znanja o modeliranju učenja, koja se kasnije može iskoristiti za bolji posao s rudarenjem podataka (lakše, brže, jeftinije)

Svaki od ovih ciljeva rudarenja podataka povezan je sa skupom ciljeva. Na primjer, dobar skup ciljeva za cilj razvoja i implementacije modela može uključivati sljedeće: (Nisbet et al., 2009)

- Stjecanje prikladnog skupa podataka za modeliranje
- Izrada užeg popisa prediktorskih varijabli
- Izrada modela prihvatljive točnosti
- Primjena modela u proizvodnim operacijama
- Praćenje prihvatljivog učink
- Ažuriranje modela trenutnim podacima
- Pružanje povratne informacije o inteligenciji stečenoj primjenom modela

Svaki od ovih ciljeva provodit će se nizom zadataka. Primjer popisa zadataka za cilj stvaranja užeg popisa prediktorskih varijabli može uključivati ove zadatke:

- Identifikacija/izvođenje ciljne varijable (varijable koju treba predvidjeti)

- Univarijatna i bivarijatna analiza kandidatskih prediktorskih varijabli
- Multivarijantna analiza prediktorskih varijabli kandidata
- Korelacijska analiza varijabli kandidata prediktora
- Preliminarni pregled varijabli s različitim metrikama i algoritmima probira (npr. Gini bodovanje ili s nekom mjerom "zanimljivosti")
- Preliminarno modeliranje ciljne varijable (npr. s algoritmom stabla odluka) za odabir varijabli za uži popis

Svaki od ovih zadataka bit će sastavljen od podzadataka ili koraka koji se slijede za postizanje zadatka. Na primjer, koraci koji se slijede u zadatku univarijatne ili bivarijatne analize mogu uključivati: (Nisbet et al., 2009)

- Generiranje različitih deskriptivnih statistika (npr. srednje vrijednosti, standardne devijacije, itd.)
- Dvovarijantne dijagrame raspršenja
- Analiza povezanosti i povezanosti

Na temelju navedenog, moguće je vidjeti kamo dalje je potrebno ići s ovim skupom metodologije. Naravno, sve ciljeve, zadatke i korake potrebno je sastaviti u projektni plan i onda njime upravljati. Potrebno je nadalje planirati posao, a zatim odraditi plan. Ovaj plan treba svakom cilju, zadatku i koraku dodijeliti početne i krajnje datume, te identificirati resurse potrebne za njegovo postizanje (ljudi, novac i oprema) (Nisbet et al., 2009).

4.6. Izvedene funkcije rudarenja podataka

Sljedeće se funkcije mogu izvoditi s uslugama rudarenja podataka: (Weiss i Davison, 2010)

- Ekstrakcija znanja

  Ovo je postupak za pronalaženje korisnih trendova u podacima koji se mogu koristiti u donošenju odluka. To je zato što se odluke moraju donositi na temelju točnih/točnih podataka i dokaza.

- Prikupljanje podataka

  Scraping-om putem povezanih web-mjesta i baza podataka moguće je prikupiti informacije o ulagačima, portfeljima i fondovima korištenjem procesa web-scraping-a.

- Podaci s weba

Web podatke je poznato da je teško rudariti. To je zbog suštine situacije. Web podaci, na primjer, mogu se smatrati dinamičnim, što znači da se mijenjaju tijekom vremena. Kao rezultat toga, proces rudarenja podataka treba replicirati u redovitim intervalima.

- Prethodna obrada podataka

Ovdje se radi o tome da se obično prikupljeni podaci pohranjuju u podatkovnom centru. Ove informacije moraju biti prethodno obrađene. Stručnjaci za rudarenje podataka trebali bi ručno izbrisati sve podatke koji se smatraju nevažnim tijekom predobrade.

- Istraživanje tržišta, ankete i analize

Data mining može se koristiti za istraživanje proizvoda, ankete i istraživanje tržišta. Moguće je prikupiti podatke koji bi bili korisni u kreiranju novih marketinških strategija i promocija.

- Skeniranje podataka

Podaci dobiveni i obrađeni bili bi beskorisni dok se ne skeniraju. Skeniranje je bitno za otkrivanje trendova i sličnosti u podacima.

- Povratne informacije kupaca

Povratne informacije i prijedlozi kupaca pod velikim su utjecajem na poslovanje tvrtke. Kupci mogu lako pronaći detalje na forumima, časopisima i drugim stranicama na kojima mogu otvoreno izraziti svoje mišljenje.

- Vijesti

S obzirom da gotovo sve glavne novine i novinske kuće ovih dana dijele svoje vijesti na internetu, lako je prikupiti informacije o razvoju i drugim važnim temama. Na ovaj način moguće je biti na boljem mjestu za natjecanje na tržištu.

- Ažurni podaci

Ovdje se misli na to kako je važno ažurirati podatke. Prikupljene informacije bile bi beskorisne osim ako se ne izmijene. Time se osigurava valjanost podataka prije donošenja odluka na temelju njih.

- Internet istraživanje

Internet je poznat po svojoj ogromnoj količini znanja. Očito je da je to najvažniji izvor podataka. Moguće je prikupiti mnogo znanja o raznim poduzećima, potrošačima i klijentima tvrtke. Prijevare se mogu otkriti korištenjem internetskih resursa.

- Proučavanje konkurenata

Važno je znati kako vaši konkurenti stoje u poslovnom svijetu. Važno je razumjeti i njihove snage i slabosti. Njihove metode marketinga i distribucije mogu se minirati, uključujući njihove metode smanjenja ukupnih troškova (Weiss i Davison, 2010).

4.7. Prednosti korištenja podataka u sektoru osiguranja

Data mining i njegove značajke imaju mnoge prednosti, te postavljaju potrebu za tržištem vođenim podacima, jer su kombinirani s analitikom i velikim podacima. Neke od prednosti su sljedeće: (Umamaheswar i Janakiraman, 2014)

- Uslužne industrije imaju koristi od rudarenja podataka otkrivanjem nepogodnih i korisnički nepodesnih ponuda, pomoću inženjerskih podataka. To pomaže u uklanjanju loših paketa ponuda iz asortimana.
- Pomaže društvima u analizi financijskih podataka i transakcija kako bi ih modelirali u upotrebljive podatke.
- Data mining je koristan ne samo za izradu prognoza, već i za razvoj novih usluga i paketa.
- Prediktivni modeli se koriste u osiguravateljnom sektoru. Bolja kvaliteta i uvid potrošača mogući su u osiguravajućim kućama. Za izračun popusta i otkupa koriste se povijesni podaci.
- Data mining pomaže osiguravajućim kućama u financijskoj dobiti i upozorava na moguće prijevare. Oni stvaraju model temeljen na podacima klijenata. Klijenti stječu povjerenje u tvrtke, što dovodi do povećanja broja klijenata.
- Marketinški odjel osiguravajućih tvrtki koriste data mining za izradu modela podataka i predviđanja na temelju povijesnih podataka. Oni upravljaju promocijama, marketinškim strategijama i tako dalje. To dovodi do brzog rasta i prosperiteta.
- Data mining rezultira stvaranjem novih izvora prihoda, što rezultira širenjem osiguravajuće tvrtke.
- Data mining pomaže u poboljšanju strategije i procesa donošenja odluka u organizacijama.
- Kada se pronađu konkurentske prednosti, rudarenje podataka može pomoći u smanjenju troškova marketinga.

Microsoft Project je dobar paket za planiranje projekta koji se koristi za formiranje i praćenje plana projekta. Ugrađeni cilj dobrog planiranja projekta je završiti plan prije roka i ispod proračuna. Mnogo je napisano o tome kako se to radi, tako da ovdje nije potrebno detaljnije analizirate. Mnogo dobrih informacija o planiranju projekata dostupno je na Internetu, posebice od Instituta za upravljanje projektima (PMI). PMI certifikat kao stručnjak za upravljanje projektima (PMP) dobar je dodatak uspješnom rudarenju podataka u osiguravateljnom sektoru (Devale i Kulkarni, 2012).

5. ZAKLJUČAK

Upravljanje odnosima s klijentima (CRM) je sustav za upravljanje interakcijama tvrtke sa sadašnjim i budućim kupcima, koje često uključuje korištenje tehnologije za organiziranje, automatizaciju i sinkronizaciju prodaje, marketing, korisničku podršku i tehničku podršku. CRM, koristi prednosti upravljanja podacima, koje omogućuje resursi podataka za rad, kao jedinstvena integrirana baza podataka. Podrijetlo pojma CRM može se pratiti unatrag 1990-ih, kada se koncept marketinga promijenio iz transakcijskog u racionalni. CRM je namijenjen za izgradnju dugotrajnih veza, te se često smatra marketingom baze podataka, koji prvenstveno povezuje marketing organizacija s bazom podataka kupaca. Neki teoretičari su ovaj marketing razmatrali, kao vježbu za zadržavanje kupaca, obzirom da su mnoge teorije i studije naglašavale razloge za zadržavanje kupaca, što zahtijeva razne tehnike, posebno inicijative nakon prodaje, kako bi se kupci zadržali doživotno. Vjerovalo se da je to mehanizam koji će zadržati postojeće kupce sretnima, kako bi oni ostali uz organizaciju i ako je moguće, generirali pozitivne preporuke za proizvode i usluge tvrtke. Uspješan CRM bi trebao bi dati sposobnost osiguravatelju mjerenja vrijednosti kupaca i poboljšanja percepcije usluge korisnika, uz istovremeno smanjenje troškova servisiranja.

Nakon telekomunikacija i bankarstva, osiguravajuća društva su se posvetila upravljanju odnosima s klijentima, kao rješenje za poboljšanje svog poslovanja. Kako je konkurencija sve veća, tvrtke pokušavaju zadržati postojeće kupce, koristeći u tu svrhu i CRM aplikacije. Osiguravajuća društva troše gotovo određeni dio svojih IT budžeta na CRM softver i usluge, očekujući da im CRM pomogne u rastu poslovanja, poput pružanja boljeg iskustva korisničke službe, povećanje prihoda kupaca, identificiranje kupaca, omogućavanje prodajnom osoblju brže sklapanje poslova, stvaranje učinkovitijih pozivnih centara, kao i ažuriranje klijenata o novostima, te promocijama itd. U slučaju zaposlenika u osiguranja, osim stalnih kupaca, koji imaju policu kod osiguravatelja, postoji niz potencijalnih kupaca koje je moguće agitirati, pri čemu se CRM ukazuje kao koristan alat.

Otkrivanje znanja u osiguravajućim kućama, izgrađeno je i djeluje uglavnom kao podrška donošenju odluka, koristeći znanje kao strateški čimbenik. U ovom radu istraženo je korištenje različitih tehnika rudarenja podataka za otkrivanje znanja u poslovanju osiguranja. Pokazalo se važnim sagledati postojeći softver u okviru osiguravajućih tvrtki, obzirom da se isti ukazuje često kao neučinkovit u prikazivanju određenih karakteristika podataka. Stoga je

potrebno uvesti različite eksponate za otkrivanje znanja u obliku pravila asocijacije, grupiranja, klasifikacije i korelacije prikladne za karakteristike podataka. Predloženim tehnikama rudarenja podataka, donositelj odluka u sektoru osiguranja, može definirati širenje aktivnosti osiguranja kako bi se osnažile različite snage u određenom sektoru osiguranja.

POPIS KRATICA

- CSF - kritični čimbenici uspjeha
- GST - opća teorija sustava
- SFA - automatizacije prodajne snage

LITERATURA

- http://safirdep.com/wp-content/uploads/2020/05/%D9%86%D9%82%D8%B4-%D8%AF%D8%A7%D8%AF%D9%87-%DA%A9%D8%A7%D9%88%DB%8C-%D8%AF%D8%B1-%D8%B5%D9%86%D8%B9%D8%AA-%D8%A8%DB%8C%D9%85%D9%87.pdf
- https://www.researchgate.net/publication/266507095_Applications_of_Data_Mining_Techniques_in_Life_Insurance
- https://www.talisma.com/role-of-crm-in-insurance-industry/
- https://link.springer.com/article/10.1057/dbm.2008.5
- https://link.springer.com/article/10.1057/dbm.2008.5
- https://www.forbes.com/sites/forbesagencycouncil/2017/10/24/why-is-customer-relationship-management-so-important/?sh=f19371f7dacd
- https://www.sciencedirect.com/science/article/pii/S2314728817300168
- https://eprints.whiterose.ac.uk/92517/10/Baltic%20Journal%20of%20Management%202015%20(10)%204%20398-412.pdf
- https://isiarticles.com/bundles/Article/pre/pdf/81902.pdf
- https://hbr.org/2004/11/crm-done-right
- https://www.sciencedirect.com/science/article/pii/S2212567114005681
- https://www.diva-portal.org/smash/get/diva2:428076/FULLTEXT01.pdf
- https://hbr.org/2018/12/why-crm-projects-fail-and-how-to-make-them-more-successful
- https://www.sciencedirect.com/science/article/pii/S2314728817300168
- https://www.intechopen.com/chapters/16917
- https://innovation-entrepreneurship.springeropen.com/articles/10.1186/s13731-018-0093-4
- https://hbr.org/1983/05/the-globalization-of-markets
- https://www.forbes.com/sites/forbesagencycouncil/2017/10/24/why-is-customer-relationship-management-so-important/?sh=6133e4667dac
- https://www.researchgate.net/publication/228399399_Customer_Relationship_Management_In_Organizations
- https://hbr.org/2004/11/crm-done-right
- https://www.sibm.edu/assets/pdf/customerrelationshipmanagement.pdf
- https://www.superoffice.com/blog/what-is-crm/
- https://www.researchgate.net/publication/232580888_A_multilevel_approach_to_theory_and_research_in_organizations_Contextual_temporal_and_emergent_processes
- https://www.researchgate.net/publication/314341370_An_empirical_study_to_identify_and_rank_CSFs_in_customer_relationship_management_CRM_A_case_study_of_oil_products_distribution
- https://www.sciencedirect.com/science/article/pii/S2314728817300168
- https://www.salesforce.com/ap/hub/crm/why-do-crm-projects-fail/
- http://web.mit.edu/esd.83/www/notebook/gst.pdf
- https://www.researchgate.net/publication/330500755_Complexity_Theory_An_Overview_with_Potential_Applications_for_the_Social_Sciences
- https://www.researchgate.net/publication/336890527_Customer_Relationship_Management_and_Customer_Retention
- https://www.researchgate.net/publication/312491333_Critical_Success_Factors_of_CRM_Antecedents_to_successful_implementation

- https://www.researchgate.net/publication/233625006_Critical_success_factors_of_continuous_improvement_in_the_public_sector_A_literature_review_and_some_key_findings
- https://resources.sei.cmu.edu/asset_files/TechnicalReport/2004_005_001_14393.pdf
- https://www.researchgate.net/publication/242759843_What_makes_for_CRM_system_success_-_Or_failure
- https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.1043.3378&rep=rep1&type=pdf
- https://www.researchgate.net/publication/235294141_Managing_Customer_Relationships
- https://umu.diva-portal.org/smash/get/diva2:1222286/FULLTEXT01.pdf
- https://www.sciencedirect.com/science/article/pii/S2314728817300168
- https://www.researchgate.net/publication/228399399_Customer_Relationship_Management_In_Organizations
- https://searchcustomerexperience.techtarget.com/definition/CRM-customer-relationship-management
- https://www.researchgate.net/publication/349139007_The_Best_Practice_of_CRM_Implementation_for_Small-_and_Medium-Sized_Enterprises
- https://www.researchgate.net/publication/263719743_Customer_relationship_management_The_evolving_role_of_customer_data
- https://www.vtiger.com/crm/evolution-of-crm/
- https://sloanreview.mit.edu/article/why-crm-and-how-to-fix-it/
- https://www.researchgate.net/publication/220672580_Adopting_customer_relationship_management_technology
- https://scholarworks.waldenu.edu/cgi/viewcontent.cgi?article=5437&context=dissertations&httpsredir=1&referer=
- https://www.investopedia.com/terms/c/customer_relation_management.asp
- https://www.researchgate.net/publication/222913815_The_impact_of_technological_and_organizational_implementation_of_CRM_on_customer_acquisition_maintenance_and_retention
- http://www.davidpublisher.com/Public/uploads/Contribute/577df1007eb21.pdf
- https://www.researchgate.net/publication/286198853_Customer_relationship_management_concepts_and_technologies

- https://core.ac.uk/download/pdf/147833553.pdf

- https://www.researchgate.net/publication/242759843_What_makes_for_CRM_system_success_-_Or_failure
- https://www.business2community.com/strategy/12-reasons-crm-implementation-will-fail-01574024
- https://espace.curtin.edu.au/bitstream/handle/20.500.11937/19345/154177_154177.pdf;jsessionid=FAD3F9FA7995B409B3DB52E793BF30C4?sequence=2
- https://www.salesforce.com/ap/hub/crm/why-do-crm-projects-fail/
- https://hbr.org/2007/02/understanding-customer-experience
- https://www.nextiva.com/blog/operational-crm.html
- https://www.researchgate.net/publication/232864187_Strategic_Operational_and_Analytical_Customer_Relationship_Management
- https://www.researchgate.net/publication/235639916_Social_CRM_A_Review_of_the_Academic_and_Practitioner_Literatures_and_Research_Agendas

- https://www.sciencedirect.com/science/article/pii/S2405844021010161
- https://customerthink.com/the-top-reasons-crm-fails/
- https://hbr.org/2014/07/unlock-the-mysteries-of-your-customer-relationships
- https://www.researchgate.net/publication/264437100_Web_20_in_the_CRM_domain_defining_social_CRM
- https://www.scielo.br/j/bar/a/Y5stQ8DsFNH5Jp7R7SsbbWj/?lang=en
- https://hbr.org/2018/12/why-crm-projects-fail-and-how-to-make-them-more-successful
- https://blog.hootsuite.com/social-crm/
- https://www.appvizer.com/magazine/customer/client-relationship-mgt/ecrm-meaning
- https://www.diva-portal.org/smash/get/diva2:437221/FULLTEXT01.pdf
- https://www.zendesk.com/blog/3-types-crm-everything-need-know/
- http://www.diva-portal.org/smash/get/diva2:1023082/FULLTEXT01.pdf
- https://www.researchgate.net/publication/264437100_Web_20_in_the_CRM_domain_defining_social_CRM
- https://www.researchgate.net/publication/241743222_Customer_Relationship_Management_CRM's_Impact_on_B_to_B_Sales_Professionals'_Collaboration_and_Sales_Performance
- https://trujay.com/collaborative-crm-key-features-and-benefits/
- https://www.businessmanagementideas.com/crm/e-crm/e-crm-meaning-evolution-and-benefits/3688
- https://core.ac.uk/download/pdf/33812277.pdf

- https://blog.perfectmind.com/benefits-of-using-crm-for-your-business
- https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7194637/
- https://www.businessnewsdaily.com/15963-benefits-of-crm.html
- https://www.sciencedirect.com/science/article/pii/S0022435920300725
- https://www.managementstudyguide.com/analytical-crm.htm
- https://www.researchgate.net/publication/220672580_Adopting_customer_relationship_management_technology
- https://survicate.com/customer-satisfaction/importance-customer-satisfaction/
- https://www.superoffice.com/blog/crm-benefits/
- https://www.tandfonline.com/doi/full/10.1080/1331677X.2019.1676283
- https://www.researchgate.net/publication/319085560_Market_Segmentation_Targeting_and_Positioning
- https://www.superoffice.com/blog/what-is-crm/
- https://www.sibm.edu/assets/pdf/customerrelationshipmanagement.pdf
- https://www.sciencedirect.com/science/article/pii/S2210832718300735
- https://core.ac.uk/download/pdf/147833553.pdf
- https://www.sciencedirect.com/science/article/pii/S2314728817300168
- https://scholarworks.gsu.edu/cgi/viewcontent.cgi?article=1016&context=cis_facpub
- https://link.springer.com/article/10.1057/dbm.2008.5
- https://www.researchgate.net/publication/228399399_Customer_Relationship_Management_In_Organizations
- https://www.researchgate.net/publication/220017413_Customer_Relationship_Management_Advances_Dark_Sides_Exploitation_and_Unfairness
- https://www.computerworld.com/article/2588337/amazon-apologizes-for-price-testing-program-that-angered-customers.html

- https://www.researchgate.net/publication/235275069_Customer_management_and_CRM_Addressing_the_dark_side
- https://www.talisma.com/role-of-crm-in-insurance-industry/
- https://www.leadsquared.com/role-of-crm-in-insurance-sector/
- https://www.iosrjournals.org/iosr-jbm/papers/Vol19-issue6/Version-2/D1906023135.pdf
- https://www.softwaresuggest.com/blog/crm-in-insurance-sector/#
- https://www.researchgate.net/publication/275536407_Customer_Relationship_Management_in_the_Insurance_Industry
- Hrvatska enciklopedija, mrežno izdanje. Leksikografski zavod Miroslav Krleža, 2021. Pristupljeno 16. 10. 2021. <http://www.enciklopedija.hr/Natuknica.aspx?ID=27338>.