



ȘCOALA DOCTORALĂ INTERDISCIPLINARĂ

Facultatea: Facultatea de Științe economice și administrarea afacerilor

Marius Geru

Impactul modelelor predictive asupra comportamentului clienților

în e-Commerce folosind algoritmi de Inteligență Artificială

**The impact of predictive models on e-Commerce customer
behavior using Artificial Intelligence algorithms**

REZUMAT / ABSTRACT

Conducător științific

Prof.dr.ing. Adrian Micu

BRAȘOV, 2021

D-lui (D-nei)

COMPONENȚA

Comisiei de doctorat

Numită prin ordinul Rectorului Universității Transilvania din Braşov

Nr. din

PREȘEDINTE:

Conf. dr. Radu Constantin Lixăndroiu

CONDUCĂTOR ȘTIINȚIFIC:

Prof.dr.ing. Adrian Micu

REFERENȚI:

Prof. dr. Orzan Mihai Cristian

Prof. dr. Gabriel Brătucu

Prof. dr. Alexandru Căpățînă

Data, ora și locul susținerii publice a tezei de doctorat:, ora, sala

Eventualele aprecieri sau observații asupra conținutului lucrării vor fi transmise electronic, în timp util, pe adresa marius@thecon.ro

Totodată, vă invităm să luați parte la ședința publică de susținere a tezei de doctorat.

Vă mulțumim.

CUPRINS (lb. română)

	Pg. teza	Pg. rezumat
Listă Abrevieri	6	
Introducere	11	4
CAPITOLUL 1. Stadiul actual al cercetării în domeniul marketingului online și tehnologiilor emergente în comerțul electronic	13	6
Modele și practici ale comerțului electronic	18	10
Abordări ale Marketingului digital în e-commerce	22	
Factori ce determină credibilitatea informației în comerțul electronic	27	
Direcții emergente în comerțul electronic	33	
Bariere și oportunități de natură geopolitică în e-commerce	34	
Instrumente de Marketing digital folosite în e-Commerce	42	
Strategii de Marketing online	42	
Perspective de Marketing Digital ale Big Data în Internet of Things	46	
Evaluarea calității în marketing digital	55	12
Big Data în comerțul electronic și Marketing Digital	55	
Perspectiva academică asupra Big Data	56	
Metode analitice folosite cu Big Data	57	
Definirea Big Data în contextul analizei comportamentului consumatorului	59	
Provocări în infrastructuri de tip Big Data	61	
Resurse necesare pentru implementarea Big Data	62	
Rolul rețelelor sociale în e-Commerce	64	
Analiza relației cu clientul în e-Commerce și rețele sociale	64	
Valoarea adăugată în rețelele sociale	66	
Inovația și limitările Big Data în Marketing	70	
CAPITOLUL 2. Analiza sistematică a literaturii de specialitate în comerțul electronic și algoritmi de învățare automată	74	15

Recenzia literaturii de specialitate	74	15
Metoda de cercetare	76	18
Concepte generale	80	
Algoritmi de Învăţare Automată Supervizată	83	
Algoritmi de învăţare nesupervizată	91	
Învăţarea Automată prin Recompensă (RML)	95	
Reţele Neuronale şi Învăţare Profundă	98	21
Metode de Tip Ansamblu	105	
Servicii în Cloud disponibile pentru Machine Learning	106	
Utilizarea inteligenţei artificiale în e-commerce	111	
Soluţii CRM de recomandare produse	111	
Detecţia identităţii vizuale pe reţelele sociale şi e-Commerce	115	
Modele predictive folosind Big data generate de reţele sociale	126	
Agenţii virtuali (chatboţii) în comerţul electronic	133	
Discuţii şi concluzii privind analiza sistematică a literaturii de specialitate	135	
CAPITOLUL 3. Cercetări practice privind comportamentul clienţilor în e-commerce folosind algoritmi de inteligenţă artificială	142	25
Selectarea cadrului şi definirea structurii de cercetare	142	25
Fluxul de date - Integrări de tipul Big Data	160	
Metodologia cercetării calitative	173	
Scopul şi obiectivele cercetării calitative	174	
Metodele de cercetare utilizate	175	
Stabilirea ghidului de interviu şi culegerea datelor	177	
Cercetarea cantitativă	184	31
Metodologia cercetării	184	31
Modalităţi de culegere a datelor	184	32
Stabilirea mărimii eşantionului	185	33
Obiectivele şi ipotezele cercetării pentru clienţii Cleşte.ro	186	34

Obiectivele și ipotezele cercetării pentru managementul magazinelor online	190	35
Modelul conceptual al cercetării	192	
Analiza datelor cercetării	193	
Ipoteze privind comportamentul clienților pe dispozitive mobile	193	
Ipoteze testare canale de comunicare	207	
Testarea ipotezelor legate de bugetul clienților	211	
Ipoteze automatizari de marketing si algoritmi de inteligenta artificiala	215	
Aplicabilitatea modelelor predictive ce folosesc inteligență artificială	218	36
Concluzii	225	38
Implicatii manageriale si limitarile cercetarii	229	40
Bibliografie	231	41
Anexe	253	
Anexa 1 - Terminologie	253	
Anexa 2 - Lista Figuri	258	
Anexa 3 - Lista Tabele	259	
Anexa 4- Rezumat Limba Română	260	65
Anexa 4- Rezumat Limba Engleză	262	67

Introducere

În contextul digitalizării accelerate, rolul marketingului online (MO) în strategia unei firme se extinde semnificativ, după cum reiese din creșterea investițiilor firmelor în activitățile de comerț electronic (e-Commerce). Aproximativ un sfert (26%) din bugetele totale de marketing sunt folosite de companii care au ca model unic de activitate comerțul online (Alvarez, Gartner, 2013). În plus, față de rentabilitate și schimbările în comportamentul clientului, orientate către o informare continuă, investițiile în MO sunt argumentate în primul rând de rezultatele sale, dar și de faptul că acestea sunt mai ușor de măsurat comparativ cu cele ale marketingului tradițional (Hennig-Thurau et al., 2010; Pickton, 2005).

Pe măsură ce clienții interacționează din ce în ce mai mult cu companiile prin canale digitale și rețele sociale, comercianții au realizat necesitatea de a urmări aceste interacțiuni și de a măsura performanța lor (Chaffey și Patron, 2012). În acest scop, firmele sunt nevoite să adopte unelte de Analiză Web (AW), ce ajută la măsurarea, colectarea, analizarea și raportarea datelor vizitatorilor web, în scopul înțelegerii și optimizării utilizării platformelor de comerț electronic numite și Big Data (Web Analytics Association, 2008). Marketingul online este o ramură esențială integrantă a comerțului electronic în prezent și include modalități diferite de prezentare a unei companii, cum ar fi marketingul prin e-mail, marketingul de conținut, social media, marketingul afiliat și alte strategii de marketing. Diversitatea canalelor de distribuție a conținutului pe internet și modul cum acesta este formatat, impune specialiștilor în marketing să țină cont de locația și modul în care clienții acestora comunică.

Mobile commerce (m-commerce) este o versiune naturală de îmbunătățire a comerțului electronic, care permite utilizatorilor să interacționeze cu alți utilizatori sau cu întreprinderi într-un mod fără fir, oriunde și oricând. De asemenea, cumpărăturile online se fac și pe dispozitive post-pc cum ar fi smartphone-uri sau tablete. Se constată că peste o treime dintre cumpărători au făcut minim o achiziție printr-un dispozitiv mobil inteligent în ultimele 6 luni (Alvarez, Gartner, 2013). Kang și Kim (2015) au evidențiat utilizarea sporită a comunicațiilor mobile, iar creșterea rapidă a tehnologiilor de cumpărături mobile are un potențial financiar considerabil, în special pentru piețele cu amănuntul între întreprinderi și consumatori. Practic, m-commerce este unul dintre canalele de marketing prin care clientul are acces la comunicarea directă cu furnizorul, sau la comunități în care acesta poate oferi recenzii referitoare la produsele și serviciile achiziționate.

Provocările cu care se confruntă în prezent atât mediul economic cât și societatea sunt adeseori preluate de domeniul TIC, care își asumă rolul de a pivota și transforma modelele tradiționale de business. Odată cu evoluția sistemelor de tip IoT (Internet of Things), acest proces a fost accelerat semnificativ, astfel că în ultimul deceniu tehnologia inovativă și buna gestionare a datelor (*Big Data*) au pus la dispoziție o varietate consistentă de produse noi, rezultând astfel oportunități de business în diverse domenii de activitate, cum ar fi: inginerie, agricultură, logistică, medicină ș.a. Noile segmente ale industriei, care combină aplicații virtuale și produse fizice prin intermediul senzorilor și dispozitivelor inteligente, promit

eficientizarea consumului de energie, dar și un mod mai ușor de interacțiune cu acestea, generând informații ce pot fi valorificate instant de consumatorul final, aflate la un nivel încă incipient de exploatare în piața. În contextual folosirii pe scara largă a dispozitivelor mobile există o lacună în cercetarea academică (research gap) în identificarea comportamentului consumatorului folosind telefoanele mobile inteligente. Mai mult nu este documentat în literatură de specialitate cum inteligența artificială este folosită de consumatori sau comercianți în a-si eficientiza activitatea.

În acest cadru, sunt explorate următoarele **întrebări de cercetare**:

1. Care sunt cerințele specifice de resurse pentru firme pentru a profita de datele colectate online despre consumatori pentru a obține un avantaj competitiv durabil?
2. În ce componente ale comerțului electronic și marketing digital se folosește inteligența artificială?
3. Ce funcții e-commerce nu au fost analizate în literatura de specialitate pentru a fi automatizate folosind algoritmi de inteligență artificială?
4. Există o diferență semnificativă între comportamentul clienților pe dispozitive mobile și calculatoare desktop?
5. Cum poate fi identificată intenția clientului de schimbare a furnizorului raportat dispozitivul folosit pentru a efectua cumpărăturile online?
6. Este diferit comportamentul cumpărătorilor online în funcție de vârstă și ocupație?

Dacă în primele două capitole obiectivul general a fost înțelegerea și așezarea cunoștințelor privind comerțul digital pe un model structurat folosind analiza sistematică a literaturii de specialitate. În capitolul 3 sunt elaborate ipoteze concrete în cadrul unui studiu calitativ printr-un interviu aplicat echipei implicate în administrarea platformei e-commerce, care ulterior sunt testate folosind metodele statistice hi pătrat, regresie multiplă și antrenarea unei rețele neuronale. Studiul cantitativ folosește date colectate de la manageri de platforme e-commerce prin telefon, clienți online din platforme e-commerce și date secundare financiare a firmelor ce au domeniul de activitate comerțul online.

Pe măsură ce volumul de date crește, devine mai complex și mai inexplicabil, capacitățile limitate ale oamenilor prezintă adevărate provocări în descifrarea și interpretarea unui mediu economic tot mai imprevizibil (Sammur & Sartawi, 2012). În esență, Big Data este artefactul inteligenței individuale și colective generate și împărtășite în principal prin mediul tehnologic, unde aproape orice informație poate fi documentată, măsurată și stocată digital, transformându-se astfel în date ce pot fi prelucrate pentru a genera informații acționabile reutilizabile în multiple sfere de activitate.

CAPITOLUL 1. Stadiul actual al cercetării în domeniul marketingului online și tehnologiilor emergente în comerțul electronic

Pentru a se adapta la dinamica pieței, este necesar ca o companie să susțină procese complexe de stabilirea a unei strategii de marketing coerente, bazată pe o relație mutuală, între client și afacere. Odată cu apariția comerțului electronic bazat pe internet, companiile experimentează noi modele de afaceri pentru a obține profit și eficiență organizațională. Deseori, noile tehnologii nu funcționează la capacitatea maximă din cauza faptului că managerii impun o structură de decizie a celui mai potrivit model de afacere, bazându-se pe circumstanțe interne și externe specifice (Fisher, 1997; Janssen și Sol, 2000).

Aflat printre dintre cele mai importante progrese tehnologice din ultimii douăzeci de ani, comerțul electronic a transformat într-un mod revoluționar mediul de afaceri global, principalele beneficii fiind accesul la noi piețe de desfacere, extinderea bazei de clienți, lanțuri de aprovizionare modernizate, îmbunătățirea relației cu clienții, profit crescut și eficientizarea costurilor cu logistica (Karavdic și Gregory, 2005). Trecerea de la piețele tradiționale la cele electronice impune noi abilități și cunoștințe de marketing, care sunt de regula oferite de firme specializate, orientate spre atingerea eficienței maxime în marketing. Operatorii industriali pot dezvolta cu ușurință aceste abilități, în cazul în care există o capacitate specializată corelată cu tehnologia informației. Investiția în resursele specifice comerțului electronic a devenit o practică obișnuită în exportul actual, și, prin urmare, ușor de însușit de către mediul economic. Totuși, investițiile în resurse aparținând tehnologiei informației (IT) nu garantează succesul, ceea ce duce la necesitatea verificării efectului pe care resursele IT îl au asupra performanței (Ravichandran, Liu, Han, și Hasan, 2009).

Încorporând capacitatea de marketing a comerțului electronic, putem explica modul în care exportatorii folosesc tehnologia informației (IT) pentru a crește eficiența și a îmbunătăți procesul de export. Prin urmare, raționamentul care stă la baza obiectivelor strategice ale companiei este planificarea unui set de activități care pot controla numeroasele caracteristici ale clienților săi.

Specialiștii în marketing tind să facă o distincție între istoria practicilor comerciale și istoria cercetării academice de marketing:

1. *Istoria practicilor comerciale* se referă la o analiză a modurilor în care marketingul este practicat și cum aceste practici au evoluat pentru a răspunde schimbărilor socio-economice.
2. *Istoria gândirii cercetării academice de marketing* se referă la examinarea modului în care marketingul a fost studiat și predat.

Este ușor de înțeles că, în zilele noastre, cel mai important obiectiv al oricărei activități de marketing - vânzarea propriu-zisă, tinde să îndeplinească toate scopurile și obiectivele organizației, fapt care

conturează principalele elemente și importanța oricărei abordări sau strategii de marketing. Prin punerea în practică a acestei teorii, marketingul a fost supus unui progres continuu (Solomon, 2009).

Încă de la începuturile școlii ideologice de marketing, specialiștii au creat seturi de instrumente de analiză pentru dezvoltarea strategiei de marketing ca știință aplicată a conceptului de afacere în practicile vieții de zi cu zi. Aceste concepte de marketing au apărut pe la sfârșitul secolului al XVIII-lea, începutul secolului următor. Treptat, aceste activități au condus specialiștii către primele încercări de a formula teoria privitoare la marketing, în cadrul Universității din Pennsylvania și a Universității din Pittsburgh între anii 1905-1909, iar la Universitatea din Wisconsin în 1910. Pe atunci, conceptele teoretice și metodologice ale viitoarei științe au încercat să explice cum diviziunea internațională a muncii cu migrația sa internațională și relațiile economice internaționale au crescut rapid. În zilele noastre, cu pârgă tehnologiei și a internetului, aceste concepte metodologice pot fi testate și aplicate, fapt care duce la obținerea unui feedback în câteva ore sau chiar minute, fiind posibilă, în acest fel, adaptarea noilor strategii în cadrul campaniilor active. Acest fapt a făcut posibilă apariția discuțiilor pe marginea dezvoltării reale a practicilor și a eforturilor echivalente în ceea ce privește teoretizarea marketingului ca știință (Hauser, Tellis, și Griffin, 2006).

Datele rezultate în urma activităților de comerț electronic au fost folosite pentru a îmbunătăți aspecte operaționale precum procesarea comenzilor, finalizarea comenzilor și livrarea, dar și aspecte care țin de îmbunătățirea strategiei de marketing online. În literatura de specialitate există studii de cercetare care au ca scop identificarea modului în care IMM-urile au beneficiat de adoptarea comerțului electronic. De exemplu, Santarelli și D'altri (2003), au identificat modul în care comerțul electronic a ajutat IMM-urile italiene să își mărească numărul de clienți, să dezvolte noi piețe de desfacere și să își perfecționeze comunicarea cu clienții.

Dezvoltarea progresivă a marketingului continuă să influențeze pozitiv și astăzi multe piețe, transformând comportamentul online al clientului într-un instrument real, foarte important în îmbunătățirea și creșterea complexității teoriilor privitoare la marketingul aplicat.

Astfel, putem spune că la ora actuală marketingul se bazează pe trei dimensiuni:

- I. *Dimensiunea științifică:* marketingul este considerat o știință relativ nouă, care face parte din familia științelor sociale și economice.
- II. *Dimensiunea managerială:* activitatea de marketing tinde să integreze toate acțiunile sale în afacere pentru a coordona și crește eficiența.
- III. *Dimensiunea filozofică:* beneficiile organizaționale sunt transferate către client.

Termenul de comerț electronic este interpretat diferit și contextual (Gunasekaran et al., 2002; Chaffey, 2006). La început, acesta a fost definit într-o manieră simplistă, referindu-se la tranzacții pe internet (Adam et al., 1999). Odată cu trecerea timpului, interpretarea comerțului electronic a inclus o varietate de activități organizaționale precum vânzarea, cumpărarea, logistica și alte activități organizațional-manageriale prin intermediul Web-ului sau desfășurarea afacerilor prin intermediul rețelelor informatice (Westland et al., 1999). Marketingul reprezintă una dintre cele mai noi ramuri ale

ştiinţelor economice (Malkiel, 2003), fiind caracterizat de flexibilitatea sa enormă şi iese în evidenţă prin consolidarea analizelor cantitative şi calitative în teoria economiei moderne. Una dintre principalele caracteristici ale acestei noi ştiinţe este gradul ridicat de aplicabilitate pe care îl are în câmpurile micro şi macro-economice. Marketingul poate fi de asemenea explicat studiind fazele dezvoltării teoriei economice însăşi, care a evoluat în jurul comerţului direct din moment ce majoritatea noţiunilor au fost stabilite prin extragerea directă din realitatea economică.

Marketingul online, comunicarea în marketingul integrat, marketingul mixt, segmentarea, poziţionarea şi multe alte concepte sunt rezultatul studiilor bazate pe diverse teorii iniţiale ce au la bază activitatea directă de marketing a numeroase corporaţii. Specialişti în marketing, experţii, cercetătorii şi consultanţii din domeniu, toţi au fundamentat cercetarea ştiinţifică în marketing cu aplicarea activităţii sale în cadrul companiilor.

Rolul comerţului electronic în economia digitală

Evoluţia tehnologică din ultimii ani a pus industriile în mişcare din multe puncte de vedere. A trecut un sfert de secol din momentul folosirii internetului în scopuri comerciale. În tot acest timp, mediul de business a suferit transformări radicale iar procesul de digitalizare disruptivă reprezintă un real interes pentru guverne şi alte organisme de conducere ce construiesc mecanisme de finanţare pentru a spori acest fenomen.

Marketingul digital a progresat semnificativ în urma implementării unor algoritmi inteligenţi, iar astăzi putem vorbi chiar despre o sub-ramură a industriei numită marketing automatizat (MA). În 2017, Gartner a evidenţiat într-un raport faptul că bugetele alocate noilor tehnologii din departamentele de marketing sunt la fel de mari ca acelea din departamentele de IT, în acelaşi an estimând o depăşire a lor. Explicaţia este simplă: marketingul digital este conectat direct la ultimele unelte digitale.

Un raport publicat de Nielsen (nielsen.com) în 2017 cu privire la încrederea consumatorilor în acţiunile publicitare anticipează cele menţionate anterior. Realizat la nivel global, studiul a arătat că încrederea în publicitatea tradiţională a scăzut treptat. Astăzi, o medie de 80% dintre consumatori, indiferent de categoria de vârstă, are încredere în recomandările primite de la alte persoane, acest aspect fiind şi cel mai mai des invocat în cazul motivării unor procese de cumpărare. Şi mai interesant este faptul că peste 60% dintre aceştia culeg recomandările din mediul online, acolo unde sunt prezenţi *influencerii*. Diferenţele între generaţii apar doar la nivelul platformei preferate. Generaţia *millennials* (generaţia Y - 1985-1998) este cea mai influenţată de *vloggeri*, care şi-au construit comunităţi de milioane de urmăritori pe canalul Youtube.

Economia digitală reprezintă modul în care organizaţiile găsesc modalităţi inovative de a realiza mai mult, la costuri reduse, pentru a fi competitive şi pentru a satisface nevoile clienţilor. Folosirea instrumentelor inteligente de marketing în procesul de studiere a pieţei, dezvoltarea de noi produse şi promovarea acestora asigură o astfel de performanţă economică.

Acest nou tip de economie tinde spre o eficiență maximă și este determinată de modelele de afaceri bazate pe tehnologii inovative. Perspectivele de dezvoltare ale organizațiilor sunt astfel influențate de convingerea și constrângerea că este necesară o interoperabilitate folosind puține resurse interne și instrumente tot mai inteligente, pentru a-și asigura succesul în următorii ani. Devine tot mai dificil pentru organizațiile de dimensiuni medii și mari să se conecteze cu potențialii clienți, care utilizează multiple canale online și sunt tot mai exigenți, ca urmare a accesului constant la un volum mare de informații. Monitorizarea permanentă a profilelor de consumatori necesită timp și este costisitoare, în special ținând cont de volumul de date foarte mare din mediul online.

Evoluția pieței de comerț electronic

Internetul a schimbat dramatic modul în care consumatorii cumpăra bunuri și servicii, colectează informații, compară produsele și prețurile acestora, ceea ce a dus la modificări fundamentale privind comportamentul companiilor care își desfășoară activitatea în mediul online. În ultimele decenii, piața de comerț electronic (E-commerce) a crescut aproape exponențial la nivel mondial. Cifra de afaceri globală a pieței B2C (Business to Consumer) este de aproximativ 2272,7 miliarde de dolari în 2015, ceea ce reprezintă o creștere de 19,9% față de cifra de afaceri raportată în anul anterior. Această creștere poate fi explicată prin diferiți indicatori cum sunt: rata de penetrare pe piață, accesibilitatea oferită de internet, indicatorii economici favorabili.

Mulți comercianți cu amănuntul și giganți online, cum este Amazon, aleg să investească în cercetare și dezvoltare (1.86 miliarde de dolari anual) pentru a crește și mai mult cifra lor de afaceri. În economia modernă, rezultatele activității de cercetare științifică și dezvoltare tehnologică stau la baza performanțelor marilor corporații și a agenților economici pe plan mondial, într-o proporție tot mai mare. Abilitatea de a folosi tehnologia și dezvolta produse inovative ce sunt integrate digital reprezintă varful de lance a uneo economii dezvoltate. Politicile de dezvoltare a multor state europene stimulează folosirea resurselor tehnologice și încurajează plasarea produselor digitale pe piața mondială. Pentru evaluarea nivelului de digitalizarea a economiei unui anumit stat se poate urmări valorile Indicelui DESI (Digital Economy and Society Index). Luând în calcul scorul general agregat de 33,21% România se află pe ultimul loc în Europa, media europeană fiind de 52,25%.

Comportamentul consumatorului se schimbă radical în mediul online, virtualizarea generată de răspandirea internetului provoacă clienții să aprecieze alte atribute ale produselor în procesul de cumpărare. În cadrul unui studiu realizat de valoria.ro (2018) sunt surprinse etapele pe care consumatorii le urmează în realizarea achizițiilor online și care sunt informațiile pe care aceștia le urmăresc pentru a finaliza vânzarea:

- Surse de informare – 84% dintre respondenți folosesc mediul online pentru a se informa în legătură cu produsele sau serviciile pe care doresc să le achiziționeze;
- Reclamele care influențează decizia – 56% dintre respondenți spun că reclamele care le influențează cel mai mult decizia de cumpărare sunt cele de pe website-uri;

- Loialitatea față de brand – 25% dintre respondenți spun că sunt loiali brandurilor și că numai o ofertă mult mai bună le-ar putea schimba opțiunea actuală;
- Decizia de cumpărare – 74% dintre respondenți spun că sunt influențați de informațiile despre produse/servicii prezentate în mediul online;
- Experiența de cumpărare – 72% dintre respondenți spun că o experiență de cumpărare mai bună este dată de o mai bună comunicare cu clientul;
- Servicii digitale suplimentare – mai mult de 45% dintre utilizatori sunt dispusi sa plateasca servicii ce le eficientizeaza munca.

Modele și practici ale comerțului electronic

Comerțul electronic poate fi definit ca utilizarea rețelelor de calculatoare și a internetului pentru a desfășura procese precum achiziția, vânzarea, transferul și schimbul de servicii, produse și informații (Rainer et al., 2011). Din 1994, comerțul electronic a crescut rapid, preconizându-se că până în anul 2050, întreg comerțul va fi sub formă de comerț electronic. Acesta a început cu introducerea EDI (Electronic Data Interchange) între companii și bancomate pentru servicii bancare. Introducere motoarelor de căutare web au deschis o nouă eră prin combinarea internetului deschis și facilitatea de a accesa interfețele website-urilor de către utilizatori. S-au evidențiat în decursul timpului *patru tipuri de magazine online (Dezhi Wu et. al 2003)*, pornind de la tehnologiile utilizate și tipul de produse sau servicii comercializate:

1. *Magazine online pe platforme de tip open source* ce folosesc licențe fără costuri de administrare (de exemplu Magento, Prestashop, Woocommerce). Aceste soluții sunt potrivite atât pentru magazinele online cu produse și plată integrată, cât și magazine online de servicii sau site-uri care nu necesită livrarea unui produs fizic sau digital, acestea din urmă folosind platforma pentru a îndruma clienții către locații fizice, vânzarea făcându-se offline.
2. *Magazine online licențiate și găzduite de proprietarul magazinului* (de exemplu Enterprise, Actinic, Shopify). Aceste soluții implică taxe continue pentru menținerea live a magazinului online și de cele mai multe ori sunt preferate de magazinele mari, cu mii sau zeci de mii de produse, a căror cost de rulare pot susține costurile de administrare a platformei.
3. *Soluții SaaS (Software as a service)*, se referă la platformele ce percep costuri de administrare în funcție de volumul produselor administrate (de exemplu Volusion, Shopify, Bigcommerce). Această soluție este dedicată magazinelor online mici spre medii, ce doresc implementarea unei infrastructuri utilizate la scară largă, dar de asemenea nu gestionează intern dezvoltarea tehnică a magazinului online, apelând astfel la o terță parte ce oferă structura predefinită, însă cu un grad scăzut de personalizare.
4. *PASS (platformă ca serviciu)*, de exemplu plata platformelor de vânzare de tip B2B cu API extinse, însă pentru care există taxe continue de administrare.

Site-urile de comerț electronic (e-Commerce), au crescut semnificativ de-a lungul anilor și au evoluat în sisteme complexe de tranzacționare de bunuri și servicii. În afara bunurilor și serviciilor materiale, exista și bunuri digitale ce pot fi tranzacționate, contextul virtual unde cererea întâlnește oferta produselor digitale purtând denumirea de piață electronică (*e-marketspace*).

La fenomenul e-Commerce pot participa atât persoanele fizice și cât și juridice, precum și statul sau instituțiile acestuia, existând diferite forme ale comerțului electronic în strânsă dependență cu relațiile dintre acești participanți.

Comunicare de marketing în comerțul electronic și rețelele sociale

E-marketingul concentrează adaptarea și dezvoltarea tuturor strategiilor clasice de marketing în transpunerea lor în spațiul virtual web și în rețelele sociale prin raportarea la noile tendințe comportamentale ale utilizatorilor. Analiza comportamentului cumpărătorului a determinat dezvoltarea de noi metode privind identificarea nevoilor și tendințelor, cunoașterea "călătoriei de decizie a consumatorului" și întărirea angajamentului permanent față de client în vederea determinării consumatorului în a lua decizia de cumpărare (Gerrikagoitia, Castandera, Rebóna & Sorzabala, 2015).

Marketingul pe dispozitivele mobile este un aspect din ce în ce mai important al strategiei de promovare a unei companii. Timpul petrecut de utilizatori pe dispozitivele mobile este în continuă creștere, importanța acestui aspect fiind susținută și de generarea vânzărilor pe acest canal, determinate direct și indirect prin diverse strategii de marketing aplicate. Eficacitatea mobile-marketingului necesită îmbunătățiri pe baza analizării unor criterii precum abandonarea coșului de cumpărături, rata de respingere, dimensiunea medie a comenzii și rata de tip *add-to-cart* (adaugă în coș). Strategiile pe care trebuie să se bazeze marketingul pe dispozitive mobile au la bază trei avantaje majore: (1) dispozitivele mobile sunt întotdeauna conectate la internet și în posesia permanentă a consumatorului; (2) posibilitatea de a ține campanii și oferte determinate de locație; și (3) posibilitatea transmiterii de mesaje și oferte relevante și personalizate.

Firmele trebuie să aibă în vedere, de asemenea, dezvoltarea și implementarea unor strategii eficiente de marketing mobil bazate pe optimizarea designului website-ului și adaptarea lui pentru dispozitivele mobile și tablete. Pentru a facilita procesul de cumpărare, este esențial accesul la rețelele sociale prin intermediul e-commerce-ului și, implicit, la interacțiunea cu alți cumpărători și experiența acestora ce duce la creșterea ratei de prezență online și implicarea clienților și dezvoltarea de soluții de fidelizare mobile eficiente. (Berman, 2016). Rețelele sociale au devenit principalul mod de operare al mișcărilor sociale ce au obiective comune în secolul XXI. Bazându-se pe structura internetului și Web 2.0 ca tehnologie avansată, aplicațiile pe rețelele sociale au facilitat o creștere fără precedent în interacțiunea umană și stau la baza afacerilor și a comerțului electronic.

Importanța brandului comercial în rețelele sociale este factorul principal care determină decizia consumatorului, iar cercetătorii pot beneficia de conținutul regăsit în rețelele sociale. Companiile se pot baza pe clienți care doresc să-și aducă aportul la procesul de creație, contribuind cu noi idei, gânduri și cunoștințe la dezvoltarea valorii adăugate pentru noi produse (Füller, J et. al, 2006; Nambisan, S. 2002). Prin urmare, companiile trebuie să găsească o modalitate de a se asigura că acești

consumatori sunt pregătiți și motivați să contribuie la activități de creație comună în lumea digitală pentru a oferi ajutor în mod eficient în cadrul procesului de creație de valoare.

Rețelele sociale permit companiilor să interacționeze și să facă afaceri cu clienții la un nivel personal pentru a consolida imaginea companiei, în opoziție cu principiul spionajului (Mangold și Faulds, 2009). Site-urile de tip rețele sociale își fac mărcile accesibile pentru a câștiga reputație sub forma unor reacții rapide din partea consumatorului, a marketingului eficient, a clienților implicați și a tiparului în funcție de care aceștia revin (Park et al., 2019), îmbunătățind astfel marca și reputația. Experiența mărcii și calitatea serviciilor, precum și influența acestora asupra implicării clientului sunt studiate de către Prentice et al. (2018), folosind modele conceptuale existente. Prin urmare, rețelele sociale devin centrul comerțului digital inteligent, iar specialiștii încep să înțeleagă comportamentul consumatorului în ceea ce privește achizițiile, obținând o perspectivă vis-a-vis de preferințele acestuia pentru anumite mărci (Rockendorf, 2011). Aceste oportunități permit specialistului în marketing să comunice cu consumatorul, să șlefuiască mesajul comercial și să mențină prezența mărcii pe piețele online (Evans and McKee, 2010).

Rețelele sociale constituie o pârghie pentru numeroase mărci, iar companiile au început să interacționeze cu clienții prin intermediul lor. În ton cu explozia popularității unei mărci și a creșterii sale prin canalele rețelelor sociale, rolul analizării și cercetării comportamentului concurenței pe rețelele de socializare a devenit crucial. Folosind aceste comportamente, o marcă poate investiga și optimiza strategiile competitive, pentru a crește audiența, și implicit numărul clienților, dar și pentru a crește profitul. Monitorizarea și analiza comportamentului concurenței în rețelele sociale este cea mai nouă metodă de stabilire a prețurilor competitive și totodată un mod eficient de a înțelege concurența.

Numeroși cercetători au lucrat în această direcție pentru a obține date relevante din surse web precum site-urile de rețele sociale Facebook, Instagram, Twitter, Youtube. Pentru a da roade, acestor resurse web li s-au aplicat numeroase tehnici din știința computerelor, metodologii, abordări și algoritmi precum Extragerea Datelor, Prelucrarea limbajului natural, Tehnici de învățare automată (ML) și multe altele. În general, companiile de renume nu sunt familiarizate cu modul de recuperare și extragere a datelor din rețelele sociale sau cu modalitățile de efectuare a analizelor în ceea ce privește aceste date. Tot sub semnul întrebării stă și tipul de tehnici utile în distribuirea anumitor date privitoare la afaceri. Viul grai este un instrument puternic în influențarea oamenilor, fiind capabil să le influențeze, de asemenea, și comportamentul privitor la achizițiile făcute. Acest fapt poate fi dovedit, conform lui Richins (Richins și Root-Shaffer, 1998), care susține că viul grai s-a dovedit a juca un rol esențial în deciziile clienților cu privire la achiziții. Conform lui Hennig-Thurau (2004), *Word of mouth* (e-WOM) este definit ca: „orice declarație, pozitivă sau negativă, făcută de către un client potențial, actual sau trecut, în legătură cu un anumit produs sau companie, declarație accesibilă unui eșantion de persoane și instituții prin intermediul internetului”. Consumatorii utilizează tot mai frecvent internetul și rețele sociale precum Facebook, Twitter și Instagram pentru a fi conectați cu prietenii, însă Cheung et al. (2008), ilustrează cum din ce în ce mai mulți dintre acești utilizatori folosesc unelte ale internetului precum forumurile de discuții online, site-urile de recenzii și blogurile, pentru a face schimb de informații cu privire la produsele folosite. În mediul online, viul grai poate oferi consumatorilor atât posibilitatea de a citi opiniile altor consumatori cu privire la experiența acestora

legată de anumite produse sau servicii, cât și de a-și scrie propria părere despre produsele sau serviciile respective.

Rețelele sociale ajută companiilor cu mărci (branduri) puternice să păstreze legătura cu fanii și admiratorii. Credibilitatea formatorilor de opinie din mediul online este de asemenea pusă sub semnul întrebării de către cercetători în noile condiții. În ceea ce privește credibilitatea și efectul interacțiunii para-sociale a formatorilor de opinie asupra ratei de conversie, *influencerii* au o contribuție directă (Sokolova și Kefi, 2019). Afacerile industriale folosesc rețelele sociale ca pe o oportunitate a oricărei perspective de afacere precum: cumpărarea, conștientizarea, analizarea, conversia, loialitatea și utilitatea (Anderson et al., 2011). Odată cu creșterea concurenței prin intermediul rețelelor sociale, un aspect nou, adăugat relativ recent în scenariul afacerilor, este acela de a lua decizii cu privire la extragerea, analizarea și adaptarea factorilor critici pentru succes din conținutul publicat pe rețelele de socializare.

În timp ce intenția de cumpărare se raportează la raționamentul subiectiv al cumpărătorului, care se reflectă după evaluarea generală de a cumpăra produse sau servicii (Hsu, 1987), există câteva interpretări în acest sens, cum ar fi: (1) consimțământul consumatorului de a lua în considerare achiziția, (2) intenția de achiziție în viitor, (3) decizia de a cumpăra din nou. În afară de asta, intenția de cumpărare se raportează la gradele de convingere perceptuală ale clientului de a cumpăra un anumit produs (sau serviciu).

Clientul joacă un rol central în procesul de creare a unor noi valori pentru companie și principalele părți interesate (Hoyer et al., 2010). Internetul, ca un valoros mediu de comunicare, facilitează în primul rând creația comună datorită funcției sale de platformă interactivă care face posibilă resurselor interne și externe din toată lumea să se interconecteze și să colaboreze, contribuind la procesul de creație al valorii unei organizații (Lee, Olson, și Trimi, 2012). „Rețelele de socializare online se referă la activitățile de socializare care au loc în mediul online când utilizatorii internetului se grupează pentru a forma legături online” a afirmat Razzaque în studiul său. Apariția acestor comunități virtuale oferă o multitudine de platforme pentru consumatorii online, unde aceștia pot împărtăși sau face schimb de idei, viziuni sau informații privitoare la produse/servicii. Acest fapt conferă oportunități enorme pentru comercianții cu amănuntul, mai ales pentru cei care își desfășoară activitatea online.

Un exemplu ideal de implicare a clienților în activitățile de dezvoltare a produselor și serviciilor folosite, a fost lansat de compania americană globală de cafea Starbucks, care a întemeiat platforma online MyStarbucksIdea.com, unde clienții își pot împărtăși ideile cu privire la produse, dar și propriile experiențe, participând la discuții deschise despre ideile propuse și votându-le. O dată cu viziunea de „a construi experiența Starbucks cu ei și ei sunt deja acolo” în loc de „a o construi și ei vor veni” compania Starbucks a găsit o modalitate de a-și păstra clienții loiali și de a reduce riscul în campaniile de lansare a noilor produse sau servicii (Ramaswamy, V. 2009).

Recomandările și părerile prompte ale clienților pot fi monitorizate îndeaproape, iar rolul participării online ar trebui văzut ca esențial în sprijinirea specialiștilor în marketingul online pentru a-și proiecta strategiile de marketing, astfel încât acestea să atingă o cotă de piață mai ridicată. Mutarea proceselor și tranzacțiilor de business în mediul virtual implică de cele mai multe ori și un transfer al

fluxurilor informaţionale și interacţiunilor cu clientul, astfel prin digitalizarea textului, transformarea aspectelor vizuale sau auditive sunt convertite într-o formă care să poată fi înţeleasă și procesată într-o manieră cursivă prin intermediul unui calculator (Schaupp, et al. 2017). Noua epocă digitală prezintă avantaje uriașe, însă și numeroase riscuri, de aceea este recomandat atât clienţilor cât și companiilor să se informeze temeinic atunci când decid să își desfășoare activitatea în mediul online. (Davis, Brodersen, Böhmer & Siemens, 2017).

Crearea de valoare prin intermediul platformelor e-commerce

Pentru a înţelege valoarea creată de platformele e-Commerce, este important să definim dimensiunile de evaluare a calităţii din perspectiva clientului. Următoarele caracteristici conferă credibilitate și influenţează decizia de cumpărare în comerţul electronic:

1. Serviciul de asistență pentru clienți (Customer support);
2. Fiabilitatea soluției software;
3. Diversitatea gamei de produse;
4. Siguranța datelor;
5. Ușurința de interacțiune (usability);
6. Transparența procesului de cumpărare și livrare;
7. Strategia de preț.

Valoarea percepută de client își are rădăcinile în teoria tratamentului echitabil (equity), care validează opinia consumatorului asupra raportului cost-beneficiu cu cel oferit de furnizor de produse sau servicii (Oliver și DeSarbo 1988). Equity se referă la evaluarea de către clienți a ceea ce este „corect” sau „meritat” (beneficiu) pentru costul perceput al ofertei (Bolton și Lemon 1999). Costurile percepute includ plăți, date colectate și alte sacrificii, cum ar fi consumul de timp și stresul consumatorului. Rezultatele teoriei equity sunt comparate cu sacrificiile și recompensele primite de cealaltă parte la un schimb. În acest sens, valoarea percepută de client rezultă dintr-o evaluare globală a recompenselor și sacrificiilor asociate serviciului. În comerţul online, unde decizia de schimbare a furnizorului de produse sau servicii este la un click distanta și implica eforturi minime, este important ca viziunea managerială să-și îmbunătățească capacitatea adaptativă, generată de Big Data pentru crearea de valoare (Liao et al., 2015). Häubl și Trifts (2000) au constatat că preferințele consumatorilor și disponibilitatea de a plăti (willingness to pay - WTP) pentru produse poate fi influențată de valorile afișate în recomandările personalizate și sugerează că comportamentele consumatorilor sunt vulnerabile față de agenții de recomandare. Acest flux nașterea unor oportunități de cercetare pentru înţelegerea efectelor comportamentale ale caracteristicilor detaliate ale recomandărilor de produse online. Cu toate acestea, cercetările anterioare s-au concentrat în principal asupra modului în care caracteristicile sistemului de recomandare influențează alegerea produselor (Ho et al. 2011; Oestreicher-Singer și Sundararajan 2012a).

Mediul de business online oferă exemple de creare a valorii prin intermediul locației (transportul anticipativ, folosit de companii precum Amazon) și de promovare (de exemplu, utilizarea datelor geo-locație pentru a trimite mesaje specifice) însă, de asemenea și prețul produsului poate beneficia în urma tehnologiei Big Data. Fie ca este evidentiat prin prețul din cei 4P sau ASK (întreabă) din cei 5a a lui Kotler (2017), în mediul online prețul poate fi monitorizat și comparat foarte ușor. Valorile

dinamice de preţ permit unei organizaţii să implementeze o strategie flexibilă de stabilire a costurilor produselor bazate pe schimbarea cererii consumatorilor. Liga de baseball american a adoptat frecvent preţuri dinamice bazate pe Big Data pentru a îmbunătăţi gestionarea veniturilor (Chen, 2012). Pentru a stabili frecvent preţurile în timpul unui sezon, în anumite cazuri au fost integrate multiple variabile şi surse de informaţii. În plus, faţă de poziţionare şi calendarul vânzărilor de bilete, se utilizează acum o varietate de alte dimensiuni, inclusiv vremea, echipele în plină ascensiune, potenţialul pentru un eveniment de stabilire a înregistrărilor video, cantitatea de discuţii despre un joc în mediile sociale. Acum, prin utilizarea Big Data, organizaţia care lansează produsul îşi poate gestiona preţurile pentru a capta disponibilitatea fanilor de a plăti mai mult pentru un joc special. Dacă dinamica companiei nu include o strategie de preţ coerentă, clientul va exploata acest lucru în beneficiu propriu sau pur şi simplu schimbând furnizorul.

În comunicarea de marketing în mediul digital este esenţială gestionarea eficientă a recenziilor clienţilor, fie că sunt targetate către produse care sunt comercializate pe platformele de comerţ electronic, fie vizează servicii sau brandul direct. Văzute ca o formă a eWOM (electronic word of mouth) de Pelsmacker, Tilburg şi Holthof (2018), recenziile online pot lua multe forme, cea mai întâlnită fiind recenzia de produse. eWOM are un efect profund asupra atitudinilor şi comportamentului de cumpărare al consumatorilor şi asupra rezultatelor comerciale în multe categorii de produse, cum ar fi cărţi (Chevalier şi Mayzlin, 2006), filme (Duan et al., 2008), jocuri online (Zhu şi Zhang, 2010) şi restaurante (Kim et al., 2016). Pentru că nevoile în aceste industrii sunt diferite, au fost diferenţiate o serie de practici specifice clienţilor care folosesc aceste platforme. Pentru platformele e-Commerce cu livrare de produse, există opţiunea solicitării recenziei pentru anumite produse doar după ce produsul a fost achiziţionat. În cazul anumitor platforme, livrarea nu este făcută de firma care gestionează platforma, astfel că sunt solicitate fotografiile sau clipuri video cu produsul pentru a întări reputaţia comerciantului. Potenţialul recenziilor este corelat cu un anumit grad de maturitate al platformei online, care este de cele mai multe ori asigurat de o masă critică de clienţi.

Micro-momentele (momentele decizionale) au loc atunci când oamenii apelează instinctiv la un dispozitiv din nevoia de a-şi extinde câmpul de cunoaştere, pentru a face, a descoperi, a viziona sau pentru a cumpăra ceva. Acestea sunt momente extrem de valoroase pentru că valorifică intenţia de cumpărare, ţin cont de preferinţele clientului şi deciziile luate anterior. În aceste momente, aşteptările consumatorului sunt mai ridicate ca oricând, iar existenţa unui algoritm bine gândit, care poate satisface nevoia consumatorului de a afla noi informaţii privitoare la achiziţiile necesare printr-o discuţie, este imperativă. Acest tip de tehnologii disponibile chiar în buzunarele noastre ne-au obişnuit să presupunem că firmele ne pot oferi ceea ce căutăm exact atunci când căutăm. Vrem lucruri bune şi le vrem numaidecât, interpretând AI ca Atenţie şi Interes, ceea ce este plauzibil din moment ce trebuie să ne deplasăm atenţia de pe utilizator pe experienţa personală.

CAPITOLUL 2. Analiza sistematică a literaturii de specialitate în comerţul electronic şi algoritmi de învăţare automată

Recenzia literaturii de specialitate

Scopul acestui studiu este de a prezenta o recenzie a literaturii de specialitate referitoare la aplicabilitatea algoritmilor de inteligenţă artificială în comerţul electronic. Pentru a realiza acest lucru, au fost analizate 140 articole academice indexate în bazele de date Science Direct şi Google Scholar relevante acestui subiect, sintetizate sistematic şi folosind metodologia Recenzia Structurată a Literaturii (SLR). Atenţia sporită acordată de cercetători din domeniul comerţului electronic dovedeşte conştientizarea importanţei transformării digitale şi a impactul asupra dezvoltării durabile, totodată este vizibilă dorinţa continuă de a identifica noi metode de optimizare a proceselor folosind algoritmi de inteligenţă artificială. Aceste două paradigme emergente, e-Commerce-ul şi inteligenţa artificială, pot avea un impact asupra standardelor sociale de interacţiune între consumatori şi comercianţi, dar şi a politicilor publice care guvernează şi reglementează cadrul legal în care aceşti actori activează.

Creşterea rapidă a comerţului electronic a stimulat aplicaţiile de extragere şi înţelegere a datelor generate de tranzacţiile financiare ale clienţilor. În prezent, exploatarea datelor financiare a fost unul dintre cele mai importante subiecte de cercetare din comunitatea de valorificare a datelor, ceea ce a rezultat într-un volum de muncă considerabil pentru comunitatea academică.

Progresele în dezvoltarea învăţării profunde structurate (deep learning) şi inovarea accelerată în materie de recunoaştere digitală a imaginilor (computer vision), au potenţialul de a oferi managerilor şi oamenilor de marketing capacitatea de a îmbunătăţi performanţa campaniilor de comerţ electronic şi marketing digital. În practică, însă, aplicarea învăţării profunde (deep learning) şi a recunoaşterii digitale a imaginilor (computer vision) ca un subset al inteligenţei artificiale, a fost limitată datorită unor provocări tehnice (de exemplu, acurateţe şi fiabilitate) pentru a fi folosite în procesul de decizie managerială. Aceste provocări sunt un produs al naturii dinamice şi complexe a marketingului şi a dificultăţilor asociate cu achiziţionarea de date privind comportamentul consumatorilor. Înainte de a lua orice decizie de afaceri, inteligenţa în afaceri (Business Intelligence) este un instrument necesar şi esenţial pentru managerii de marketing. Business Intelligence (BI) este un set de tehnici pentru analiza datelor mari (Big Data) şi prezentarea informaţiilor într-o manieră acţionabilă managementului.

Diversitatea solicitată de consumatori în mediul online şi nivelul accelerat al utilizatorilor de internet forţează marile corporaţii să ofere soluţii hardware viabile pentru a stoca şi gestiona fiabil BD. Învăţarea automată asigură creşterea puterii de gestionare şi, totodată, înţelegerea posibilelor tipare de diferenţiere bazate pe atribute specifice din date, diferenţe culturale şi comportamente ale consumatorilor. În ultimii ani, au fost obţinute rezultate remarcabile în managementul relaţiilor cu clienţii odată cu dezvoltarea algoritmilor care permit comunicarea mai eficientă cu clienţii. Aceste realizări sunt integrate tehnicilor de învăţare automată pe vizualizare computerizată (computer

vision) care să facă față nevoilor consumatorilor și care permit companiilor să obțină un avantaj competitiv.

Marketerul modern are acces la un spectru divers de instrumente digitale, care îi permite să înțeleagă mai bine tendințele de marketing și să obțină informații specifice despre cum poate îmbunătăți noi produse. Cu toate acestea, în comparație cu datele obținute din sondajele de marketing pentru clienți, BD obținute din minarea comportamentului consumatorilor în mediul online prezintă caracteristici contrastante. De exemplu, un volum mare de opinii online este afișat pe site-urile de comerț electronic, cum ar fi Amazon.com sau Emag.ro, fără un înțeles agregat specific. În aceste site-uri web, clienții sunt încurajați să-și împărtășească opiniile cu privire la produsele cumpărate anterior doar pentru o validare umană și indexarea conținutului în motoarele de căutare. Platformele de comerț electronic nu sunt singurele locuri unde se pot observa preferințele consumatorilor, date se regăsesc și pe site-urile de rețele sociale precum Twitter.com, pe site-urile de recenzie precum tripadvisor.com, pe site-urile media cum ar fi Cnet.com. În timp ce atenția cercetătorilor a fost focalizată pe utilizarea învățării profunde (deep learning) și a vizualizării computerizate (computer vision) pentru a monitoriza comportamentul consumatorilor în magazinele fizice, există un ocean de date disponibile, deoarece conținutul de tip text online poate fi transformat în inteligență acționabilă de către specialiști în marketing. În plus, deoarece instrumentele și dispozitivele noi permit clienților să creeze conținut mai versatil sub formă de imagini, text, audio și video, opțiunile de cercetare cresc și mai mult, atâta timp cât există instrumente adecvate pentru interpretarea tuturor acestor informații.

În domeniul informaticii, învățarea automată (machine learning), care este un subset al inteligenței artificiale (MI Jordan și TM Mitchell, 2015), a fost aplicată pe scară largă în domenii precum procesarea limbajului natural (NLP) (Guimaraes et al. 2018), recunoașterea vorbirii (S. Agarwalla și KK Sarma, 2016) și vizualizare computerizată. Abordările convenționale de învățare automată sunt limitate în capacitatea lor de a prelucra date sub forma lor brută (Y. LeCun et al., 2015). Incapacitatea de a prelucra datele se datorează faptului că este necesară o cantitate considerabilă de cunoștințe în programare și domenii pentru proiectarea unui extractor de caracteristici (Y. LeCun et al., 2015). Însă, în 2018, în cadrul unui proiect finanțat de Amazon, XL Dong et al. a reușit să creeze un nomenclator ce extrage automat și indexează produse și atribute specifice ale acestora.

Învățarea profundă (deep learning) este o metodă de reprezentare care poate fi folosită pentru a extrage automat caracteristici sofisticate la niveluri ridicate de abstractizare. Această metodă poate învăța, de asemenea, din date cu mai multe niveluri de reprezentări end-to-end (Y. LeCun et al., 2015). Prin combinarea metodelor de învățare profundă (rețele neuronale) cu vizualizare computerizată, elemente specifice sau produse din imagini pot fi extrase și utilizate pentru decizii manageriale sau strategii de marketing. Un tip particular de metodă de învățare profundă care a fost utilizat pe scară largă este CNN (Convolutional Neural Network), care a reușit să depășească în materie de precizie alte rețele neuronale pentru clasificarea imaginilor (A. Krizhevsky, 2018), detectarea obiectelor și segmentarea acestora. Învățarea profundă a permis dezvoltarea aplicațiilor bazate pe vizualizare computerizată, de exemplu, în cazul vehiculelor autonome și în diagnosticarea automată de cancer de sân sau de piele (P. Mehta și B. Shah, 2016).

Metoda de cercetare

Motivația utilizării metodei de cercetare structurată a literaturii de specialitate pleacă de la Tranfield et al. (2003) și este fundamentată de înțelegerea în profunzime a algoritmilor de învățare automată și utilizarea lor în comerțul electronic. Îndrumările specifice ale metodei de cercetare cu dovezi completează obiectivele studiului cu un set concis de pași și procedură riguroasă pentru efectuarea, raportarea și diseminarea acestei analize a literaturii. O revizuire sistematică a literaturii ajută la reducerea prejudecăților nefondate în selectarea studiilor de revizuit și în furnizarea unui traseu de audit al deciziilor, procedurilor și concluziilor recenzorilor pentru a produce o cercetare transparentă și reproductibilă. Tranfield et al. (2003) a studiat metode adaptate din domeniul științei medicale, având o abordare mai omogenă față de „știința normală”, cum ar fi studiile sale de control aleatoriu dublu-orb pentru testarea intervențiilor. Tranfield et al. (2003) a modificat instrumentele pentru a se potrivi cu realitățile unei științe sociale orientate practic. Drept urmare, metodologia lor de revizuire încorporează literatură calitativă în setul de date și sprijină meta-sinteza calitativă, precum și meta-analiza cantitativă. Scopul acestor instrumente noi rezidă în înlocuirea obiectivelor superioare bazate pe dovezi ale științei cu politici și ghiduri de practică informate.

Obiectivele și ipotezele cercetării

Obiectivul acestui capitol constau în așezarea cunoștințelor privind comerțul digital pe un model structurat, dar și explorarea unor componente adiționale (module) sau soluții aplicate în E-commerce ce au la bază algoritmi de inteligență artificială. Acest mecanism investigativ al literaturii de specialitate și al rezultatelor, ajută pe deoparte la identificarea viitoarelor oportunități de cercetare și afaceri, dar și la identificarea limitelor industriei.

Definirea întrebărilor de cercetare este o parte esențială a unei analize sistematice, deoarece acestea conduc întreaga metodologie de evaluare. Pentru a atinge obiectivele acestei recenzii, am identificat următoarele întrebări de cercetare:

1. În ce componente ale comerțului electronic și marketing digital se folosește inteligența artificială?
2. Care sunt procesele de marketing folosite în e-commerce ce pot fi automatizate folosind Machine learning?
3. Ce funcții e-commerce nu au fost analizate în literatura de specialitate pentru a fi automatizate folosind algoritmi de inteligență artificială?

Ținând cont de dinamica celor două domenii de interes din această cercetare, e-commerce și Machine learning, este important de menționat că analiza a fost efectuată în intervalul Aprilie-Iulie 2020.

Protocolul de căutare utilizat

Au fost identificate articole academice și științifice din jurnale, indexate în bazele de date Science Direct și Google Scholar. Aceste baze de date deschise sunt referințe pentru comunitatea academică și pot fi utilizate ca instrumente în evaluarea performanței academice a anumitor state sau universități.

Criteriile de selecție folosite pentru identificarea articolelor au fost bazate pe cuvinte cheie cum ar fi: „machine learning e-commerce”, „machine learning marketing digital”, „artificial intelligence in marketing”, „artificial intelligence in e-commerce”, „artificial intelligence in digital commerce” sau denumiri de algoritmi de inteligență + “e-commerce” sau “digital commerce”. La aceste criterii de căutare au fost incluse alte articole considerate relevante, identificate în lista de referințe ale articolelor din baza de date. Până la momentul redactării tezei, Iulie 2020, au fost identificate 257 articole și recenzii publicate în jurnale academice. Este important de menționat că 12 articole identificate au fost publicate în jurnale în limba română. Au fost excluse din baza de date articole ale căror titlu sau abstract nu erau relevante sau nu aveau o legătură directă cu tematica cercetării. Astfel, versiunea finală a bazei de date conține 140 de articole și include: titlu, jurnal, data publicării, cuvinte cheie, scor subiectiv de relevanță și adresa către versiunea pdf a articolului.

Datorită domeniului extrem de divers, pentru a menține o direcție de cercetare centrată pe aplicabilitatea în marketing, au fost stabilite următoarele dimensiuni de analiză în comerțul electronic:

- Catalog de produse ale aplicațiilor de e-commerce;
- Coșuri de cumpărături;
- Modalități de plată și finalizare a tranzacțiilor;
- Managementul și procesarea comenzilor;
- Elemente legate de logistică și livrare a produselor;
- Optimizarea procesului de vânzare folosind sisteme CRM;
- Strategii de outreach (promovare) e-commerce în digital marketing:
 - Social media;
 - Optimizare pentru motoare de căutare;
 - Email marketing;
 - Marketing direct folosind date colectate în platformele de comerț digital;
 - Strategii de inbound marketing;
- Procese sau funcții ce asigură siguranța tranzacțiilor și securitatea datelor în comerțul online;

- Comerț pe dispozitive mobile;
- Poziționare de produs;
- Strategii de dezvoltare de produs folosind externalizare de proces către public (crowdsourcing).

Extragerea și sintetizarea datelor

În această etapă, a fost conceput un formular de extragere a datelor pentru a înregistra cu exactitate toate informațiile. Acest proces a fost realizat prin parcurgerea cu atenție a fiecărui articol și extragerea datelor asociate cu ajutorul Google Sheets/Excel, QDA Miner lite și Mendely. Am adaptat verticale stabilite în capitolul "Protocolul de căutare utilizat" la cadrul de cercetare propus de Liang și Turban (2011). Cadrul a fost introdus pentru a integra mai multe elemente în cercetarea comerțului electronic și cuprinde șase elemente cheie: tema de cercetare, teorii, metode de cercetare, activități comerciale, activități de marketing și obiective de rezultat. Cu toate acestea, în această revizuire, pentru extragerea datelor au fost luate în considerare mai multe dimensiuni structurate pe următoarele coloane: referința studiului, autorii, titlul studiului, anul publicării, jurnalul în care a fost publicat, tema cercetării, subiectul abordat, algoritmul de inteligență artificială folosit, domeniul de impact (ex. finanțe, marketing, management), verticala în comerțul electronic și țara primului autor. Aceste articole au fost selectate în conformitate cu obiective și întrebările de cercetare ale acestei revizuirii.

Descrierea fiecărui articol este prezentată în tabelul 3.

Nr.	Date extrase	Descriere
1.	Year	Anul în care articolul a fost publicat
2.	Journal	Jurnalul în care articolul a fost publicat
3.	Reftype	Tipul elementului, ex. Articol academic, carte
4.	Title	Titlul articolului
5.	DOI/URL	Numărul DOI și URL-ul către pagina web a articolului
6.	Machine learning algorithm	Algoritmul folosit în cercetare: ex. Convolutional Neural Network (CNN), Reinforcement Learning, Naïve Bayes (NB), Decision Tree (DT), Support Vector Machines (SVM), Logistic Regression Algorithm, KNN
7.	Technical domain of interest	Domeniul tehnic de aplicabilitate: NLP (Natural Language Processing), computer vision, generic computer science

8.	Domain applicability	Domeniu de interes: Marketing, Management, Business, Economics, Finance, Social sciences
9.	e-commerce vertical	Verticala comerț digital: Digital Marketing, Social Media, product catalog, Shopping cart, Payment, CRM
10.	First author country	Țara primului autor: țara unde autorul a fost angajat la momentul publicării

Tabel 3. Dimensiuni studiate în articolele analizei sistematice

Folosind acest cadru analitic, a fost efectuată codificarea datelor pentru identificarea algoritmilor vizați și domeniul lor de aplicabilitate în e-commerce și marketing digital. Mai mult, au fost documentate și încadrate pentru fiecare algoritm cate un studiu de caz relevant, descrierea utilității, datele de input, rezultatele și posibile avantaje sau dezavantaje.

În lucrarea de cercetare, un rol aparte îl deține limbajul tehnic, specific industriei vizate, care a necesitat traduceri specializate și precizarea definițiilor utilizate, pentru păstrarea sensului indicat de autor și asigurarea integrității informației, în concordanță cu normele și convențiile general acceptate. Terminologia specifică Marketingului și a tehnologiilor informaționale emergente este dominată de termeni în limba engleza, traduși în limba română adeseori cu un conținut tehnic sărac, fiind caracterizată de pragmatism, structuri și expresii impersonale, având la baza trăsături stilistice precum claritate, precizie, simplitate și concizie. În tabelul Abrevieri și Terminologie anexat au fost centralizate abrevierile utilizate precum și traducerile termenilor specializați, în varianta lor originală din limba engleză și română (acolo unde exista traduceri introduse în uz). Din motive practice și pentru a evita posibile confuzii, au fost utilizate strict abrevierile din versiunea în engleza a termenilor de specialitate.

Rețele Neuronale și Învățare Profundă

Rețelele neuronale (Neural Network) au fost dezvoltate pentru a simula sistemul nervos uman pentru sarcini de învățare automată prin tratarea unităților de calcul într-un model de învățare într-un mod similar cu neuronii umani. Rețelele neuronale și învățarea profundă (Deep Learning) oferă în prezent cele mai bune soluții pentru multe probleme în recunoașterea imaginii, recunoașterea vorbirii și procesarea limbajului natural. De aici pleacă și viziunea rețelelor neuronale de a crea inteligență artificială prin construirea de instrumente a căror arhitectură simulează calculele din sistemul nervos uman. În mod evident, aceasta nu este o sarcină simplă, puterea de calcul a celui mai rapid computer de astăzi este o fracțiune minusculă din puterea de calcul a creierului uman.

Rețelele neuronale au fost dezvoltate la scurt timp după apariția calculatoarelor, în anii cincizeci și șazeci. Primul element fundamental în dezvoltarea rețelelor neuronale a fost algoritmul perceptronului descris pentru prima oară de Rosenblatt, în 1958, în cadrul laboratorului Cornell, acest principiu a creat mult entuziasm în ce privește perspectivele inteligenței artificiale. Cu toate acestea,

după euforia inițială, a existat o perioadă de dezamăgire în care natura flămândă de date și puterea de calcul limitată, rețelelor neuronale au fost văzute ca un vis infantil greu de realizat.

Rețelele neuronale au posibilitatea să învețe orice funcție matematică dacă sunt furnizate suficiente date de instruire, iar unele variante precum rețelele neuronale recurente (recurrent neural network) sunt folosite și pentru predicții sau identificare de anomalii în serii temporale. Punctul sensibil al acestei metode este legat de cantitatea de date necesare pentru a învăța chiar și sarcini simple, aceasta fiind adesea extraordinar de mare, ceea ce provoacă o creștere corespunzătoare a timpului de antrenare (dacă presupunem că sunt disponibile suficiente date de instruire).

Aplicabilitatea rețelelor neuronale în comerțul electronic poate viza o serie de activități care să ajute managementul sau personalul implicat în automatizarea unor procese ce necesită un volum de muncă intens. Pe de altă parte, ținând cont că tot acest efort este direcționat în înțelegerea comportamentului clientului final și a prezentării unui conținut relevant astfel încât să fie convins să cumpere, poate rezulta o mașină complexă de interacțiune cu clienții. Utilizatorii pot fi copleșiți de numărul de articole disponibile pentru a alege dintre site-urile de comerț electronic de astăzi. Ajutarea clientului prin limitarea acestei selecții cu recomandări de produse personalizate poate, prin urmare, crește substanțial probabilitatea unei achiziții. Cu toate acestea, selectarea celor mai potrivite elemente este o sarcină dificilă. Feigl și Bogdan (2019) propun o arhitectură de rețea neuronală pentru a învăța preferințele în perechi și pentru a arăta similitudini între modelul nostru și un model de factorizare matricială, instruit cu criteriul de optimizare BPR (BPRMF) pentru comanda produselor e-commerce, bazate pe preferințele clientului.

Modelul propus este o rețea neuronală avansată modificată cu patru layer - L specifice: un layer utilizator L1 cu unități N , un layer ascuns L2 cu unități K , un nivel de element L3 cu produse M și un layer de clasificare L4 cu o unitate (Fig. 13). Prin urmare, nivelul de utilizator L1 are un număr egal de noduri cu numărul clienților, iar nivelul (layerul) L3 un unități echivalent cu numărul de produse din platforma. Parametrul K determină mărimea reprezentărilor utilizatorului și ale produselor.

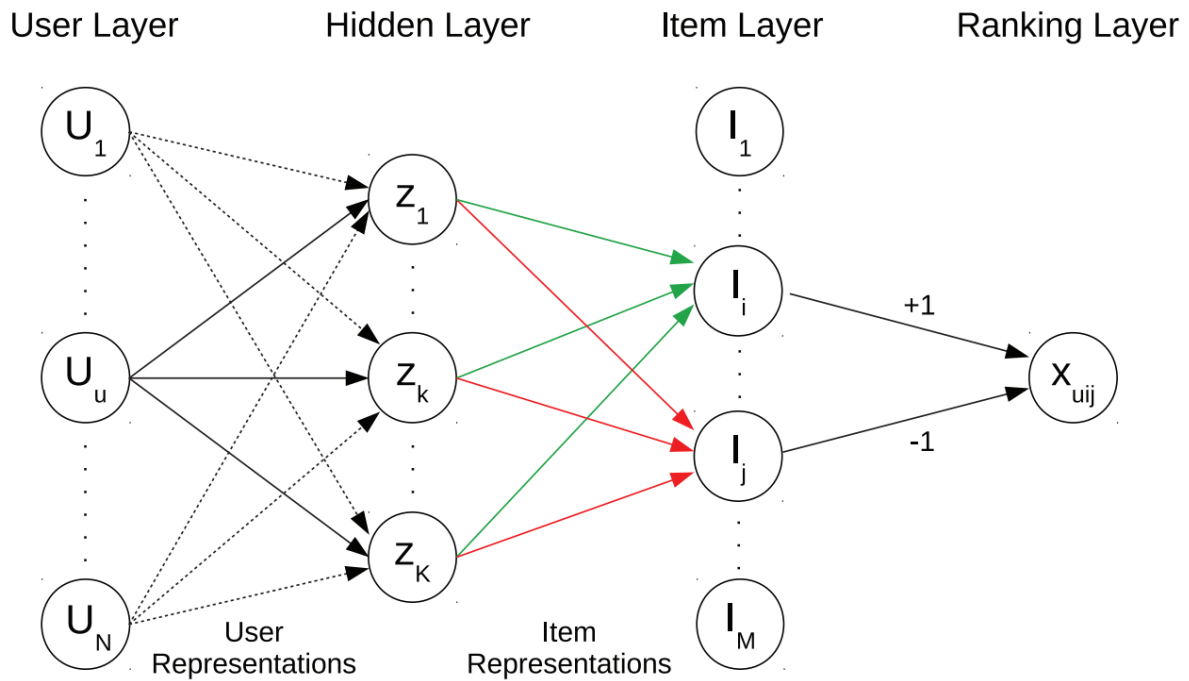


Figura 1. Arhitectura rețelei neuronale

Liniile solide care se conectează la stratul ascuns reprezintă ponderile utilizatorului u . Liniile verzi care se conectează la elementul superior reprezintă ponderile unității pozitive i . Unitatea de articol conectată inferioară reprezintă unitatea de articol negativ j . Sursa: Feigl și Bogdan (2019)

Ca nucleu al recomandării, filtrarea colaborativă (FC) estimează posibilitatea unor elemente de care utilizatorii ar putea să fie interesați pe baza interacțiunilor istorice ale utilizatorilor (de exemplu, cumpărături și clickuri). Y. Lv et al. (2017) propun o metodă de filtrare colaborativă bazată pe elemente pentru scenarii de recomandare Top-N, numită AICF, care integrează rețele neuronale. Argumentul cheie este că elementele istorice ale utilizatorilor contribuie diferit la reprezentarea preferințelor utilizatorilor. Atunci când estimăm preferințele utilizatorilor față de elementele noi, modelul propus acordă ponderi distincte diferitelor elemente interactive istorice pentru a măsura importanța acestora. Performanța sistemului produs de Y. Lv et al. (2017) îmbunătățește considerabil performanța recomandării de produse, aplicând modele individuale pentru fiecare client în parte.

Strategia de preț este una dintre deciziile cheie pe care o firmă trebuie să le ia în considerare pentru a supraviețui pe o piață tot mai competitivă. Stabilirea strategiei de preț și dinamicitatea acestora pot fi transformate în modelarea unei rețele neuronale bazată pe nivelurile (layerele) interacțiunii dintre o serie de factori diferiți, cum ar fi prețul produsului în diferite perioade, cererea produsului, prețurile practicate de concurenți. Shakya et al. (2012) propun un model pentru stabilirea prețurilor dinamic, bazat pe o rețea neuronală. Acest algoritm prezintă o abordare inedită, însă nu a fost testat într-un mediu e-Commerce efectiv, riscul asociat implementării fiind unul foarte ridicat.

Rețele Neuronale Convoluționale (CNN)

Rețelele neuronale convoluționale (CNN sau ConvNet) au luat naștere din dorința de a reface conexiunile biologice ale neuronilor, plecând de la tradiționalele rețele neuronale profunde. Eficiența acestor rețele fiind superioară algoritmilor de clasificare a imaginilor, aplicabilitatea acestor metode fiind extrem de vastă în analiza imaginilor și computer vision. Fiind o importantă ramură a rețelelor neuronale profunde, rețelele neuronale convoluționale profunde (Deep Convolutional Neural Networks - DCNN) au aplicabilitate într-o gamă variată de industrii. Observațiile empirice au condus la convingerea că funcția de convoluție permite DCNN-urilor să învețe eficient caracteristicile invariante de schimbare și, astfel, să își demonstreze capacitățile în procesarea vorbirii și a imaginilor.

Rețele neuronale convoluționale au la bază același principiu ca rețelele neuronale standard, însă pot fi gândite ca un fel de rețea neuronală care folosește multe copii identice ale aceluiași neuron. Acest lucru permite rețelei să aibă o mulțime de neuroni și să exprime modele computaționale diverse, păstrând numărul de parametri. CNN-urile s-a popularizat în mare parte datorită efortului lui Yann LeCun, acum director al AI Research pe Facebook. Acesta a venit cu ideea de a crea o rețea neuronală, folosind o funcție similară pe care o realizează creierul uman. Crearea zonelor de neuroni care pot detecta și interpreta zone de interes pentru algoritmul ce trebuie antrenat. De exemplu, în loc să alimenteze imagini întregi într-o rețea neuronală ca o grilă de numere, DCNN profită de ideea că un obiect este același, indiferent de locul în care apare în imagine. Deci, straturile ascunse devin straturi de convoluție care încearcă să identifice anumite obiecte sau elemente din imagine. Mai mult, datorită faptului că rețelele neuronale convoluționale au abilitatea să țină cont de invarianții reușesc să aibă o performanță ridicată pe date ce au date aberante (outlieri). Această clasă de rețele neuronale convoluționale ce au o arhitectură bazată pe greutăți comune și caracteristici invariante au fost denumite SIANN (Invariant Artificial Neural Networks). Astfel, acestea au aplicații de recunoaștere a imaginilor și a clipurilor video, sisteme de recomandare, clasificare a imaginilor, analize de imagini medicale, procesarea limbajului natural și serii de timp financiare.




Figura 2. Descrierea la nivel înalt a unei scheme de clasificare a imaginilor profunde, Torre, J., Puig, D., Valls, A. (2018)

Așa cum se arată în Fig. 14 pentru clarificarea imaginilor, mai multe rețele neuronale convoluționale sunt optimizate pentru a face o extracție a caracteristicilor. Aceste layere sunt urmate de unul sau mai multe straturi de clasificare. În stratul de ieșire, este foarte posibil să se folosească o funcție softmax care să reprezinte probabilitatea de ieșire a fiecărei clase de predicție. În mod normal, clasa alocată imaginii îi corespunde cea mai mare valoare de probabilitate.

Valoarea managerială pusă pe abilitatea de a estima vânzările depinde de acuratețea acesteia. Prognozele inexacte pot duce la reziduuri de marfă sau la supraevaluare, ceea ce ar afecta eficiența

deciziei în comerţul electronic. Tehnicile tradiţionale de estimare a vânzărilor se bazează pe analiza seriilor de timp, care nu ia decât datele istorice de vânzări ca input. Aceste metode pot fi aplicate cu succes mărfurilor cu tendinţe de vânzare stabile sau sezoniere. Cu toate acestea, mărfurile din comerţul electronic sunt mult mai neregulate în tendinţele lor de vânzare, iar estimările obţinute prin aceste metode tradiţionale sunt inacceptabile într-o piaţă tot mai competitivă (Beheshti-Kashi, 2019). Din fericire, o cantitate masivă de date este disponibilă în comerţul electronic şi este posibilă exploatarea acestor date pentru a îmbunătăţi precizia estimărilor.

Zhao şi Wang (2017) propun o abordare inedită pentru a învăţa automat caracteristicile relevante din datele structurate în soluţiile de e-Commerce, folosind o Reţea Neuronală Convoluţională (CNN). Procesul se realizează folosind două etape: (1) transformarea datelor de jurnal ale platformei de comerţ electronic într-un cadru de date proiectat. Apoi (2) este folosită o reţea neuronală convoluţională pe cadrul de date, unde caracteristicile relevante vor fi extrase din layerele (straturile) ascunse şi, apoi, utilizate pentru predicţia vânzărilor la layerul de ieşire. Abordarea preia datele de jurnal brute şi face facilă integrarea datelor nou disponibile în modelul de predicţie a vânzărilor cu puţine intervenţii umane. Mai mult, tehnicile de descompunere a greutatea eşantionului şi tehnologiile de învăţare prin transfer sunt utilizate pentru a îmbunătăţi în continuare precizia prognozei. Metoda a fost testată pe un set de date din lumea reală de la CaiNiao.com, iar rezultatele experimentale validează eficacitatea metodei.

Au fost identificate provocări interesante ce pot fi investigate folosind reţele neuronale convoluţionale profunde (DCNN): (1) posibilitatea de a găsi cei mai importanţi indicatori pentru prognozarea vânzărilor din datele de jurnal ale platformelor de e-Commerce; (2) identificarea unui cadru dedicat pentru extragerea datelor relevante din toate structurile de date existente.

CAPITOLUL 3. Cercetări practice privind comportamentul clienţilor în e-commerce folosind algoritmi de inteligenţă artificială

Selectarea cadrului și definirea structurii de cercetare

Clește.ro este un business online (magazin online) cu sediul în Galați, care comercializează produse și componente electronice destinate dezvoltării proiectelor de automatizare, proiectelor IoT integrabile în case inteligente, în agricultură inteligentă. Totodată, magazinul online comercializează o gamă largă de produse IoT care atrage și tinerii sau copiii dornici să învețe programare într-un mod interactiv. În cadrul platformei online sunt puse la dispoziție componente și kit-uri utilizate de instituțiile de cercetare, cum ar fi Institutul Național de Cercetare-Dezvoltare pentru Fizica Pământului și departamente de cercetare, inovare din diverse industrii.

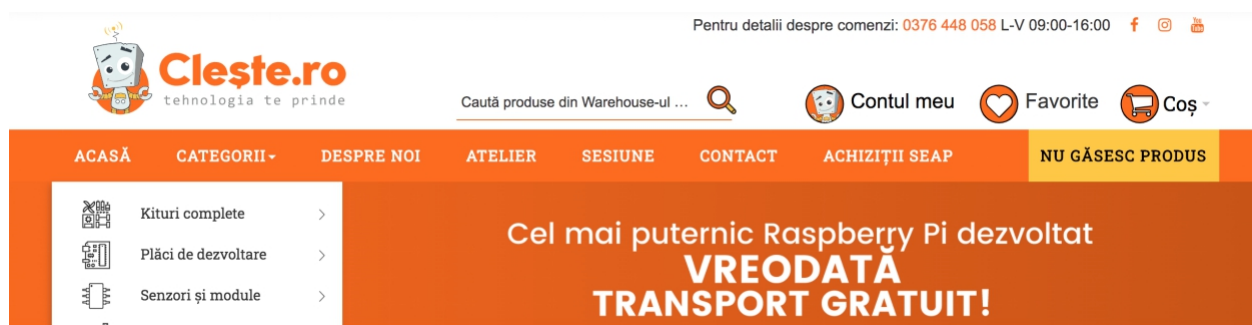


Figura 3. Secțiune pagină principală, Interfață frontend Clește.ro

În România, piața pentru astfel de produse este constituită cu precădere din centre universitare și companii ce produc echipamente electronice, această piață fiind deservită în prezent de 6 magazine online care vizează nișa de produse IoT. Putem afirma așadar că domeniul IoT este unul emergent, aflat într-un stadiu incipient de dezvoltare în mediul economic românesc.

În urma unei analize de piață efectuată intern de Clește.ro, acesta a decis să ofere clienților transportul gratuit la un coș de cumpărături de peste 90 lei, în timp ce concurența menține acest plafon mai ridicat, majoritatea competitorilor situându-se în intervalul 100-150 lei. De asemenea, Clește.ro oferă 30 de zile drept de retur iar clienții au posibilitatea să plătească în rate fără dobândă cu carduri de cumpărături de la diferite bănci partenere, lucru ce nu se găsește momentan la concurență. Încă de la început, strategia de promovare a constat în derularea de campanii de marketing și reduceri pentru toate sărbătorile naționale, asemenea magazinelor mari din România, lucru care din nou, lipsea pe o astfel de nișă.

Site-ul Cleşte.ro a fost lansat în decembrie 2017 și este dezvoltat pe platforma open source Magento 1.9, la acest moment fiind în curs de lansare o nouă versiune îmbunătățită a platformei, dezvoltată pe platforma open source Prestashop 1.7. Noua platformă va avea un design modernizat, cât și noi funcționalități integrate ce vor îmbunătăți experiența vizitatorilor, având un accent pus pe optimizarea procesului de plasare comandă, interacțiunea generală cu platforma, documentare și informare.

Magazinul online se adresează în mod direct persoanelor pasionate de automatizări și dispozitive electronice, cu segmente de vârstă extrem de variate, de la copii, ce cuprind elevi, studenți cat și adulți cu diferite nivele de experiență profesională.

În luna iulie 2020, platforma Cleste.ro deține o bază de date de 2.800 de produse, strategia companiei fiind centrată pe mărirea constantă a portofoliului de produse și diversificarea gamei de categorii de produs. Cele 2500 de produse existente sunt organizate în 16 categorii principale de produse, respectiv: Kituri complete, Plăci de dezvoltare, Senzori și module, Conectivitate, Plăci expansiune, Alimentare, Wireless și Bluetooth, Display, Motoare și drivere, Robotică, Imprimante 3D, Unelte și accesorii, Aparate de măsură, Smart House, Raspberry Pi, Carcase. Aceste categorii principale au la rândul său subcategorii în care sunt alocate produsele.

Meniul principal al site-ului este: Acasă, Categori, Despre noi, Atelier, Sesiune, Contact, Achiziții Seap. În zona de subsol (Footer) a paginii principale sunt listate pagini secundare specifice site-urilor e-Commerce precum: Termeni și Condiții, Politică de retur, De ce noi, Cum comand, Livrare, Plată, Plata cu cardul în rate fără dobândă, link extern către ANPC.

Platforma este conectată prin link-uri de acces cu paginile și conturile de rețele sociale principale, precum Facebook, Instagram si Youtube.

Majoritatea produselor din oferta magazinului online au ca țară de proveniență China, dar produsele comandate de persoanele juridice sau instituții sunt în general produse importate din Europa. Gama de produse include și produse din SUA, însă acestea sunt comandate destul de rar.

La momentul efectuării lucrării de cercetare, angajații responsabili de de activitățile Cleşte.ro sunt în număr de 5, vizând departamentele: management, ambalare și manipulare, aprovizionare, vânzări și

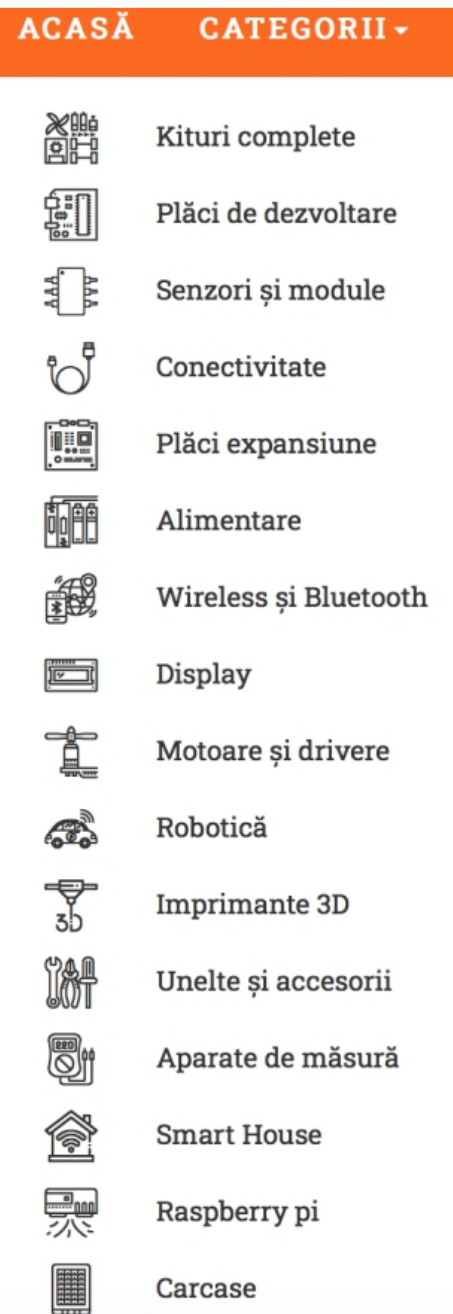


Figura 4. Meniu Categori, Interfață frontend Cleşte.ro

relații cu clienții. De asemenea, sunt externalizate o serie de operațiuni, prin contractarea următoarelor: servicii de contabilitate, resurse umane precum și serviciile specializate ale unei agenții web, care oferă suport de dezvoltare web a magazinului online, grafică, servicii de marketing și optimizare web, în total fiind peste 15 oameni care contribuie direct la dezvoltarea business-ului.

Misiunea și viziunea companiei

Misiunea Clește.ro este de a se diferenția de competitorii principali prin diversitatea gamei de produse și creșterea numărului de produse în portofoliu, astfel încât să devină lider pe nișa sa în piață. De asemenea, echipa Clește.ro prețuiește calitatea serviciilor și în acest sens dorește să ofere clienților o experiență completă autentică. Susținută de politică internă, misiunea firmei este de asemenea de a oferi clienților un raport calitate-preț al produselor optim și facilitarea procesului de a plasa comenzi pentru toate produsele dorite din sfera dezvoltării proiectelor de automatizare, proiecte IoT integrabile în case inteligente, în agricultură inteligentă, toate în cadrul unui singur magazin online.

Viziunea firmei este de a integra tehnologii de ultimă generație în interacțiunea cu consumatorul final și a inova în mediul online prin metode și strategii orientate către dezvoltare continuă. Clește.ro își propune să fie permanent orientat către nevoile clienților și punerea la dispoziția clienților sau de instrumente moderne și inteligente pentru a ajuta la inovarea cât mai multor industrii.

Poziționarea companiei

Platforma Clește.ro a fost lansată în plin sezon de reduceri (noiembrie - blackfriday și decembrie - craciun) după o perioadă de 6 luni de planificare strategică a managementului, ce a vizat setarea relației cu furnizorii, crearea stocului de produse și dezvoltarea magazinului online, elemente de branding și identitate vizuală. Deși la început nu exista un volum considerabil de comenzi și trafic în site, treptat, cu ajutorul campaniilor de marketing desfășurate, Clește.ro și-a făcut loc printre competitori, ajungând în prezent în top 3 cele mai populare site-uri pe acest profil din România. Raportat la numărul de comenzi preluate de către fiecare competitor, s-a constatat că este o creștere constantă a fiecăruia în parte, păstrându-se raportul între cei 4 competitori direcți, printre care și Clește.ro, în anumite perioade existând mici fluctuații datorate tipurilor de campanii desfășurate, bugetelor alocate sau campaniilor de rebranding.



Figura 5. Rezultate Google pentru cuvântul cheie "placă arduino", Google.ro Search

Piața țintă - o nișă a pasionaților de electronică

Campaniile de marketing desfășurate în cadrul Clește.ro sunt adresate exclusiv pieței din România, însă au fost testate și comercializate produsele și în țări precum Bulgaria și Ungaria, având în vedere intenția managementului de a se dezvolta pe viitor și în alte marketplace-uri din afara țării. De la intrarea în piață a companiei, au fost create campanii dedicate pe Google Adwords pentru 28 de orașe din țară, cele mai populare fiind București, Galați, Brașov, Timișoara, Iași, Cluj, Constanța și Sibiu. Având în vedere bugetele limitate de Marketing disponibile în primele 6 luni de activitate, a fost demarată o campanie A/B testing ce a vizat doar trei orașe, urmând apoi ca pe o perioadă de 3 luni să fie rulate campanii doar în două orașe (Galați și Iași), considerând rata de conversie superioară a acestora.

În cadrul acestor campanii inițiale de marketing au fost descoperite aspecte importante referitoare la comportamentul consumatorilor brandului Clește.ro, printre care și faptul că segmentul de vârstă 18-24 ani avea o rată de conversie peste 3%, chiar dacă utilizatorii nu petreceau la fel de mult timp pe website. Acest segment este imediat urmat de intervalul 25-34 ani, care include mai mult de o treime din traficul de pe platformă, însă cu o rată de conversie ușor mai mică.

Colectarea datelor despre clienți a ajutat managementul companiei și a personalului de decizie la confirmarea unor ipoteze legate de genul clienților, 78.4% dintre aceștia fiind bărbați, și petrecând cu 50% mai mult timp pe platformă, deși rata conversiei s-a dovedit ca nu este sensibil diferită față de cea a femeilor. Folosind instrumente de analiză a traficului (ex. Google Analytics, Facebook page insights), a fost posibilă segmentarea audienței în funcție de interes și alte branduri cu care clienții interacționează. Astfel, putem spune că 14% din audiență este reprezentată de ingineri care sunt interesați de produse din categoria de casă și grădină (Home & Garden/ Do-It-Yourselfers), sau că utilizatorii care au o educație tehnică (Education/Post-Secondary Education/Technology Education), au o rată de conversie de patru ori mai mare față de cei care lucrează în sectorul privat (Employment/ Government & Public Sector Jobs). Este important ca aceste dimensiuni să fie validate prin mărimea

eşantionului pentru a evita valorile aberante (outlieri), cum ar fi de exemplu utilizatorii care călătoresc în Buenos Aires care au o rata de conversie de 10.34% (3 din 29 utilizatori).

Catalogul de produse și gestiunea internă

De la lansarea sa în mediul web, până în prezent, magazinul online Clește.ro a înregistrat o creștere permanentă a gamei de produse, diversificându-și atât produsele din fiecare categorie, cât și furnizorii, categoriile și subcategoriile de produse, furnizorii precum și funcționalitățile oferite clienților. În prezent sunt disponibile și active în interfața magazinului online disponibilă pentru utilizatori 2.800 de produse, cu valori cuprinse între 80 de bani și 35.781 lei.

Strategia pe 2020 țintește creșterea bazei de date de produse cu valoare mai mare, observându-se din experiența anterioară deschiderea clienților față de aceste produse. De asemenea, bazat pe feedback-ul primit de la cumpărători, s-a identificat nevoia acestora de a naviga printr-o gamă mai mare de produse cât mai diverse și, de asemenea, de a cumpăra anumite produse specifice care în acest moment nu se regăsesc în platformă. La cererea clienților, Clește.ro urmărește aducerea pe stoc în cel mai scurt timp a celor mai solicitate produse.

De la lansarea sa până în prezent, furnizorii principali ai produselor aprovizionate și listate pe Clește.ro sunt localizați în China și în procente mai reduse în Europa și SUA.

În acest moment, dată fiind situația la nivel global și barierele teritoriale ridicate din cauza pandemiei covid-19, firma a întâmpinat reale dificultăți la importul produselor din China. Stocul de marfă existent și colaborarea cu furnizorii europeni și din America au permis preluarea comenzilor fără a afecta în vreun fel livrarea acestora sau scoaterea din site a anumitor produse.

În ceea ce privește catalogul de produse, în structura de date au fost incluse elemente de optimizarea pentru motoare de căutare (SEO) ca urmare a unei analize riguroase a cuvintelor cheie. Platforma e-commerce a jucat un rol important în acest process, însă au fost necesare module adiționale și modificări ale paginii sursă pentru afișarea produselor, astfel Google poate înțelege atribute specifice pentru fiecare produs.

Stocul de produse

În procesul de aprovizionare, la momentul completării stocului de marfă și înaintea plasării comenzii către furnizor, se analizează mai mulți indicatori pentru a stabili necesarul de marfă.

Există 3 tipuri de comenzi:

- Refacerea stocului - Se analizează ce produse au un stoc redus sau 0 și se decide în funcție de popularitatea lor care să fie aduse/completate în stoc. Se monitorizează de asemenea alertele de stoc, cele mai vandute produse, cele mai vizualizate etc;
- Comandarea de produse noi - În funcție de strategia de marketing, se decide ce tipuri de produse noi vor fi aduse în site. Se analizează în baza informațiilor existente care sunt cele

mai populare categorii de produse, tipuri de proiecte și produse existente pentru care exista versiuni îmbunătățite. Anul acesta s-a decis să fie aduse produse cu valoare mare în stoc pentru a crește valoarea medie a comenzii;

- Produse pentru campanii și Black Friday - Atunci când se planifică campanii de reduceri de preț, se fac previziuni în funcție de ofertele stabilite pentru a estima stocul necesar de marfă pentru produsele din campanie.

Cercetarea cantitativă

Metodologia cercetării

Deoarece încă din primele interviuri cu angajații Clește.ro, viziunea echipei de management a fost să identifice diferențe în comportamentul clienților și modalități cum pot îmbunătăți comunicarea cu aceștia, chestionarul a fost proiectat pentru a reflecta acest obiectiv. Intenția a fost să fie identificate o serie de dimensiuni sau proceduri prin care se pot recomanda produse clienților într-o manieră cât mai prietenoasă. Proiectarea acestei forme de comunicare va fi inițial implementată folosind unelte generaliste aflate în platformă și pe soluții terțe, ca ulterior, după validarea soluției pe Clește.ro să fie dezvoltat un modul care automatizează tot acest proces, folosind unul din algoritmi de învățare automată descrise în capitolul doi. Chestionarul conține 29 de întrebări și a fost proiectat pe baza informațiilor culese de la angajați în cadrul interviului, focus grupului și analizei sistematice. Din cei aproximativ 8000 de clienți, a fost selectat un eșantion aleatoriu de 5000 utilizatori care au plasat o comandă în trecut în site, către care a fost trimis chestionarul prin e-mail, folosind platforma SurveyMonkey. Chestionarul a fost împărțit în patru secțiuni pentru a înțelege mai bine comportamentul și a testa ipotezele studiului:

1. Profilarea clientului în vederea înțelegerii comportamentul cumpărătorilor online (Q1-Q5). Aceste întrebări erau referitoare la frecvența cu care clienții fac cumpărăturile online și pe alte website-uri, dispozitivele pe care le preferă când fac cumpărături online și reticența acestora în utilizarea cardului la plata cumpărăturilor.
2. Începând cu întrebarea 6 până la întrebarea 15, s-a urmărit înțelegerea comportamentului clienților pe Clește.ro.
3. Mod de comunicare preferat de către clienți cu platforma e-commerce Clește dar și pe alte website-uri.
4. Colectare date demografice.

Întrebările au fost validate cu managementul Clește.ro și au trecut prin două revizii pentru a fi ușor de înțeles de clienții care nu au un limbaj tehnic, dar și pentru a stabili o ordine ușor de parcurs. Întrebările cu un nivel ridicat de dificultate au fost adresate spre finalul chestionarului, în cazul în care utilizatorul abandonează procesul de completare și finalizare a chestionarului, să fie colectate

răspunsurile completate parțial, până la momentul abandonării. Tot în scopul de a veni în sprijinul utilizatorilor, chestionarul a fost împărțit pe două secțiuni pentru a fi mai ușor de navigat și după înregistrarea răspunsului la fiecare întrebare, se trece automat la următoarea, fără a fi nevoie de apăsarea click-ului sau scroll.

Modalități de culegere a datelor

Colectarea datelor a fost realizată prin email, folosind baza de date a clienților înregistrați pe platforma Clește.ro, acesta a fost exportată în fișier excel, unde a fost formatată conform cerințelor SurveyMonkey. Pentru a obține o rată de răspuns mai mare, a fost folosit numele persoanei chestionate în forma de salut și, de asemenea, s-a formulat solicitarea clară în subiectul emailului privind scopul chestionarului, și anume de sprijin pentru a îmbunătăți serviciile oferite de Clește.ro

Date de contact obținute de pe paginile de contact ale magazinelor online- A fost realizată o bază de date cu magazine online indexate în comparatoare de preț, websiteuri ce fac marketing afiliat și evenimente dedicate comerțului electronic.

Această analiză încrucișată a audienței a permis identificarea diferențelor de înțelegere a comportamentului managementului în afacerile ce au o componentă de comerț electronic, dar și a consumatorului final.

Stabilirea mărimii eșantionului

Prima parte a eșantionului pentru chestionarul distribuit pe email clienților Clește.ro a fost validat pe statskingdom.com/sample_size_chi2.html, din cele 250 de chestionare completate, fiind complete și validate 241. Pragul de semnificație α pentru acest eșantion (241) fiind de 0,05, acesta reprezentând probabilitatea sub care ipoteza nulă într-un test hi pătrat (χ^2 , Chi square) să fie respinsă. Estimarea mărimii eșantionului este o sarcină dificilă în studiile de cercetare statistice. Majoritatea metodelor de estimare a mărimii eșantionului se bazează pe volumul populației reprezentative, cercetătorii experimentați au dezvoltat metode complexe pentru determinarea mărimilor eșantionului pe baza experienței, a regulilor generale statistice și a restricțiilor bugetare. Însă este important de menționat că estimarea eșantionului este doar o „*estimare*”, pentru validarea unui test Hi pătrat, este nevoie ca celulele să nu conțină un număr mai mic de 5 valori în cazul în care sunt analizate mai mult de două dimensiuni și, respectiv, 10 dacă sunt analizate doar două.

Dimensiunea eșantionului pentru hi-pătrat, în ciuda numeroaselor ambiguități asociate interpretării, ridică probleme în a fi stabilită corect, elaborarea unui indice de potrivire fiind dificilă și direct dependentă de distribuția eșantionării. Cu toate acestea, este sensibil la dimensiunea eșantionului; pe măsură ce mărimea eșantionului crește (în general peste 200); testul statistic are tendința de a indica un nivel de probabilitate semnificativ (Hoyle and Ed, 1995). În schimb, pe măsură ce dimensiunea eșantionului scade (în general sub 100), testul statistic este predispus să indice un nivel de probabilitate nesemnificativ (Fan et. al 1999). Chi-pătrat este sensibil la dimensiunea eșantionului, semnificația sa devenind mai puțin fiabilă cu dimensiunile eșantionului în afara acestui interval. Acest lucru face mai probabil să respingă modelul în modelarea ecuațiilor structurale datorită dimensiunii

eşantionului mai mare. În eşantioane mari, diferenţele de dimensiuni mici pot fi considerate a fi semnificative, în timp ce la eşantioane mici, chiar şi diferenţe considerabile pot fi testate ca fiind ne semnificative. Dificultatea obţinerii unui număr mare de respondenţi la cel de-al doilea chestionar distribuit managerilor de magazine online a limitat numărul respondenţilor la 202. Multe din testele efectuate au fost invalidate de numărul mic de date colectate, însă a fost realizată o bază de date cu 3000 de magazine online din 5000 estimate în România.

Timiraş et. al (2012) susţine că pentru un sondaj de opinie reprezentativ, este necesară o eroare egală sau mai mică de $\pm 5\%$ şi probabilitate cel puţin egală sau mai mare de 95%. Astfel, se poate calcula mărimea eşantionului "n":

$$n = z^2 * p * q / E^2$$

Unde:

E - reprezintă eroarea admisă (5%)

z - pentru $\alpha=0,05$ a fost identificată în tabelul de distribuţie cu valoarea 1.96

p,q - valori ale probabilităţilor necunoscute momentan, însă sunt estimate la 50% fiecare cu condiţia ca $q = 1-p$.

Folosind această metodă pentru populaţia cumpărătorilor online din România care depăşeşte de 7.000.000 de consumatori, eşantionul reprezentativ este de **384** subiecţi. Valoare validată folosind şi calculatorul erorii în chestionarele de opinie pe <https://www.infomass.ro/resurse/calculator-eroare-esantion/>.

Obiectivele şi ipotezele cercetării pentru clienţii Cleşte.ro

Obiectivul general al cercetării cantitative este identificarea acţiunilor ce pot fi automatizate folosind algoritmi de învăţare automată în îmbunătăţirea relaţiei şi comunicării cu clienţii pe platformele de comerţ electronic. În mod specific, în cadrul studiului se doreşte identificarea canalelor de comunicare preferate de clienţi şi modul cum doresc aceştia să interacţioneze cu conţinutul website-ului. Generalizând pe rezultatele acestui studiu, se doreşte dezvoltarea unui modul şi ulterior a unei aplicaţii de marketing digital care să vină în întâmpinarea managementului şi antreprenorilor de magazine digitale în a măsura, testa şi îmbunătăţi performanţa ratei de conversie. Cu aceste direcţii clar conturate, au fost stabilite următoarele obiective specifice de cercetare pentru acest studiu empiric:

1. Există o diferenţă semnificativă între comportamentul clienţilor pe dispozitive mobile şi calculatoare desktop sau laptopuri;
2. Intenţia de cumpărare a clienţilor este influenţată de campaniile de marketing pe care magazinul online le desfăşoară;
3. Identificarea, prioritizarea şi înţelegerea modului cum sunt folosite canalele de comunicare în relaţia cu clienţii;
4. Principalele aspecte ce ţin de cumpărarea online pe care firma le poate îmbunătăţi;
5. Frecvenţa cu care clienţii fac cumpărături online, şi existenţa unor diferenţe în funcţie de bugetul anual pe care îl alocă aceştia pentru produse IoT şi piese electronice;

6. Tendința clientului de schimbare a furnizorului raportat la bugetul anual și dispozitivul folosit pentru a efectua cumpărăturile online;
7. Înțelegerea modului cum sunt folosite produsele achiziționate;
8. Stabilirea bugetului anual pentru piese electronice în funcție de dispozitiv, vârstă și frecvența cumpărăturilor;
9. Clienții pentru dispozitive mobile doresc funcții specifice pentru optimizarea cumpărăturilor online;
10. Comportamentul cumpărătorilor online în funcție de vârstă și ocupație.

Bazat pe aceste obiective generale, au fost formulate următoarele ipoteze statistice pentru cercetarea cantitativă:

Formularea Ipotezelor pentru cercetarea cantitativă

H1

H_0 . Frecvența cu care utilizatorii fac cumpărături online nu diferă în funcție de dispozitivul folosit.

H_a - Există o asociere semnificativă între persoanele care fac cumpărături online de pe mobil și frecvența cu care aceștia fac cumpărături online.

H2

H_0 - Clienții care fac cumpărături online de pe mobil, preferă același tip de conținut cu cei care fac cumpărăturile pe calculator.

H_a - Există o asociere semnificativă între tipul de conținut prezentat în descrierea produselor și intenția clienților de a face cumpărături online de pe mobil.

H3

H_0 - Nu există diferențe în afișarea numărului de bucăți disponibile pe stoc în funcție de dispozitivul folosit la cumpararea online.

H_a - Există o asociere semnificativă între dispozitivul folosit pentru achiziții online și afișarea **cantității disponibile în stoc**.

Obiectivele și ipotezele cercetării pentru managementul magazinelor online

Plecând de la percepția generală a managementului față de algoritmi de învățare automată, se dorește înțelegerea modului cum aceștia doresc să integreze aceste tehnologii. Este importantă calibrarea modului de gândire a managementului față de procesele interne ale business-ului și

identificarea direcțiilor de automatizare. Cum a fost descris în capitolul doi și ulterior în analiza calitativă, opinia utilizatorilor față de automatizare diferă semnificativ în funcție de scopul acestuia. Dacă angajatul sau consumatorul are teama că automatizarea poate să îi afecteze siguranța locului de muncă sau influența procesul de decizie, așteptările din partea managementului se doresc a fi diferite. Motiv pentru care se dorește stabilirea unor obiective și ipoteze clare pentru acest studiu. Este important de menționat că analizele pe cele două eșantioane au fost realizate independent, chiar dacă 4 întrebări au fost identice în ambele chestionare.

Obiective:

1. Identificarea percepției managementului față de automatizarea proceselor interne și utilizarea algoritmilor de învățare automată;
2. Identificarea canalelor de comunicare preferate de afacerile de comerț digital;
3. Impactul comerțului electronic de pe dispozitivele mobile asupra afacerilor online;
4. Fluxuri de date și integrări pe care managementul le folosește sau intenționează să le conecteze la platforma de comerț electronic;
5. Procese de marketing ce necesită automatizări sau folosesc în momentul acesta algoritmi de inteligență artificială;
6. Utilitatea folosirii unui produs CRM (aplicație de management a relațiilor cu clienții) într-o afacere e-commerce;
7. Identificarea unor particularități și strategii ale comunicării prin email a magazinelor online.

Formularea ipotezelor pentru managementul magazinelor online:

Q1

H₀ - Nu există corelație statistică între folosirea algoritmilor de inteligență artificială în procese ale gestionării magazinelor online și poziția pe care o deține în firmă interviuatul.

H_a - Există corelație statistică între folosirea algoritmilor de inteligență artificială în procese ale gestionării magazinelor online și poziția pe care o deține în firmă interviuatul.

Q2

H₀ – Campaniile de marketing prin SMS **nu sunt corelate statistic** cu disponibilitatea unei aplicații pentru mobil a magazinului online.

H_a - Campaniile de marketing prin SMS **sunt corelate statistic** cu disponibilitatea unei aplicații pentru mobil a magazinului online.

Q3

H₀ – Managerii care consideră că este importantă comunicarea cu clienții, nu folosesc campanii de marketing prin newsletter/email.

H_a - Există o asociere semnificativă între managerii care consideră că este importantă comunicarea cu clienții și utilizarea newsletterului ca instrument de marketing digital.

Q4

H_0 - Nu există corelație statistică între managerii care folosesc instrumente de inteligență artificială și folosirea campaniilor de marketing prin rețeaua Google Adwords.

H_a - Există o asociere semnificativă între firmele care folosesc unele ce folosesc inteligență artificială și derularea campaniilor de marketing pe Google Adwords.

Aplicabilitatea modelelor predictive ce folosesc inteligență artificială

Metode folosite și set de date utilizat

Pentru a pune în valoare puterea predictivă a algoritmilor de inteligență artificială, a fost proiectat și realizat un test comparativ în cadrul acestei lucrări, care are în vedere regresii liniare simple, regresii liniare multiple, rețele neuronale profunde (DNN) cu o singură variabilă de intrare (input) și rețele neuronale profunde cu mai multe variabile de intrare. Chiar dacă crearea și antrenarea unei rețele neuronale cu o singură intrare este considerată o metodă redundantă, utilitatea acesteia este dată de compararea cu restul metodelor, dar și vizualizarea regresiei neliniare ce rezultă din maparea grafică a rezultatelor. Pentru compararea rezultatelor acestor teste a fost folosită metoda eroarea absolută medie (*Mean absolute error*), care este calculată folosind formula:

$$MAE = \frac{1}{m} \sum_{i=1}^m |y - \hat{y}|$$

Unde m este numărul de erori pentru fiecare estimare făcută, y este valoarea din setul de test și \hat{y} este valoarea estimată de algoritmul antrenat.

Performanța algoritmului este media erorilor pentru fiecare element estimat din eșantionul de test, date pe care algoritmul nu le-a văzut (nu le-a știut) în procesul de antrenare.

În procesul de antrenare a fost folosit limbajul de programare *python* și următoarele librării de analiză a datelor:

- Matplotlib - pentru vizualizarea datelor și crearea graficelor;
- Numpy - librărie pentru operațiuni matematice, oferă funcții ce permit lucrul facil cu vectori și matrici;
- Pandas - permite vizualizarea și realizarea de operații tabelare pentru validarea datelor și excluderea datelor aberante (outliers);
- Seaborn - utilizat în crearea graficilor pentru distribuțiile datelor din setul de date;

- Scipy - librărie pentru analiza descriptivă a datelor;
- Tensorflow - librărie pentru antrenarea reţelelor neuronale profunde (DNN).

Setul de date pentru această analiză a fost obţinut prin selecţia şi exportul de pe listafirme.ro în format csv a 3972 de firme ce au codul Caen 4791 - companii ce au activitate în comerţ cu amănuntul prin intermediul internetului, activitate autorizată în România pentru comercializarea produselor online. Din setul de date au fost excluse firmele ale căror date financiare erau incomplete sau lipseau, astfel, eşantionul final conţine 1400 de firme. Datele financiare analizate sunt pentru anii 2015, 2016, 2017, 2018, 2019 şi includ:

1. Cifra de afaceri;
2. Profit;
3. Număr angajaţi;
4. Active Imobilizate;
5. Active Circulante;
6. Stocuri;
7. Disponibilităţi;
8. Creanţe;
9. Capital propriu;
10. Datorii;
11. Venituri.

Obiectivul analizei este să fie antrenat şi identificat un model predictibil ce foloseşte algoritmul de inteligenţă artificială deep neural network (DNN) ce are performanţe mai bune decât regresia liniară simplă sau multiplă. Astfel, au fost formulate următoarele ipoteze:

1. Numărul angajaţilor poate fi estimat folosind antrenarea unei reţele neuronale profunde bazate pe datele financiare ale unei firme;
2. Profitul poate fi estimat folosind datele financiare ale firmei din ultimii 5 ani;
3. Cifra de afaceri poate fi estimată folosind o reţea neuronală profundă a unei firme folosind numărul de angajaţi şi datele financiare înregistrate în anii precedenţi.

Regresie liniară în tensorflow

Regresia liniară ajută în estimarea rezultatului unei valori continue, cum ar fi preţul unui produs sau cifra de afaceri a unei întreprinderi, luând în calcul una sau mai multe variabile de intrare. Spre deosebire de o problemă de clasificare, unde obiectivul este să fie selectată o variantă (o clasă) dintr-o serie de opţiuni disponibile (de exemplu, dintr-o listă de imagini care conţine anumite produse specifice), rezultatul regresiei este o valoare estimată a variabilei. Pentru testarea primei ipoteze a fost ales un scenariu relativ simplu, pentru care rezultatul este predictibil. Dat fiind numărul de angajaţi ai unei firme în anul 2017, se doreşte crearea unui model folosind regresia liniară pentru estimarea numărului de angajaţi în 2018. Antrenarea modelului a fost realizată cu *tf.keras* (keras este o clasă a bibliotecii tensorflow) şi pentru optimizarea rezultatelor a fost predefinit un prim strat (layer) pentru normalizarea datelor de intrare.

```
angajati2017 = np.array(setdate_antrenare['Angajati2017'])
```

```
angajati2017_norm = preprocessing.Normalization(input_shape=[1,])  
angajati2017_norm.adapt(angajati2017)
```

Antrenarea unui model cu *tf.keras* de este demarată prin definirea arhitecturii modelului, folosind `keras.Sequential` model, ce foloseşte doar două straturi în cazul regresiei liniare:

1. Normalizarea datelor de intrare *angajati2017*;
2. Aplicarea transformării liniare ($y = mx + b$) pentru a rezulta o ieşire (output), folosind *layers.Dense*.

Numărul de date de intrare (inputs) poate fi introdus folosind argumentul *input_shape*, sau, în mod automat, când modelul rulează pentru prima dată. Apoi este creat modelul regresiei liniare folosind metoda `Sequential`, care conţine stratul de normalizare, şi un strat *Dense*, care conţine o singură unitate pentru ieşire (output). Acest model secvenţial poate fi vizualizat folosind funcţia `.summary()`.

Concluzii

Comertul electronic este un fenomen in plina expansiune, barierele pentru noii veniti sunt aproape insesizabile si in fiecare an sunt indentificate noi industrii care trec in mediul online. Raportandune la comertul traditional numarul competitorilor este inca mic, daca la nivel national sunt estimate aproximativ 5000 de maganzin online, doar in luna ianuarie 2020 au for infiintate 6000 de firme noi (onrc.ro). In romania sunt inregistrate peste 2000000 de firme, 1.2 milioane fiind estimate ca active, 200000 avand ca prim domeniu de activitate comertul (listafirme.ro). Avantajule pe care cleste.ro a reusit sa il exploateze in aceasta piata sunt:

- Numarul mici de competitori
- Crearea unei identitati de brand solida
- Diferentierea prin campanii de marketing strategice
- Cresterea pietei in care activeaza

Situatia geo-politica a romaniei i-a permis sa-si dezvolte unelte compotitive inaintea interventiilor corporatiilor straine. Industria model si mai recent horeca prin delivery apps au fost preluat in decursul ultimilor doi ani. Amenintarea este inca prezenta motiv pentru care este necesara o coalizare a pietei sau asigurarea unei cote de piata considerabila in urmatorii 2-3 ani. Evident ca acest lucru necesita capital rulant suficient, strategii de marketing eficiente, acces la landuri de distributie diverse si putere de negociere. Exceptand accesul la capital aceste aspecte pot fi bifate facil prin acces la date actionabile, gestionate responsabil. Internetul si mai nou retelele sociale reprezinta un izvor de date inepuizabil despre consumator care, folosite eficient in campanii de marketing pot transforma procesul de vanzare intr-o joaca. Proces mult indragit de generatia Z, care recent a devenit activa pe piata muncii, insa atenta la date si extrem de tehnologizata. Telefonul mobil este instrumentul indispensabil in identificarea noilor trenduri pe retele sociale, identificarii de oportunitati de cost pentru produse in supermarketuri sau validarea uneo oferte promotionale. Managementul magazinelor online trebuie sa fie extrem de atent in comunicarea strategiilor de marketing, millenians sau zoomers (zeneratia z), desfiintand instant pe retelele sociale promotiile false cat si identitatea de brand.

Analiza surselor de date in timp real poate fi o povara, algoritmi de invatare automata descrisi in capitolul 2 ofera suport in a reduce acest efort. Este important ca managementul sa inteleaga modul cum acestea functioneaza si situatiile cand pot fi de folos. In ipoteza Q5 a fost validata dorinta managerilor de a automatiza fluxuri in procese de marketing este corelat statistic cu detinerea unei aplicatii CRM. Folosind algoritmul random forest, se poate optimiza platforma CRM prin crearea de recomandari de produse specifice pentru un anumit client. Acest lucru poate fi extins in segmentarea clientilor in functie de dispozitivul folosit, estimarea bugetului anual, preferinta pentru vouchere (folosind K-means clustering sau Fuzzy clustering) pentru eficientizarea campaniilor de marketing (H6, H7, H10). Luand in calcul dinamicitatea noii generatii pot fi stabilite strategii de pret coerente folosind retele neuronale profunde pentru a nu forta clientul sa faca achizitii de la alti furnizori (H11). O data ce un client este prezent pe platforma, costul de schimbare catre un alt furnizor trebuie sa fie suficient de mare. Acest lucru se realizeaza prin monitorizarea constanta si colectarea datelor despre furnizori si identificarea modului cum produsele se pot diferentia. Totodata este importanta segmentarea clientilor in functie de sensibilitatea asupra costului, sau folosind retele neuronale convolutionale sa se testeze performanta unui nou produs, cu attribute specifice.

Feedback-ul primit de la clienți, dar și informațiile extrase din aplicațiile de raportare sunt instrumente foarte importante atunci când vine vorba de setarea de noi campanii de promovare, alegerea produselor aflate la promoție, modul de comunicare a ofertelor. De asemenea, o activitate recurentă relevantă în procesul de setare al campaniilor este prospectarea pieței și analiza competiției pentru a identifica strategiile aplicate de aceștia în desfășurarea campaniilor de marketing. Toate aceste date trebuiesc stocate, interpretate si afisate intr-un mod usor de inteles si actionabil pentru echipa de marketing.

Bazat pe direcțiile de cercetare cat și de rezultate acestui studiu, echipa tehnică a optimizat timpul de încărcare al site-ului cleste.ro, acest lucru fiind de asemenea un avantaj față de competitori.

Cea mai oportună strategie identificată este mărirea bazei de date de produse și diversificarea categoriilor, astfel încât platforma Clește.ro să poată concura în piață. O nișă neexploatăată în prezent, însă cu care competiția se diferențiază, este zona de produse electrice, categoriile existente în site fiind acum doar de produse electronice. In urmatoarea etapa va fi exploatăata baza de date de clienti prin campanii newsletter prin selectia atenta a produselor adaugate in campanie.

În cadrul acestei cercetări au fost realizate peste 370 de teste statistice, într-un final fiind acceptate 25. Un rezumat al testelor realizate poate fi urmărit în tabelul 25, insa este important intregul parcurs al acestei lucrari pentru a pune in context aceste rezultate. Chiar daca anumite ipoteze nu au fost confirmate analiza descriptiva a adus beneficii enorme in intelegerea comportamentului clientilor cleste.ro dar si strategii de marketing folosite de alte plafrome ecommerce.

Analiza comparativă arată performanța rețelelor neuronale profunde în crearea de modele predictive folosind date financiare ale firmelor ce au activitate în domeniul comerțului electronic. Plecând de la estimarea numărului de persoane într-o firmă pentru a ilustra eficiența algoritmului de inteligență artificială, rețeaua neuronală este extinsă în a determina valoarea stocului necesar pentru un magazin

online în funcție de alți indicatori financiari. Acest lucru permite managementului să folosească acest instrument pentru a evalua performanța angajaților, dar și pentru a-și planifica stocurile în funcție de obiectivele stabilite și campaniile de marketing pe care intenționează să le desfășoare în viitor.

O alta provocare este una de natura etica, modul cum sunt colectate și stocate datele despre competiție și clienți este încontinuu dezbateră activă. Au fost făcute progrese semnificative prin introducerea GDPR-ului la nivel European însă cu siguranță vor veni și alte reglementări. Este important ca managementul magazinelor online să se conformeze acestor norme și totodată să folosească acest cadru în avatajul propriu.

Implicații manageriale și limitările cercetării

Implicațiile manageriale ale prezentei lucrări pot fi clasificate în trei componente diferite:

1. Acțiuni pe care managementul să le desfășoare pentru a îmbunătăți comunicarea cu consumatorii;
2. Ce instrumente de marketing să folosească în campaniile de promovare și cum folosirea funcțiilor de inteligență artificială poate îmbunătăți performanța campaniilor de marketing digital;
3. Cum pot fi modelele predictive folosite în managementul afacerii și stabilirea valorii stocului în atingerea unor indicatori cum ar fi profitul sau cifra de afaceri.

Este esențial ca managementul magazinelor online să înțeleagă beneficiile aduse de utilizarea algoritmilor de inteligență artificială, acest lucru a fost descris în detaliu în cadrul capitolului doi, *Analiza sistematică a literaturii de specialitate*. Însă, totodată, să stabilească care sunt resursele și datele pe care le deține intern pentru a le transforma cu ajutorul acestor algoritmilor de inteligență artificială în avantaje competitive. Să înțeleagă fluxul de date (big data), pe care platforma e-commerce îl are cu terțe aplicații pentru a nu oferi cu titlu gratuit informații pe care alte companii le pot exploata în a monitoriza activitatea clienților în platforma proprie.

Pentru antrenarea algoritmilor au fost folosiți unul din indicatorii financiari sau toți, însă, pot fi obținute rezultate mai bune dacă sunt folosite două, trei sau mai multe variabile pentru a obține cea mai bună combinație de date de intrare. Această limitare necesită însă timp îndelungat de antrenare și resurse hardware performante care nu au fost disponibile în acest moment. O altă limitare a acestor teste este că au fost analizate doar rapoarte anuale, analizele nu țin cont de sezonabilitate, un factor extrem de important în comerțul online. Aceste date secundare nu sunt disponibile public, însă pot fi colectate în cadrul unui chestionar distribuit online. În același timp, corelarea datelor din chestionare cu datele financiare și crearea de modele predictive în funcție de bugetele de marketing pe care le au companiile în e-commerce, reprezintă un potențial valoros în cercetările viitoare. Folosirea unor alte dimensiuni ale magazinelor online (viteza de încărcare, diversitate produse, aplicație mobilă) pentru realizarea de modele predictive ale datelor financiare vor fi integrate de asemenea cu scopul de a identifica care din acestea au impact real asupra performanței.

Analiza comparativă demonstrează cum managementul poate să creeze modele predictive în evaluarea performanței luând în calcul indicatori financiari pentru 1400 de firme din România.

Informații pe care managementul le poate folosi să valideze performanța propriei afaceri, să stabilească obiective pentru următorul an, să compare impactul pe care îl au valoarea stocului disponibil și numărul angajaților asupra profitului și cifrei de afaceri. Aceste teste și predicții reprezintă o mică parte din multitudinea de aplicații pe care algoritmi de inteligență artificială le poate avea asupra activității unei firme. Măsurând și stocând datele despre activitatea clienților, competitorilor și a proceselor din interiorul firmei, managerii pot înțelege mai bine ariile unde pot performa. În comerțul digital acest lucru este extrem de facil, ceea ce va da naștere unor inovații extrem de interesante în viitorul apropiat.

Bibliografie

1. Abawajy J. H., 2015, Comprehensive analysis of big data variety landscape. *Int. J. Parallel Emergent Distributed Syst.* 30(1): 5-14
2. Abbar, S., Mejova, Y., & Weber, I. (2015). You Tweet what you eat: Studying food consumption through Twitter. Paper presented at CHI 2015, April 18–23, Seoul, Republic of Korea. Available from arXiv:1412.4361 on 10.05.15.
3. Abdullah, H. H., Bohari, A. M., Warokka, A., Abdussalam, A., 2012, Strategic Role of Mobile Commerce (M-Commerce) Payment System: Establishing New Competitive Advantage, *Journal of Electronic Banking Systems*
4. Abed, S., Dwivedi, Y., & Williams, M. (2015). Social media as a bridge to E-commerce adoption in SMEs: A systematic literature review. *The Marketing Review*, 1, 39.
5. Abraham J., van Welie R., Willemsen R., 2016, "Global Ecommerce Foundation report". Retrieved from <https://www.ecommercewiki.org>,
6. Adam, N.R., Dogramaci, O., Gangopadhyay, A., Yesha, Y., 1999, *Electronic Commerce: Technical, Business, and Legal Issues*. Prentice-Hall, Upper Saddle River, NJ.
7. Agarap, A. F., Grafilon, P., 2018, Ph.D, *Statistical Analysis on E-Commerce Reviews, with Sentiment Classification using Bidirectional Recurrent Neural Network*
8. Agarwalla, S., Sarma, K.K., 2016, Machine learning based sample extraction for automatic speech recognition using dialectal Assamese speech, *Neural Netw.* 78 (2016) 97–111
9. Agnihotri, R. Dingus, R., Hu, M.Y., Krush, M.T., 2011, Social media: Influencing customer satisfaction in B2B sales, *Industrial Marketing Management*, 53 (2016), pp. 172-180
10. Ahsan, M. N. I., Nahian, T., Kafi, A. A., Hossain, M. I., & Shah, F. M., 2016, An ensemble approach to detect review spam using hybrid machine learning technique. 2016 19th International Conference on Computer and Information Technology (ICCIIT)
11. Ailawadi, K.L., Neslin, S.A., Gedenk, K., 2001, Pursuing the value-conscious consumer: store brands versus national brand promotions, *J. Mark.*, 65, pp. 71-89
12. Akerkar R., Maret R., Vercouter L., 2014, Exploring intelligence of web communities. *WWW (Companion Volume)*: 985-990
13. Akram, U., Ansari, A. R., Fu, G., & Junaid, M. (2020). Feeling hungry? let's order through mobile! examining the fast food mobile commerce in China. *Journal of Retailing and Consumer Services*, 56, 102142. doi:10.1016/j.jretconser.2020.102142
14. Al Nuaimi E., Al Neyadi H., Mohamed N., Al-Jaroodi J., 2015, Applications of big data to smart cities. *J. Internet Serv. Appl.* 6(1): 25:1-25:15

15. Alex Krizhevsky, 2020, The CIFAR-10 dataset, www.cs.toronto.edu/~kriz/cifar.html, accesat 20.09.2020
16. Alexandra Păunescu, GPeC 2019 Romanian E-Commerce Report, www.gpec.ro/blog/en/gpec-2019-romanian-e-commerce-report-2019, accesat 19.09.2020
17. Alvarez, G., Gartner Inc, 2013, Hype Cycle for E-Commerce 2013, <https://www.gartner.com/en/documents/2571916/hype-cycle-for-e-commerce-2013>
18. AM Turing, R Braithwaite, G Jefferson, MHA Newman, 1952, Can automatic calculating machines be said to think?, *The Essential Turing*, 487-506
19. Ambrosini, V. and Bowman, C., 2009, What Are Dynamic Capabilities and Are They a Useful Construct in Strategic Management? *International Journal of Management Reviews*, 11, 29-49
20. Amrhein, V., Greenland, S., McShane, B., Scientists rise up against statistical significance, *natura*, march 2019
21. Anderson, M., Sims, J., Price, J., Brusa, J., 2011. Turning "Like" to "Buy" social media emerges as a commerce channel. *Booz & Company Inc* 2 (1), 102–128.
22. Anders Quitzau, 2019, IBM tech predictions for 2019, www.ibm.com/blogs/nordic-msp/tech-predictions-2019/
23. Apampa, O., 2016, Evaluation of Classification and Ensemble Algorithms for Bank Customer Marketing Response Prediction. *Journal of International Technology and Information Management*, 25(4), 6.
24. Ashutosh Kumar, Arijit Biswas, and Subhajit Sanyal, 2018, eCommerceGAN : A Generative Adversarial Network for E-commerce. In *Proceedings of* , April 2018 (Arxiv).
25. Assael, H., Kofron, J. H., & Burgi, W., 1967, Advertising performance as a function of print ad characteristics. *Journal of Advertising Research*, 7(2), 20–26.
26. Aswani, R., Ghreera, S. P., Kar, A. K., & Chandra, S. (2017). Identifying buzz in social media: a hybrid approach using artificial bee colony and k-nearest neighbors for outlier detection. *Social Network Analysis and Mining*, 7(1). doi:10.1007/s13278-017-0461-2
27. Ay, B., Aydin, G., Koyun, Z., Demir, M., 2019, A Visual Similarity Recommendation System using Generative Adversarial Networks. 2019 International Conference on Deep Learning and Machine Learning in Emerging Applications (Deep-ML).
28. Aydinli, A., Bertini, M., Lambrecht, A., Ku,G., Pham, M.T., Tavassoli, N., Prasad, L., 2014, Price promotion for emotional impact, *J. Mark.*, 78, pp. 80-96
29. Baack, D. W., Wilson, R. T., van Dessel, M. M., & Patti, C. H., 2016, Advertising to businesses: Does creativity matter? *Industrial Marketing Management*, 55, 169–177.
30. Babić Rosario, A., Sotgiu, F., De Valck, K. Bijmolt, T.H., 2016, The effect of electronic word of mouth on sales: a meta-analytic review of platform, product, and metric factors, *J. Mark. Res.* 53 (3), 297–318.
31. Bakir, H., Chniti, G., Zaher,H.,2018, E-Commerce Price Forecasting Using LSTM Neural Networks, *International Journal of Machine Learning and Computing*, Vol. 8, No. 2
32. Balaure, V., Adascalitei, V., Balan, C., Boboc, S., Catoiu, I., Olteanu, V., Pop, N., Teodorescu, N., 2003, *Marketing. Editia a II-a revazuta si adaugita - Virgil Balaure, URANUS*
33. Barbierato E., Gribaudo M., Iacono M., 2014, Performance evaluation of NoSQL big-data applications using multi-formalism models. *Future Gener. Comput. Syst.* 37: 345-353

34. Barnaghi P. M., Sheth A. P., Henson C. A., 2013, From Data to Actionable Knowledge: Big Data Challenges in the Web of Things. *IEEE Intell. Syst.* 28(6): 6-11
35. Barney, J. B., 1991, Firm resources and sustained competitive advantage. *Journal of Management*, 17(1), 99–120.
36. Barry, T. E., & Howard, D. J., 1990, A review and critique of the hierarchy of effects in advertising. *International Journal of Advertising*, 9(2), 121–135.
37. Bayo-Moriones, J.A.; Lera-López, F., 2007, A Firm-Level Analysis of Determinants of ICT Adoption in Spain, *Technovation*, XXVII (6-7) 2007: 352-366
38. Beheshti-Kashi, S., Karimi, H. R., Thoben, K.-D., Lutjen, M., Teucke, M., 2010, A survey on retail sales forecasting and prediction in fashion markets. *Systems Science & Control Engineering*, 3(1):154–161, 2015.
39. Berman, B., 2016, „Planning and implementing effective mobile marketing programs”, *Business Horizons*, vol. 59, issue 4.
40. Berthon, P. R., Pitt, L. F., Plangger, K., & Shapiro, D., 2012, Marketing meets Web 2.0, social media, and creative consumers: Implications for international marketing strategy. *Business Horizons*, 55(3), 261–271.
41. Bezdek, J.C., Ehrlich, R., Full, W., 1984. FCM: the fuzzy c-means clustering algorithm. *Comput. Geosci.* 10 (2–3), 191–203.
42. Bharadwaj A., El Sawy O. A., Pavlou P. A., Venkatraman N., 2013, Visions and Voices on Emerging Challenges in Digital Business Strategy. *MIS Q.* 37(2): 633-661
43. Bharadwaj, A., El Sawy, O. El, Pavlou, P., & Venkatraman, N., 2013, Digital business strategy: toward a next generation of insights. *MIS Quarterly*, 37(2), 471–482.
44. Bihani P., Patil S.T., 2014, A comparative study of data analysis techniques, *International Journal of Emerging Trends & Technology in Computer Science*, 3 (2), pp. 95-101
45. Bishop, C., 2007. *Pattern Recognition and Machine Learning (Information Science and Statistics)*. 2006. corr. 2nd printing edn.. first ed. Springer, New York.
46. Blunsom, P., 2004, Hidden Markov Models. Lecture notes, August, 15(18-19), 48
47. Bogina, V., Mokryn, O., & Kuflik, T., 2019, Will this session end with a purchase? Inferring current purchase intent of anonymous visitors. *Electronic Commerce Research and Applications*, 100836. doi:10.1016/j.elerap.2019.100836
48. Borgelt, C., 2005. An Implementation of the FP-growth algorithm. In: *Proceedings of the 1st international workshop on open source data mining: frequent pattern mining implementations*. ACM, pp. 1–5.
49. Bowman, M., 2017. Video marketing: the future of content marketing. *Forbes* 2017. <https://www.forbes.com/sites/forbesagencycouncil/2017/02/03/video-marketing-the-future-of-content-marketing/#694731296b53>.
50. Box, G. E. P. , Jenkins, G. M., Reinsel, G. C., 2013, *Time Series Analysis: Forecasting and Control*, 4th ed. John Wiley & Sons, Inc.
51. Boydell, B., McBratney, A., 2002. Identifying potential within-field management zones from cotton-yield estimates. *Precis. Agric.* 3 (1), 9–23.
52. Bratucu, T.O., Bratucu.G., 2006, Metode calitative utilizate în cercetarea de piata, *Qualitative Methods Used in Market Research*, Editura Economica

53. Braun, J., Amirshahi, S. A., Denzler, J., & Redies, C., 2013, Statistical image properties of print advertisements, visual artworks and images of architecture (Original Research) *Frontiers in Psychology*, 4(808).
54. Brodie, R. J., Hollebeek, L. D., Jurić, B., & Ilić, A., 2011, Customer Engagement. *Journal of Service Research*, 14(3), 252–271. doi:10.1177/1094670511411703
55. Bruckhaus, T., 2010, Collective Intelligence in Marketing. *Studies in Fuzziness and Soft Computing*, 131–154. doi:10.1007/978-3-642-15606-9_12
56. Bt Mohd, N. A., Zaaba, Z. F. (2019). A Review of Usability and Security Evaluation Model of Ecommerce Website. *Procedia Computer Science*, 161, 1199–1205. doi:10.1016/j.procs.2019.11.233
57. Budden, C.B., Anthony, J.F., Budden, M.C., Jones, M.A. (2011) Managing The Evolution Of A Revolution: Marketing Implications Of Internet Media Usage Among College Students. *College Teaching Methods & Styles Journal (CTMS)*
58. Bulut, A. (2015). Lean Marketing: Know who not to advertise to! *Electronic Commerce Research and Applications*, 14(6), 631–640. doi:10.1016/j.elerap.2015.09.004
59. Burges, C.J., 1998. A tutorial on support vector machines for pattern recognition. *Data Min. Knowl. Disc.* 2 (2), 121–167
60. Buttarelli, G., 2016, The EU GDPR as a clarion call for a new global digital gold standard. *International Data Privacy Law*, 6(2), 77–78. doi:10.1093/idpl/ipw006.
61. Cai, Filos-Ratsikas, Tang, Zhang, 2018, Reinforcement Mechanism Design for Fraudulent Behaviour in e-Commerce, AAAI Conference on Artificial Intelligence Thirty-Second AAAI Conference on Artificial Intelligence
62. Cappellini, B., Kravets, O., & Reppel, A., 2018, Shouting on social media? A borderscapes perspective on a contentious hashtag. *Technological Forecasting and Social Change*. doi:10.1016/j.techfore.2018.07.016
63. Caragher, J. M., 2013, "The Five Crucial Questions to Ask about Inbound Marketing," CPA Practice Management Forum.
64. Carey, P., 2004, *The Internet and E-Commerce*. London: Thorogood, 2001; Chan, H. "Consumer-Oriented Electronic Commerce." In *The Internet Encyclopedia*, Volume 1, edited by Hossein Bidgoli, 284-293. New Jersey: John Wiley & Sons, Inc.
65. Casanova, J.J., O'Shaughnessy, S.A., Evett, S.R., Rush, C.M., 2014. Development of a wireless computer vision instrument to detect biotic stress in wheat. *Sensors* 14 (9), 17753–17769.
66. Cha, J., 2009. Shopping on social networking Web sites: attitudes towards real versus virtual items. *J. Interactive Advertising* 10 (1), 77–93.
67. Chae, B., 2015, Insights from hashtag #supplychain and Twitter Analytics: Considering Twitter and Twitter data for supply chain practice and research. *International Journal of Production Economics*, 165, 247–259. doi:10.1016/j.ijpe.2014.12.037
68. Chaffey, D., 2006. *E-business and E-commerce Management: Strategy, Implementation and Practice*. Pearson Education, London.
69. Chamblee, R., & Sandler, D. M., 1992, Business-to-business advertising: Which layout style works best. *Journal of Advertising Research*, 32(6), 39–46.
70. Chandon, P., Wansink, B., Laurent, G., 2000, A benefit congruency framework of sales promotion effectiveness, *J. Mark.*, 64, pp. 65-81

71. Chang, E. C., Lv, Y., Chou, T. J., He, Q., & Song, Z., 2014, Now or later: Delay's effects on post-consumption emotions and consumer loyalty. *Journal of Business Research*, 67(7), 1368–1375.
72. Charles X Ling, Chenghui Li, 1998, Data mining for direct marketing: Problems and solutions., *Kdd* 73-79
73. Chatterjee, R. P., Deb, K., Banerjee, S., Das, A., 2019, WEB MINING USING K-MEANS CLUSTERING AND LATEST SUBSTRING ASSOCIATION RULE FOR E-COMMERCE, *Journal of Mechanics of Continua and Mathematical Sciences*, Netaji Subhash Engineering College, Kolkata, India.
74. Chen, M., Mao, S., Zhang, Y., Leung, V.C., 2014, *Big Data Related Technologies, Challenges and Future Prospects*, Springer International Publishing.
75. Chen, R., Hua, Q., Gao, Q., & Xing, Y., 2018, A Hybrid Recommender System for Gaussian Mixture Model and Enhanced Social Matrix Factorization Technology Based on Multiple Interests. *Mathematical Problems in Engineering*, 2018, 1–22. doi:10.1155/2018/9109647
76. Chen, X. C., Karpatne, A., Chamber, Y., Mithal, V., Lau, M., Steinhaeuser, K., Castilla-Rubio, J. C., 2012, A new data mining framework for forest fire mapping. 2012 Conference on Intelligent Data Understanding. doi:10.1109/cidu.2012.6382190
77. Chen, X., Xun, Y., Li, W., Zhang, J., 2010. Combining discriminant analysis and neural networks for corn variety identification. *Comput. Electron. Agric.* 71, S48–S53.
78. Cheng C. and Zhang C., 2014, Data-intensive applications, challenges, techniques and technologies: A survey on Big Data. *Information Sciences*. 275 (Aug. 2014). 314--34
79. Cheung, C.M., Thadani, D.R., 2012, The impact of electronic word-of-mouth communication: a literature analysis and integrative model, *Decis. Support. Syst.* 54 (1), 461–470.
80. Cheung, C.M., Thadani, D.R., 2012, What drives consumers to spread electronic word of mouth in online consumer-opinion platforms, *Decis. Support. Syst.* 53 (1), 218–225.
81. Cheung, M, Luo, C., Sia, C, and Chen, H., 2009, "Credibility of electronic word-of-mouth: Informational and Normative determinants of online consumer recommendations," *International Journal of Electronic Commerce*, Vol. 13, No.4, pp. 9-38.
82. Chevalier, J., & Mayzlin, D., 2006, The effect of word of mouth on sales: online book reviews. *Journal Of Marketing Research*, 43(3), 345–354
83. Chitturi, R. Raghunathan, R. Mahajan, V., 2008, Delight by design: the role of hedonic versus utilitarian benefits, *J. Mark.*, 72, pp. 48-63
84. Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H. and Bengio, Y., 2014. Learning phrase representations using RNN encoder-decoder for statistical machine translation. arXiv preprint arXiv:1406.1078.
85. Chu, S. C., & Kim, Y. J., 2011, Determinants of consumer engagement in electronic word-of-mouth (eWOM) in social networking sites. *International Journal of Advertising*, 30(1), 47–75.
86. Chua, A., Banerjee, S., 2013, Customer Knowledge Management via Social Media: The case of Starbucks. *Journal of Knowledge Management*, 17(2):237-249.
87. Chung, C., & Austria, K., 2010, Social media gratification and attitude toward social media marketing messages: a study of the effect of social media marketing messages on online shopping value. *Proceedings Of The Northeast Business & Economics Association*, 581–586

88. Comisia Europeană, On Artificial Intelligence - A European approach to excellence and trust, ec.europa.eu/info/sites/info/files/commission-white-paper-artificial-intelligence-feb2020_en.pdf, Brussels, 19.2.2020 COM (2020) 65 final
89. Cortes, C., Vapnik, V., 1995. Support-vector networks. *Machine Learn.* 20 (3), 273–297.
90. Comportamente de cumpărare în era consumatorilor digitali 2018, valoria.ro/produs/comportamente-de-cumparare-in-era-consumatorilor-digitali-2018, accesibil 19.09.2020
91. Criminisi, A., Shotton, J., Konukoglu, E., 2012. Decision forests: a unified framework for classification, regression, density estimation, manifold learning and semi-supervised learning. *Found. Trends Comput. Graph. Vis.* 7 (2–3), 81–227.
92. Cui, J. Mou, J. Cohen, Y. Liu, K. Kurcz, Understanding consumer intentions toward cross-border m-commerce usage: a psychological distance and commitment-trust perspective, *Electronic Commerce Research and Applications* (2019), doi: <https://doi.org/10.1016/j.elerap.2019.10092>
93. Dang, T. K., Vo, A. K., & Küng, J., 2017, A NoSQL Data-Based Personalized Recommendation System for C2C e-Commerce. *Database and Expert Systems Applications*, 313–324. doi:10.1007/978-3-319-64471-4_25
94. Dave Chaffey, Mark E Patron, 2012, From web analytics to digital marketing optimization: Increasing the commercial value of digital analytics, *Journal of Direct, Data and Digital Marketing Practice*
95. Davenport T. H., Harris J. G., 2007, *Competing on Analytics: The New Science of Winning*, Harvard Business School Press, 60 Harvard Way Boston, MA, United States
96. Davenport, T. H., Barth, P., & Bean, R., 2012, How big data is different. *MIT Sloan Management Review*, 54(1), 43–46.
97. David Rohde, Stephen Bonner, Travis Dunlop, Flavian Vasile, Alexandros Karatzoglou, 2018, RecoGym: A Reinforcement Learning Environment for the problem of Product Recommendation in Online Advertising, *Information Retrieval; Machine Learning (cs.LG)*.
98. Davis, S., Brodersen, S., Böhmer, G., & Siemens, A., 2017, „Digitalization sparks a quiet revolution”, *World Pumps*, Volume 2017, Issue 5, May 2017, Pages 28-31
99. De Bruyn, A., & Lilien, G. L., 2008, A multi-stage model of word-of-mouth influence through viral marketing. *International Journal of Research in Marketing*, 25(3), 151–163.
100. De la Torre, J., Puig, D., & Valls, A., 2018, Weighted kappa loss function for multi-class classification of ordinal data in deep learning. *Pattern Recognition Letters*, 105, 144–154. doi:10.1016/j.patrec.2017.05.018
101. De Maio, C., Fenza, G., Gallo, M., Loia, V., & Parente, M., 2017, Social media marketing through time-aware collaborative filtering. *Concurrency and Computation: Practice and Experience*, 30(1), e4098. doi:10.1002/cpe.4098
102. De Pelsmacker, P., van Tilburg, S., & Holthof, C., 2018, Digital marketing strategies, online reviews and hotel performance. *International Journal of Hospitality Management*, 72, 47–55. doi:10.1016/j.ijhm.2018.01.003
103. Delen, D., & Zolbanin, H. M., 2018, The analytics paradigm in business research. *Journal of Business Research*, 90, 186–195. doi:10.1016/j.jbusres.2018.05.013
104. Dempster, A.P., Laird, N.M., Rubin, D.B., 1977. Maximum likelihood from incomplete data via the EM algorithm. *J. Roy. Stat. Soc. B(methodological)* 1–38.

105. Deng, J., W. Dong, R. Socher, L.-J. Li, K. Li, and L. Fei-Fei, 2009, "ImageNet: A Large-Scale Hierarchical Image Database." Proceedings of the 2009 IEEE Conference on Computer Vision and Pattern Recognition. Miami, FL, pp. 248-255.
106. DeSteno, D., Wegener, D. T., Petty, R. E., Rucker, D. D., & Braverman, J., 2004. Discrete Emotions and Persuasion: The Role of Emotion-Induced Expectancies. *Journal of personality and social psychology*, 86(1), 43-56.
107. Deval, H., & Kardes, F. R., 2010, Consumer information processing. *Wiley International Encyclopedia of Marketing*. John Wiley & Sons, Ltd.
108. Dezhi Wu, Il Im, Tremaine, M., Instone, K., & Turoff, M. (2003). A framework for classifying personalization scheme used on e-commerce Websites. 36th Annual Hawaii International Conference on System Sciences, 2003. Proceedings of The. doi:10.1109/hicss.2003.1174586
109. Dhruv Parthasarathy, A Brief History of CNNs in Image Segmentation: From R-CNN to Mask R-CNN, <https://blog.athelas.com/a-brief-history-of-cnns-in-image-segmentation-from-r-cnn-to-mask-r-cnn-34ea83205de4>
110. Domingos., P., 2012, A few useful things to know about machine learning. *Communications of the ACM*, 55(10):78–87, 2012.
111. Dong-Hee S., Min Jae C., 2015, Ecological views of big data: Perspectives and issues. *Telematics Informatics* 32(2): 311-320
112. Dong, X., 2012, Index system and evaluation model of e-commerce customer satisfaction. 2012 IEEE Symposium on Robotics and Applications (ISRA). doi:10.1109/isra.2012.6219219
113. Duan, W., Gu, B., Whinston, A.B., 2008, The dynamics of online word of mouth and product sales: an empirical investigation of the movie industry. *J. Retail.* 84 (2), 233–242.
114. Duch-Brown, Nn., Martens, B., & Mueller-Langer, F., 2017, The Economics of Ownership, Access and Trade in Digital Data. *SSRN Electronic Journal* . doi:10.2139/ssrn.2914144.
115. E. Francesconi, Paolo Frascioni, Marco Gori, S. Marinai, J.Q. Sheng, G. Soda, and Alessandro Sperduti, 1998, Logo recognition by recursive neural networks, *Graphics Recognition Algorithms and Systems*.
116. E. Holmen, T.B. Aune, A.-C. Pedersen, 2013, Network pictures for managing key supplier relationships, *Industrial Marketing Management*, 42 (2), pp. 139-151
117. Eckler, Petya and Shelly Rodgers, 2010, "Viral Advertising: A Conceptualization," Annual Meeting of the Association for Education in Journalism and Mass Communication, Denver, CO
118. Eisenmann, T., Parker, G., Alstyne, M.W.V., 2006, Strategies for two-sided markets, *Harvard Business Review*, 84 (10), pp. 92-101
119. Engle, R. F. , 1982, "Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation," *Econometrica*, vol. 50, issue 4, pp. 987-1008.
120. Erevelles, S., Nobuyuki Fukawa, N, Swayne, L, 2016, Big Data consumer analytics and the transformation of marketing, *Journal of Business Research*, 2016, vol. 69, issue 2, 897-904
121. Evans, D. and McKee, J., 2010. *Social Media Marketing: The Next Generation of Business Engagement*. Indiana: John Wiley and Sons.
122. Fan, X., B. Thompson and L. Wang, 1999. Effects of sample size, estimation method and model specification on structural equation modeling fit indexes. *Structural Equation Modeling*, 6: 56-83.
123. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks, <https://arxiv.org/abs/1506.01497>

124. Fatanti, M. N., & Suyadnya, I. W., 2015, Beyond User Gaze: How Instagram Creates Tourism Destination Brand? *Procedia - Social and Behavioral Sciences*, 211, 1089–1095. doi:10.1016/j.sbspro.2015.11.145
125. Feigl, J., Bogdan, M., 2019, Neural networks for personalized item rankings, *Neurocomputing* 342 (2019) 60–65 61
126. Finn, A., 1988, Print ad recognition readership scores: An information processing perspective. *Journal of Marketing Research*, 25(2), 168–177.
127. Fisher, M., 1997, What is the right supply chain for your product? A simple framework can help you figure out the answer, *Harvard Business Review*, 36, 105–116.
128. Forrest N. Iandola, Anting Shen, Peter Gao, Kurt Keutzer, 2015, DeepLogo: Hitting Logo Recognition with the Deep Neural Network Hammer, *Computer Vision and Pattern Recognition*, Oct 2015
129. Francisco J. Martínez-López, Yangchun Li, Huaming Liu, Changyuan Feng, 2020, Do safe buy buttons and integrated path-to-purchase on social platforms improve users' shopping-related responses?, *Electronic Commerce Research and Applications* 39 (2020) 100913.
130. Frank, E., Trigg, L., Holmes, G., Witten, I.H., 2000. Naive bayes for regression. *Machine Learn.* 41 (1), 5–25
131. Franses, Ph.H.B.F., & van Oest, R.D., 2004, On the econometrics of the Koyck model (No. EI 2004-07). Report / Econometric Institute, Erasmus University Rotterdam. Retrieved from <http://hdl.handle.net/1765/1190>
132. Füller, J., Bartl, M., Ernst, H., & Mühlbacher, H., 2006, Community based innovation: How to integrate members of virtual communities into new product development. *Electronic Commerce Research*, 6(1), 57–73.
133. G.N. Punj, 2013, Do consumers who conduct online research also post online reviews? A model of the relationship between online research and review posting behavior, *Mark. Lett.* 24.
134. Gandomi, A., & Haider, M., 2015, Beyond the hype: Big data concepts, methods, and analytics. *International Journal of Information Management*, 35(2), 137–144.
135. Gangyan Xu, Xuan Qiu, Meng Fang, Xiaofei Kou, Ying Yu, 2019, Data-driven operational risk analysis in E-Commerce Logistics, *Advanced Engineering Informatics*
136. Gerrikagoitia, J., Castander, I., Rebóna, F., & Sorzabala, A., 2014, „New trends of Intelligent E-Marketing based on Web Mining for e-shops” *Procedia - Social and Behavioral Sciences* 175: 75–83
- 137. Marius Geru, Angela Eliza Micu, Alexandru Capatina, Adrian Micu, (2018), Using Artificial Intelligence on Social Media's User Generated Content for Disruptive Marketing Strategies in eCommerce, *Economics and Applied Informatics*, 2, 2018**
138. Ghavamipour, H., Hashemi Golpayegani, S. A., 2019, A Reinforcement Learning Based Model for Adaptive Service Quality Management in E-Commerce Websites. *Business & Information Systems Engineering*. doi:10.1007/s12599-019-00583-6
139. Ghosh, S., Dubey, S.K., 2013, Comparative analysis of k-means and fuzzy c-means algorithms. *Int. J. Adv. Comput. Sci. Appl.* 4 (4), 35–39.
140. Gilliland, D. I., & Johnston, W. J., 1997, Toward a model of business-to-business marketing communications effects. *Industrial Marketing Management*, 26(1), 15–29.

141. Girshick, R., Donahue, J., Darrell, T., Malik, J., 2014, "Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation." Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition. Columbus, OH, June 2014, pp. 580-587.
142. Goel, A., Gautam, J., & Kumar, S., 2016, Real time sentiment analysis of tweets using Naive Bayes. 2016 2nd International Conference on Next Generation Computing Technologies (NGCT). doi:10.1109/ngct.2016.7877424
143. Golovin, N., Rahm, E., 2004, Reinforcement learning architecture for Web recommendations. International Conference on Information Technology: Coding and Computing. Proceedings. ITCC 2004. doi:10.1109/itcc.2004.1286487
144. Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., et al. (2014). Generative adversarial nets. Advances in Neural Information Processing Systems. Montréal: NeurIPS.
145. Govindarajan, M., & Chandrasekaran, R., 2010, Evaluation of k-Nearest Neighbor classifier performance for direct marketing. Expert Systems with Applications, 37(1), 253–258. doi:10.1016/j.eswa.2009.04.055
146. Grandon, Elizabeth and Pearson, J. Michael, 2004, "E-Commerce Adoption: Perceptions of Managers/Owners of Small and Medium Sized Firms in Chile," Communications of the Association for Information Systems: Vol. 13 , Article 8. DOI: 10.17705/1CAIS.01308 Available at: <https://aisel.aisnet.org/cais/vol13/iss1/8>
147. Grönroos, C., & Ravald, A., 2011, Service as business logic: Implications for value creation and marketing. Journal of Service Management, 22(1), 5–22.
148. Guan, S.-U., Chan, T. K., & Zhu, F., 2005, Evolutionary intelligent agents for e-commerce: Generic preference detection with feature analysis. Electronic Commerce Research and Applications, 4(4), 377–394. doi:10.1016/j.eelerap.2005.07.002
149. Guerrero, J.M., Pajares, G., Montalvo, M., Romeo, J., Guijarro, M., 2012. Support vector machines for crop/weeds identification in maize fields. Expert Syst. Appl. 39 (12), 11149–11155.
150. Guimaraes, C.V., Grzeszczuk, R., Bisset, G.S., Donnelly, L.F., 2018, Comparison between manual auditing and a natural language process with machine learning algorithm to evaluate faculty use of standardized reports in radiology, J. Am. Coll. Radiol. 15 (2018) 550–553
151. Gunasekaran, A., Marri, H.B., McGaughey, R.E., Nebhwani, M.D., 2002. E-commerce and its impact on operations management. International Journal of Production Economics 75 (1–2), 185–197.
152. GUO Wei-gang, SONG Yi-bing ,LUO Yi-ling, 2005, Mining User Access Patterns at E-Commerce Sites , MICROELECTRONICS & COMPUTER XiAn China, vo122, May 2005, pp 170-174.
153. Hajli, M. N., Lin, X., Featherman, M., & Wang, Y., 2014, Social word of mouth: how trust develops in the market. International Journal of Market Research, 56(5)
154. Hajli, N., & Lin, X., 2014, Exploring the security of information sharing on social networking sites: the role of perceived control of information. Journal of Business Ethics, 1–13.
155. Hand, D. J., & Henley, W. E., 1997, Statistical classification methods in consumer credit scoring: A review. Journal of Royal Statistics Society, 160, 523–541

156. Hang Su, Xiatian Zhu, Shaogang Gong., 2017, Deep Learning Logo Detection with Data Expansion by Synthesising Context IEEE Winter Conference on Applications of Computer Science (WACV), Santa Rosa, USA, March 2017.
157. Hanna, R., Rohm, A., Crittenden, V. L., 2011. "We're all connected: The power of the social media ecosystem," *Business Horizons*, Elsevier, vol. 54(3), pages 265-273
158. Hanssens, D. M., & Weitz, B. A., 1980, The effectiveness of industrial print advertisements across product categories. *Journal of Marketing Research*, 17(3), 294–306.
159. Häubl, G., and Trifts, V. 2000. "Consumer decision making in online shopping environments: The effects of interactive decision aids," *Marketing Science* (19:1), pp. 4–21.
160. Hauser, J., Tellis, G.J., Griffin, A., 2006, Research on innovation: A review and agenda for marketing science. *Marketing science*, 25(6), pp.687-717
161. Hayes, Jameson L. and Karen W. King, 2014, "The Social Exchange of Viral Ads: Referral and Coreferral of Ads Among College Students," *Journal of Interactive Advertising*, 14, 2, 98–109, <https://doi.org/10.1080/15252019.2014.942473>.
162. Hennig-Thurau, T., Gwinner, K. P., Walsh, G., & Gremler, D. D., 2004, Electronic word-of mouth via consumer-opinion platforms: What motivates consumers to articulate themselves on the internet? *Journal of Interactive Marketing*, 18(1), 38–52.
163. Hirschman, E. C., Holbrook, M. B., 1982, Hedonic consumption: Emerging concepts, methods and propositions. *Journal of Marketing*, 92–101.
164. Ho, S. Y., Bodoff, D., and Tam, K. Y. 2011. "Timing of adaptive web personalization and its effects on online consumer behavior," *Information Systems Research* (22:3), pp. 660–679.
165. Hochreiter, S., Bengio, Y., Frasconi, P. and Schmidhuber, J., 2001. Gradient flow in recurrent nets: the difficulty of learning long-term dependencies.
166. Hochreiter, S., Schmidhuber, J., 1997. Long short-term memory. *Neural computation*, 9(8), pp.1735-1780.
167. Hollebeek, L. D., Glynn, M. S., & Brodie, R. J., 2014, Consumer Brand Engagement in Social Media: Conceptualization, Scale Development and Validation. *Journal of Interactive Marketing*, 28(2), 149–165. doi:10.1016/j.intmar.2013.12.002
168. Holman L., Head M.L., Lanfear R., Jennions M.D., 2015, Evidence of Experimental Bias in the Life Sciences: Why We Need Blind Data Recording. *PLoS Biol* 13(7): e1002190. <https://doi.org/10.1371/journal.pbio.1002190>
169. Hong, H., Xu, D., Wang, G.A., Fan, G.A., 2017, Understanding the determinants of online review helpfulness: a meta-analytic investigation, *Decis. Support. Syst.* 102, 1–11.
170. Hong, I.B, Cha, H. S. 2013, The mediating role of consumer trust in an online merchant in predicting purchase intention, *International Journal of Information Management*, Volume 33, Issue 6, December 2013, Pages 927-939
171. Hong, W., Zhu, K., 2006, Migrating to internet-based e-commerce: Factors affecting e-commerce adoption and migration at the firm level. *Information & Management*, 43(2), 204–221. doi:10.1016/j.im.2005.06.003
172. Hosseini, S. M. S., Maleki, A., & Gholamian, M. R., 2010, Cluster analysis using data mining approach to develop CRM methodology to assess the customer loyalty. *Expert Systems with Applications*, 37(7), 5259–5264. doi:10.1016/j.eswa.2009.12.070

173. Hoyer, W. D., Chandy, R., Dorotic, M., Krafft, M., & Singh, S. S., 2010, Consumer cocreation in new product development. *Journal of Service Research*, 13(3), 283–296.
174. Hoyle, R.H., Ed, 1995. *Structural Equation Modeling. Concepts, Issues and Applications*, Thousand Oaks, CA: Sage Publications.
175. Hsu, Shih C., 1987, *English of Management*. Tunghua Publishing Co., LTD. Retrieved from <http://www.amsreview.org/articles/mcquitty10-2000.pdf>
176. Hype Cycle for Digital Marketing and Advertising, 2017, <https://www.gartner.com/en/documents/3765365/hype-cycle-for-digital-marketing-and-advertising-2017>
177. Imran K. Jalozie, H. Joseph Wen, H. Lisa Huang, 2016, A Framework for Selecting E-Commerce Business Models,
178. Jain, K., 2015, "Machine learning basics for a newbie," <https://www.analyticsvidhya.com/blog/2015/06/machine-learning-basics/>, june 11, 2015
179. Jansen, B.J., Sobel, K., Cook, G., 2011. Classifying ecommerce information sharing behaviour by youths on social networking sites. *Journal of Information Science* 37 (2), 120–136.
180. Janssen, M. & Sol, H., 2000, Evaluating the role of intermediaries in the electronic value chain. *Internet Research: Electronic Networking Applications and Policy*, 10, 5.
181. Jevons, W. S. , 1879, *The Theory of Political Economy*, Macmillan and Company.
182. Jian Jin, Ying Liu, Ping Ji & Hongguang Liu, 2016, Understanding big consumer opinion data for market-driven product design, *International Journal of Production Research*, 54:10, 3019-3041, DOI: 10.1080/00207543.2016.1154208
183. Jian-Guo Zhang, Pengcheng Zou, Zhao Li, Yao Wan, Xiuming Pan, Yu Gong, Philip S. Yu, 2019, Multi-Modal Generative Adversarial Network for Short Product Title Generation in Mobile E-Commerce, arXiv:1904.01735
184. Jiang, H., Chen, Y., Qiao, Z., Weng, T.H., Li, K.C., 2015, Scaling up MapReduce-based big data processing on multi-GPU systems, *Cluster Computing*, 18 (1), pp. 369-383
185. Jin X., Wah B. W., Cheng X., Wang Y, 2015, Significance and Challenges of Big Data Research. *Big Data Res.* 2(2): 59-64
186. Joel S.E. Teo , Eiichi Taniguchi , Ali Gul Qureshi, *Procedia*, 2012, *Social and Behavioral Sciences* 39, 349 – 359 357
187. Jones, M. A., Reynolds, K. E., & Arnold, M. J., 2006, Hedonic and utilitarian shopping value: Investigating differential effects on retail outcomes. *Journal of Business Research*, 59(9), 974–981.
188. Jordan, M.I., Mitchell, T.M., 2015, Machine learning: trends, perspectives, and prospects, *Science* 349
189. Joseph., R. C., Johnson., N. A., 2013, Big data and transformational government. *IT Professional*. 15(6). 43-45.
190. Jukic, N., Sharma, A., Nestorov, S., Jukic, B, 2015, Augmenting Data Warehouses with Big Data. *IS Management* 32(3): 200-209
191. Juntunen, M., Ismagilova, E., Oikarinen, E.-L., 2019, B2B brands on Twitter: Engaging users with a varying combination of social media content objectives, strategies, and tactics, *Industrial Marketing Management*.

192. Kang, M., Gao, Y., Wang, T., & Wang, M., 2015, The Role of Switching Costs in O2O Platforms: Antecedents and Consequences. *International Journal of Smart Home*, Vol. 9, No. 3 (2015), pp. 135-150.
193. Kao, S.-C., Wu, C., 2016, The role of creation mode and social networking mode in knowledge creation performance: Mediation effect of creation process, *Information & Management*, 53 (6), pp. 803-816.
194. Kapoor, K. K., Tamilmani, K., Rana, N. P., Patil, P., Dwivedi, Y. K., & Nerur, S., 2018, Advances in social media research: Past, present and future. *Information Systems Frontiers*, 20(3), 531–558.
195. Karavdic, M., & Gregory, G., 2005, Integrating e-commerce into existing export marketing theories: A contingency model. *Marketing Theory*, 5(1), 75–104.
196. Katharina Ebner, Thilo Buhnen, Nils Urbach, 2014, Think Big with Big Data: Identifying Suitable Big Data Strategies in Corporate Environments. *HICSS 2014*: 3748-3757
197. Kennedy, D., Norman, C., 2005, What Don't We Know? *Science*, 309, 78
198. Kessler, J. S., 2017, Scattertext: a Browser-Based Tool for Visualizing how Corpora Differ, arXiv:1703.00565v3
199. Kim G., Trimi S. and Chung J., 2014. Big-data applications in the government sector. *Communications of the ACM*. 57, 3 (Mar. 2014). 78--85
200. Kim, A. J., Ko, E., 2012, Do social media marketing activities enhance customer equity? An empirical study of luxury fashion brand. *Journal of Business Research*, 65, 1480–1486
201. Kim, K., & Ahn, H., 2005, Using a Clustering Genetic Algorithm to Support Customer Segmentation for Personalized Recommender Systems. *Artificial Intelligence and Simulation*, 409–415. doi:10.1007/978-3-540-30583-5_44
202. Kim, Phil., 2017, *Matlab Deep Learning: With Machine Learning, Neural Networks and Artificial Intelligence*, <https://www.apress.com/us/book/9781484228449>
203. Kirchgässner, G., Wolters, J., 2007, *Introduction to Modern Time Series Analysis*, Springer.
204. Kleijnen, M, Lievens, A., de Ruyter, J.C., Wetzels, M.G.M, 2009. Knowledge creation through mobile social networks and its impact on intentions to use innovative mobile services. *J. Serv. Res.* 12, 15–35.
205. Kohler, C.F., Rohm, A.J., Ruyter, J.C.de, Wetzels, M., 2011. Return on interactivity: the impact of online agents on newcomer adjustment. *J. Market.* 75, 93–108 93 March 2011.
206. Kotler, P., 2003, *Marketing Management*. 11th Edition, Prentice-Hall, Upper Saddle River
207. Kotler, P., Kartajaya, H., and Setiawan, I., 2017, *Marketing 4.0: Moving from Traditional to Digital*. Hoboken, NJ: John Wiley and Sons.
208. Koyck, L. M., 1954, "Distributed Lags and Investment Analysis," Amsterdam: North-Holland
209. Kozlenkova, I., Samaha, S., Palmatier, R., 2014, Resource-Based Theory in Marketing, *Journal of the Academy of Marketing Science*
210. Krizhevsky, A., Sutskever, I., Hinton, G.E., 2017, ImageNet classification with deep convolutional neural networks, *Commun. ACM* 60
211. Kukar-Kinney, M., Close, A.G., 2010, The determinants of consumers' online shopping cart abandonment, *Journal of the Academy of Marketing Science*,
212. Kumar A., Niu F., Ré C., Hazy, 2013, Making it Easier to Build and Maintain Big-Data Analytics, *Communications of the ACM* 56 (3) 40–49.

213. Kumar, A., Bezawada, R., Rishika, R., Janakiraman, R., & Kannan, P. K., 2016, From social to sale: The effects of firm-generated content in social media on customer behavior. *Journal of Marketing*, 80(1), 7–25.
214. Kumar, B.S., Rukmani, K.V., 2010. Implementation of web usage mining using APRIORI and FP growth algorithms. *Int. J. Adv. Netw. Appl.* 1 (06), 400–404.
215. Kumar, R., Novak, J. si Tomkins, A., 2010. Structure and evolution of online social networks, *Link Mining: Models, Algorithms and Applications*
216. Kumar, V., Lahiri, A., Dogan, O.B., 2017, A strategic framework for a profitable business model in the sharing economy, *Industrial Marketing Management*, 69, pp. 147-160
217. Labrinidis A., Jagadish H. V., 2012, Challenges and Opportunities with Big Data. *Proc. VLDB Endow.* 5(12): 2032-2033
218. Latiff, Z. A., & Safiee, N. A. S., 2015, New Business Set Up for Branding Strategies on Social Media – Instagram. *Procedia Computer Science*, 72, 13–23. doi:10.1016/j.procs.2015.12.100
219. Lau, H. C. W., Jiang, Z.-Z., Ip, W. H., & Wang, D., 2010, A credibility-based fuzzy location model with Hurwicz criteria for the design of distribution systems in B2C e-commerce. *Computers & Industrial Engineering*, 59(4), 873–886. doi:10.1016/j.cie.2010.08.018
220. Lee, I., Lee, K., 2015, The Internet of Things (IoT): Applications, investments, and challenges for enterprises, *Business Horizons*, Volume 58, Issue 4, July–August 2015, Pages 431-440
221. Lee, S. M., Olson, D. L., & Trimi, S., 2012, Co-innovation: convergenomics, collaboration, and co-creation for organizational values. *Management Decision*, 50(5), 817–831.
222. LEE, S., LEE, S., PARK, Y., 2007, A prediction model for success of services in e-commerce using decision tree: E-customer's attitude towards online service. *Expert Systems with Applications*, 33(3), 572–581. doi:10.1016/j.eswa.2006.06.005
223. Leeflang, P.S., Verhoef, P.C., Dahlström, P., and Freundt, T., 2014, Challenges and solutions for marketing in a digital era. *European management journal*, 32(1), 1–12
224. Lei, S., Xinming, M., Lei, X., & Xiaohong, H., 2010, Financial Data Mining Based on Support Vector Machines and Ensemble Learning. 2010 International Conference on Intelligent Computation Technology and Automation. doi:10.1109/icit.2010.787
225. Lemon, K. N., & Verhoef, P. C., 2016, Understanding customer experience throughout the customer journey. *Journal of Marketing*, 80(6), 69–96.
226. Li, Y., Murali, P., Shao, N., & Sheopuri, A., 2015, Applying Data Mining Techniques to Direct Marketing: Challenges and Solutions. 2015 IEEE International Conference on Data Mining Workshop (ICDMW). doi:10.1109/icdmw.2015.30
227. Liang, T.-P., Turban, E., 2011, Introduction to the special issue social commerce: a research framework for social commerce. *International Journal of Electronic Commerce*, 16(2) [5–14]
228. Liao, Z., Yin, Q., Huang, Y., & Sheng, L., 2015, Management and application of mobile big data. *International Journal of Embedded Systems*, 7(1), 63. doi:10.1504/ijes.2015.066143
229. Libai, B., Bart, Y., Gensler, S., Hofacker, C. F., Kaplan, A., Kötterheinrich, K., & Kroll, E. B.. 2020, Brave New World? On AI and the Management of Customer Relationships. *Journal of Interactive Marketing*. doi:10.1016/j.intmar.2020.04.002
230. Lin, Y., Wu, L.-Y., 2014, "Exploring the role of dynamic capabilities in firm performance under the resource-based view framework," *Journal of Business Research*, Elsevier, vol. 67(3), pages 407-413.

231. LINDSTROM, M., 2016, Small Data. Indicii mărunte care scot la iveală trenduri în masă. Traducere de Emilia Vasiliu. Bucureşti: Publica.
232. Lipsman, A., 2019. Global ecommerce 2019: ecommerce continues strong gains amid global economic uncertainty. available at: <https://www.emarketer.com/content/global-ecommerce-2019>.
233. Liu, D.-R., & Liou, C.-H., 2011, Mobile commerce product recommendations based on hybrid multiple channels. *Electronic Commerce Research and Applications*, 10(1), 94–104. doi:10.1016/j.elerap.2010.08.004
234. Lixandriou, R. Maican, C., 2015, An Analysis On Choosing A Proper Ecommerce Platform, Risk in Contemporary Economy, Dunarea de Jos University of Galati, Faculty of Economics and Business Administration.
235. Llorca, D. F., Arroyo, R., Sotelo, M. A., 2013, Vehicle logo recognition in traffic images using HOG features and SVM, 16th International IEEE Conference on Intelligent Transportation Systems (ITSC 2013).
236. Lohtia, R., Johnston, W. J., & Aab, L., 1995, Business-to-business advertising: What are the dimensions of an effective print ad? *Industrial Marketing Management*, 24(5), 369–378.
237. Lord, K. R., & Gupta, p. B., 2010, Response of buying-center participants to B2B product placements. *Journal of Business & Industrial Marketing*, 25(3), 188–195.
238. Lu, P., Wu, X., & Teng, D., 2015, Hybrid Recommendation Algorithm for E-Commerce Website. 2015 8th International Symposium on Computational Intelligence and Design (ISCID). doi:10.1109/iscid.2015.140
239. Ludwig, S., de Ruyter, J.C., 2016, Decoding social media speak: developing a speech act theory research agenda. *J. Consum. Market.* 33, 124–134.
240. Luo, X., 2010, Uses and gratifications theory and e-consumer behaviors: A structural equation modeling study. *Journal of Interactive Advertising*, 2(2), 34–41.
241. Luo, X., Tong, S., Fang, Z., & Qu, Z., 2019, Frontiers: machines vs. humans: The impact of artificial intelligence chatbot disclosure on customer purchases. *Marketing Science*, 38(6), 937–947. Marr, B. (2018). The AI skills crisis and how to close
242. Lv, Y., & Zhai, C., 2009, Adaptive relevance feedback in information retrieval. In *Proceeding of the 18th ACM conference on information and knowledge management (CIKM)* (pp. 255–264).
243. Lycett M., 2013, 'Datafication': making sense of (big) data in a complex world. *Eur. J. Inf. Syst.* 22(4): 381–386
244. Ma, N., Guan, J., Zhao, Y., 2008, Bringing PageRank to the citation analysis. *Information Processing & Management*, 44(2), 800–810.
245. Mackenzie, S. B., 1986, The role of attention in mediating the effect of advertising on attribute importance. *Journal of Consumer Research*, 13(2), 174–195.
246. MacInnis, D. J., & Jaworski, B. J., 1989, Information processing from advertisements: Toward an integrative framework. *Journal of Marketing*, 53(4), 1–23.
247. Maican, C., Lixandriou, R., & Constantin, C., 2016, Interactivia.ro – A study of a gamification framework using zero-cost tools. *Computers in Human Behavior*, 61, 186–197. doi:10.1016/j.chb.2016.03.023
248. Malekipirbazari, M., Aksakalli, V., 2015, Risk assessment in social lending via random forests. *Expert Systems with Applications*, 42(10), 4621–4631. doi:10.1016/j.eswa.2015.02.001

249. Malkiel, B.G., 2003, The efficient market hypothesis and its critics. *Journal of economic perspectives*, 17(1), pp.59-82.
250. Mangold, W. G., Faulds, D.J., 2009, Social media: The new hybrid element of the promotion mix. *Business Horizons*, 52(4): 357-365
251. Manyika, J., Chui, M., Brown, B., Bughin, J., Dobbs, R., Roxburgh, C., Hung Byers, A., 2011, *Big Data: The Next Frontier for Innovation, Competition, and Productivity*, McKinsey Global Institute.
252. Marlene ten Ham, 2019, European Ecommerce report, https://www.ecommerce-europe.eu/wp-content/uploads/2019/07/European_Ecommerce_report_2019_freeFinal-version.pdf
253. Martin Lindstrom, 2010, *Buyology: Truth and Lies About Why We Buy*, Paperback, Broadway Business
254. Martínez-Ruiz, M. P., Mollá-Descals, A., Gómez-Borja, M. A., & Rojo-Álvarez, J. L., 2006, Assessing the impact of temporary retail price discounts intervals using SVM semiparametric regression. *The International Review of Retail, Distribution and Consumer Research*.
255. McAfee, A., Brynjolfsson, E., 2012, *Big Data: The Management Revolution*. Harvard Business Review.
256. McLean, G., Osei-Frimpong, K., Al-Nabhani, K., & Marriott, H. (2020). Examining consumer attitudes towards retailers' m-commerce mobile applications – An initial adoption vs. continuous use perspective. *Journal of Business Research*, 106, 139–157. doi:10.1016/j.jbusres.2019.08.032
257. Meenal Dhande, 2020, What is the difference between AI, machine learning and deep learning?, www.geospatialworld.net/blogs/difference-between-ai%EF%BB%BF-machine-learning-and-deep-learning, accesat 20.09.2020
258. Mehta, P., Shah, B., 2016, Review on techniques and steps of computer-aided skin cancer diagnosis, *Procedia Computer Science* 85 (2016) 309–316
259. Melody Y. Kiang, T. S. Raghu, Kevin Huei-Min Shang, 2000, Marketing on the Internet - who can benefit from an online marketing approach? *Decis. Support Syst.* 27(4)
260. Mikolov, T. et al. (2013b). "Efficient Estimation of Word Representations in Vector Space". In: arXiv preprint arXiv:1301.3781.
261. Minsky, M. (1961). Steps toward Artificial Intelligence. *Proceedings of the IRE*, 49(1), 8–30. doi:10.1109/jrproc.1961.287775
262. Mitchell, T.M., 1997, *Machine Learning*, WCB
263. Mitik, M., Korkmaz, O., Karagoz, P., Toroslu, I. H., & Yucel, F. (2016). Data Mining Based Product Marketing Technique for Banking Products. 2016 IEEE 16th International Conference on Data Mining Workshops (ICDMW).
264. Mobasher, B., Cooley, R., & Srivastava, J. (n.d.). Creating adaptive Web sites through usage-based clustering of URLs. *Proceedings 1999 Workshop on Knowledge and Data Engineering Exchange (KDEX'99)* (Cat. No.PR00453).
265. Moe, W. W., Fader, P. S., 2004, Dynamic Conversion Behavior at E-Commerce Sites. *Management Science*, 50(3), 326–335.
266. Moe, W.W., Fader, P.S., 2004. Capturing evolving visit behaviour in clickstream data. *Journal of Interactive Marketing* 18 (1), 5e19.

267. Mohammad Nazir Ahmad Sharif, Ng Moon Ching, Aryati Bakri, Nor Hidayati Zakaria, 2005, Using a Priori Algorithm for Supporting an e-Commerce System, *Journal of Information Technology Impact*, Vol. 5, No. 3, pp. 129-138
268. Mollen, A., & Wilson, H., 2010, Engagement, telepresence and interactivity in online consumer experience: Reconciling scholastic and managerial perspectives. *Journal of Business Research*, 63(9-10), 919–925. doi:10.1016/j.jbusres.2009.05.014
269. Monaghan A., Lycett M., 2013, Big data and humanitarian supply networks: Can Big Data give voice to the voiceless? *GHTC*: 432-437
270. Naik, H.S., Zhang, J., Lofquist, A., Assefa, T., Sarkar, S., Ackerman, D., Ganapathysubramanian, B., 2017. A real-time phenotyping framework using machine learning for plant stress severity rating in soybean. *Plant Methods* 13 (1), 23.
271. Nam, K., Baker, J., Ahmad, N., Goo, J., 2019, Determinants of writing positive and negative electronic word-of-mouth: empirical evidence for two types of expectation confirmation, *Decis. Support. Syst.*
272. Nambisan, S., & Baron, R. A., 2007, Customer environments: Relationship management. *Journal of Interactive Marketing*, 21(2), 42–62.
273. Nambisan, S., & Baron, R. A., 2009, Virtual customer environments: Testing a model of voluntary participation in value co-creation activities, (518), 388–406.
274. Nambisan, S., 2002, Designing virtual customer environments for new product development: Toward a theory. *The Academy of Management Review*, 27(3), 392–413.
275. Total consumer report, www.nielsen.com/us/en/insights/report/2017/total-consumer-report/, disponibil 19.092020
276. Nikolinakou, Angeliki and Karen Whitehill King (2018a), "Viral Video Ads: Examining Motivation Triggers to Sharing," *Journal of Current Issues & Research in Advertising*, 39, 2, 120–39.
277. Niranjnamurthy M, Kavyashree N, 2013, Analysis of E-Commerce and M-Commerce: Advantages, Limitations and Security issues. *Int J Advanced Res Computer Commu Engr* 2(6):2360–2370
278. Nunan, D., Sibai, O., Schivinski, B., Christodoulides, G., 2018, Reflections on "social media: Influencing customer satisfaction in B2B sales" and a research agenda, *Industrial Marketing Management*, 75, pp. 31-36
279. Oestreicher-Singer, G., and Sundararajan, A. 2012a. "Recommendation networks and the long tail of electronic commerce," *MIS Quarterly* (36:1), pp. 65–83.
280. Orzan, G., Platon, O.-E., Stefansson, C.D., & Orzan, M., 2016, Conceptual model regarding the influence of social media marketing communication on brand trust, brand affect and customer loyalty. *Economic Computation and Economic Cybernetics Studies and Research*, 50(1), 141-156.
281. Orzan, M., Orzan, G., 2007, Word-of Mouth Marketing Vs Marketing Viral, *Revista de Marketing Online*–Vol.1, Nr. 3
282. Palazon, M., Delgado-Ballester, E., 2013, Hedonic or utilitarian premiums: does it matter?, *Eur. J. Market.*, 47, pp. 1256-1275
283. Pallant J., 2007, *SPSS survival manual, a step by step guide to data analysis using SPSS for windows*. 3 ed. Sydney: McGraw Hill.
284. Papamichail, G. P., Papamichail, D. P., 2007, The k-means range algorithm for personalized data clustering in e-commerce. *European Journal of Operational Research*, 177(3), 1400–1408.

285. Park, E., 2019. Motivations for customer revisit behavior in online review comments: analyzing the role of user experience using big data approaches. *J. Retail. Consum. Serv.* 51, 14–18.
286. Park, J., Ulsoy, A. G., 1993, "On-Line Flank Wear Estimation Using an Adaptive Observer and Computer Vision, Part 2: Experiment." *ASME. J. Eng. Ind.* February 1993;
287. Park, S., Ryu, D., Fuentes, S., Chung, H., Hernández-Montes, E., O'Connell, M., 2017. Adaptive estimation of crop water stress in nectarine and peach orchards using highresolution imagery from an unmanned aerial vehicle (UAV). *Remote Sens.* 9 (8), 828.
288. Pearson, J. M., Grandon, E. E., 2005, An Empirical Study of Factors That Influence E-Commerce Adoption/Non-Adoption in Small and Medium Sized Businesses. *Journal of Internet Commerce*, 4(4), 1–21. doi:10.1300/j179v04n04_01
289. Perera C., Zaslavsky A., Christen P., Georgakopoulos D., 2012, CA4IOT: Context Awareness for Internet of Things, *IEEE International Conference on Green Computing and Communications*.
290. Person, W. M., 1919, "Indices of business conditions," *Review of Economics and Statistics*, vol. I, pp. 5-107.
291. Petty, R. E., Cacioppo, J. T., & Schumann, D., 1983, Central and peripheral routes to advertising effectiveness: The moderating role of involvement. *Journal of Consumer Research*, 10(2).
292. Phang, C. W., Tan, C.-H., Sutanto, J., Magagna, F., & Lu, X., 2014, Leveraging O2O commerce for product promotion an empirical investigation in Mainland China. *IEEE TRANSACTIONS ON ENGINEERING MANAGEMENT*, Vol. 61.
293. Pickton, D., Broderick, A., 2005, *Integrated Marketing Communications*, Pearson Education Limited
294. Pieters, R., Wedel, M., 2004, Attention capture and transfer in advertising: Brand, pictorial, and text-size effects. *Journal of Marketing*, 68(2), 36–50.
295. Pitman, A., Zanker, M., 2010, Insights from Applying Sequential Pattern Mining to E-commerce Click Stream Data. 2010 *IEEE International Conference on Data Mining Workshops*. doi:10.1109/icdmw.2010.31
296. Pitt, L. F., Berthon, P. R., Watson, R. T., Zinkhan, G. M., 2002, The Internet and the birth of real consumer power, *Business Horizons*, Elsevier, vol. 45(4), pages 7-14.
297. Porter, Lance and Guy J. Golan, 2006, "From Subservient Chickens to Brawny Men: A Comparison of Viral Advertising to Television Advertising," *Journal of Interactive Advertising*, 6, 2, 30–8, <https://doi.org/10.1080/15252019.2006.10722116>.
298. Pourgholamali, F., Kahani, M., Bagheri, E., & Noorian, Z., 2017, Embedding unstructured side information in product recommendation. *Electronic Commerce Research and Applications*, 25, 70–85.
299. Prentice, C., Loureiro, S. M. C., 2018, Consumer-based approach to customer engagement – The case of luxury brands
300. Qian Hai, 2016. Common Modes of Payment in Europe. http://blog.sina.com.cn/s/blog_e64e7c110102wfmf.html
301. R. D. Martin, Connor, J. T., Atlas, L. E. , 1994, "Recurrent neural networks and robust time series prediction," *IEEE Transactions on Neural Networks*, vol. 5, issue 2 pp. 240-254, Mar. 1994.

302. Rainer, K., C. Cegielski, 2011, *Introduction to Information Systems: Enabling and Transforming Business*, Third Edition, John Wiley and Sons Inc.
303. Rajkumar Buyya, Chee Shin Yeo, and Srikumar Venugopal, 2008, *Market-Oriented Cloud Computing: Vision, Hype, and Reality for Delivering IT Services as Computing Utilities*, The 10th IEEE International Conference on High Performance Computing and Communications.
304. Ramaswamy, V., 2009, *Co-creation of value: Towards an expanded paradigm of value creation*. *Marketing Review St. Gallen*, 6, 11–17. Romero, D., & Molina, A. (2011). *Collaborative networked organisations and customer communities: value co-creation and co-innovation in the networking era*. *Production Planning & Control*, 22(5-6), 447–472.
305. Raschka, S., 2014, *Naive Bayes and Text Classification – Introduction and Theory*, ArXiv Preprint arXiv:1410.5329.
306. Ravichandran, T., Liu, Y., Han, S., & Hasan, I., 2009, *Diversification and firm performance: Exploring the moderating effects of information technology spending*. *Journal of Management Information Systems*, 25(4), 205–240.
307. Reid, M., Thompson, P., Mavondo, F., Brunsø, K., 2015, *Economic and utilitarian benefits of monetary versus non-monetary in-store sales promotions*
308. Reynolds, D., 2015. *Gaussian mixture models*. *Encyclopedia Biometr.* 827–832.
309. Richins, M. L., Shaffer, T. R., 1998, *The Role of Evolvement and Opinion Leadership in Consumer Word-Of-Mouth: an Implicit Model Made Explicit*, in *NA - Advances in Consumer Research Volume 15*, eds. Micheal J. Houston, Provo, UT : Association for Consumer Research, Pages: 32-36.
310. Rockendorf, D., 2011, *Continental 2011 Social Media Strategy*. [Interview] (Personal Communication, 14 June 2011). Senecal, S and Nantel, H (2004) "the influence of online product recommendations on consumers' online choices". *Journal of retailing*, 80, pp. 159-169
311. Roos, I., Edvardsson, B., & Gustafsson, A., 2004, *Customer switching patterns in competitive and noncompetitive service industries*. *Journal of Service Research*, 6(3), 256–271.
312. Ross Girshick, Jeff Donahue, Trevor Darrell, Jitendra Malik (UC Berkeley), *R-CNN for Object Detection*, https://courses.cs.washington.edu/courses/cse590v/14au/cse590v_wk1_rcnn.pdf
313. Rossiter, J. R., & Percy, L., 1983, *Visual communication in advertising*. In R. J. Harris (Ed.). *Information Processing Research in Advertising* (pp. 83–125). Hillsdale, NJ: Erlbaum.
314. Sambamurthy, V., Bharadwaj, A., Grover, V., 2003, *Shaping agility through digital options: Reconceptualizing the role of information technology in contemporary firms*, *MIS Quarterly*, 27 (2), pp. 237-263
315. Sammut, G., & Sartawi, M., 2012, *Perspective-taking and the attribution of ignorance*. *Journal for the theory of social behavior*, 42(2), 181-200.
316. Sang-Hyun Cho, Hang-Bong Kang, 2012, *Text sentiment classification for SNS-based marketing using domain sentiment dictionary*. 2012 IEEE International Conference on Consumer Electronics (ICCE).
317. Santarelli, E., D'altri, S., 2003. *The diffusion of e-commerce among SMEs: theoretical implications and empirical evidence*. *Small Business Economics* 21 (3), 273–283
318. Schaupp, E., Abelea, E., & Metternich, J., 2017, *„Potentials of digitalization in tool management“*, *Procedia CIRP* 63 :144 – 149

319. Scherer, K., Shuman, V., Fontaine, J., & Soriano, C., 2013, The GRID meets the Wheel: Assessing emotional feeling via self-report. *Components of emotional meaning: a sourcebook*, 281–298
320. Schniederjans, M. J., Cao, Q., 2002, *E-Commerce Operations Management*, World Scientific-Business & Economics
321. Shakya, S. Kern, M. Owusu, G. Chin, C.M., 2012, Neural network demand models and evolutionary optimisers for dynamic pricing, *Knowledge-Based Systems* 29 (2012) 44–53
322. Shaokun Fan, Raymond Y. K. Lau, J. Leon Zhao, 2015, Demystifying Big Data Analytics for Business Intelligence Through the Lens of Marketing Mix, *Big Data Res.* 2(1): 28-32
323. Shimp, T., 2010, *Advertising Promotion and Other Aspects of Integrated Marketing Communications*, (eighth ed.), South-Western Cengage Learning, Mason, USA
324. Simentel, 2014, Cat Wants You. Retrieved March 18, 2018, from [https:// www.simantel.com/cat-wants-you/](https://www.simantel.com/cat-wants-you/).
325. Simmons, A. B., & Chappell, S. G., 1988, Artificial intelligence-definition and practice. *IEEE Journal of Oceanic Engineering*, 13(2), 14–42. doi:10.1109/48.551
326. Sismeiro, C., Bucklin, R. E., 2004, Modeling Purchase Behavior at an E-Commerce Web Site: A Task-Completion Approach. *Journal of Marketing Research*, 41(3), 306–323. doi:10.1509/jmkr.41.3.306.35985
327. Sivarajah, U. Irani, Z. Weerakkody, V., 2015, Evaluating the use and impact of Web 2.0 technologies in local government, *Government Information Quarterly*.
328. Skålén, P., Gummerus, J., von Koskull, C., & Magnusson, P. R., 2015, Exploring value propositions and service innovation: A service-dominant logic study. *Journal of the Academy of Marketing Science*, 43(2), 137–158.
329. Small, T. A., 2011, WHAT THE HASHTAG? *Information, Communication & Society*, 14(6), 872–895. doi:10.1080/1369118x.2011.554572
330. Smith, Jordan W., Christos Siderelis, Roger L. Moore, and Dorothy H. Anderson. 2012. "The Effects of Place Meanings and Social Capital on Desired Forest Management Outcomes: A Stated Preference Experiment." *Landscape and Urban Planning* 106(2): 207–18.
331. Smith, M., Szongott, C., Henne, B. and Von Voigt, G., 2012, Big Data Privacy Issues in Public Social Media. *Digital Ecosystems Technologies (DEST)*. 6th IEEE International Conference on Digital Ecosystems Technologies, Campione d'Italia
332. Smithson, M., 1985, Toward a Social Theory of Ignorance. *Journal for the Theory of Social Behaviour*, 15: 151-172.
333. Sokolova, K., Kefi, H., 2019. Instagram and YouTube bloggers promote it, why should I buy? How credibility and parasocial interaction influence purchase intentions. *J. Retail. Consum. Serv.*
334. Soley, L. C., & Reid, L. N., 1983, Predicting industrial ad readership. *Industrial Marketing Management*, 12(3), 201–206.
335. Soley, L. C., 1986, Copy length and industrial advertising readership. *Industrial Marketing Management*, 15(3), 245–251
336. Solomon, M. R., 2009, *Consumer Behavior, Buying, Having and Being*. New Jersey, USA: Pearson International Edition.

337. Stathopoulou, A., Borel, L., Christodoulides, G., & West, D., 2017, Consumer Branded #Hashtag Engagement: Can Creativity in TV Advertising Influence Hashtag Engagement? *Psychology & Marketing*, 34(4), 448–462. doi:10.1002/mar.20999
338. Stolze, M., Ströbel, M., 2001, Utility-Based Decision Tree Optimization: A Framework for Adaptive Interviewing. *Lecture Notes in Computer Science*, 105–116. doi:10.1007/3-540-44566-8_11
339. Sun, K.-A., Kim, D.-Y., 2013. Does customer satisfaction increase firm performance? An application of American Customer Satisfaction Index (ACSI). *Int. J. Hosp. Manag.*
340. Sutton, R.S., Barto, A.G., 1998. *Reinforcement Learning: An Introduction*. MIT press.
341. Taheri J., Zomaya A. Y., Siegel H. J., Tari Z., 2014, Pareto frontier for job execution and data transfer time in hybrid clouds. *Future Gener. Comput. Syst.* 37: 321-334
342. Teo, J. S. E., Taniguchi, E., & Qureshi, A. G., 2012, Evaluating City Logistics Measure in E-Commerce with Multiagent Systems. *Procedia - Social and Behavioral Sciences*, 39, 349–359. doi:10.1016/j.sbspro.2012.03.113
343. Thaichon, P., Lobo, A., Prentice, C., Quach, S., 2014, The development of service quality dimensions for internet service providers: Retaining customers of different usage patterns, *Journal of Retailing and Consumer Services*
344. Tibshirani, R., James, G., Witten, D., Hastie, T., 2013. *An Introduction to Statistical Learning-with Applications in R*. Springer publishing Co, New York, NY, USA.
345. Tole, A.A, 2013, Big data challenges, *Database Systems Journal*, 4 (3), pp. 31-40
346. TopLogo-10 Dataset, http://www.eecs.qmul.ac.uk/~hs308/qmul_toplogo10.html/
347. Tran, T., Cohen, R., 2002, A Reputation-Oriented Reinforcement Learning Strategy for Agents in Electronic Marketplaces. *Computational Intelligence*, 18(4), 550–565.
348. Tranfield, D. , Denyer, D. , & Smart, P., 2003, Towards a methodology for developing evidence-informed management knowledge by means of systematic review. *British Journal of Management*, 14(3), 207–222.
349. imiraş, L.C., Gheorghe, R., Epuran, E., HARJA, BOIER, 2012, *CERCETĂRI DE MARKETING*, Bacău : Alma Mater, 2012, ISBN 978-606-527-222-4
350. Ukanwa, K., & Rust, R. T., 2018, *Discrimination in Service*. 18-121-07 Marketing Science Institute.
351. Urista, M. A., Day, K. D., & Dong, Q., 2008, Explaining why young adults use myspace and facebook through uses and gratifications theory. *Human Communication*, 12(2), 215–229.
352. Van den Bergh, J., & Behrer, M. (2016). *How cool brands stay hot: Branding to Generations Y and Z*. London: Kogan Page Publishers.
353. Vapnik, V., 1998. *Statistical Learning Theory*. Wiley, New York.
354. Vasarhelyi, M. A., A. Kogan, B. M. Tuttle. 2015. *Big Data in Accounting: An Overview*. *Accounting Horizons* 29 (2): 381-396
355. Venkatraman, V., Dimoka, A., Pavlou, p. A., Vo, K., Hampton, W., Bollinger, B., & Winer, R. S., 2015, Predicting advertising success beyond Traditional measures: New insights from neurophysiological methods and market response modeling. *Journal of Marketing Research*, 52(4), 436–452.
356. Villarroel Ordenes, F., Ludwig, S., de Ruyter, J.C., Grewal, D., Wetzels, M.G.M., 2017. Unveiling what is written in the stars: analyzing explicit, implicit and discourse patterns of sentiment in social media. *J. Consum. Res.* 43 (6), 875–894.

357. Vinodhini, G., Chandrasekaran, R. M., 2014, Opinion mining using principal component analysis based ensemble model for e-commerce application. *CSI Transactions on ICT*, 2(3), 169–179.
358. Vinodhini, G., Chandrasekaran, R., 2014, Measuring the quality of hybrid opinion mining model for e-commerce application. *Measurement*, 55, 101–109.
359. Waller M.A., Fawcett S.E., 2013, Data science, predictive analytics, and big data: a revolution that will transform supply chain design and management, *Journal of Business Logistics*, 34 (2), pp. 77–84
360. Wang Y., Veeravalli B., Tham C. K., 2013, On Data Staging Algorithms for Shared Data Accesses in Clouds. *IEEE Trans. Parallel Distrib. Syst.* 24(4): 825–838
361. Wang Y., Wiebe V. J., 2014, Big Data Analytics on the Characteristic Equilibrium of Collective Opinions in Social Networks. *IJCINI* 8(3): 29–44
362. Wang, P., Lin, W.-H., Chao, K.-M., & Lo, C.-C., 2017, A Face-Recognition Approach Using Deep Reinforcement Learning Approach for User Authentication. 2017 IEEE 14th International Conference on e-Business Engineering (ICEBE). doi:10.1109/icebe.2017.36
363. Wang, T. Cai, Y. Song, L., Chang, Q., 2014, "Financial time series forecasting using directed-weighted chunking SVMs," *Mathematical Problems in Engineering*, p. 7, Apr. 2014.
364. Wang, Y., & Wiebe, V. J., 2014, Big Data Analytics on the Characteristic Equilibrium of Collective Opinions in Social Networks. *International Journal of Cognitive Informatics and Natural Intelligence*, 8(3), 29–44.
365. Ward, M. R., Lee, M. J., 2000, Internet Shopping, Consumer Search And Product Branding, *Journal of Product & Brand Management*
366. Wedel, M., & Pieters, R., 2000, Eye fixations on advertisements and memory for brands: A model and findings. *Marketing Science*, 19(4), 297–312.
367. Wedel, M., & Pieters, R., 2008, A review of eye-tracking research in marketing. In N. K. Malhotra (Vol. Ed.), *Review of Marketing Research*. Vol. 4. Armonk, N.Y.; London: M.E. Sharpe.
368. Weihua Song, Phoha, V. V., & Xin Xu., 2004, The HMM-based model for evaluating recommender's reputation. *IEEE International Conference on E-Commerce Technology for Dynamic E-Business*. doi:10.1109/cec-east.2004.64
369. Welch, G., Bishop, G., 1995, *An introduction to the Kalman filter*, Citeseer
370. Wen, H., Zhao, J., 2017, Aspect term extraction of E-commerce comments based on model ensemble. 2017 14th International Computer Conference on Wavelet Active Media Technology and Information Processing (ICCWAMTIP). doi:10.1109/iccwamtip.2017.8301421
371. Weng, H., Li, Z., Ji, S., Chu, C., Lu, H., Du, T., & He, Q., 2018, Online E-Commerce Fraud: A Large-Scale Detection and Analysis. 2018 IEEE 34th International Conference on Data Engineering (ICDE). doi:10.1109/icde.2018.00162
372. Westland, J.C., Clark, C., Theodore, H.K., 1999. *Global Electronic Commerce: Theory and Case Studies*. The MIT Press, Cambridge, MA.
373. Wheeler, R., & Aitken, S., 2000, Multiple algorithms for fraud detection. *Knowledge Based Systems*, 99, 93–99.
374. Wortmann, F., & Flüchter, K., 2015, Internet of Things. *Business & Information Systems Engineering*, 57(3), 221–224. doi:10.1007/s12599-015-0383-3

375. Wu, R.-S., Chou, P.-H., 2011, Customer segmentation of multiple category data in e-commerce using a soft-clustering approach. *Electronic Commerce Research and Applications*, 10(3), 331–341. doi:10.1016/j.elerap.2010.11.002
376. Xuan, S., Liu, G., Li, Z., Zheng, L., Wang, S., & Jiang, C., 2018, Random forest for credit card fraud detection. 2018 IEEE 15th International Conference on Networking, Sensing and Control (ICNSC). doi:10.1109/icnsc.2018.8361343
377. Xue, W.-X., & Li, D.-D., 2016, Innovative Research on O2O Marketing Mode Based on Social Networks. *Software Engineering and Information Technology: Proceedings of the 2015 International Conference on Software Engineering and Information Technology (SEIT2015)*, pp. 113-117.
378. Y. LeCun, Y. Bengio, G. Hinton, 2015, Deep learning, *Nature*, 521, 436
379. Y. You, G.G. Vadakkepatt, A.M. Joshi, 2015, A meta-analysis of electronic word-of-mouth elasticity, *J. Mark.* 79 (2), 19–39.
380. Y.-H. Joo, Y. Kim, S.-J. Yang, 2011, Valuing customers for social network services, *Journal of Business Research*, 64 (11), pp. 1239-1244
381. Yan, X., 2013, O2O business model application in the area of marketing. *Art and Culture communication*
382. Yang, T. Qian, K. Tao, L., 2016, Improve the Prediction Accuracy of Naïve Bayes Classifier with Association Rule Mining, *International Conference on Big Data Security on Cloud, IEEE International Conference on High Performance and Smart Computing*
383. Yang, Z., Cao, S., & Yan, B., 2011, Using linear discriminant analysis and data mining approaches to identify E-commerce anomaly. 2011 Seventh International Conference on Natural Computation. doi:10.1109/icnc.2011.6022591
384. Yanhui Ma, Yonghong Xie., 2010, A novel collaborative filtering framework based on Fuzzy C-Means clustering using FP-Tree. 2010 International Conference on Computer Application and System Modeling (ICCA SM 2010).
385. Yao, L., Li, Z., Nie, T., & Zhao, Z., 2018, Research and Implementation of a Brand Normalization Method across E-Commerce Platforms. 2018 4th International Conference on Big Data Computing and Communications (BIGCOM).
386. Zhang G., Wang J., Huang W., Su H., Lv Z., Yao Q., Ye S., 2015, Big Data Collection and Analysis Framework Research for Public Digital Culture Sharing Service. *BigMM*
387. Zhang H., Chen G., Ooi B. C., Tan K. L., Zhang M., 2015, In-Memory Big Data Management and Processing: A Survey. *IEEE Trans. Knowl. Data Eng.* 27(7): 1920-1948
388. Zhang, D.Z., 2011, Towards theory building in agile manufacturing strategies—Case studies of an agility taxonomy, *International Journal of Production Economics*, 131 (1), pp. 303-312
389. Zhang, J., Chen, H., & Wu, X., 2015, Operation Models in O2O Supply Chain When Existing Competitive Service Level. *International Journal of u- and e- Service, Science and Technology*, Vol. 8(No. 9), pp. 279-290.
390. Zhang, J., & Mao, E. (2008). Understanding the acceptance of mobile SMS advertising among young Chinese consumers. *Psychology and Marketing*, 25(8), 787–805. doi:10.1002/mar.20239
391. Zhao, K. and Wang, C., 2017, Sales forecast in e-commerce using convolutional neural network. arXiv preprint arXiv:1708.07946.

392. Zhao, Z., Zhang, R. Cox, J. Dulmg, D. Sc Sarle, W., 2013, Massively parallel feature selection: an approach based on variance preservation. *Machine Learning*. 92(1). 195–220.
393. Zheng, X., Zhu, S., & Lin, Z., 2013, Capturing the essence of word-of-mouth for social commerce: Assessing the quality of online e-commerce reviews by a semi-supervised approach. *Decision Support Systems*, 56, 211–222. doi:10.1016/j.dss.2013.06.002
394. Zhou, T., 2017. Understanding location-based services users privacy concern: an elaboration likelihood model perspective. *Internet Res.* 27 (3), 506-519
395. Zhu, F., Zhang, X., 2010. Impact of online consumer reviews on sales: the moderating role of product and consumer characteristics. *J. Mark.* 74, 133–148. eMarketer.
396. Zicari, R.V., 2014, Big Data: Challenges and opportunities. *Big Data computing*, 104-128
397. <http://www.gpec.ro/blog/razvan-acsent-olx-in-continuare-piatade-e-commerce-din-romania-este-reactiva-si-mai-putin-proactiva-video>; World Economic Forum. "3 predictions for the future of retail – from the CEO of Walmart." Last modified January 6, 2017.
398. <http://www.gpec.ro/blog/bilant-e-commerce-romania-2015-cumparaturileonline-au-deposit-pragul-de-14-miliarde-eur>; GPeC. "Romanian E-Commerce Market Size at the end of 2016: 1.8 billion EUR." Last modified January 17, 2017.
399. <http://www.gpec.ro/blog/en/romanian-e-commerce-market-size-at-the-end-of-2016-1-8-billioneur-infographic>; GPeC (2). "Principalele tendințe în marketing online pentru e-commerce în 2017". Last modified January 25, 2017.
400. <http://www.gpec.ro/blog/principalele-tendinte-in-marketing-online-pentru-e-commerce-in-2017>; GPeC (3). "Răzvan Acseente, OLX: În continuare piața de e-commerce din România este reactivă și mai puțin proactivă", 2017.
401. https://www.weforum.org/agenda/2017/01/3-predictions-for-the-future-of-retail-from-theceo-of-walmart/?utm_content=buffer8add1&utm_medium=social&utm_source=twitter.com&utm_campaign=buffer; Schneider, G.P. *Electronic Commerce*, Eleventh Edition. Stamford: Cengage Learning, 2015.
402. https://en.wikipedia.org/wiki/Autoregressive_integrated_moving_average
403. YouTube: Over one billion users <https://www.youtube.com/yt/about/press/>

Anexa 4- Rezumat Limba Română

Piatra de temelie a inovării în economia bazată pe cunoaştere este informaţia. Cu toate acestea, pentru a utiliza informaţia cu scopul de a îmbunătăţi procesul de asumare a deciziilor şi de a stimula inovaţia, aceasta trebuie transformată în cunoaştere. Tom Peters a identificat provocarea convertirii informaţiilor către cunoaştere în cartea sa "Prosperitatea din haos" (Thriving on Chaos, 1991), afirmând că "ne înecăm în informaţii şi că nu avem cunoştinţe!" Această provocare a atins cote dramatice, experţii estimând că în următorii trei ani omenirea va genera mai multe date decât cele înregistrate digital până în prezent (Mark, 2006).

La un nivel practic, toate organizaţiile pot transforma astăzi un produs secundar, ce conţine date neutilizate, într-o resursă care îmbunătăţeşte procesul decizional organizaţional, creează cunoştinţe şi oferă valoare adăugată clienţilor. În plus, cercetătorii au din ce în ce mai multe oportunităţi de a identifica şi de a examina modelele de informaţii pentru a crea cunoştinţe valoroase pentru societate. Supravieţuirea într-o economie bazată pe cunoaştere derivă din capacitatea de a transforma informaţiile în cunoştinţe. Pentru a face acest lucru, cercetătorii şi antreprenorii se bazează din ce în ce mai mult pe domeniul **analizei predictive**.

Scopul prezentei lucrări este de a oferi o perspectiva asupra analizelor predictive, de a rezuma modul în care acestea influenţează crearea de cunoştinţe în **marketing** şi de a sugera evoluţii viitoare în domeniul marketingului şi analizei predictive atât pentru organizaţii, cât şi pentru cercetători.

Dacă pentru companiile de marketing digital afiliat, marketing pentru motoare de căutare sau social media marketing, este relativ facil să se urmărească rezultatele finale, în schimb în cadrul campaniilor de Guerilla marketing, unde este utilizat conţinut de tip imagine sau video, cu strategii de plasare a produselor/ serviciilor, acest lucru este dificil de monitorizat şi analizat. Prin folosirea algoritmilor de inteligenţă artificială se doreşte adresarea directă a acestor factori, care determină succesul în campaniile ce au ca obiectiv vânzarea unui produs/ serviciu cu scopul de a deservi nevoile clientului. Prin intermediul unor astfel de campanii, produsul în sine poate deveni unul din cele mai bune canale de marketing pentru a creşte afacerea în mediul digital într-un mod creativ, bazat pe măsurare şi testare continua.

Aceasta lucrare are drept obiectiv central studierea modului în care analizele predictive pot fi integrate în marketing şi aplicate în sectorul în e-commerce, în vederea îmbunătăţirii proceselor organizationale şi performanţa companiilor, având la baza datele generate de comportamentul clienţilor.

Pentru a putea îndeplini scopul acestei teze doctorale, acesta a fost structurată pe *trei capitole* care vizează în ansamblu abordarea tematicii la nivel conceptual, sistematic şi aplicat.

Primul capitol fundamentează teoretic conceptele de baza ale Marketingului digital şi a comerţului electronic, având drept obiectiv cunoaşterea ştiinţifică a domeniului vizat. Au fost documentate şi specificate elementele definitorii pentru stadiul de etapă al cercetării în domeniu asupra modelelor şi

a practicilor din comerţul electronic, precum și abordările Marketingului digital, corelate cu contextul geopolitic și direcțiile emergente din piața.

Pornind de la volumul de date imens generate de sistemele e-commerce și uneltele de marketing încorporate în cadrul acestora, au fost analizate în ce masura datele generate de Big Data pot constitui un punct de plecare pentru revoluționarea domeniului Marketing.

Capitolul doi constituie o analiza sistematică a literaturii de specialitate a domeniului e-commerce și a algoritmilor de învățare automată, punand accentul pe instrumentele metodologice utilizate și definirea întrebărilor de cercetare. Scopul analizei efectuate la nivel investigativ asupra literaturii de specialitate și al rezultatelor acestora a constat în identificarea viitoarelor oportunități de cercetare și afaceri, dar și la identificarea limitelor industriei.

Analiza cantitativă efectuată în cadrul capitolului doi a avut în vedere documentarea tuturor algoritmilor de învățare automată (Machine Learning) existenți la momentul elaborării lucrării și identificarea domeniului lor de aplicabilitate în e-commerce și marketing digital. Concluziile rezultate în urma studiilor de caz efectuate argumentează aplicabilitatea algoritmilor de inteligență artificială specific pe comerț electronic și necesitatea continuării cercetărilor de marketing și managementul afacerii în acest domeniu.

Capitolul trei abordează la nivel practic comportamentul clienților în e-commerce, selectand drept cadru de cercetare activitatea de Marketing a unei companii locale, centrată pe domeniul e-commerce și IoT (Internet of Things). Au fost efectuate cercetări prin utilizarea următoarelor metode: focus grupul, interviul (cercetare calitativă) și cercetare cantitativă, pe un eșantion de 429 persoane, clienți ai companiei vizate. Focus grupul a fost realizat împreună cu reprezentanți ai mediului de business local, deținători de afaceri bazate pe comerțul electronic și a condus la problematizarea unor aspecte relevante privind înțelegerea instrumentelor de marketing bazate pe algoritmi de învățare automată și optimizarea nevoii de interpretare a datelor. Interviul a fost aplicat unui număr de 8 persoane, responsabili de administrarea platformei de comerț electronic cleste.ro, și a avut drept scop validarea ipotezelor rezultate în focus grup prin explorarea unor scenarii posibile în automatizarea proceselor interne și folosirea algoritmilor de învățare automată.

În urma cercetărilor practice au rezultat o serie de constatări cheie privind instrumentele de învățare automată, ce pot fi utilizate în cadrul companiilor pentru eficientizarea proceselor de Marketing și reducerea costurilor implicate în campaniile de promovare. Rezultatele obținute în urma analizelor calitative și cantitative din capitolul 3 pot avea implicații atât la nivelul completării studiilor academice din domeniul cercetat, cât și la nivelul aplicării acestora în mediul economic, cu precădere în comerțul electronic și în Marketingul digital. Totodată, acest capitol evidențiază antrenarea unei rețele neuronale ce estimează numărul angajaților într-o firmă ce are activitate în domeniul e-commerce, dar și valoarea stocului bazat pe indicatori financiari anuali a 1400 de companii.

Anexa 4- Rezumat Limba Engleză

The cornerstone of innovation in economics based on knowledge and information is data. Even so, to use information in the goal of improving the process of decision-making and to stimulate growth, one has to convert it into knowledge. Tom Peters had identified the challenge of converting information into knowledge in his 1991 book "Thriving on Chaos", stating that "we drown in information and we don't have knowledge!" This challenge reached frightening odds, experts estimating that in the next three years humankind will generate more data than the number we have stored so far (Mark, 2006).

In practice, today every organisation can convert a secondary product, which contains unused data, into a resource which improves the organisational decision-making process, creates knowledge and offers added value to their clients. Additionally, researchers have more and more opportunities to identify and analyse the information models in order to create valuable knowledge for society. One's survival in an economy based on knowledge is derived from one's capability to convert information into knowledge. To achieve this, researchers and entrepreneurs rely more and more on **predictive analytics**.

The goal of this paper is to offer a broader image on predictive analytics, to resume the way in which it influences the generation of knowledge in **marketing** and to suggest future progress in the domain of marketing and of predictive analytics for both organisations and researchers.

If it is relatively accessible for affiliate digital marketing campaigns, marketing for search engines or social media marketing to examine final results, in the case of Guerilla marketing campaigns, in which visual content such as images and videos are used, with product/service placement tactics, final results become more difficult to analyse. Through the use of artificial intelligence algorithms researchers want to target these factors that determine the success of campaigns which have the objective of selling a product/service that will meet the client's needs. Through these types of campaigns, the product itself can become one of the best marketing channels which determines the business' digital growth, presenting a modern and creative approach, based on measuring and testing.

This thesis has the objective of studying the way in which predictive analytics can be integrated in marketing and applied in the field of e-commerce, with the goal of improving the organisational process and the performance of companies, based on the data generated by consumer behaviour.

In order to fulfill this doctoral thesis' goal it was structured in three chapters which broadly targets the approach on the theme on a conceptual, systematic and applied level.

The first chapter builds the theoretical foundation of the main digital marketing and e-commerce concepts, the objective being the better understanding of the studied field. The defining elements for the stage study of e-commerce models and practices, as well as the digital marketing approaches, correlated with the geopolitical context and the emergent directions of the market have been documented and specified.

Starting from the vast volume of generated data by e-commerce and some marketing systems, we have analysed to what degree the data generated by Big Data can be regarded as a starting point for the innovation of the marketing field.

The second chapter represents a systematic analysis of the specialised literature in the e-commerce field and the machine learning algorithms, focusing on the methodological tools used and defining the research questions. The goal of the investigative analysis on the specialised literature and on their results has consisted in the identification of future research and business opportunities, as well as the identification of the industry's limits.

The qualitative analysis that done in the second chapter targeted the documentation of all existing Machine Learning as of this paper's inception and the identification of their field of applicability in e-commerce and digital marketing. The conclusions of the conducted case studies argue for the applicability of specific e-commerce artificial intelligence algorithms and the necessity of further marketing and business management research in this field.

The third chapter approaches consumer behaviour in e-commerce on a practical level, the research setting being the marketing activity of a local company, centered on e-commerce and IoT (Internet of Things). Research using the following methods have been conducted: the focus group, the interview (centralised quality) and quantitative research, on a sample of 429 people, clients of the company in question. The focus group was created with the help of local business representatives, executives of businesses working in e-commerce, which led to questioning of some important aspects regarding the understanding of marketing tools based on machine learning and the optimisation of need of data interpretation. A number of 8 people were interviewed, responsible for the administration of the e-commerce platform cleste.ro, and the interview had the goal of validating the resulting hypotheses in the focus group through research of possible scenarios in the automatisisation of internal processes and the use of machine learning.

The practical research has resulted in a series of key findings regarding the machine learning tools, which can be utilised by companies for optimising marketing processes and cost reduction for promoting campaigns. The qualitative and quantitative analysis results from chapter three can have implications in both adding to the academic studies in the field of research and applying them in the economic field, mostly in e-commerce and digital marketing. And also, the development of predictive models using deep neural networks that estimates the number of employees of an ecommerce company and the value of stock on annual financial indicators.