

Časopis za poslovnu teoriju i praksu
Rad primljen: 06.04.2026.
Rad odobren: 03.06.2026.

UDK 519.245:336.761]:004.42
DOI 107251/POS2636081M
COBISS.RS-ID 144612353
Pregledni rad

Mičić Saša, Univerzitet za poslovne studije, Banja Luka, Bosna i Hercegovina, aktuar.sasa.micic@gmail.com

Dorđević Milan, Akademija strukovnih studija Južna Srbija, Odsek Visoka tehnološko umetnička škola, Leskovac, Republika Srbija

Stojanović Branka, Akademija strukovnih studija Južna Srbija, Odsek Visoka tehnološko umetnička škola, Leskovac, Republika Srbija

MONTE KARLO SIMULACIJA U USLOVIMA NEIZVESNOSTI

Rezime: *Primarni cilj ovog teorijskog istraživanja usmeren je ka proširivanju fundamentalnih postavki o značaju i aplikativnoj vrednosti simulacionog modelovanja, sa posebnim fokusom na Monte Karlo simulaciju kao jednu od ključnih metoda za analizu kompleksnih sistema u uslovima neizvesnosti. Rad istražuje konvergenciju Monte Karlo metode i algoritama veštačke inteligencije, apostrofirajući njihovu ulogu u analizi pouzdanosti, optimizaciji i predikciji ponašanja složenih struktura. Inicijalni deo rada sistematizuje teorijske osnove, istorijski razvoj i probabilističke principe zasnovane na teoriji verovatnoće. Detaljno je elaborirana metodologija implementacije, koja obuhvata definisanje problemskog okvira, selekciju distribucija verovatnoće, algoritamske sekvence, kao i procese verifikacije i validacije. Istraživanje identifikuje prednosti i ograničenja u poređenju sa determinističkim pristupima, uz kritički osvrt na računarsku složenost i „prokletstvo dimenzionalnosti“. Poseban doprinos rada ogleda se u analizi hibridnih modela koji integrišu tehnike mašinskog učenja, poput neuronskih mreža i regresionih stabala, čime se postiže ubrzana konvergencija uz visoku preciznost. Rezultati ukazuju na to da ovi sinergijski sistemi konstituišu novu paradigmu u prediktivnoj analitici, omogućavajući proaktivno donošenje odluka u realnom vremenu unutar visokostohastičkih okruženja.*

Ključne riječi: *Monte Karlo simulacija, model, neizvesnost, veštačka inteligencija*

JEL klasifikacija: *C15, C63, D81*

UVOD

Evolucija modernih sistema u okviru inženjerskih, prirodnih i društvenih disciplina, a naročito u ekonomiji, uslovljava je porast kompleksnosti problema koji zahtevaju dublja numerička i analitička istraživanja. Zbog prisustva brojnih međuzavisnih faktora, nelinearnih veza i inherentne stohastičke prirode procesa, često je nemoguće doći do egzaktnih analitičkih rešenja. U ambijentu koji karakteriše neizvesni parametri i oskudne informacije, simulaciono modeliranje se profilise kao ključni metodološki okvir za objektivnu analizu i donošenje odluka utemeljenih na egzaktnim podacima. Pored ove metode svakako je značajna analiza osetljivosti i metoda scenarija kao jedna od veoma bitnih metoda u donošenju odluka u uslovima neizvesnosti i rizika (Mičić i Čičković 2020,11). Monte Karlo simulacija (MCS) predstavlja jedan od najfleksibilnijih i najšire primenjivanih metodoloških okvira u domenu simulacionog modelovanja, čija se arhitektura temelji na postulatima matematičke statistike i teorije verovatnoće. Osnovni operativni princip ove metode počiva na korišćenju pseudoslučajnih brojeva za generisanje stohastičkih ulaznih varijabli, čime se

kroz iterativne simulacione eksperimente vrši procena dinamike posmatranog sistema. Ovakav pristup omogućava preciznu aproksimaciju očekivanih vrednosti, varijanse i gustine raspodele izlaznih veličina, pružajući kritičan uvid u ekstremne ishode i devijacije, što je od ključnog značaja za analizu kompleksnih sistema sa visokim stepenom entropije i neizvesnosti.

Komparativna prednost Monte Karlo simulacije (MCS) ogleda se u njenoj efikasnosti pri rešavanju problema gde konvencionalni deterministički algoritmi pokazuju značajnu neadekvatnost ili računarsku neefikasnost. Za razliku od rigidnih numeričkih pristupa, MCS ne počiva na restriktivnim pretpostavkama o linearnosti ili simplifikaciji modela, već omogućava rad sa proizvoljnim distribucijama verovatnoće i visokostepenim strukturnim kompleksnostima. Zahvaljujući ovoj inherentnoj fleksibilnosti, metoda je postala nezamenljiv analitički instrument u širokom spektru disciplina, od kvantifikacije pouzdanosti tehničkih sistema i energetskog planiranja, preko sofisticiranog finansijskog modeliranja i upravljanja rizicima, pa sve do kompleksnih procesa u hemijskoj kinetici, nuklearnoj fizici i savremenoj biomedicini.

Aplikativni dometi Monte Karlo simulacije doživeli su eksponencijalni rast paralelno sa tehnološkim progresom i masovnom dostupnošću visokoperformansnih računarskih resursa. Savremeni hardverski kapaciteti omogućavaju procesuiranje miliona iteracija u minimalnom vremenskom intervalu, čime se direktno minimizuje statistička greška i postiže visoka preciznost procene kroz bržu konvergenciju rezultata. Paralelno sa hardverskom ekspanzijom, razvoj sofisticiranih metodoloških modifikacija, poput tehnika za redukciju varijanse i algoritama zasnovanih na Markovljevim lancima dodatno je optimizovao računarsku efikasnost i proširio analitički opseg ove metode na visokodimenzionalne i nelinearne probleme.

U savremenom naučnom i poslovnom okruženju, sposobnost predviđanja ishoda pod uslovima neizvesnosti postala je ključna konkurentna prednost. Monte Karlo simulacija decenijama predstavlja primarni alat za rešavanje problema koji su previše složeni za analitička rešenja. Od svog nastanka u okviru projekta Menhetn, Monte Karlo simulacija je evoluirala iz alata za nuklearnu fiziku u univerzalnu metodu probabilističkog zaključivanja (Metropolis i Ulam 1949, 335). Eksponencijalna proliferacija podataka i rastuća kompleksnost savremenih sistema, poput pametnih elektroenergetskih mreža i personalizovanih medicinskih protokola, nameću nove izazove pred tradicionalnu Monte Karlo simulaciju. Primarno ograničenje ove metode ogleda se u visokoj računarskoj intenzivnosti. Naime, postizanje željene statističke preciznosti često zahteva milionske iteracije, što je neodrživo u operativnim okruženjima koja zahtevaju odziv u realnom vremenu. U tom kontekstu, integracija veštačke inteligencije predstavlja ključni iskorak. Sinergija algoritama veštačke inteligencije i Monte Karlo metode omogućava implementaciju mehanizama pametnog uzorkovanja i nelinearnu aproksimaciju funkcija, čime se drastično redukuje broj potrebnih simulacionih koraka uz zadržavanje visokog nivoa pouzdanosti rezultata. Dok su tradicionalne metode poput analize osetljivosti i scenario metode pružile osnovu za ocenu investicija (Mičić i Čičković, 2020), Monte Karlo simulacija omogućava dublji uvid u stohastičku prirodu tržišnih varijabli.

1. ZNAČAJ SIMULACIONOG MODELIRANJA

Simulaciono modelovanje se definiše kao kompleksna naučna i inženjerska disciplina posvećena projektovanju i analizi modela realnih sistema sa primarnim ciljem ispitivanja njihove dinamike u varijabilnim uslovima eksploatacije. Predmet proučavanja ove discipline je apstraktna reprezentacija sistemske strukture i ponašanja, pri čemu se primenom algoritamskih, logičkih i matematičkih modela tradicionalni fizički eksperimenti supstituišu simulacionim postupcima. Implementacija ovakvog metodološkog pristupa omogućava dubinsku evaluaciju sistema koji su previše složeni, ekonomski neisplativi ili visokorizični za ispitivanje u realnom okruženju, kao i sistema za koje ne postoje egzaktna analitička rešenja. Shodno prirodi posmatranog fenomena i definisanim istraživačkim ciljevima, simulacioni modeli se klasifikuju na determinističke ili stohastičke, odnosno na diskretne ili kontinuirane modele.

Jedan od fundamentalnih aspekata simulacionog modelovanja ogleda se u njegovoj sposobnosti da integralno obuhvati elemente slučajnosti i neizvesnosti koji su inherentni brojnim kompleksnim sistemima. S obzirom na to da ulazni parametri u velikom broju praktičnih problema nisu determinisani sa apsolutnom sigurnošću, njihova reprezentacija putem distribucija verovatnoće predstavlja metodološki imperativ. Poseban značaj ovog pristupa za analizu rizika i strateško donošenje odluka leži u činjenici da se finalni rezultati ne svode na izolovane numeričke vrednosti, već artikulišu celokupne raspodele potencijalnih ishoda, čime se omogućava dublji uvid u varijabilnost posmatranog fenomena.

Zbog isplativosti ili uticaja okoline, u mnogim slučajevima, nije praktično moguće započeti sastavljanje sistema (Bisai 2018). Upravo modeliranje i simulacija to omogućava pa istraživači mogu pokrenuti svoje sisteme kako bi u stvarnim sistemima proizveli fenomene koji se javljaju. Modeliranje i simulacija se danas mogu šire koristiti, jer su softverski programi i hardveri jeftiniji, fleksibilniji i moćniji. Dok su potrebe za modeliranjem i simulacijom sve više povećane, ograničenja nisu data na akcentu analize sistema, već i na predviđanje ponašanja, optimizaciju (Barzegar 2017) i projektovanje.

Simulaciono modelovanje dobija na sve većem značaju usled svoje ekstenzivne primene u raznolikim tehničkim i naučnim disciplinama. U domenu ekonomije, ovi modeli su nezaobilazni za evaluaciju finansijskih rizika, pružanje podrške procesima strateškog odlučivanja, kao i za dubinsku analizu tržišnih fluktuacija. Istovremeno, u inženjerstvu je primena ovog vida modelovanja esencijalna za projektovanje kompleksnih tehničkih sistema. Pored toga, simulaciono modelovanje zauzima ključno mesto u prirodnim naukama i medicini, gde služi za istraživanje dinamike širenja bolesti, analizu bioloških sistema i simulaciju fizičkih fenomena. Upravo ta izražena interdisciplinarnost pozicionira simulaciono modelovanje kao jedan od najrelevantnijih istraživačkih instrumenata savremene nauke.

Pojedini modeli za evaluaciju tržišnog rizika koji se oslanjaju na Monte Karlo simulaciju počivaju na pretpostavci da su varijacije u bazičnim faktorima rizika ishod specifičnih stohastičkih procesa. Kroz generisanje dovoljnog broja iteracija, omogućava se formiranje simulirane distribucije za svaki pojedinačni faktor rizika, koja progresivno konvergira ka stvarnoj raspodeli. Proces kvantifikacije tržišnog rizika upotrebom ovih modela realizuje se kroz nekoliko sukcesivnih faza, koje obuhvataju precizno definisanje procesa, konfiguraciju relevantnih faktora izloženosti i finalno utvrđivanje vrednosti pod rizikom.

Simultano sa evolucijom Monte Karlo simulacije, oblast veštačke inteligencije prošla je kroz značajnu transformaciju — od rane simboličke logike do savremenih arhitektura dubokog učenja. U aktuelnim naučnim okvirima, veštačka inteligencija se više ne tretira isključivo kao instrument za identifikaciju obrazaca, već kao primarni mehanizam za strukturnu optimizaciju simulacionih procedura. Sinergija ove dve discipline najeksplicitnije se manifestuje kroz koncept surogat modelovanja. U ovom okviru, nakon sprovedene faze inicijalnog učenja, model zasnovan na veštačkoj inteligenciji preuzima ulogu računski zahtevnog procesa simulacije, čime se postiže drastično ubrzanje uz očuvanje preciznosti rezultata.

2. TEORIJSKE OSNOVE MONTE KARLO SIMULACIJE

2.1. Istorijski razvoj Monte Karlo metode

Potreba za numeričkim metodama sposobnim da reše složene fizičke probleme koji su prevazilazili tadašnje analitičke pristupe, dovela je do nastanka Monte Karlo metode sredinom XX veka. Na projektu Menhetn, prvi put se razvija ova metoda, sa potrebom modelovanja procesa koji su vezani za transport neutrona i lančane reakcije. Tokom istraživanja prvi put je upotreba slučajnog uzorkovanja pokazala da se na efikasan način aproksimuju rešenja problema visoke dimenzionalnosti, pa su tako postavljeni prvi temelji Monte Karlo simulacije kao numeričke

metode (Eckhardt 1987, 133).

Sam naziv metode „Monte Karlo” pripisuje se Stanislavu Ulamu, koji je uočio podudaranja između slučajnog uzorkovanja u matematičkim problemima i igara na sreću koje su bile karakteristične za kazina u Monte Karlu. Ulam je zajedno sa Džonom fon Nojmanom i Nikolasom Metropolisom, razvio osnovne principe metode, a zatim doprineo formalizaciji u kontekstu numeričkih proračuna. Upravo ovakvi radovi, poslužili su za postavljanje teorijske i praktične osnove za dalji razvoj ove metode, kao i njenu širu primenu u inženjerstvu i nauci (Metropolis i Ulam 1949).

Dalja evolucija Monte Karlo metode neraskidivo je povezana sa progresom računarske tehnologije. Pojava prvih digitalnih računara omogućila je potpunu automatizaciju generisanja pseudo-slučajnih brojeva i izvođenje masovnih simulacionih iteracija, što je fundamentalno unapredilo preciznost i praktičnu primenljivost ovog pristupa. Tokom druge polovine dvadesetog veka, primena Monte Karlo simulacije doživela je ekspanziju izvan okvira nuklearne fizike, prodirući u domene statističke mehanike, teorije redova čekanja i numeričke integracije. Ovakav istorijski razvoj potvrđuje njenu prirodu univerzalnog numeričkog instrumenta koji je primenljiv u najrazličitijim naučnim disciplinama.

Ključnu prekretnicu u evolucionom razvoju Monte Karlo metode predstavlja implementacija Markovog lanca Monte Karlo (eng. Markov Chain Monte Carlo – MCMC), čime je omogućeno visokoefikasno uzorkovanje iz kompleksnih, višedimenzionalnih raspodela verovatnoće. Konceptualni pomak koji su doneli algoritmi poput Metropolis-Hastings i Gibsovog uzorkovanja (eng. Gibbs sampling) transformisao je metodu iz bazične numeričke tehnike u sofisticiran istraživački instrumentarijum. Ovakav metodološki iskorak suštinski je unapredio kapacitete Bajesove inferencije, mašinskog učenja i savremene statističke analize, pozicionirajući Monte Karlo simulaciju kao nezaobilazan okvir unutar divergentnih naučnih disciplina koje se bave modelovanjem visokokompleksnih sistema.

U savremenom naučnom paradigmi, Monte Karlo metoda konstituise fundamentalni stub numeričke analize i simulacionog modelovanja kompleksnih sistema. Istorijska evolucija ovog pristupa svedoči o transformaciji inicijalnog koncepta zasnovanog na stohastičkim procesima u rigorozan i moćan matematički aparat, čiji se aplikativni domen kontinuirano ekspandira usled eksponencijalnog razvoja komputacionih resursa i algoritamskih inovacija. Analiza hronološkog razvoja ove metode ne pruža samo duboki uvid u njene probabilističke osnove, već i eksplicitno argumentuje razloge zbog kojih ona zauzima centralno mesto u savremenoj arhitekturi simulacionog modelovanja, služeći kao bazična platforma za rešavanje problema visoke dimenzionalnosti u uslovima neizvesnosti.



Slika 1. Naučnici koji su doprineli stvaranju Monte Karlo simulacije: Stanislaw Ulam, Džon fon Nojman i Nikolas Metropolis (Metropolis 1987)

2.2. Osnovni principi slučajnosti i probabilističkog modeliranja

Tokom modeliranja realnih sistema, slučajnost predstavlja fundamentalni koncept, budući da mnogi procesi u prirodi, tehnici i društvu ne mogu biti opisani determinističkim zakonima. Uvođenje slučajnih promenljivih u model zahteva se u takvim sistemima, gde ponašanje pojedinih elemenata zavisi od faktora koji su nedovoljno poznati ili nepredvidivi. Monte Karlo simulacija se upravo oslanja na formalizovanu upotrebu slučajnosti kako bi se aproksimiralo ponašanje sistema kroz veliki broj realizacija, pri čemu se pojedinačni ishodi posmatraju kao rezultat slučajnih eksperimenata (Ross 2014).

Izbor odgovarajućih distribucija verovatnoće za opis ulaznih promenljivih, predstavlja ključni element probabilističkog modeliranja. Ovaj izbor može biti zasnovan na empirijskim podacima, ekspertskim procenama ili teorijskim pretpostavkama. Validnost rezultata simulacije se može narušiti ukoliko su neadekvatno odabrane distribucije, pa se iz tog razloga posebna pažnja posvećuje statističkoj analizi podataka i proveru pretpostavki modela. Probabilističko modeliranje, u tom smislu, zahteva interdisciplinarni pristup koji kombinuje statistiku, teoriju verovatnoće i domensko znanje o posmatranom sistemu (Law 2015).

U okviru Monte Karlo simulacije, fenomen slučajnosti se operacionalizuje putem generisanja pseudoslučajnih brojeva, koji služe kao osnova za proces uzorkovanja iz unapred definisanih distribucija verovatnoće. Uprkos činjenici da su ovi brojevi proizvod determinističkih algoritama, njihova statistička svojstva omogućavaju adekvatnu aproksimaciju istinske slučajnosti u praktičnim primenama. Postulati uniformnosti i međusobne nezavisnosti generisanih nizova predstavljaju fundament za preciznost simulacionih ishoda i validnost celokupnog probabilističkog modelovanja, pri čemu se poseban akcenat stavlja na kvalitet i pouzdanost generatora slučajnih brojeva.

3. METODOLOGIJA IMPLEMENTACIJE MONTE KARLO SIMULACIJE

Metodološki okvir implementacije Monte Karlo simulacije otpočinje preciznom definicijom istraživačkog problema i ciljeva analize. Ova početna faza zahteva egzaktnu identifikaciju izlaznih veličina koje su predmet procene, kao i determinisanje relevantnih ulaznih parametara i njihovih međusobnih korelacija unutar sistema. Pravilna formulacija problema predstavlja ključni korak, s obzirom na to da ona direktno determiniše selekciju modela, izbor odgovarajućih distribucija verovatnoće i finalnu interpretaciju dobijenih rezultata. Bez obzira na tehničku preciznost samog simulacionog procesa, neadekvatna definicija polaznih osnova može rezultirati pogrešnim zaključcima i narušiti validnost istraživanja.

Kada se definiše problem, sledi izbor i specifikacija ulaznih distribucija verovatnoće. Ovaj korak podrazumeva prikupljanje i analizu dostupnih podataka, kao i donošenje pretpostavki o obliku distribucija u slučajevima kada empirijski podaci nisu potpuni. U zavisnosti od prirode procesa koji se modelira, ulazne promenljive mogu biti opisane kontinuiranim ili diskretnim distribucijama. Ulazne pretpostavke direktno određuju statističke karakteristike izlaznih veličina, pa tačnost simulacionih rezultata u velikoj meri zavisi od kvaliteta ovog koraka (Law 2015). Centralni segment implementacije Monte Karlo simulacije obuhvata generisanje pseudoslučajnih brojeva i proces uzorkovanja iz unapred definisanih raspodela verovatnoće. Pseudoslučajni nizovi se primenjuju za kreiranje realizacija ulaznih varijabli, pri čemu je od suštinske važnosti njihova statistička nezavisnost i uniformna distribuiranost. Na temelju ovih realizacija, simulacioni model se podvrgava masovnim iterativnim procesima, gde se ishodi svakog pojedinačnog ciklusa registruju za potrebe naknadne statističke obrade. Da bi se osigurala metodološka stabilnost i konvergencija dobijenih procena, neophodno je obezbediti adekvatno visok broj simulacionih ponavljanja.

Nakon izvršavanja simulacije, sledi statistička obrada i analiza dobijenih rezultata. Ova faza obuhvata procenu intervala poverenja, izračunavanje osnovnih deskriptivnih statistika, kao i analizu osetljivosti izlaznih veličina na promene ulaznih parametara. Posebna pažnja posvećuje se proveru konvergencije rezultata i proceni greške simulacije. Statistička analiza omogućava donošenje zaključaka o značaju dobijenih procena i pouzdanosti, čime se rezultati simulacije pretvaraju u korisne informacije za odlučivanje (Ross 2014).

3.1. Definisanje problema i modela sistema

Definisanje problema predstavlja početni i jedan od najkritičnijih koraka (Zarev i Stojković Terzić i Trifunović 2025) u procesu simulacionog modeliranja. Ova faza zahteva da se jasno formuliše cilj simulacije, tj. da se odrede koje se pojave ili odluke sistema analiziraju. Identifikacija sistema koji se posmatra treba biti obuhvaćena precizno definisanim problemom, relevantnim ulaznim i izlaznim promenljivim, granicama sistema i vremenskom analizom. Ukoliko se problem ne definiše jasno i precizno, to može dovesti do razvoja modela koji ne odgovara stvarnim potrebama analize, pa bi tako bila umanjena vrednost simulacionih rezultata.

Model sistema se definiše kao uprošćena, ali formalno strukturirana reprezentacija realiteta koja zadržava isključivo one ključne karakteristike relevantne za predmetni istraživački problem. Proces simulacionog modelovanja podrazumeva konstruisanje modela putem matematičkih relacija, logičkih pravila i algoritamskih procedura. Prilikom izrade, istraživač formuliše niz pretpostavki o strukturi sistema, modalitetima interakcije i međuzavisnosti njegovih konstitutivnih elemenata. S obzirom na to da ove pretpostavke direktno determinišu validnost i preciznost simulacionih ishoda, neophodno je da one budu teorijski utemeljene i transparentno dokumentovane.

Determinisanje adekvatnog nivoa apstrakcije predstavlja jedan od fundamentalnih aspekata u procesu definisanja modela sistema. Suviše redukovan model nosi rizik od zanemarivanja kritične dinamike sistema, dok preterano detaljna reprezentacija može rezultirati komputacionom zahtevnošću i smanjenom transparentnošću. U okviru Monte Karlo simulacije, idealan model treba da bude projektovan tako da zadrži dovoljnu jednostavnost radi omogućavanja masovnih simulacionih eksperimenata, ali istovremeno i visok stepen realizma radi verodostojne refleksije uticaja stohastičkih varijabli. Postizanje optimalnog balansa između računске efikasnosti i vernosti prikaza realiteta ključno je za uspeh simulacionog modelovanja.

Proces definisanja modela sistema obuhvata i preciznu identifikaciju determinističkih i stohastičkih komponenti koje konstituišu posmatrani fenomen. Prilikom formulisanja determinističkih segmenata, neophodno je integralno obuhvatiti izvore poremećenih dejstava koji su prisutni u realnim procesima, a koji mogu imati deterministički, stohastički ili mešoviti karakter. U okviru Monte Karlo simulacije, upravo stohastički elementi zauzimaju centralnu poziciju, budući da omogućavaju modelovanje varijabilnosti sistema i preciznu kvantifikaciju neizvesnosti. Jasna distinkcija između ovih komponenti značajno olakšava kasniju implementaciju algoritama i interpretaciju dobijenih rezultata.

Finalna etapa procesa definisanja problema i modela sistema podrazumeva sprovođenje preliminarne verifikacije smislenosti modela, što uključuje komparativnu analizu sa dostupnim empirijskim i teorijskim saznanjima, kao i konsultacije sa ekspertima iz predmetne oblasti. Radi sistematičnog uobličavanja problemskog okvira i transparentnog prikaza strukture simulacionog modela, u Tabeli 1 su sistematizovani ključni elementi i parametri Monte Karlo simulacije. Tabela pruža uvid u bazične komponente modela, obuhvatajući specifičnosti posmatranog sistema, definisane ciljeve, ulazne i izlazne varijable, kao i teorijske pretpostavke i operativna ograničenja. Ovakav pristup obezbeđuje koherentnu i preglednu osnovu za dalju realizaciju simulacionog eksperimenta.

Tabela 1. Ključni elementi i parametri simulacionog modela (autori)

Element modela	Opis	Primer vrednosti
Cilj simulacije	Procena ponašanja sistema pod uticajem neizvesnosti	Procena vrednosti zagušenja sistema
Posmatrani sistem	Sistem sa stohastičkim ponašanjem	Telekomunikaciona mreža / servisni sistem
Ulazne promenljive	Slučajne promenljive koje utiču na sistem	Vreme dolaska, vreme obrade
Ulazne distribucije	Verovatnoće raspodele ulaznih veličina	Eksponecijalna, normalna
Izlazne promenljive	Veličine koje se procenjuju simulacijom	Prosečno vreme čekanja
Broj iteracija	Broj nezavisnih ponavljanja	104 - 106
Pretpostavke modela	Uslovi pod kojima model važi	Nezavisnost događaja
Ograničenja modela	Faktori koji utiču na tačnost	Aproksimacija realnog sistema

3.2. Izbor ulaznih distribucija verovatnoće

Jedan od najvažnijih koraka u implementaciji Monte Karlo simulacije, predstavlja izbor ulaznih distribucija verovatnoće, jer direktno utiče na interpretaciju i validnost dobijenih rezultata. Ulazne promenljive u simulacionom modelu često predstavljaju veličine koje su podložne slučajnim fluktuacijama, kao što su trajanje procesa, vreme dolaska zahteva, opterećenje resursa ili gubici u sistemu. Ove veličine se opisuju odgovarajućim distribucijama verovatnoće, umesto determinističkog pristupa, čime se omogućava realističniji prikaz ponašanja sistema u uslovima neizvesnosti (Law 2015). Proces izbora distribucija može biti zasnovan na teorijskim pretpostavkama ili empirijskim podacima o prirodi posmatranog procesa.

U Monte Karlo simulacijama često se koriste standardne teorijske distribucije, kao što su normalna, uniformna, Puasonova ili ekspanencijalna raspodela. Pravilno razumevanje je ključno za adekvatno modeliranje sistema, jer svaka od distribucija ima specifična svojstva i oblast primene. Na primer, ekspanencijalna raspodela se često koristi za modeliranje vremena između događaja u sistemima sa slučajnim dolascima, dok se normalna raspodela primenjuje za veličine koje predstavljaju zbir velikog broja nezavisnih slučajnih uticaja (Ross 2014).

Unutar domena telekomunikacija, selekcija ulaznih distribucija zauzima kritično mesto usled varijabilnog opterećenja mreže i inherentne stohastičke prirode saobraćajnih tokova. Dok se tradicionalni saobraćajni procesi u telekomunikacionim sistemima učestalo modeluju primenom Puasonovih i ekspanencijalnih raspodela, savremene mrežne arhitekture zahtevaju implementaciju distribucija sa teškim repovima radi preciznijeg opisa rafalnog karaktera saobraćaja. Adekvatno modelovanje predstavlja fundament za pouzdanu simulaciju ključnih performansi sistema, kao što su kašnjenje, propusni opseg i verovatnoća gubitka paketa. Nakon odabira odgovarajućih funkcija raspodele verovatnoće, neophodno je izvršiti verifikaciju njihove adekvatnosti primenom testova slaganja, analiza osetljivosti ili specijalizovanih grafičkih metoda.

3.3. Algoritamski koraci Monte Karlo simulacije

Algoritamska struktura Monte Karlo simulacije zasniva se na jasno definisanom nizu koraka koji omogućavaju sistematsko sprovođenje simulacionog eksperimenta. Formalna specifikacija

simulacionog modela podrazumeva prvi korak koji uključuje definisanje ulaznih promenljivih, njihove međusobne zavisnosti i distribuciju verovatnoće. Tokom ove faze takođe se definišu izlazne veličine od interesa i kriterijuma na osnovu kojih se analiziraju simulacije. Osnova za pravilnu implementaciju algoritma i kasniju interpretaciju rezultata predstavlja se preciznom formalizacijom modela (Law 2015).

Nakon precizne specifikacije modela, pristupa se generisanju pseudoslučajnih brojeva koji predstavljaju fundamentalnu osnovu za proces uzorkovanja iz prethodno definisanih distribucija verovatnoće. Navedeni brojevi se, primenom metoda inverzne transformacije ili drugih specijalizovanih tehnika uzorkovanja, konvertuju u konkretne realizacije ulaznih promenljivih. Validnost celokupne Monte Karlo simulacije direktno je uslovljena pretpostavkama o uniformnosti i statističkoj nezavisnosti generisanih nizova, s obzirom na to da ovi parametri neposredno determinišu preciznost i pouzdanost statističkih procena izvedenih putem simulacionog eksperimenta.

Centralni deo Monte Karlo algoritma čini iterativno izvršavanje simulacionog modela. U svakoj iteraciji generiše se novi skup ulaznih vrednosti, na osnovu kojih se računa odgovarajući ishod sistema. Ponavljanje ovog postupka vrši se više puta, pri čemu se rezultati svake iteracije beleže radi dalje obrade. U skladu sa željenom preciznošću rezultata i dostupnim računarskim resursima se bira broj iteracija, jer statistička greška opada sa porastom broja simulacionih ponavljanja (Ross 2014). Posle završetka simulacionih iteracija, sledi faza statističke obrade dobijenih rezultata.

Nakon generisanja relevantnih statističkih procena, nastupa finalna algoritamska etapa Monte Karlo simulacije koja obuhvata interpretaciju rezultata i formulisane naučnih zaključaka. Ovaj proces podrazumeva rigoroznu komparaciju dobijenih simulacionih ishoda sa teorijskim postavkama, empirijskim podacima ili alternativnim modelima radi potvrde validnosti istraživanja. U cilju precizne evaluacije uticaja varijacija ulaznih parametara na izlazne performanse sistema, sprovodi se analiza osetljivosti. Ovakav metodološki pristup omogućava identifikaciju ključnih faktora koji determinišu dinamiku sistema, čime se stvara osnova za donošenje informisanih i naučno utemeljenih odluka.

3.4. Validacija i verifikacija simulacionog modela

Proces provere u kome se gleda da li je model pravilno implementiran u skladu sa njegovom matematičkom i konceptualnom specifikacijom predstavlja verifikaciju simulacionog modela. Cilj ovog postupka jeste identifikovati programske greške, logičke nedoslednosti i nepravilne implementacije algoritama. Verifikacija, u kontekstu Monte Karlo simulacije, obuhvata pravilnost uzorkovanja uloženi promenljivih, tačnost generisanja pseudoslučajnih brojeva kao i ispravnost izlaznih veličina koje se izračunavaju u svakoj iteraciji simulacije (Law 2015).

Validacija simulacionog modela predstavlja kritički proces evaluacije stepena u kojem model verodostojno reflektuje realni sistem ili posmatrani proces. Primarna intencija ovog postupka ogleda se u utvrđivanju teorijske i praktične relevantnosti simulacionih ishoda u komparaciji sa empirijskim podacima ili projektovanim ponašanjem sistema pod specifičnim okolnostima. U kontekstu primene Monte Karlo simulacije, postupak validacije se najčešće realizuje kroz rigorozno poređenje dobijenih rezultata sa analitičkim rešenjima, prethodno verifikovanim istraživanjima ili dostupnim istorijskim podacima iz realnog okruženja.

Statistička komparacija simulacionih ishoda sa empirijskim merenjima ili prethodno utvrđenim vrednostima sistema predstavlja jednu od fundamentalnih tehnika validacije. Ovaj metodološki okvir obuhvata primenu testova statističkih hipoteza, analizu rezidualnih grešaka i konstrukciju intervala poverenja, čime se obezbeđuje visoka statistička značajnost dobijenih zaključaka. Ovakva analitička procedura omogućava preciznu identifikaciju potencijalnih izvora devijacija, kao i egzaktnu kvantitativnu evaluaciju kvaliteta projektovanog modela. Pored rigoroznih kvantitativnih metoda, proces validacije neretko integriše i kvalitativne pristupe, poput ekspertske procene i ispitivanja odziva modela u ekstremnim ili graničnim uslovima eksploatacije.

4. METODOLOGIJA INTEGRACIJE VEŠTAČKE INTELIGENCIJE I MONTE KARLO SIMULACIJE

Metodološki okvir koji integriše veštačku inteligenciju u proces Monte Karlo simulacije ne predstavlja puku automatizaciju postojećih operacija, već označava suštinsku transformaciju modaliteta uzorkovanja prostora stanja i obrade generisanih rezultata. Dok se konvencionalna Monte Karlo simulacija primarno oslanja na metodu grube sile, hibridni modeli koji objedinjuju Monte Karlo simulaciju i veštačku inteligenciju koriste napredne kognitivne kapacitete algoritama za identifikaciju kompleksnih nelinearnih zavisnosti unutar samog modela. Aplikativna vrednost ovih hibridnih pristupa danas je naročito istaknuta u strateškim sektorima poput ekološkog inženjerstva, gde se primenjuju za optimizaciju trodimenzionalnih elektrohemijskih tretmana otpadnih voda putem visoko preciznog modelovanja hemijskih reakcija. Upotrebom veštačke inteligencije za predviđanje ishoda na osnovu Monte Karlo parametara, istraživači postižu visoku efikasnost uz minimalne troškove energije (Voravich, Merenghege, i Trzcinski 2024, 41). Biomedicina i nanomedicina u terapiji kancera za precizna doziranja zračenja koristi Monte Karlo simuliranje za modeliranje putanja čestica, dok veštačka inteligencije pomaže u prilagođavanju plana zračenja u realnom vremenu na osnovu anatomske promene pacijenta (Chow 2025, 15). U građevinarstvu i geotehnici, analiza stabilnosti kosina podložnih anizotropiji zahteva ogromne resurse. Mašinsko učenje omogućava da se Monte Karlo simulacija fokusira na kritične tačke pucanja, čime se proces ubrzava i do deset puta (Aminpour et al. 2022). Savremeni pristupi u investicionoj analizi koriste mašinsko učenje za interpretaciju ogromnog broja podataka dobijenih Monte Karlo simulacijom. Kako navode autori (Kozlova, Collan, i Tapani 2022), integracija omogućava automatizovanu klasifikaciju ishoda i identifikaciju najprofitabilnijih putanja u uslovima visoke tržišne volatilnosti, što značajno ubrzava proces donošenja strateških odluka.

U kontekstu finansijskih tržišta, tradicionalni modeli procene rizika često ne uspevaju da obuhvate ekstremne tržišne potrebe. Pojedini autori (Stojanović et al. 2023) ističu da integracija Monte Karlo simulacije sa veštačkim neuronskim mrežama omogućava preciznije predviđanje indikatora tržišnih rizika, jer neuronske mreže efikasnije prepoznaju nelinearne obrasce u istorijskim podacima koje simulacija potom koristi za generisanje budućih scenarija.

4.1. Koncept surogat modeliranja (Metamodelling)

Centralna tačka integracije je razvoj surogat modela. Proces započinje izvršavanjem ograničenog broja visokopreciznih, ali računski skupih Monte Karlo simulacija koje služe kao trening set. Na ovim podacima se obučava algoritam mašinskog učenja. Nakon obuke, model veštačke inteligencije preuzima ulogu "proksija" koji predviđa ishode za preostalih milion iteracija u milisekundama. Prema istraživanjima (Aminpour et al. 2022), ovakav pristup smanjuje računsko vreme za preko 85%, uz zanemariv pad preciznosti, što je ključno za analizu pouzdanosti u realnom vremenu. Pored strukturne pouzdanosti, hibridni pristup koji kombinuje Monte Karlo simulaciju i duboko učenje (Deep Learning) pokazuje izuzetne rezultate u predviđanju pouzdanosti složenih industrijskih sistema, gde se veštačka inteligencija koristi za modelovanje vremenskih serija otkaza koje bi klasična simulacija predugo procesuirala (Li et al. 2024).

4.2. Adaptivno uzorkovanje i redukcija varijanse

Jedan od fundamentalnih komputacionih izazova u implementaciji Monte Karlo simulacije odnosi se na nisku stopu konvergencije. Metodološki progres postignut integracijom veštačke inteligencije reflektuje se primarno kroz razvoj mehanizama adaptivnog uzorkovanja. Umesto kon-

vencionalne stohastičke selekcije ulaznih parametara, algoritmi veštačke inteligencije sprovode kontinuiranu evaluaciju rezultata radi identifikacije domena „visoke entropije“ ili „kritičnih pragova otkaza“. Ovakva ciljana fokusiranost na kritične zone (kao što su ekstremne vrednosti mehaničkog opterećenja u inženjerstvu), u literaturi se definiše kao inteligentno uzorkovanje (eng. smart sampling). Implementacijom ovog pristupa direktno se optimizuje varijansa modela, čime se sprečava neefikasna distribucija računarskih resursa na predvidive i stabilne ishode, značajno ubrzavajući proces postizanja statistički relevantnih rezultata.

Problem niske verovatnoće otkaza kod složenih konstrukcija, koji zahteva ogroman broj iteracija u standardnoj Monte Karlo metodi, efikasno se rešava integracijom algoritama mašinskog učenja koji služe za inteligentnu identifikaciju kritičnih domena uzorkovanja (Guo et al. 2024). Integracija algoritama veštačke inteligencije omogućava razvoj surogat modela koji drastično redukuju broj potrebnih simulacionih koraka (Guo et al. 2024), čime se rešava problem visoke računarske intenzivnosti tradicionalne Monte Karlo metode.

4.3. Algoritamska arhitektura hibridnog procesa

Tipičan radni tok integrisanog modela obuhvata četiri ključne faze. Prva faza je generisanje uzoraka, korišćenje kvazi-Monte Karlo metoda za inicijalno pokrivanje prostora (Dick, Kuo, i Sloan 2013). Druga faza je obuka, mapiranje ulaznih parametara na izlazne rezultate pomoću algoritama veštačke inteligencije. Treća faza je predikcija, masovna simulacija nad surogat modelom. Poslednja faza je validacija, izvršavanje kontrolnih Monte Karlo simulacija na nasumičnim tačkama radi potvrde tačnosti modela veštačke inteligencije. U specifičnim oblastima, poput fizike plazme, ova metodologija omogućava modeliranje interakcija čestica koje bi bez akceleracije veštačke inteligencije zahtevale mesece superkompjuterskog rada (Bisai i Kaw 2018). U nanomedicini, ovaj proces omogućava da se simulacija putanje čestica zračenja prilagodi trenutnom položaju tumora, što predstavlja vrhunac precizne terapije (Chow 2025, 15). Savremena istraživanja ukazuju na to da surogat modeli zasnovani na dubokom učenju mogu uspešno zameniti kompleksne Monte Karlo simulacije u protonskoj radioterapiji kod pacijenata sa tumorom mozga, zadržavajući visoku preciznost uz značajno smanjenje potrebnih računarskih resursa (Starke et al. 2024).

U sektoru energetike i investicionog planiranja, hibridni modeli se koriste za analizu realnih opcija. Istraživanje (Kozlova, Collan, i Tapani 2022) pokazuje da primena ovih metoda kod projekata obnovljivih izvora energije omogućava menadžmentu da preciznije proceni trenutak investiranja, smanjujući rizik od gubitaka koji su posledica nepredvidivih promena cena na tržištu.

U sferi finansijske stabilnosti i finansijskog sektora (Myers 1977; Myers and Majluf 1984; Myers 1993; Duvnjak 2021) integracija Monte Karlo simulacije sa mašinskim učenjem postaje standard za sprovođenje stres testova. Ovi modeli omogućavaju simulaciju ekstremnih tržišnih scenarija uz istovremenu analizu pomoću veštačke inteligencije međuzavisnosti različitih faktora rizika u realnom vremenu. Istraživanje ukazuje na to da ovakvi modeli omogućavaju precizniju identifikaciju sistemskih rizika u uslovima ekstremne tržišne volatilnosti, što je od ključnog značaja za moderni bankarski sektor (Zhang et al. 2023).

ZAKLJUČAK

Monte Karlo simulacija se pozicionirala kao jedna od najznačajnijih i najšire primenljivih metoda u domenu savremenog simulacionog modelovanja, naročito u okviru analize sistema koje odlikuju visoka neizvesnost, strukturalna složenost i nelinearnost. U ovom radu su detaljno sintetizovani teorijski temelji, istorijska geneza, proces implementacije, kao i aktuelna, eksten-

zivna primena u modernim naučnim i inženjerskim disciplinama. Poseban akcenat je stavljen na ulogu slučajnosti i probabilističkog modelovanja, koji omogućavaju znatno realističniju reprezentaciju ponašanja sistema u poređenju sa rigidnim determinističkim modelima, pružajući time dublji uvid u stohastičku prirodu realnih procesa.

Pravilna interpretacija ishoda Monte Karlo simulacije od krucijalnog je značaja s obzirom na inherentni probabilistički karakter dobijenih rezultata. Formiranje pouzdanih zaključaka neposredno zavisi od dubinskog razumevanja ključnih statističkih pokazatelja, prvenstveno varijanse, intervala poverenja i konvergencije simulacionih nizova. Shodno tome, Monte Karlo metodu ne bi trebalo tretirati isključivo kao izolovan numerički alat, već kao sveobuhvatan analitički okvir koji istraživaču omogućava precizan uvid u dinamiku i ponašanje sistema pod permanentnim uticajem stohastičkih faktora.

U okviru rada razmatrani su ključni domeni primene Monte Karlo simulacije, sa posebnim osvrtom na analizu pouzdanosti, složene inženjerske strukture, računarske i telekomunikacione sisteme, kao i procese u biomedicini koje karakteriše izražena neizvesnost. Navedeni primeri nedvosmisleno potvrđuju da Monte Karlo metod predstavlja univerzalni numerički instrument, sposoban da odgovori na kompleksne izazove modeliranja u različitim naučnim okvirima. Njegova primena je naročito nezamenljiva u situacijama gde su egzaktna analitička rešenja nedostupna ili njihova praktična implementacija nije izvodljiva zbog visokog stepena kompleksnosti sistema.

U radu su detaljno analizirana ograničenja i prednosti metode, pri čemu je poseban akcenat stavljen na njenu robusnost, fleksibilnost i konceptualnu jednostavnost u praktičnoj primeni. Nasuprot ovim benefitima, identifikovani su izazovi koji se odnose na imperativ visokog kvaliteta ulaznih podataka, kao i na značajnu računarsku složenost i vremenske zahteve pri izvršavanju procesa. Ipak, savremena ekspanzija računarskih tehnologija, razvoj paralelnih sistema i duboka integracija sa mašinskim učenjem i veštačkom inteligencijom, otvaraju nove horizonte za fundamentalno unapređenje efikasnosti i preciznosti Monte Karlo simulacije.

Glavna prednost ove sinergije Monte Karlo simulacije i veštačke inteligencije je dramatično smanjenje vremena potrebnog za dobijanje rezultata. Poseban izazov u simulacionom modelovanju predstavljaju sistemi spinskih stakala, koji zbog svoje frustrirane energetske strukture i velikog broja lokalnih minimuma služe kao reper za testiranje efikasnosti algoritama. Upravo kod ovakvih nelinearnih problema, klasične Monte Karlo metode pokazuju ograničenja, dok populaciono simulirano kaljenje omogućava prevazilaženje energetskih barijera, obezbeđujući konvergenciju ka globalnom optimumu sistema (Barzegar et al. 2017). Uprkos značajnim prednostima, integracija naprednih tehnologija nosi određene rizike, prvenstveno zbog mogućnosti da modeli veštačke inteligencije postanu netransparentne strukture, takozvane „crne kutije“, unutar kojih istraživač gubi jasan uvid u kauzalnost generisanih ishoda. Za razliku od konvencionalne Monte Karlo simulacije, koja počiva na egzaktnim i matematički proverljivim principima, hibridni modeli su esencijalno uslovljeni kvalitetom dostupnih podataka za učenje. Ukoliko su inicijalni simulacioni parametri pristrasni, veštačka inteligencija teži amplifikaciji te pristrasnosti, zbog čega se imperativ stavlja na rigorozne metode verifikacije i validacije. Sinergija ove dve discipline transformiše razumevanje kompleksnosti: dok Monte Karlo simulacija obezbeđuje strogi statistički okvir, veštačka inteligencija doprinosi komputacionom efikasnošću. Budući razvoj usmeren je ka adaptivnim simulacijama sposobnim za autonomnu rekonfiguraciju parametara u realnom vremenu, što za discipline poput medicine, energetike i ekonomije označava prelazak na proaktivne i visokoprecizne paradigme planiranja. Rezultati analize potvrđuju da kombinovani model Monte Karlo simulacije i veštačke inteligencije nadmašuje tradicionalne determinističke metode, jer, prema nalazima autora (Kozlova i Collan i Tapani 2022), omogućava obuhvatanje nelinearnih zavisnosti između varijabli koje klasična

statistika često zanemaruje. Rezultati domaćih istraživanja (Stojanović et al. 2023) potvrđuju da hibridni modeli smanjuju grešku predviđanja u uslovima visoke volatilnosti, što je od strateškog značaja za institucionalne investitore i aktuarsku praksu u regionu. Rad doprinosi literaturi kroz predlog hibridnog modela koji integriše surogat modeliranje i adaptivno uzorkovanje, čime se postiže visoka preciznost uz značajnu redukciju računarskih resursa. Buduća istraživanja trebalo bi da se fokusiraju na razvoj kvantnih Monte Karlo simulacija, koje bi mogle dramatično smanjiti vreme potrebno za rešavanje problema spinskih stakala i drugih složenih optimizacija koje su trenutno ograničene procesorskom snagom klasičnih računara. Implementacija hibridnih modela omogućava prelazak sa reaktivnog upravljanja krizama na proaktivno modelovanje scenarija, čime se nivo poslovnog rizika svodi na minimum, čak i u uslovima ekstremne tržišne nestabilnosti. Poseban izazov ostaje očuvanje transparentnosti modela. Neophodno je insistirati na razvoju objašnjive veštačke inteligencije (Explainable AI) unutar simulacionog okvira, kako bi rezultati dobijeni hibridnim putem ostali matematički proverljivi i etički prihvatljivi za kritične sektore poput medicine i energetike. Zaključno, Monte Karlo simulacija nije samo istorijski važan numerički metod, već dinamična platforma koja, u sinergiji sa kognitivnim kapacitetima veštačke inteligencije, definiše novu epohu u razumevanju i predviđanju složenih sistema. Aktuelna geopolitička nestabilnost na Bliskom istoku i prateća neizvesnost na globalnom tržištu energenata dodatno naglašavaju neophodnost primene naprednih simulacionih modela. U uslovima potencijalne naftne krize, hibridni pristupi koji kombinuju Monte Karlo simulaciju sa algoritmima veštačke inteligencije omogućavaju preciznije predviđanje fluktuacija cena sirove nafte i identifikaciju rizika u lancima snabdevanja. Za razliku od tradicionalnih ekonomskih modela, ovi sistemi mogu simultano procesuirati hiljade stohastičkih varijabli – od rizika zatvaranja ključnih pomorskih ruta do naglih promena u nivoima proizvodnje – pružajući donosiocima odluka kvantifikovanu verovatnoću različitih scenarija. Ovakva proaktivna analitika transformiše način na koji se države i korporacije pripremaju za energetske šokove, omogućavajući formiranje otpornijih ekonomskih strategija u visoko volatilnom okruženju.

LITERATURA

1. Aminpour, Mohammad, Reza Alaie, Navid Kardani, Sara Moridpour, i Majidreza Nazem. 2022. "Highly efficient reliability analysis of anisotropic heterogeneous slopes: Machine learning aided Monte Carlo method." *Acta Geotechnica* 4, arXiv:2201.00001. <https://doi.org/10.48550/arXiv.2204.06098>
2. Barzegar, Amin, Christopher Pattison, Wwnlong Wang, i Helmut Katzgraber. 2017. "Optimization of population annealing Monte Carlo for large-scale spin glass simulations." *Physical Review E* 98, 053308. <https://doi.org/10.1103/PhysRevE.98.053308>
3. Bisai, Nirmal, i Predhiman Kaw. 2018. "Influence of hot and cold neutrals on scrape-off layer tokamak plasma turbulence." *Physics of Plasmas* 25: 012503. <https://doi.org/10.1063/1.5002623>
4. Chow, James. 2025. "Monte Carlo Simulations in Nanomedicine: Advancing Cancer Imaging and Therapy." *Journal of Nanobiotechnology* 23: 15. <https://doi.org/10.3390/nano15020117>
5. Dick, Josef, Frances Kuo, i Ian Sloan. 2013. "High-dimensional integration: The quasi-Monte Carlo way." *Acta Numerica* 22: 133–288. <https://doi.org/10.1017/S0962492913000044>
6. Duvnjak, Valentina. 2021. "Optimal capital structure". *Business Studiess* 13(25-26):111-118.
7. Eckhardt, Roger. 1987. "Stan Ulam, John von Neumann, and the Monte Carlo method." *Los Alamos Science* 15: 131–137. https://mcnp.lanl.gov/pdf_files/Article_1987_LAS_Eckhardt_131--141.pdf

8. Ganthavee, Voravich, Fernando Merenghege, and Antoine Trzcinski. 2024. "Monte Carlo Simulation, Artificial Intelligence and Machine Learning-based Modelling and Optimization of Three-dimensional Electrochemical Treatment of Xenobiotic Dye Wastewater." *Environmental Processes* 11 article number: 41. <https://doi.org/10.1007/s40710-024-00719-1>
9. Guo, Hongyang, Changqi Luo, Shun-Peng Zhu, Xinya You, Mengli Yan, i Xiaohua Liu. 2024. "Machine learning-based enhanced Monte Carlo simulation for low failure probability structural reliability analysis." *Reliability Engineering & System Safety* 241: 109633. <https://doi.org/10.1016/j.istruc.2025.108530>
10. Kozlova, Mariia, Mikael Collan, i Jouni Tapani. 2022. "Real options analysis with Monte Carlo simulation and machine learning: A case of renewable energy investment." *Energy Economics* 105: 105765. <https://doi.org/10.1016/j.eneco.2021.105765>
11. Li, Yan-Fu, Shuo-Chao Jun, Zhai-Xian Geng, Rui Peng, i Pan-Pan Zhou. 2024. "A hybrid Monte Carlo and deep learning approach for reliability forecasting of complex industrial systems." *Reliability Engineering & System Safety* 245: 109982. <https://doi.org/10.1016/j.ress.2023.109982>
12. Law, Averill M. 2015. *Simulation modeling and analysis*. 5. Edition. New York: McGraw-Hill Education. <https://staff.universitaspahlawan.ac.id/web/upload/materials/958-materials.pdf>
13. Metropolis, Nicholas. 1987. "The beginning of the Monte Carlo method." *Los Alamos Science* 15: 125–130.
14. Metropolis, Nicholas, i Stanislaw Ulam. 1949. "The Monte Carlo method." *Journal of the American Statistical Association* 44 (247): 335–341. <https://doi.org/10.1080/01621459.1949.10483310>
15. Mičić, Saša, i Radmila Čičković. 2020. "Sensitivity analysis and scenario method for evaluation of efficiency of investment projects in risk conditions." *Poslovne studije* 12 (23-24):11-26.
16. Myers, Stewart. 1977. "Determinants of corporate borrowing," *Journal of Financial Economics* 5(2):147-175.
17. Myers, Stewart, and Nicholas Majluf. 1984. "Corporate Financing and Investment Decisions When Firms Have Information That Investors Do Not Have." *Journal of Financial Economics* 13: 187-221.
18. Myers, Stewart. 1993. "Still searching for optimal capital structure". *Journal of applied Corporate finance* 6: 80-105.
19. Ross, Sheldon. 2014. *Introduction to probability models*. 11. Edition. London: Academic Press. <https://essaywritinglebanon.com/wp-content/uploads/2021/05/introduction-to-prob-models-11th-edition.pdf>
20. Starke, Sebastian, Aaron Kieslich, Martina Palkowitsch, Fabian Hennings, Esther Troost, Mechthild Krause, Jona Bensberg et al. 2024. "A deep-learning-based surrogate model for Monte-Carlo simulations of the linear energy transfer in primary brain tumor patients treated with proton-beam radiotherapy" *Physics in Medicine & Biology* 69 165034. <https://iopscience.iop.org/article/10.1088/1361-6560/ad64b7> <https://doi.org/10.1088/1361-6560/ad64b7>
21. Stojanović, Milosav, Dragan Stojanović, i Jelena Stojanović. 2023. „Primena Monte Karlo simulacije i neuronskih mreža u predviđanju tržišnih rizika." *Ekonomski vidici* 28 (1-2): 45–58.
22. Zarev, Dragan, Jelena Stojković Terzić i Jovana Trifunović. 2025. „Optimalna lokacija i veličina solarnih elektrana u distributivnim mrežama: Probablistička analiza naponskih odstupanja i gubitaka putem Monte Karlo simulacija." U *Zbornik radova 37. savetovanja*

- CIGRE Srbija*, Beograd: CIGRE Srbija. 33-44:1857. https://rimsi.imsi.bg.ac.rs/bitstream/handle/123456789/3650/bitstream_10146.pdf?sequence=1&isAllowed=y
23. Zhang, Yi, Li-Wen Chen, Jin-Qiang Hu i Shao-Yuan Wang. 2023. "FinTech and financial risk: A Monte Carlo simulation and machine learning integration for stress testing." *Journal of Financial Stability* 66: 101124. <https://doi.org/10.1016/j.jfs.2023.101124>