

**IZVORNI ZNANSTVENI RAD****519.243:657.6****Prof. dr. sc. Ksenija Dumičić****IZUČAVANJE ALFA I BETA RIZIKA  
U DOKAZNIM TESTOVIMA REVIZORA****STUDYING ALPHA AND BETA RISKS  
IN AUDITORS' SUBSTANTIVE TESTS**

---

**SAŽETAK:** U radu su prikazani istraživački nalazi do kojih je autorica došla uporabom metode uzoraka i metode statističke kontrole kvalitete u analizi revizijskih rizika nastalih zbog uzorka. Primjenom modela testiranja revizijskih hipoteza, uz hipotetične primjere pri dokaznom testu revizora, otkriveni su sljedeći odnosi: uočena je obrnuta proporcionalnost između  $\alpha$  rizika i  $\beta$  rizika; obrnuta proporcionalnost  $\beta$  rizika s inherentnim, kontrolnim i rizikom analitičkih postupaka; veličina uzorka je obrnuto proporcionalna vrijednostima: rizika  $\alpha$ , prihvatljive preciznosti (A), kao i dopuštene pogreške (TM). Preciznost A poprima veću vrijednost kada je veća vrijednost  $\beta$  rizika. Analizom krivulja operativne karakteristike (OC) pri odabranom planu uzorkovanja za prihvaćanje zaključuje se da između rizika pogrešnog prihvaćanja revizijske populacije  $\beta$  (rizika korisnika revizijskih nalaza), uz fiksirane vrijednosti ostalih relevantnih faktora ( $\alpha$ , AQL i LTPD) i veličine potrebnog uzorka, postoji obrnuta proporcionalnost. Variranjem razine rizika pogrešnog odbacivanja revizijske populacije  $\alpha$  (rizika menadžmenta) na niskim razinama, uz nepromijenjene druge relevantne faktore ( $\beta$ , AQL i LTPD), veličina uzorka se nije vidljivo promjenila.

**KLJUČNE RIJEĆI:** statistički uzorak, model testiranja revizijskih hipoteza, revizijski rizici, plan uzorka za prihvaćanje, vjerojatnost pogrešnog odbacivanja ( $\alpha$ ), vjerojatnost pogrešnog prihvaćanja ( $\beta$ ).

**ABSTRACT:** The paper presents the author's research results achieved using sampling methods and methods of statistical quality control in the analysis of audit risks caused by sampling. Using the audit hypothesis testing model and substantive test based on hypothetical examples, the following relationships were discovered: inverse proportionality between  $\alpha$  risk and  $\beta$  risk; inverse proportionality between  $\beta$  risk and inherent, control and analytical procedures risks; the sample size was inversely proportionate to the level of:  $\alpha$  risk, acceptable precision (A), and to the size of tolerable misstatement (TM), as well. The value of precision A would increase if  $\beta$  risk would increase. When analyzing operation characteristic curves (OC) of a selected acceptance sampling plan, the conclusion arose that, with fixed values of other relevant factors ( $\alpha$ , AQL and LTPD), an inverse proportionality between the risk of incorrect acceptance of an audit population  $\beta$  (the risk of audit results users) and the needed sample size existed. When changing on low levels of the risk of incorrect rejection of an audit population  $\alpha$  (the management risk), with unchanged values of other relevant factors ( $\beta$ , AQL and LTPD), the needed sample size did not change visibly.

**KEY WORDS:** statistical sample, audit hypothesis testing model, audit risks, acceptance sampling plan, probability of incorrect rejection ( $\alpha$ ), probability of incorrect acceptance ( $\beta$ ).

---

## 1. UVOD

Koncept revizijskih rizika svakako je jedan od najznačajnijih u procesu revizije finansijskih izvještaja. Kad god se odluke revizora temelje na rezultatima uzorka, postoje nezabilazni rizici uzorka da će se pri odlučivanju pogriješiti. Iako se ti rizici pogrešnog prihvaćanja ili pogrešnog odbacivanja populacije ne mogu ukloniti, oni se mogu nadzirati. Od domaćih autora o primjeni metode uzoraka u reviziji vidjeti, primjerice, Tušek (2001b) te Vitežić (1998.), a o rizicima u reviziji Spremić (1995.) i Tušek (2001a, 2003.).

Predmet istraživanja u ovom radu je model revizijskih rizika, s posebnim osvrtom na njegove statističke komponente koje potječu od uzorka: (1) rizik pogrešnog odbacivanja  $\alpha$ , koji u reviziji označuje rizik da će rezultati ispitivanja uzorka ukazati na netočnosti u inače točnim računovodstvenim podacima, te (2) rizik pogrešnog prihvaćanja  $\beta$ , koji u reviziji predstavlja rizik da će rezultati ispitivanja uzorka ukazati na točnost iako su u iskazanim računovodstvenim podacima prisutne značajne netočnosti<sup>1</sup>. Rizici  $\alpha$  i  $\beta$  mogu stvoriti pogrešnu sliku o finansijskim izvještajima te zahtijevaju dodatni rad revizora odnosno klijenta i kao takvi se čine neiscrpnom temom za izučavanje.

Svrha ovoga rada je u davanju znanstvenog doprinosa glede otkrivanja novih spoznaja o variranju i kovariranju pojedinih vrsta rizika uzorka u reviziji, te njihovim stavljanjem u interakciju s potrebnom veličinom statističkog uzorka i to uz revizijsku strategiju dokaznih testova<sup>2</sup>. Također se promatra i plan uzorkovanja za prihvaćanje<sup>3</sup> revizijske populacije i krivulja operativne karakteristike ( $OC^4$  krivulja), kako bi se donijeli zaključci o povezanosti  $\alpha$  rizika pogrešnog odbacivanja i  $\beta$  rizika pogrešnog prihvaćanja te prihvatljive razine kvalitete AQL, razine kvalitete neprihvatljive populacije LTPD s veličinom revizijskog uzorka.

U istraživanju se polazi od sljedećih hipoteza:

H1: Uz primjenu modela testiranja revizijskih hipoteza<sup>5</sup> pri dokaznom testu veličina revizijskog uzorka povezana je s rizicima uzorka  $\alpha$  i  $\beta$ , s veličinom maksimalne pogreške koja se tolerira TM te s veličinom prihvatljive preciznosti A.

H2: Kod dokaznog testa revizora uz uporabu plana uzorka za prihvaćanje, rizik pogrešnog odbacivanja revizijske populacije  $\alpha$  i rizik pogrešnog prihvaćanja revizijske populacije  $\beta$  povezani su s veličinom uzorka. Pritom veličina uzorka reagira i na veličine prihvatljive razine kvalitete AQL i na razine kvalitete neprihvatljive populacije LTPD.

Nakon teorijskog dijela rada, nastalog temeljem bogatih bibliografskih izvora iz djelokruga revizije i statistike, pri utvrđivanju i izračunavanju rizika i računanju potrebne veličine uzorka, korištene su tehnike i metode probabilističkih uzoraka i odabrane metode statističke kontrole kvalitete te znanstvene metode analize, sinteze i komparacije. U radu su korišteni hipotetični primjeri.

---

<sup>1</sup> Eng. *material misstatement* se prevodi kao značajna pogreška ili značajna netočnost.

<sup>2</sup> Eng. *substantive tests*.

<sup>3</sup> Eng. *acceptance sampling*.

<sup>4</sup> Od eng. *Operating Characteristic Curve*.

<sup>5</sup> Eng. *audit hypothesis testing model*.

## 2. PRIMJENA PLANOVA UZORAKA U REVIZIJI

Prema Meigs i Meigs (1999, str. 296), finansijske izvještaje poduzeća sastavlja menadžment kompanije, a revizija tih izvještaja ima za svrhu premošćivanje jaza između menadžmenta i korisnika tih izvještaja. Revizija finansijskih izvještaja je skup postupaka usmjerenih na davanje mišljenja odgovaraju li finansijski izvještaji poduzeća izjavama koje je o tim izvještajima dala uprava poduzeća. Osnovna je svrha finansijske revizije odrediti općenitu ispravnost skupa finansijskih izvještaja, a ne otkriti bilo koje ili sve prijevare i netočnosti. Korisnici finansijskih izvještaja stoga ne očekuju jamstvo revizora za njihovom 100%-tnom točnošću. Budući da su mnogi postupci revizije zasnovani na uzorcima, pogreške uzorka su zbog nepotpunog obuhvata ispitivanih podataka neizbjegne, a i revizijom neposredno obuhvaćen materijal može omaškom, zbog mogućnosti nastanka neuzoračkih pogrešaka, biti također pogrešno ocijenjen. U ovom radu tretiraju se samo vjerojatnosti pogrešaka koje su nastale zbog uzorka.

Prema revizijskim standardima *SAS No.39, Audit Sampling*<sup>6</sup> te MRevS 530<sup>7</sup>, revizijska metoda uzorka je primjena revizijskih postupaka nad manje od 100% stavaka uključenih u saldo ili u skupinu poslovnih događaja, pri čemu su ti postupci primjenjeni u svrhu vrednovanja nekih značajki toga salda ili skupine. Općenito, revizijski uzorak može biti izabran statističkim ili nestatističkim tehnikama. Primjeni statističkih tehnika svojstveno je da su vjerojatnosti izbora elemenata pozitivne i poznate te da je moguć njihov slučajan odabir u uzorak kako bi se pri donošenju zaključaka omogućila primjena formula temeljenih na teoriji vjerojatnosti. Pritom i statističko i nestatističko uzorkovanje<sup>8</sup> podrazumijevaju da revizor koristi svoje profesionalno rasuđivanje u provedbi uzorkovanja i zaključivanja.

U ovom se radu pod uzorkovanjem razumijeva samo revizijsko statističko uzorkovanje definirano kao primjena postupka revizije nad podskupom od  $n$  jedinica izabranih od ukupno njih  $N$ , vezano za stavke iz bilance ili skupine transakcija u svrhu procjenjivanja neke karakteristike iz bilance ili skupine. Uzorkovanje se vrši sa svrhom donošenja zaključaka o cjelini koja se zove populacijom na temelju njezina reprezentativnog dijela. Populaciju u reviziji mogu činiti, npr., knjigovodstvena salda (za dužnike, kreditore, fiksna potraživanja) i transakcije (sva plaćanja najamnina, plaća itd.). Pritom se pojedine stavke nazivaju jedinicama izbora.

U reviziji je prilikom dizajniranja uzorka bitno prvo postaviti strategiju revizije, tj. važno je provodi li se: (1) strategija temeljena na testovima kontrole, tj. ispijuje li se učinkovitost sustava internih kontrola klijenta; ili (2) strategija temeljena na dokaznim testovima, tj. provjerava li se realnost i objektivnost stanja pojedinih pozicija finansijskih izvještaja.

Primjeri najčešće primjenjivanih planova statističkog uzorkovanja u reviziji za procjenu parametara populacije<sup>9</sup> i za primjenu pristupa revizijskog testiranja<sup>10</sup> vezano za

<sup>6</sup> American Institute of Certified Public Accountants, *Statement on Auditing Standards No. 39: Audit Sampling*, 1985. Compiled with amendments in *AICPA Professional Standards, Volume 1*, AU section 530.

<sup>7</sup> Vidjeti Međunarodne revizijske standarde (prijevod s engleskog) u Krajačić (2003).

<sup>8</sup> Nestatistički uzorci u reviziji su: (1) uzorak izabran nasumice (*haphazard sample*), kada nema strukturirane tehnike pri odabiru jedinica, (2) uzorak izabran namjerno (*purposive sample*), kada revizor uvodi pristranost (recimo, izbjegava jedinice preko neke vrijednosti, određene vrste pogrešaka itd.). Ovdje uzorak nije reprezentativan i zaključci se ne poopćavaju niti služe za prognozu.

<sup>9</sup> Eng. *estimation sampling*.

strategiju revizije (usporedi s Guy et al., 2001, Montgomery, 2005, Kaplan, 2003), jesu sljedeći:

- (1) Pri strategiji revizije pomoću dokaznih testova koristi se plan uzorkovanja za procjenu (ili testove) temeljem kvantitativnih mjerljivih obilježja<sup>11</sup>. S obzirom na parametar o kojem se vrši ispitivanje postoji više vrsta ovog plana uzorkovanja:
  - a) Plan uzorkovanja za procjenjivanje aritmetičke sredine po jedinici izbora<sup>12</sup> i procjenjivanje totala uz odabranu razinu pouzdanosti. Ovaj se plan kod revizijskih dokaznih testova koristi za procjenjivanje novčanih vrijednosti.
  - b) Plan uzorkovanja za procjenjivanje razlike<sup>13</sup> između, primjerice, revizijske vrijednosti i knjigovodstvene vrijednosti odnosno za procjenu salda.
  - c) Plan uzorkovanja za procjenjivanje omjera<sup>14</sup> u koju se svrhu moraju poznavati vrijednosti dviju povezanih varijabla za istu jedinicu, npr. u različitim trenutcima.
- (2) Kod strategije revizijskih testova kontrole rabi se plan uzorkovanja za procjenu temeljem atributivnih obilježja i onih numeričkih obilježja koja imaju konačan broj modaliteta<sup>15</sup>. Ovakvi se planovi koriste za procjenjivanje proporcije jedinica populacije koje imaju neko svojstvo ili atribut, npr. za zakašnjela dugovanja, oštetećene proizvode na zalihi ili greške na unesenim računima.

Svi spomenuti planovi uzorkovanja mogu biti nestratificirani ili stratificirani.

S obzirom na cilj revizije moguća su nadalje sljedeća dva plana izbora uzorka:

- Plan izbora uzorka za prihvaćanje<sup>16</sup> služi za otkrivanje stope pogrešaka u populaciji i za donošenje odluke o njezinoj prihvatljivosti ili neprihvatljivosti.
- Plan uzorkovanja za otkrivanje<sup>17</sup> predstavlja zaoštrenu inačicu uzorkovanja za prihvaćanje do te mjere da niti jedna jedinica ne smije odstupati od pravila, stoga zahtijeva veliki uzorak.

Prilikom odabiranja jedinica u uzorak iz okvira izbora revizor sām odlučuje hoće li koristiti generator slučajnih brojeva, sustavni izbor jedinica ili izbor uz vjerojatnosti proporcionalne veličini<sup>18</sup>, kada vrijednosno veće jedinice imaju veću vjerojatnost ulaska u uzorak<sup>19</sup>.

---

<sup>10</sup> Eng. *audit hypothesis approach*.

<sup>11</sup> Eng. *variable sampling*.

<sup>12</sup> Eng. *mean per unit sampling*.

<sup>13</sup> Eng. *difference estimation sampling*.

<sup>14</sup> Eng. *ratio estimation sampling*.

<sup>15</sup> Eng. *attribute sampling*.

<sup>16</sup> Eng. *acceptance sampling*.

<sup>17</sup> Eng. *discovery, exploratory sampling*.

<sup>18</sup> Eng. *probability proportionate to size* ili *pps-sampling*.

<sup>19</sup> Eng. *monetary-unit* ili *dollar-unit sampling*.

### 3. REVIZIJSKI RIZICI I STRATEGIJE REVIZIJE

Revizijski rizik je rizik davanja pogrešnog revizijskog mišljenja. To je svekoliki rizik da će revizor prihvatiti prikaz financijskih izvještaja kao točan iako je on zapravo značajno pogrešno<sup>20</sup> iskazan, odnosno to je vjerojatnost da revizor neće otkriti značajnu pogrešku<sup>21</sup> realno iskazanu u financijskim izvještajima, tj. da će izvući nevaljali zaključak i dati neadekvatno mišljenje (primjerice, pozitivno) temeljem pogrešno iskazanih financijskih informacija iz revizijske procedure. Revizijski rizik sadrži tri osnovne komponente: (1) inherentni rizik, (2) kontrolni rizik i (3) detekcijski rizik ili rizik neotkrivanja<sup>22</sup>. O definicijama, procjenjivanju i povezanosti dijelova revizijskog rizika vidjeti u MRevS 400<sup>23</sup>.

(1) Inherentni rizik je rizik da se u financijskim izvještajima mogu javiti značajne pogreške, odnosno da je neko stanje računa ili vrsta transakcija podložna pogrešci koja bi mogla postati materijalno značajna, podrazumijevajući da nema odgovarajuće interne kontrole. Ova vrsta rizika ne podliježe utjecaju revizora niti ju on može kontrolirati. Prema Tušeku (2003.), kada revizor procjenjuje inherentni rizik na razini financijskih izvještaja, on vrši procjenu značajki menadžmenta, prirode poslovanja klijenta kao i industrije. Pri procjeni inherentnog rizika na razini stanja i vrste transakcija bitna je prosudba značajki pojedinih računa i transakcija.

(2) Kontrolni rizik je rizik da značajna pogreška koja se mogla javiti u izjavama uprave poduzeća o financijskim izvještajima, neće pravodobno biti ni spriječena niti otkrivena pomoću interne kontrole. Ispitivanje interne kontrole dovodi do procjene razine kontrolnog rizika koji može biti procijenjen subjektivno kao: visok, umjeren ili nizak. Kad je testovima (interne) kontrole procijenjeno da je kontrolni rizik mali, uslijedit će manji opseg dokaznih testova, tj. bit će manje angažmana na reviziji salda. Tada revizor raspolaže dokazima da računovodstveni sustav generira značajno točne financijske informacije. Ako je kontrolni rizik velik, tada dokaz o internoj kontroli svjedoči da su moguće značajne pogreške jer su kontrole neučinkovite ili ih nema i tada je potreban veći angažman kod dokaznih testova, tj. revizije salda. To je rizik nedostatka dokaza, tj. interna kontrola ne otkriva i ne sprječava materijalne pogreške, što ima izravan utjecaj na opseg posla revizora.

(3) Detekcijski rizik je rizik da revizijski postupak neće otkriti značajne pogreške koje postoje u financijskim izvještajima, u saldima računa ili u vrstama transakcija. Razina rizika neotkrivanja izravno se odnosi na revizorove dokazne postupke, vidi MRevS 400<sup>24</sup>. Prema Tušeku (2003.), kvalitativna ili kvantitativna procjena rizika revizije nastavlja se procjenom njegovih sastavnica, inherentnog i kontrolnog rizika, kao osnove za preliminarnu procjenu rizika neotkrivanja, a što je pak baza za planiranje opsega dokaznih testova. Za detekcijski rizik odgovoran je revizor jer odabire postupke revizije s kojima je taj rizik povezan. To se prvenstveno odnosi na dokazne testove, odnosno postupke neposredne provjere realnosti i objektivnosti salda na računima glavne knjige. No, važno je naglasiti da revizor ne može u potpunosti izbjegći rizik neotkrivanja jer može odabrati neadekvatan

<sup>20</sup> Radi se o nenamjernim pogreškama ili propustima glede iznosa ili neusklađenosti u financijskim izvještajima, pri čemu su te pogreške značajne.

<sup>21</sup> "Značajna pogreška" je u eng. jeziku "*material misstatement*".

<sup>22</sup> Eng. *detection risk*.

<sup>23</sup> Vidjeti Međunarodne revizijske standarde (prijevod s engleskog) u Krajačić (2003). Prijevodi s engleskog dani su i u rječniku Business Dictionary autora Zgombića (2005).

<sup>24</sup> Vidjeti Međunarodne revizijske standarde (prijevod s engleskog) u Krajačić (2003).

revizijski postupak, na neodgovarajući način primijeniti adekvatno izabran revizijski postupak ili dati pogrešnu interpretaciju inače korektno pribavljenih rezultata revizije. Rizik neotkrivanja sadrži: a) nestatističke komponente rizika koji nisu povezani s uporabom uzorka i b) statističke rizike ( $\alpha$  i  $\beta$ ) koji se javljaju zbog primjene uzorka.

Prema MRevS 400<sup>25</sup>, međusobna povezanost dijelova revizijskog rizika može se prikazati pomoću tablice 1.

**Tablica 1. Detekcijski rizik (DR) u ovisnosti o ostalim komponentama revizijskog rizika**

		<b>Revizorova procjena kontrolnog rizika (CR)</b>		
		<b>Visok</b>	<b>Srednji</b>	<b>Nizak</b>
<b>Revizorova procjena inherentnog rizika (IR)</b>	<b>Visok</b>	DR niži	DR niži	DR srednji
	<b>Srednji</b>	DR niži	DR srednji	DR viši
	<b>Nizak</b>	DR srednji	DR viši	DR viši

Prema Tušeku (2003.), već u fazi planiranja revizor odlučuje o strategijama revizije. Pritom revizor polazi od sljedećih elemenata: prethodne procjene kontrolnog rizika, opsega upoznavanja sustava internih kontrola, testova kontrole kako bi se došlo do konačne procjene kontrolnog rizika i od planiranog opsega dokaznih testova radi kontrole ukupnog rizika revizije. U skladu s procjenom spomenutih elemenata za pojedina stanja odabire se jedna od sljedećih dviju strategija revizije:

(1) Strategija niže procjene kontrolnog rizika, kada se revizor oslanja na sustav internih kontrola klijenta i planira niži opseg dokaznih postupaka. Ova strategija temelji se na testovima kontrole.

(2) Strategija dokaznih testova planira veći opseg dokaznih postupaka. Ovdje su temelj revizijski postupci testiranja ispitivanja bilančnih stanja i bilježaka uz finansijske izvještaje kako bi se utvrdila njihova istinitost, pouzdanost, točnost i valjanost. Ti su testovi usmjereni na neposredno testiranje stavaka koje su sadržane u saldu pojedinih računa. U završnim postupcima revizije, pri dizajniranju i provedbi dokaznih testova, uobičajeno je vršiti reviziju pomoću uzorka. Prema Arens i Loebbecke (1997., str. 155), povezano s revizijom na temelju uzorka, revizor mora posebno voditi računa o revizijskim ciljevima testiranja salda koji se odnose na: realno postojanje poslovnih događaja iskazanih na računima, potpunost sadržaja računa, točnost pojedinih iznosa i zbrojeva na računima, odgovarajuće razvrstavanje ispitivanih poslovnih događaja, vrijeme na koje se knjiženja odnose, na ispunjavanje kriterija vlasništva prilikom evidentiranja poslovnih događaja i na procjenu (vrednovanje, mjerjenje) u smislu da revizor mora provjeriti jesu li poslovni događaji i stanje primjereno procijenjeni u skladu s računovodstvenim načelima, standartima i politikama.

Kombiniranje strategija revizije je uobičajeno<sup>26</sup>.

<sup>25</sup> Međunarodni revizijski standardi (prijevod s engleskog) u Krajačić (2003, str. 204.).

<sup>26</sup> Polazni elementi ovih međusobno isključivih alternativnih strategija zapravo su zajednički i povezani.

Prema Boyntonu i Kellu (1996, str. 340.), prihvatljiva razina detekcijskog rizika izravno utječe na prirodu, opseg i vrijeme obavljanja dokaznih testova. Postoji obrnuta proporcionalnost između procjene kontrolnog i inherentnog rizika s jedne strane i detekcijskog rizika s druge strane. Ako su kontrolni i inherentni rizici visoki, tada revizor može prihvati nisku razinu rizika neotkrivanja te tako kontrolirati ukupni rizik revizije na prihvatljivo niskoj razini. Uz nižu razinu detekcijskog rizika dokazni testovi mogu biti učinkoviti i mogu se provoditi potkraj razdoblja uz veći uzorak. Uz nisku razinu inherentnog i kontrolnog rizika razina detekcijskog rizika može biti viša uz još uvijek prihvatljivu razinu ukupnog rizika. I obratno, uz višu razinu detekcijskog rizika koriste se manje učinkoviti dokazni testovi koji se provode periodično uz manji uzorak.

## 4. REZULTATI IZUČAVANJA

### 4.1. Alfa i beta rizici u dokaznim testovima revizora

U testiranju statističkih hipoteza susreću se dvije vrste pogrešaka: (1) istinita nulta hipoteza može biti greškom odbačena i to je Pogreška tipa I., a vjerojatnost njezina nastanka označuje se slovom  $\alpha$ ; i (2) lažna nulta hipoteza može omaškom biti prihvaćena, kada se čini Pogreška tipa II., a vjerojatnost njezina nastanka označava se slovom  $\beta$ . Kod dokaznih testova, vjerojatnosti  $\alpha$  i  $\beta$  su aspekti rizika uzorka.

**Tablica 2. Pogreške pri testiranju statističkih hipoteza**

Odluka temeljem statističkog testa	Istinitost nulte hipoteze	
	Istinita	Lažna
Odbaciti nultu hipotezu	Pogreška tipa I. (Vjerojatnost $\alpha$ )	Ispravna odluka
Ne odbaciti nultu hipotezu	Ispravna odluka	Pogreška tipa II. (Vjerojatnost $\beta$ )

Drugi naziv za Pogrešku tipa I. je razina signifikantnosti i njezinu vrijednost određuje istraživač, odnosno revizor. Obično se ona postavlja na niskoj razini, najčešće 5% (ili 1% ili 10%), kako bi se provela zaštita od ovog tipa pogreške. Vrijedi sljedeće:

$$\alpha = P\{Pogreška \text{ tipa I.}\} = P\{odbijena H_0 | H_0 \text{ je istinita}\}$$

$$\beta = P\{Pogreška \text{ tipa II.}\} = P\{nije odbijena H_0 | H_0 \text{ je lažna}\}.$$

Vjerojatnost suprotna vjerojatnosti  $\beta$  je vjerojatnost ispravnog odbijanja nulte hipoteze, tj. snaga testa (*power*) i označuje se kao:

$$Snaga = 1 - \beta = P\{odbijena H_0 | H_0 \text{ je lažna}\}.$$

Općeniti postupak pri testiranju hipoteza provodi se tako da se prvo odredi mala vjerojatnost  $\alpha$  te da se potom dizajnira takva procedura testa koja će dati malu vjerojatnost

nastanka Pogreške tipa II.  $\beta$ . U praksi, radi se o izravnom kontroliranju rizika  $\alpha$ , dok je rizik  $\beta$  funkcija veličine uzorka i kontrolira se neizravno. Što je u testiranju korištena veća veličina uzorka  $n$ , to je manji rizik  $\beta$ , a snaga testa ( $1-\beta$ ) veća. Zbog toga što su vjerojatnost da se počini Pogreška tipa I. ( $\alpha$ ) i vjerojatnost da se počini Pogreška tipa II. ( $\beta$ ) u inverznoj proporcionalnosti, a druga je i komplement snage testa ( $1-\beta$ ), vjerojatnost  $\alpha$  i snaga testa variraju izravno. Porast razine signifikantnosti, tj. vjerojatnosti  $\alpha$ , rezultira porastom snage testa i obratno, usporedi s Levine et al. (2005.).

Za kontrolu i upravljanje detekcijskim rizikom odgovoran je revizor. On odabire posutke koji će mu to upravljanje omogućiti. Ako koristi reviziju temeljem metode uzoraka, treba razlučiti dvije vrste rizika: (1) rizik uzorka<sup>27</sup>, koji se može promatrati i kao sastavni dio rizika neotkrivanja, a određuje ga zahtijevana razina dokaznih postupaka, vidi Smith (1999); te (2) rizik izvan uzorka<sup>28</sup>.

Rizik uzorka je rizik da statistički uzorak nije reprezentativan<sup>29</sup> u odnosu na populaciju iz koje je izabran tako da je revizorov zaključak drugačiji u odnosu na zaključak do kojeg bi došao 100%-tним obuhvatom revizijom ispitivanih elemenata koristeći iste revizijske procedure, a moguće je i kod testova kontrole i kod dokaznih testova. Rizik uzorka može biti smanjen na prihvatljivo nisku razinu, no nikad ne može biti sasvim uklonjen. Veličina rizika uzorka izražava se u postotku. Primjerice, rizik 5% znači da je vjerojatnost propuštanja postojeće značajne materijalne pogreške 1:20. Rizik se može izraziti i pomoću razine pouzdanosti ili zahtijevane sigurnosti<sup>30</sup> uz prikazivanje odgovarajućih koeficijenata pouzdanosti. Razina pouzdanosti je vjerojatnost povezana s preciznošću. Interval pouzdanosti je projekcija procjene iz uzorka (recimo proporcije pogrešnih faktura obuhvaćenih uzorkom) izračunana kao procjena jednim brojem plus/minus pogreška procjene uz željenu razinu pouzdanosti.

Rizik izvan uzorka je komponenta rizika neotkrivanja koji nije povezan sa činjenicom što je ispitivan samo podskup, tj. uzorak jedinica iz populacije. Rizik izvan uzorka posljedica je mogućnosti primjene neadekvatnih revizijskih postupaka, neotkrivanja postojećih pogrešaka i pogrešne interpretacije rezultata revizije<sup>31</sup>, Tušek (2001b). Revizijsko testiranje koje ne uključuje uzorkovanje također je podložno ovim neuzoračkim pogreškama.

Rizik uzorka može se promatrati i povezano s modelom revizijskih rizika<sup>32</sup> i njegovim komponentama: inherentnim rizikom, kontrolnim i detekcijskim rizikom. Sada treba razmotriti povezanost  $\beta$  rizika, kao najznačajnijeg, s ostalim vrstama revizijskih rizika pri dokaznim testovima salda<sup>33</sup> prema fazama primjene modela revizijskih hipoteza<sup>34</sup>. Prema Guy et al. (2001, str. 147.) spomenuti model obuhvaća sljedeće četiri faze: I. provodenje

<sup>27</sup> Eng. *sampling risk*.

<sup>28</sup> Eng. *non-sampling risk*.

<sup>29</sup> Reprezentativni uzorak je izabran uz poznate vjerojatnosti (*probability sampling*). To je uzorak koji predstavlja umanjenu sliku populacije kako bi omogućio što točniju procjenu njezinih parametara.

<sup>30</sup> Razina pouzdanosti je u eng. jeziku *confidence level*, a zahtijevana sigurnost je *assurance required*.

<sup>31</sup> Izvori rizika izvan uzorka su, primjerice, propust da se istraži značajna fluktuacija u vezama pri davanju povjerenja analitičkim postupcima u reviziji ili davanje povjerenja predstavnicima menadžmenta kao zamjeni za druge revizijske evidencije za koje bismo realno mogli očekivati da su raspoložive.

<sup>32</sup> Eng. *audit risk model*.

<sup>33</sup> Eng. *tests of details of balances*.

<sup>34</sup> Model revizijskog testiranju hipoteza (eng. *audit hypothesis model*) razlikuje se od modela računovodstvenog procjenjivanja, usporedi, primjerice, s Guy et al. (2001, poglavlje 5).

zadataka interne kontrole, II. planiranje dokaznog testiranja, III. provedbu dokaznog testa te IV. evaluaciju dokaznog testa.

Prema Boyntonu, Kellu (1996, str. 234), a također i Tušku (2001b, str.132.) te Spremiću (1995.), u analizi rizika polazi se od osnovnog modela procjene revizijskog rizika koji izgleda ovako<sup>35</sup>:

$$\begin{array}{cccccc} \text{AR} & = & \text{IR} & \cdot & \text{CR} & \cdot \\ \text{Ukupan rizik revizije} & & \text{Inherentni rizik} & & \text{Kontrolni rizik} & \text{DR} \\ (\text{Audit risk}) & & (\text{Inherent risk}) & & (\text{Control risk}) & (\text{Detection Risk}) \end{array} \quad (1)$$

Teži se da ukupan rizik revizije bude što manji. Ako iznosi 5%, znači da postoji 95%-tina sigurnost da finansijski izvještaji ne sadrže materijalno značajne pogreške. Spremić (1995.) razmatra sljedeća ograničenja navedenog modela: (1) revizor ne može ni inherentni rizik IR niti kontrolni rizik CR procijeniti na nultoj razini jer bi (zbog multiplikativnosti modela) u oba slučaja i ukupni rizik revizije bio jednak nuli, te (2) rizici IR, CR niti DR ne mogu istodobno biti na gornjoj maksimalnoj granici jedan<sup>36</sup> (ili 100%) jer bi ukupni rizik revizije AR bio neprihvatljivo visok, tj.:  $AR=1.00 \cdot 1.00 \cdot 1.00=1.00$  ili 100%.

Temeljem jednadžbe (1) detekcijski rizik bi se izračunao pomoću izraza:

$$DR = \frac{AR}{IR \cdot CR}. \quad (2)$$

U skladu sa SAS No. 47 (AU 312, AU 350) i prema SAS No. 39, *Audit Sampling*<sup>37</sup>, model je procjene revizijskog rizika iz (1) u razvijenom obliku:

$$AR = IR \cdot CR \cdot AP \cdot TD \quad (3)$$

Ovdje je detekcijski rizik DT prikazan kao umnožak rizika analitičkih postupaka AP<sup>38</sup> koji se izjednačuje s rizikom  $\alpha$ , i rizikom dokaznih testova salda TD<sup>39</sup> koji odgovara riziku  $\beta$ . Prema Revizijskim standardima SAS No. 39, *Audit Sampling* te Guy et al. (2001, str. 159), detaljno se opisuju komponente detekcijskog rizika:

**(1) Rizik pogrešnog odbacivanja**<sup>40</sup> izvire kad uzorak pokazuje višu razinu pogreške no što je to za populaciju stvarno slučaj. Ovo se stanje razrješava dodatnim angažiranjem revizora. **Rizik pogrešnog odbacivanja** odgovara statističkom  $\alpha$  riziku i označuje vjerojatnost da će istinita, tj. točna knjigovodstvena vrijednost, biti odbijena revizijskim statističkim testom.

<sup>35</sup> Ovdje se prepostavlja da rizici izvan uzorka nisu prisutni u detekcijskoj komponenti rizika.

<sup>36</sup> Svi rizici izraženi kvantitativno zapravo su vjerojatnosti  $p$ , tj. negativni brojevi iz zatvorenenog intervala:  $0 \leq p \leq 1$ .

<sup>37</sup> American Institute of Certified Public Accountants, *Statement on Auditing Standards No. 39: Audit Sampling*, 1985. Compiled with amendments in *AICPA Professional Standards, Volume 1*, AU section 530. Robertson i Davis (1988, str. 386) koriste nešto drugačiju notaciju.

<sup>38</sup> Od eng. *risk of analytical procedures*.

<sup>39</sup> Od eng. *risk of test of details of balances*.

<sup>40</sup> Eng. *risk of incorrect rejection*.

**(2) Rizik pogrešnog prihvaćanja<sup>41</sup>** nastaje kada značajna pogreška nije otkrivena po-moću uzorka iako je u populaciji stvarno prisutna. **Rizik pogrešnog prihvaćanja odgo-vara β riziku i** označuje vjerojatnost da će netočnu knjigovodstvenu vrijednost revizor prihvatići.

Rizik  $\beta$  je najvažnija komponenta rizika revizije koja se temelji na uzorku jer bitno utječe na revizijsku efektivnost, tj. djelotvornost<sup>42</sup>. On se može kvantificirati uporabom statističkih tehnika, a kontrolira se variranjem odnosa prihvatljive preciznosti  $A^{43}$  prema maksimalno dopuštenoj pogrešci TM<sup>44</sup>, Guy et al. (2001, str. 159). Revizor ima ulogu pri određivanju materijalne značajnosti i rizika. Revizijska značajnost<sup>45</sup> je veličina pogreške u finansijskim izvještajima koja utječe na donošenje odluka korisnika finansijskih izvještaja. To je jedno od računovodstvenih načela prema kojem je neka informacija značajna ako utječe na donošenje odluka korisnika informacije. Revizor treba odrediti tu značajnost, tj. veličinu najveće pogreške, koja se tolerira TM u nekoj populaciji te provesti testove kako bi pružio dokaze da je stvarna pogreška u populaciji manja od pogreške koja se tolerira. Tako: ako se želi manja vrijednost  $\beta$  rizika, interval preciznosti je uži, i obratno.

Rizik  $\alpha$  se ne smatra toliko opasnim kao  $\beta$  rizik jer ne utječe na valjanost revizorovih zaključaka već utječe na revizijsku učinkovitost<sup>46</sup>, Smith (1999).<sup>47</sup> Tako  $\alpha$  rizik smanjuje efikasnost revizije zato što zahtijeva daljnji rad revizora koji bi bio suvišan da je izabrani uzorak zaista reprezentativan. On je komplement razine pouzdanosti. Tako, primjerice, ako je pouzdanost testova 90%, tada je rizik  $\alpha$  jednak 10%.

U praksi se revizijski rizik može procijeniti kvantitativno (primjerice: 5-10%), a nes-tatistički rizici i kvalitativno (primjerice: visok, nizak ili umjereni rizik).

I. U prvoj fazi primjene modela revizijskog testiranja prvo moraju biti definirani pos-toci revizijskog rizika AR, rizika interne kontrole CR te rizika ostalih revizijskih postupaka AP kako bi se mogao izračunati  $\beta$  rizik. Prema razvijenom modelu revizijskog rizika (3)  $\beta$  rizik TD računa se na sljedeći način:

$$TD = \frac{AR}{IR \cdot CR \cdot AP}. \quad (4)$$

II. U drugoj fazi primjene modela, kad je preciznost utvrđena, odabire se plan uzorka i određuje njegova veličina za dokazni test. Uz plan uzorka za varijable i test za aritmetičku sredinu koji su primjereni dokaznom testu, usporedi s Guy et al. (2001, str. 94. i 147.), prethodna veličina uzorka određuje se pomoću izraza:

$$N' = \left( \frac{Z_\alpha \cdot SD}{A} \right)^2, \quad (5a)$$

<sup>41</sup> Eng. *risk of incorrect acceptance*.

<sup>42</sup> Eng. *audit effectiveness*.

<sup>43</sup> Od eng. *acceptable precision*.

<sup>44</sup> Od eng. *tolerable misstatement*.

<sup>45</sup> Eng. *auditing materiality*.

<sup>46</sup> Eng. *audit efficiency*.

<sup>47</sup> Vidjeti: <http://www.accaglobal.com/publications/studentaccountant/30792?view=Printable+version>.

dok je kod procjene totala dana uz množenje s N na sljedeći način:

$$n' = \left( \frac{Z_\alpha \cdot SD \cdot N}{A} \right)^2. \quad (5b)$$

U reviziji se koristi izbor uzorka bez ponavljanja elemenata, a za izračun konačne veličine uzorka koristi se formula:  $n=n'/(1+f')$ . U formulama (5a) i (5b) simboli znače sljedeće:

- $Z_\alpha^{48}$  koeficijent razine povjerenja ili pouzdanosti vezan za veličinu pogreške uzorka  $\alpha$  koju je revizor voljan prihvati, primjerice uz  $\alpha=5\%$ , razina pouzdanosti je 95%, a koeficijent  $\alpha$  rizika  $Z_\alpha = 1.96$ , što je dobiveno primjenom tablica površina jedinice Gaussove distribucije i što je vidljivo u tablici broj 3 koja slijedi. Veća pouzdanost daje manji  $\alpha$ , a uz njega ide veća vrijednost koeficijenta  $Z_\alpha$ , što povećava potrebnu veličinu uzorka  $n^{49}$ .
- SD je standardna devijacija varijable  $X$  populacije procijenjena temeljem ranijih revizija,  $N$  je veličina populacije iz koje se bira uzorak. Ovu je standardnu devijaciju moguće izračunati temeljem podataka uzorka pomoću formule:

$$SD = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}} = \sqrt{\frac{\sum_{i=1}^n x_i^2 - n\bar{x}^2}{n-1}}, \text{ gdje je } n \text{ veličina uzorka i to veća od 30 elemenata tako da se postupak svodi na primjenu normalne distribucije i centralnog graničnog teorema, a } \bar{x} = \frac{\sum_{i=1}^n x_i}{n} \text{ je aritmetička sredina uzorka, tj. prosjek podataka podvrgnutih reviziji. Veličina uzorka bit će veća ako je veća varijabilnost obilježja iskazana pomoću SD.}$$

- prihvatljiva preciznost  $A$  zadana je izrazom:  $A = TM \cdot \frac{Z_\alpha}{Z_\alpha + Z_\beta}, \quad (6)$

gdje je  $Z_\beta$  koeficijent rizika  $\beta$ . Rizik  $\beta$  je svakako prethodno određen specificiranjem rizika AR, IR i AP. Temeljem (5a) i (5b) veličina uzorka je obrnuto proporcionalna veličini  $A$ . Pogreška TM je najveći iznos koji revizor ne smatra značajnim i prihvatljiva preciznost  $A$  je direktno proporcionalna s njenom veličinom.  $A$  također poprima veću vrijednost kada je  $Z_\beta$  manji, tj. uz veće vrijednosti  $\beta$  rizika, što je ilustrirano u tablici broj 3 koeficijenata  $Z_\alpha$  i  $Z_\beta$  izračunanih uporabom Gaussove distribucije vjerojatnosti.

<sup>48</sup> Kod Guy et al. (2001.) umjesto sa  $Z_\alpha$ , ovaj se koeficijent označuje sa  $U_R$ . Notacija  $Z_\alpha$  preuzeta je od Robertsona i Davisa (1988, str. 390).

<sup>49</sup> Pravilo je da troškovi rastu s povećanjem veličine uzorka, no statističke knjige poučavaju da preciznost raste sporije i da je proporcionalna s drugim korijenom veličine uzorka. Vidi Žugaj, Dumičić i Dušak (1999.).

**Tablica 3. Koeficijenti  $\alpha$  i  $\beta$  rizika uzorka u revizijskom testiranju\***

Razina prihvatljivog rizika	$Z_\alpha$ (za simetrično podijeljen rizik na površine u repovima normalne distribucije)	$Z_\beta$ (za rizik, tj. površine samo u jednom repu normalne distribucije)
1%	2.58	2.33
2%	2.33	2.05
3%	2.17	1.88
4%	2.05	1.75
5%	1.96	1.64
10%	1.64	1.28
15%	1.44	1.04
20%	1.28	0.84
30%	1.04	0.25
40%	0.84	0.25
50%	0.67	0.00

\*Koeficijenti rizika određeni su uporabom tablice površina normalne krivulje iz Šošića (2004.).

Spajanjem formula (5a) i (6) nastaje:

$$N' = \left( \frac{\frac{Z_\alpha \cdot SD \cdot N}{TM \cdot \frac{Z_\alpha}{Z_\alpha + Z_\beta}}}{\frac{Z_\alpha}{Z_\alpha + Z_\beta}} \right)^2 = \left( \frac{SD \cdot N(Z_\alpha + Z_\beta)}{TM} \right)^2. \quad (7)$$

Primjerena veličina uzorka za potrebe revizije ovisi dakle prvenstveno o značajnosti<sup>50</sup> koja se ispituje, o dopustivoj pogrešci TM<sup>51</sup> te o riziku uzorka. Dopustiva pogreška TM jest najveća pogreška koju je revizor spremjan prihvatiti pri zaključivanju i ta je veličina obrnuto proporcionalna veličini uzorka. Tako, primjerice, dva puta veća vrijednost dopuštene pogreške ima za posljedicu 2<sup>2</sup> puta manju veličinu potrebnog uzorka ili tri puta manja vrijednost TM daje 3<sup>2</sup> puta veću veličinu potrebnog uzorka. Odabrana pogreška TM je povezana s revizorovom prosudbom glede značajnosti.

<sup>50</sup> U reviziji eng. *materiality* znači značajnost.

<sup>51</sup> Još razvijeniju formulu za veličinu uzorka daju Robertson i Davis (1988, str. 390) jer uključuju i očekivanu pogrešku (eng. *expected error*) o kojoj veličina uzorka također ovisi. Koncept očekivane pogreške primjenjuju iskusniji revizori. Što je pak očekivana pogreška veća, to je veći uzorak potreban kako bi se utvrdilo da ta pogreška ne premašuje dopuštenu pogrešku. Kada revizor određuje očekivanu pogrešku u populaciji, on razmatra razine pogrešaka identificirane u prethodnim revizijama, promjenama u postupcima organizacije i evidencijama raspoloživima iz procjena sustava internih kontrola i rezultate pregledavanja analitičkim postupcima. Tako se veličina uzorka povećava porastom očekivane pogreške te smanjenjem rizika uzorka i smanjenjem maksimalne dopustive pogreške, i obrnuto.

Razina rizika uzorka koju je revizor voljan prihvati i veličina uzorka obrnuto su proporcionalni. Tako se veličina uzorka povećava smanjenjem rizika uzorka i smanjenjem maksimalne dopustive pogreške, i obrnuto. Malim uzorcima svojstven je dakle, u načelu, veći rizik, odnosno male vrijednosti  $\alpha$  i  $\beta$  traže veliki  $n$ .

Tako, primjerice, u reviziji za procjenu ukupne vrijednosti inventara (totala) uz  $N=12000$  inventarskih zapisu, standardna devijacija populacije (svih zapisu) je procijenjena pomoću pokusnog uzorka s više od 30 elemenata i ona iznosi  $SD=8$  €, te uz vrijednosti rizika revizije  $AR=0.05$  (5%),  $IR=1$  (100%), kontrolnog rizika  $CR=0.20$  (20%) i rizika analitičkih postupaka  $AP=0.90$  (90%), planirani  $\beta$  rizik  $TD$ , prema formuli (4), iznosi:

$$TD = \frac{0.05}{1.00 \cdot 0.20 \cdot 0.90} = 0.2778 .$$

Koefficijent za površinu u repu normalne razdiobe jednaku  $0.5000 - 0.2778 = 0.2222$  sada aproksimativno iznosi  $Z_\beta = 0.59$ . Ako je maksimalna dopustiva pogreška  $TM = 10000$  €, uz koefficijent za rizik  $\alpha = 0.05$  (dakle uz pouzdanost od 95%) koji iznosi  $Z_\alpha = 1.96$ , planirana je prihvatljiva preciznost  $A$  prema formuli (6):

$$A = 10000 \cdot \frac{1.96}{1.96 + 0.59} = 7686 \text{ €} ,$$

dok je odgovarajuća veličina uzorka za procjenu totala prema formuli (5b):

$$n' = \left( \frac{1.96 \cdot 8 \cdot 12000}{7686} \right)^2 = 599 .$$

Ako se uvaži frakcija izbora  $f = 599 / 12000 = 0.0499$ , tada je konačna veličina uzorka jednaka  $n = n' / (1+f) = 599 / (1+0.0499) = 570$ . U uzorak treba dakle izabrati 570 inventarskih zapisu kako bi se proveo dokazni test uz pretpostavljene i izračunane veličine rizika.

III. U trećoj fazi provedbe modela testiranja provodi se dokazni test, a pritom se započinje s izborom uzorka, revizijom uzorka i računanjem dostignute preciznosti  $A'$  s kojom se uspoređuje prihvatljiva preciznost  $A$ . Veličina  $A'$  dobiva se pomoću formule:

$$A' = Z_\alpha \cdot SE \cdot N \sqrt{1 - (n/N)} , \quad (8)$$

gdje je  $SE = \frac{SD}{\sqrt{n}}$  standardna pogreška za  $\bar{x}$ , (9)

uz pretpostavku da je frakcija izbora uzorka manja od 5% tako da se faktor korekcije za konačne populacije  $\sqrt{\frac{N-n}{N-1}}$  aproksimira jedinicom i zanemaruje.

Naposljeku, računa se još prilagođena preciznost:

$$A'' = A' + TM \left( 1 - \frac{A'}{A} \right) , \quad (10)$$

koja rezultira time da je dostignuti  $\beta$  rizik jednak planiranom  $\beta$ , vidi Guy et al. (2001, str. 148.).

IV. U četvrtoj fazi testiranja slijedi evaluacija dokaznog testa, kada revizor računa procjenu (npr. aritmetičke sredine), formira interval za donošenje odluke oko klijentove knjigovodstvene vrijednosti te prihvata ili odbacuje njezinu značajnu točnost<sup>52</sup>.

## 4.2. Alfa i beta rizici u planu uzorka za prihvatanje

U reviziji, slično kao i u statističkoj kontroli kvalitete, ponekad se daje prednost planu uzorka za prihvatanje kao posebnoj skupini metoda kontrole kvalitete<sup>53</sup> koja se odnosi na inspekciju određenog broja na slučaj odabranih jedinica iz populacije ili lota<sup>54</sup> za donošenje odluke o prihvatljivosti ili neprihvatljivosti populacije koja ima određen broj ili proporciju pogrešaka, vidi Vance i Neter (1956). Ovdje se podrazumijeva prethodno definiranje maksimalne stope pogreške koju se smije tolerirati. Ako se populacija ne može prihvati, tada revizor može zatražiti od klijenta ponovnu kalkulaciju. Vrste planova uzorka za prihvatanje su: jednostruki uzorak, dvostruki, višestruki, odnosno sekvensijalni plan uzorka. Različiti dizajni uzorka za prihvatanje mogu dati iste ishode, tj. zaključke.

Ovdje dominiraju već spomenuta dva rizika, usporedi Guy et al. (2001, str. 159):

- $\alpha$  rizik, prema Guy et al. (2001, str. 164), je jedan aspekt rizika uzorka kod dokaznih testova. To je vjerojatnost da uzorak greškom ne podupire značajnu točnost salda na kontima klijenta u slučaju kada bi isti revizijski postupci, primjenjeni na čitavu populaciju, otkrili tu značajnu točnost. U statističkoj kontroli kvalitete u industriji to odgovara riziku proizvođača<sup>55</sup> jer označuje vjerojatnost da će dobar lot, npr. pošiljka, biti odbijen. U reviziji to bi bio rizik menadžmenta, a prema Vanceu i Neteru, (1956, str. 39), "rizik firme koja proizvodi računovodstvene zapise". Radi se o vjerojatnosti odbijanja populacije, primjerice skupa određene vrste računa premda ona glede postojanja proporcije značajnih pogrešaka zadovoljava kvalitetom. Drugim riječima, populacija se odbija iako zadovoljava zadanu razinu AQL (od eng. *Acceptable Quality Level*) kao prihvatljivu razinu kvalitete dobrog lota. Radi se o Pogreški tipa I. Primjerice, to je rizik odbacivanja populacije svih kalkulacija zaliha iako je ona u redu.
- $\beta$  rizik je vjerojatnost da uzorak pogrešno podupire značajnu točnost klijentove bilance u slučaju kada bi isti revizijski postupci, primjenjeni na populaciju, otkrili značajnu pogrešku. U statističkoj kontroli kvalitete to je rizik "kupca"<sup>56</sup>, a u slučaju revizije rizik "naručitelja, korisnika revizijskih nalaza", usporedi Vancea i Netera (1956.). To je vjerojatnost prihvatanja populacije, tj. skupa računovodstvenih jedinica, iako ona sadrži veći broj (proporciju) jedinica s nekom greškom, ali to je određeno razinom kvalitete neprihvatljive populacije LTPD (od eng. *Lot Tolerance*

<sup>52</sup> Eng. *material correctness*.

<sup>53</sup> O statističkoj kontroli kvalitete i planu uzorkovanja za prihvatanje (eng. *acceptance sampling*) vidjeti, primjerice, Montgomery (2005.). Dok Vance i Neter (1956.) veoma detaljno govore o spomenutom planu uzorkovanja baš u reviziji.

<sup>54</sup> U statističkoj kontroli kvalitete populacija se naziva lot (eng. *lot* ili *batch*), Montgomery (2005.). Lot može biti, primjerice, pošiljka proizvoda koju je isporučio dobavljač ili skup finalnih proizvoda proizvođača.

<sup>55</sup> Eng. *producer's risk*.

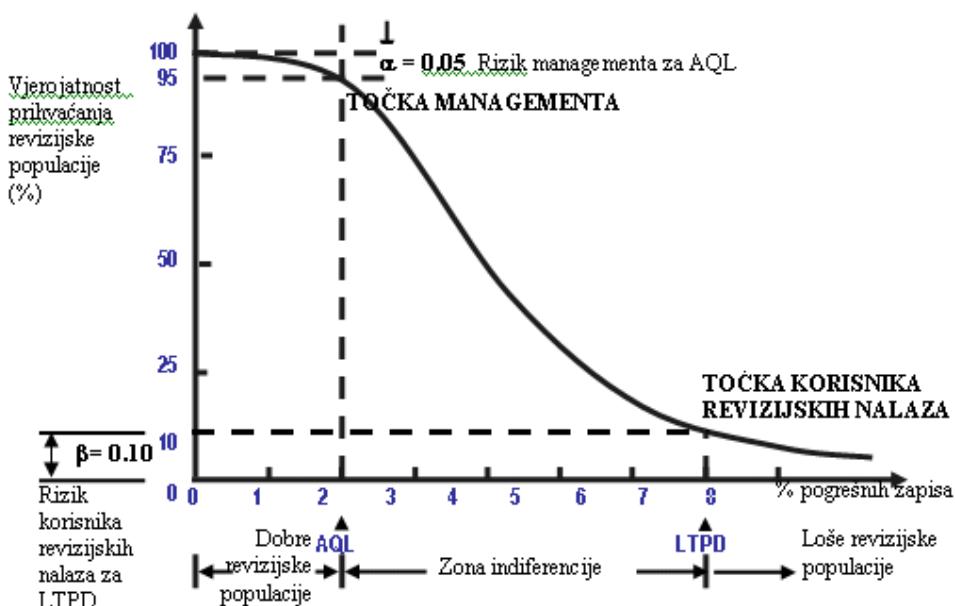
<sup>56</sup> Eng. *consumer's risk*.

*Percent Defective) granicom.* Ovaj rizik odgovara Pogreški tipa II. Korisnik ne želi populaciju s više defekata no što to dopušta zadana vrijednost LTPD.

Plan uzorka za prihvaćanje ima svoju krivulju operativne karakteristike (OC krivulju). To je grafikon koji pokazuje vjerojatnost prihvaćanja populacije (lota) za dane različite proporcije pogrešaka u lotu. Na osi apscisa su postotci jedinica koje su netočne u lotu. Os ordinata pokazuje vjerojatnost prihvaćanja lota. Tako, primjerice, vjerojatnost prihvaćanja lota s 5% netočnih zapisa iznosi 90%. Porastom proporcije netočnosti, šansa prihvaćanja populacije opada. Na slici broj 1 prikazane su spomenute vjerojatnosti na OC krivulji.

Vance i Neter (1956, str. 42) detaljno analiziraju učinkovitost plana uzorka za prihvaćanje pri različitim veličinama uzoraka. Općenito, dvostruko uzorkovanje zahtijeva manje uzorku nego jednostruko, a višestruki planovi traže najmanje veličine uzoraka uz istu razinu protekциje od rizika. Autori zaključuju da se revizor treba brinuti i o relativnoj i o apsolutnoj veličini uzorka te zaključuju da je snaga diskriminacije plana jača ako je korišten uzorak koji je apsolutno veći.

**Slika 1. Krivulja operativne karakteristike plana uzorka za prihvaćanje uz rizik pogrešnog prihvaćanja  $\beta = 0.10$  i rizik pogrešnog odbacivanja  $\alpha = 0.05$**



Za potrebe ovoga rada provedena su daljnja ispitivanja pomoću proizvoljno zadanih vrijednosti te se došlo do rezultata<sup>57</sup> koji su predočeni u tablici 4.

<sup>57</sup> U računanju je korišten softver Business Diagnosis and Monitoring Tools, vidjeti: [http://www.netgm.com/tools/useful\\_stuff/audit\\_sample\\_size.html](http://www.netgm.com/tools/useful_stuff/audit_sample_size.html).

**Tablica 4. Potrebna veličina uzorka kod plana uzorka za prihvaćanje \***

Red. br.	Prihvatljiva razina kvalitete ispravne populacije revizije	Rizik pogrešnog odbacivanja	Dozvoljena razina kvalitete neispravne populacije revizije	Rizik pogrešnog prihvaćanja	Broj** pogrešaka iznad kojeg se populacija odbacuje	Veličina uzorka (potreban broj jedinica koje treba kontrolirati)
	AQL (%)	$\alpha$ (%)	LTPD (%)	$\beta$ (%)	c	n
1.	0.1	5	0.5	15	3	1200
2.	0.1	5	0.5	10	3	1333
3.	0.1	5	0.5	5	4	1829
4.	0.1	5	1.0	5	2	628
5.	0.1	5	1.5	5	1	315
6.	0.2	5	1.5	5	3	516
7.	0.3	5	1.5	5	4	610
8.	0.1	1	1.5	5	3	516
9.	0.1	5	1.5	10	1	258
10.	0.1	10	1.5	10	1	258

\*Napomena: Uzimani su samo rezultati pod pretpostavkom: ako je pogreška u prihvaćanju populacije revizije ipak nastala, preferira se sprječavanje prihvaćanja populacije koja sadrži značajne netočnosti.

\*\*Napomena: Prema ovom planu uzorka, revizijsku populaciju se odbacuje ako je prisutno više od  $c$  netočnih zapisa.

Temeljem rezultata analize odgovarajućih krivulja operativne karakteristike u 1., 2. i 3. retku tablice broj 4 zaključuje se da smanjenje rizika  $\beta$ , uz fiksirane vrijednosti rizika  $\alpha$  te fiksiranja postotaka AQL i LTPD, uvjetuje povećanje veličine potrebnog uzorka  $n$  (uz povećanje  $c$ ), što ilustrira već razmatranu obrnutu proporcionalnost između dviju veličina.

Iz redaka 3., 4. i 5. iste tablice zaključuje se da smanjenje vrijednosti LTPD, uz konstantne vrijednosti za veličine  $\alpha$  rizika,  $\beta$  rizika i AQL, povećava potrebnu veličinu uzorka za reviziju, što navodi na zaključak o obrnutoj proporcionalnosti dviju veličina.

Povećanje razine AQL, uz fiksiranje razine LTPD,  $\alpha$  i  $\beta$  rizika, temeljem rezultata u 5., 6. i 7. retku tablice 4, uvjetuje povećanje potrebne veličine uzorka.

Promjena razine rizika  $\alpha$ , iz nepromijenjene vrijednosti  $\beta$  rizika i razina AQL i LTPD, ne mijenja vidljivo veličinu uzorka, kako je to ilustrirano u recima 9. i 10. I daljnja istraživanja potvrdila su isto.

## 5. ZAKLJUČAK

Poznato je da postoji inverzan odnos između razine rizika i potrebne količine angažiranja revizora. Spremnost na nizak rizik i veću sigurnost zahtijeva veće angažiranje u neophodnom revizijskom radu, dok sklonost većem riziku znači manje angažmana. Rizik statističkog revizijskog uzorka koji se dekomponira na  $\alpha$  i  $\beta$  rizike, može pritom biti samo smanjen, a nikako ne može biti sasvim eliminiran.

U ovom istraživanju se promatraju tri komponente revizijskih rizika: inherentni, kontrolni i detekcijski, te interakcija među njima, uz razlikovanje dviju strategija revizije: strategiji testova kontrole i strategiji dokaznih testova. Statistički rizici  $\alpha$  i  $\beta$  sastavnice su detekcijskog rizika. Rizik  $\beta$  je najvažnija komponenta rizika revizije koja se temelji na uzorku jer bitno utječe na revizijsku efektivnost. On se može kvantificirati uporabom statističkih tehnika, a kontrolira se variranjem odnosa prihvatljive preciznosti  $A$  prema maksimalno dopuštenoj pogrešci TM. Revizor ima aktivnu ulogu pri određivanju materijalne značajnosti, pogreške TM i procjeni rizika.

Prema osnovnom modelu procjene revizijskog rizika, detekcijski rizik iskazuje se kao omjer ukupnog rizika revizije i umnoška inherentnog i kontrolnog rizika. Prema razvijenom modelu procjene rizika i primjeni uzorka, detekcijski rizik je dekomponiran na dva dijela: na rizik analitičkih postupaka AP, tj. rizik pogrešnog odbacivanja ( $\alpha$ ), te rizik neposrednog testiranja salda TD koji predstavlja rizik pogrešnog prihvaćanja ( $\beta$ ). Ovdje je  $\beta$  komponenta detekcijskog rizika izražena kao omjer ukupnog rizika revizije i umnoška inherentnog i kontrolnog rizika te rizika analitičkih postupaka (tj.  $\alpha$  komponente). Vidi se dakle da postoji obrnuta proporcionalnost između  $\alpha$  rizika i  $\beta$  rizika i obrnuta proporcionalnost  $\beta$  rizika s inherentnim rizikom, kontrolnim rizikom te rizikom analitičkih postupaka  $\alpha$ .

Nadalje je analizirana povezanost ovih rizika s veličinom uzorka. Veličina uzorka je upravo proporcionalna s (procijenjenom) veličinom standardne devijacije populacije te i s vrijednošću koeficijenta  $Z_\alpha$ . To ujedno znači da je veličina uzorka obrnuto proporcionalna vrijednosti rizika  $\alpha$ . Veličina uzorka je također obrnuto proporcionalna veličini prihvatljive preciznosti  $A$  kao i obrnuto proporcionalna maksimalno dopustivoj pogrešci TM. Niža vrijednost prihvatljive preciznosti  $A$ , kao i niža vrijednost TM zahtijevaju dakle veću veličinu potrebnog uzorka. Kod dokaznih testova, preciznost  $A$  je povezana s revizorovom prosudbom glede materijalne značajnosti. Pogreška TM je najveći iznos koji revizor ne smatra značajnim, a preciznost  $A$  je direktno proporcionalna s njezinom veličinom. Preciznost  $A$  poprima veću vrijednost kada je  $Z_\beta$  manji, tj. uz višu razinu  $\beta$  rizika.

Razina rizika uzorka koju je revizor voljan prihvatiti i veličina uzorka obrnuto su proporcionalni. Tako se veličina uzorka povećava sa smanjenjem rizika uzorka, ali i sa smanjenjem maksimalne dopustive pogreške, i obrnuto. Malim uzorcima svojstven je dakle, u načelu veći rizik, a male vrijednosti  $\alpha$  i  $\beta$  traže veliki  $n$ . Tek kod 100%-tnog uzorka, tj. popisa, kada je veličina uzorka  $n$  jednaka  $N$ , obje vjerojatnosti,  $\alpha$  i  $\beta$ , bile bi jednakе nuli.

Nakon izučavanja odnosa i povezanosti, tj. variranja, stavljanjem u interakciju i kovariiranja pojedinih vrsta statističkih rizika s potrebnom veličinom statističkog uzorka u reviziji, i to uz strategiju dokaznih testova revizora, dolazi se do prihvaćanja prve istraživačke hipoteze H1, tj. do prihvaćanja pretpostavke da je kod primjene modela testiranja revizijskih hipoteza u dokaznom testu, veličina revizijskog uzorka povezana s rizicima uzorka  $\alpha$  i  $\beta$  s veličinom maksimalne pogreške koja se tolerira (TM) kao i s prihvatljivom preciznošću  $A$  te da se ta povezanost može kvantificirati, tj. izraziti odnosima navedenih direktnih i indirektnih proporcionalnosti.

Druga istraživačka hipoteza H2 ispitivana je u uvjetima promatranja plana uzorka za prihvaćanje revizijske populacije i OC krivulja operativne karakteristike kako bi se donijeli zaključci o povezanosti  $\alpha$  rizika,  $\beta$  rizika, prihvatljive razine kvalitete AQL, razine kvalitete neprihvatljive populacije LTPD i veličine uzorka za potrebe revizije. Temeljem testiranja druge istraživačke hipoteze H2 zaključuje se da je ona prihvaćena. Naime, rizik pogrešnog prihvaćanja revizijske populacije ( $\beta$ ) u obrnutom je odnosu proporcionalnosti s veličinom uzorka za prihvaćanje, dok to kod rizika pogrešnog odbacivanja revizijske populacije ( $\alpha$ ),

na niskim razinama rizika nije bilo izraženo (dakle, dio hipoteze vezan za  $\alpha$  rizik nije prihvaćen). Veličina uzorka pritom reagira i na veličinu prihvatljive razine kvalitete AQL i to upravo proporcionalno, dok je s razinom kvalitete neprihvatljive populacije LTPD veličina uzorka obrnuto proporcionalna.

## LITERATURA

1. American Institute of Certified Public Accountants, Statement on Auditing Standards No. 39: Audit Sampling, 1985. Compiled with amendments in AICPA Professional Standards, Volume 1, AU section 530. [www.aicpa.org/download/members/div/auditstd/AU-00350.PDF](http://www.aicpa.org/download/members/div/auditstd/AU-00350.PDF).
2. Arens, A.A., Loebbecke, J.K. (1997). Auditing: An Integrated Approach. 7th Edt. Prentice Hall. Upper Saddle River, New Jersey.
3. Arkin, H. (1984). Handbook of Sampling for Auditing and Accounting. 3rd Edt., McGraw-Hill, New York.
4. Boynton, W.C., Kell, W.G. (1996). Modern Auditing. Wiley, New York.
5. Dumičić, K. (1991). Značaj ispravnog korištenja teorije i metode uzoraka u praktičnom istraživanju. Ekonomski analitičar br. 5/1991, pp. 17-25.
6. Guy, D.M., Carmichael, D.R., Whittington, O.R. (2001). Audit Sampling: An Introduction. 5<sup>th</sup> Edt. Wiley, New York.
7. Kaplan, J. (2003). How to Use Statistical Sampling.  
<http://www.auditnet.org/docs/statsamp.htm> (17.6.2005.).
8. Krajačić, D. (Izdavač) (2003). Međunarodni revizijski standardi. (Prijevod s engleskog). Hrvatska udruga revizora, Zagreb.
9. Meigs, R.F., Meigs, W.B. (1999). Računovodstvo: temelj poslovnog odlučivanja. MATE, Zagreb.
10. Messier, Jr. W. F. (1998). Revizija, priručnik za revizore i studente. (prijevod s engleskog), Faber & Zgombić Plus i HUR, Zagreb.
11. Montgomery, D. C.(2003). Introduction to Statistical Quality Control. 4th Edt. Wiley, NY.
12. Robertson, J.C., Davis, F.G. (1988). Auditing. 5th Edt., Irwin, Homewood, Illinois.
13. Smith, K. (1999). Audit Sampling.  
<http://www.accaglobal.com/publications/studentaccountant/30792?view=Printable+version>
14. Spremić, I. (1995). Rizik revizije. Revija HUR-a, br. 1, HUR, Zagreb.
15. Šošić, I. (2004). Primjenjena statistika. Školska knjiga, Zagreb.
16. Taylor, D.H., Glezen, G.W. (1994). Auditing: Integrated Concepts and Procedures. Wiley, NY.
17. Tušek, B. (2001a). Revizija instrument poslovnog odlučivanja. TEB, Zagreb.
18. Tušek, B. (2001b). Revizija na temelju uzorka. Slobodno poduzetništvo, br.17/2001, TEB, Zagreb, str. 36-47.
19. Tušek, B. (2003). Rizik neotkrivanja i oblikovanja dokaznih testova u procesu revizije finansijskih izvještaja. Revizija 3/2003, str. 9-26.
20. Vance,L.L., Neter, J.(1956). Statistical Sampling for Auditors and Accountants. Wiley, NY.
21. Vitezić, N. (1998). Revizija na temelju uzorka. Računovodstvo, revizija i financije u suvremenim gospodarskim uvjetima. Pula.
22. Zgombić, H. (2005). Business Dictionary. III. dopunjeno izdanje. Faber / Zgombić Plus. Zagreb.
23. Žugaj, M., Dumičić, K., Dušak, V. (1999). Temelji znanstvenoistraživačkog rada. Metodologija i metodika. Sveučilište u Zagrebu, Fakultet organizacije i informatike, Varaždin.