POGLAVLJE 9

TESTIRANJE HIPOTEZA O ARITMETIČKOJ SREDINI I PROPORCIJI

9.1 TESTIRANJE HIPOTEZA: UVOD

- Dvije hipoteze
- Oblasti odbacivanja i neodbacivanja
- Dva tipa grešaka
- Smjerovi (oblici) testa

Dvije hipoteze

Definicija

Nulta hipoteza je tvrđenje (ili iskaz) o nekom parametru osnovnog skupa koji se smatra istinitim sve dok se ne pokaže suprotno.

Dvije hipoteze

Definicija

Alternativna hipoteza je tvrđenje o nekom parametru osnovnog skupa koje će biti istinito ako je nulta hipoteza neistinita.

Oblasti odbacivanja i neodbacivanja

Slika 9.1 Oblasti odbacivanja i neodbacivanja u sudskom procesu.

Dva tipa grešaka

Tabela 9.1 Četiri moguća ishoda u sudskom procesu

		Stvarno stanje	
		Osoba nije kriva	**Osoba jeste kriva**
Odluka suda	Osoba nije kriva	Ispravna odluka	Greška II vrste ili β greška
	Osoba jeste kriva	Greška I vrste ili α greška	Ispravna odluka

Dva tipa grešaka

Definicija

Greška I vrste se javlja kada se istinita nulta hipoteza odbaci. Vrijednost α predstavlja vjerovatnoću javljanja greške ove vrste; odnosno,

$$\alpha = P(H_0 \text{ se odbacuje} \mid H_0 \text{ je istinita})$$

Vrijednost α predstavlja ***nivo značajnosti*** testa.

Dva tipa grešaka

Definicija

Greška II vrste se javlja kada se neistinita nulta hipoteza ne odbaci. Vrijednost β predstavlja vjerovatnoću javljanja greške II vrste; odnosno,

$$\beta = P\ (H_0 \text{ se ne odbacuje} \mid H_0 \text{ je neistinita})$$

Vrijednost $1 - \beta$ se naziva ***jačina testa*** i predstavlja vjerovatnoću da se greška II vrste ne javi.

Tabela 9.2 Četiri moguća ishoda za testiranje hipoteza

		Stvarno stanje	
		H_0 je istinita	**H_0 nije istinita**
Odluka	H_0 se ne odbacuje	Ispravna odluka	Greška II vrste ili β greška
	H_0 se odbacuje	Greška I vrste ili α greška	Ispravna odluka

Smjerovi (oblici) testa

Definicija

Dvostrani test ima oblast odbacivanja na oba kraja, ***lijevostrani test*** ima oblast odbacivanja na lijevom kraju, a ***desnostrani test*** ima oblast odbacivanja na desnom kraju krive raspodjele.

Dvostrani test

- Na osnovu ankete koju je sproveo časopis Consumer Reports u 2008. godini, uzorak učenika šestog razreda odabranih iz škola u Njujorku pokazao je da su njihove školske torbe u prosjeku teške 18.4 funti (USA TODAY, 3. Avgust, 2009). Drugi časopis želi da provjeri da li se ovaj prosjek *promijenio* od ankete ili nije. Ključna riječ ovdje je *promijenio*.
- Prosječna težina torbi za učenike šestih razreda u Njujorku se promijenila ako se povećala ili smanjila u odnosu na nivo od 2008. godine. Ovo je jedan primjer dvostranog testa.

Dvostrani test

- Neka je μ težina torbi za sadašnje učenike šestih razreda u Njujorku. Dvije moguće odluke su
  - $H_0 : \mu = 18.4$ funti (Prosječna težina torbi za učenike šestih razreda u Njujorku se nije promijenila)
  - $H_1 : \mu \neq 18.4$ funti (Prosječna težina torbi za učenike šestih razreda u Njujorku se promijenila)

Dvostrani test

- Da li je test dvostrani ili jednostrani određuje znak u alternativnoj hipotezi.
- Ako se u alternativnoj hipotezi nalazi znak *nije jednako* ($\neq$), onda je taj test dvostrani.

Slika 9.2 Dvostrani test.

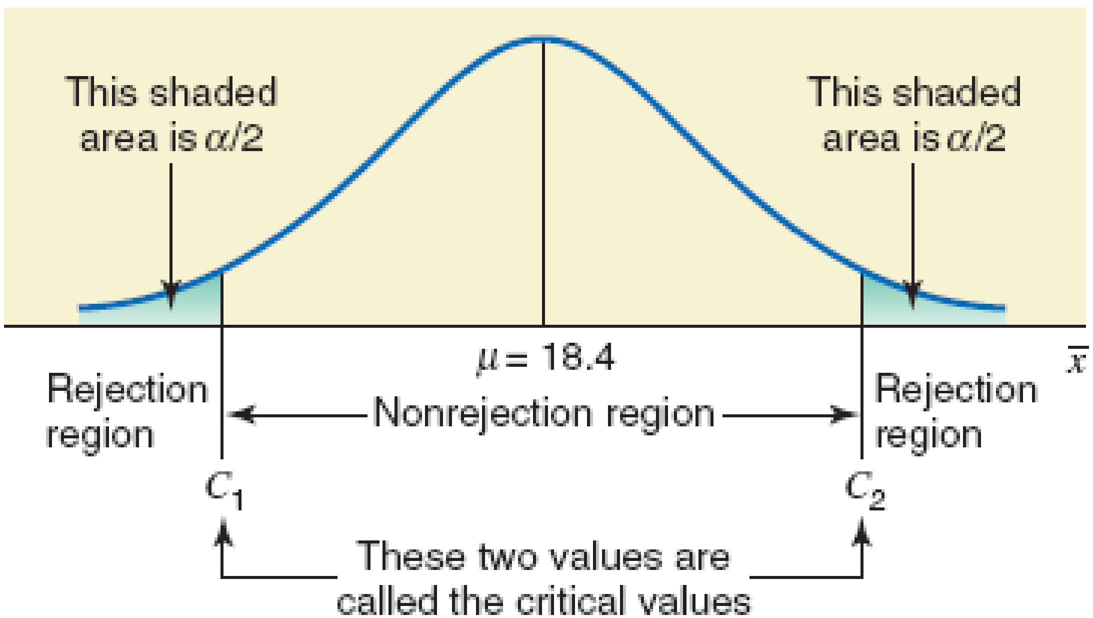

Lijevostrani test

Vratimo se primjeru u kom provjeravamo prosječnu količinu soka u limenkama bezalkoholnih pića jednog proizvođača. Proizvođač tvrdi da ove limenke u prosjeku sadrže 12 unci soka. Ali, ako je sadržaj limenki manji od navedene količine, onda proizvođač može biti optužen za prevaru. Pretpostavimo da jedna agencija za zaštitu potrošača želi da ispita da li je prosječna količina soka po limenki *manja od* 12 unci. Obratite pažnju da je ključna fraza *manje od*, koja ukazuje na lijevostrani test.

Lijevostrani test

- Neka je μ prosječna količina soka u svim limenkama. Dvije moguće odluke su
  - H_0 : μ = 12 unci (Prosjek je jednak 12 unci)
  - H_1 : μ < 12 unci (Prosjek je manji od 12 unci)

Lijevostrani test

U ovom slučaju nultu hipotezu možemo da napišemo i kao $H_0 : \mu \geq 12$. Ovo neće uticati na rezultat testa sve dok se u H_1 nalazi znak *manje od* (<).

Kada je u alternativnoj hipotezi znak *manje od* (<), test je uvijek lijevostran.

Slika 9.3 Lijevostrani test.

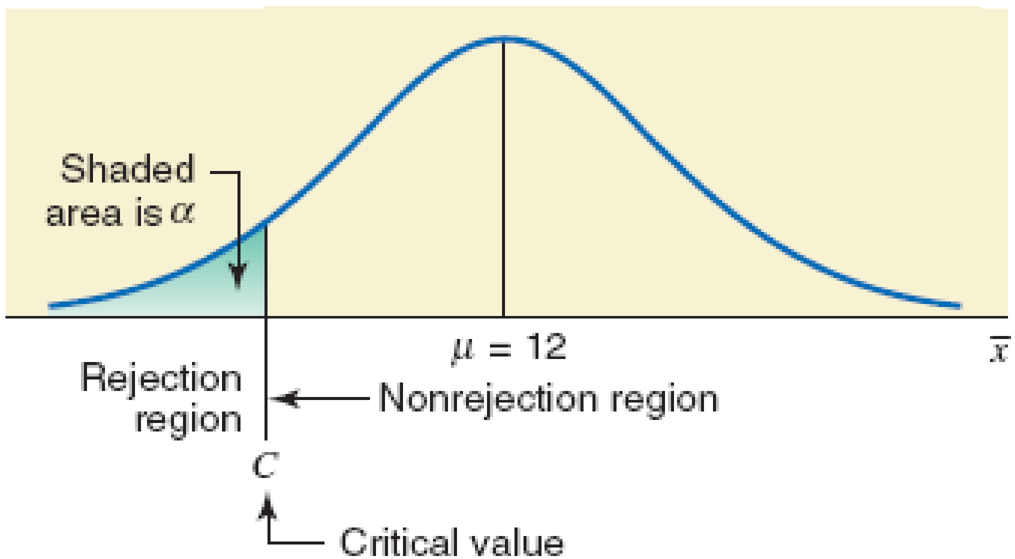

Desnostrani test

Prema www.city-data.com, prosječna cijena domova u West Orange, država New Jersey, bila je $461,216 u 2007. Pretpostavimo da istraživač nekretnina želi da provjeri da li je trenutna prosječna cijena domova u ovom gradu *veća od* $461,216. Ključna fraza u ovom slučaju je *veće od*, što ukazuje na desnostrani test.

Desnostrani test

- Neka je μ trenutna prosječna cijena domova u ovom gradu. Dvije moguće odluke su
  - $H_0 : \mu = \$461,216$ (Trenutna prosječna cijena domova u ovom gradu nije veća od \$461,216)
  - $H_1 : \mu > \$461,216$ (Trenutna prosječna cijena domova u ovom gradu je veća od \$461,216)

Desnostrani test

Kada alternativna hipoteza sadrži znak veće od (>), test je uvijek desnostrani.

Slika 9.4 Desnostrani test.

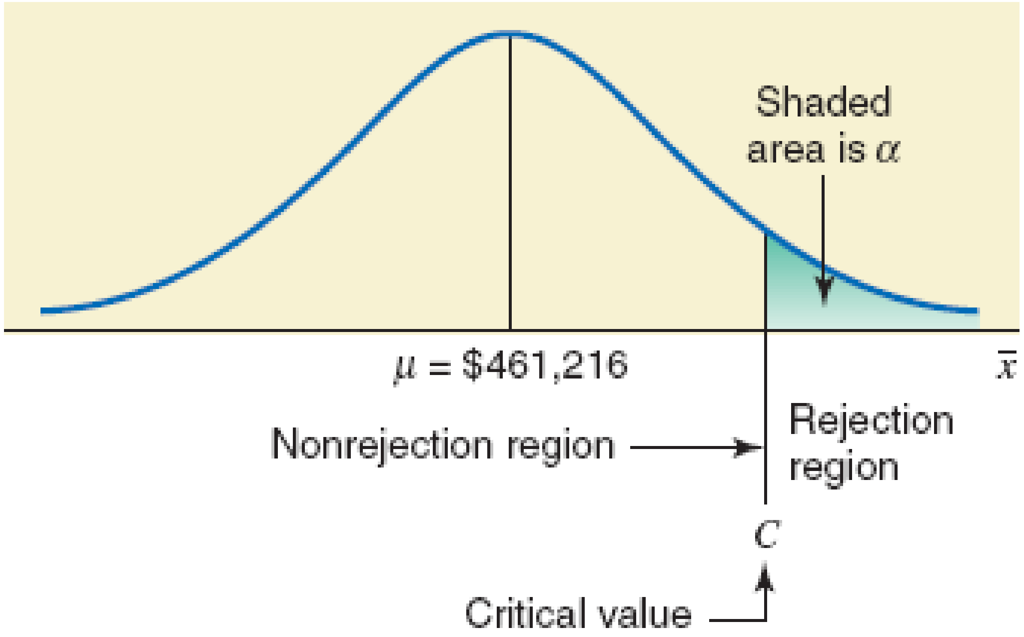

Tabela 9.3 Znaci u H_0 i H_1 i smjerovi testa

	Dvostrani test	Lijevostrani test	Desnostrani test
Znak u nultoj hipotezi H_0	$=$	$=$ ili $\geq$	$=$ ili $\leq$
Znak u alternativnoj hipotezi H_1	$\neq$	$<$	$>$
Odbast odbacivanja	Na oba kraja	Na lijevom kraju	Na desnom kraju

Dva postupka

Dva postupka testiranja hipoteza

1. Pristup zasnovan na p-vrijednosti
2. Pristup zasnovan na kritičnoj vrijednosti

9.2 TESTIRANJE HIPOTEZA O μ: σ JE POZNATA

Tri moguća slučaja

Slučaj I. Ako se ispune sledeća tri uslova:

1. Standardna devijacija osnovnog skupa σ je poznata
2. Uzorak je mali (tj., $n < 30$)
3. Osnovni skup iz kojeg se bira uzorak ima normalnu raspodjelu.

TESTIRANJE HIPOTEZA O μ: σ JE POZNATA

Tri moguća slučaja

Slučaj II. Ako se ispune sledeća dva uslova:

1. Standardna devijacija osnovnog skupa σ je poznata
2. Uzorak je veliki (tj., $n \geq 30$)

TESTIRANJE HIPOTEZA O μ: σ JE POZNATA

Tri moguća slučaja

Slučaj III. Ako se ispune sledeća tri uslova:

1. Standardna devijacija osnovnog skupa σ je poznata
2. Uzorak je mali (tj., $n < 30$)
3. Osnovni skup iz kojeg se bira uzorak nema normalnu raspodjelu (ili oblik raspodjele nije poznat).

TESTIRANJE HIPOTEZA O μ: σ JE POZNATA

Tri moguća slučaja

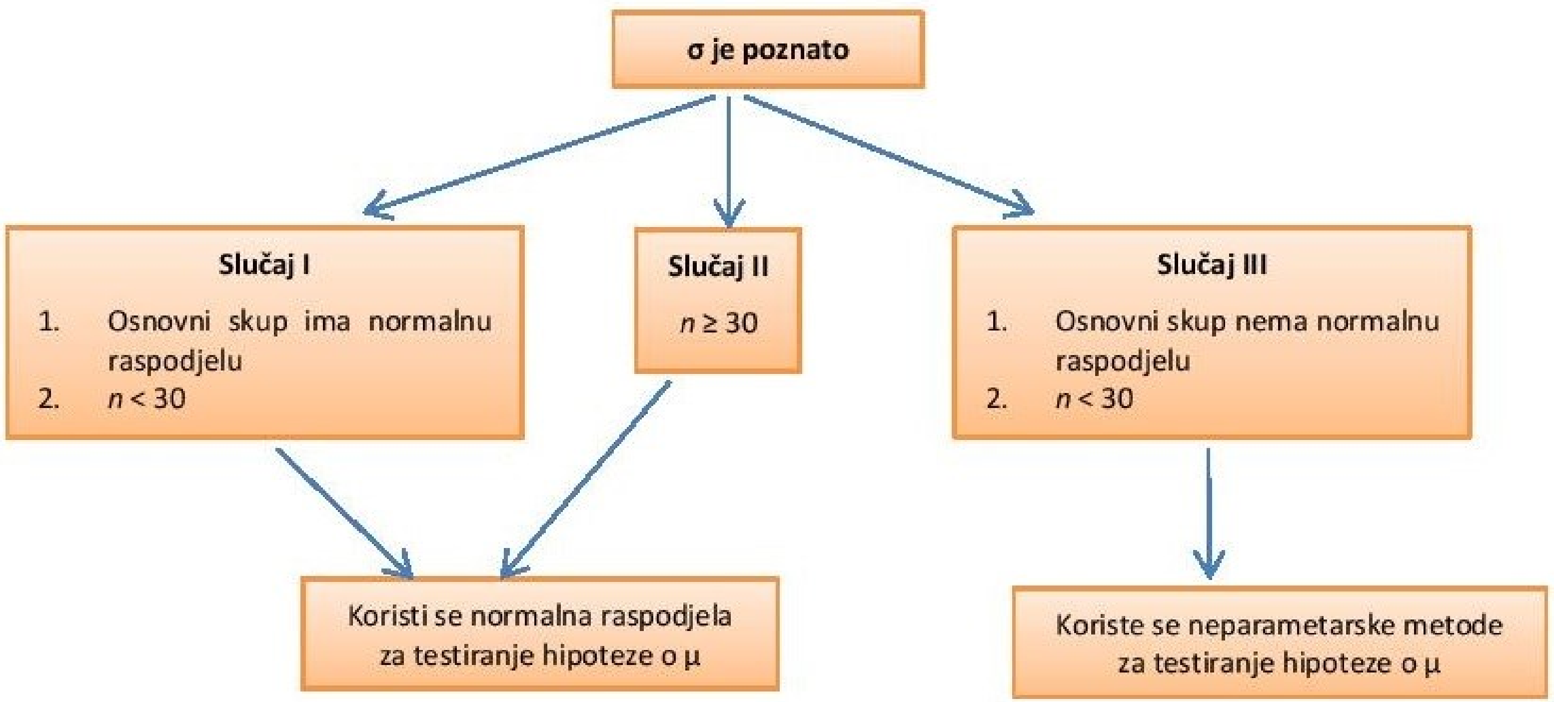

TESTIRANJE HIPOTEZA O μ: σ JE POZNATA

Definicija

Pod pretpostavkom da je nulta hipoteza tačna, p-vrijednost može da se definiše kao vjerovatnoća da statistika uzorka (kao što je aritmetička sredina uzorka) odstupa od hipotetičke vrijednosti parametra u smjeru alternativne hipoteze, barem toliko koliko i realizovana vrijednost statistike uzorka u izabranom uzorku. Napomenimo da ako je ***p*−vrijednost** manja od nivoa značajnosti, nulta hipoteza se odbacuje.

Slika 9.5 *p*–vrijednost za desnostrani test.

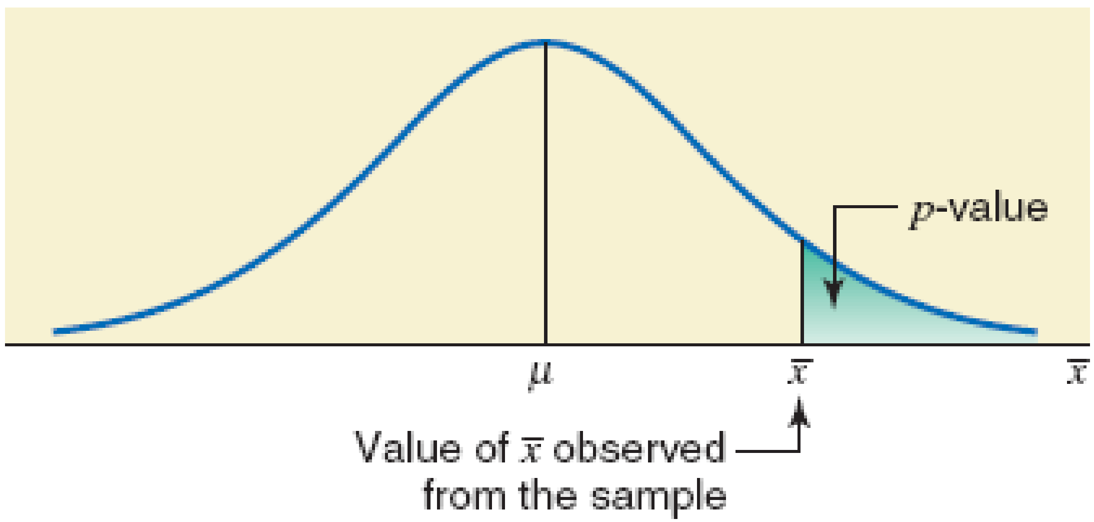

Slika 9.6 *p*–vrijednost za dvostrani test.

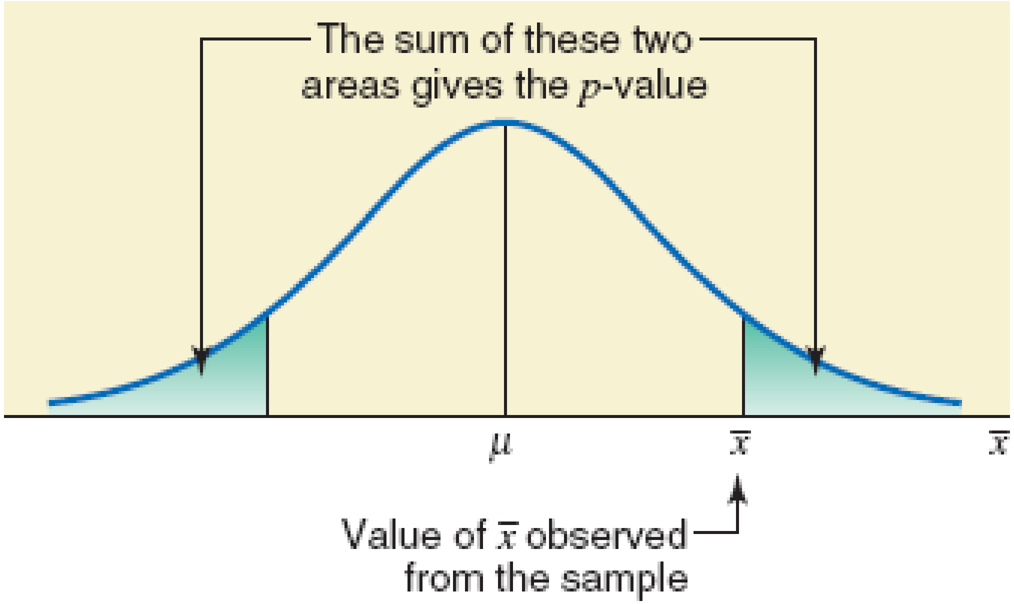

Izračunavanje z vrijednosti za $\bar{x}$

Kada u testiranju hipoteze o μ koristimo normalnu raspodjelu, onda ***vrijednost*** z, za vrijednost $\bar{x}$ u izabranom uzorku, izračunavamo na sledeći način:

$$z = \frac{\bar{x} - \mu}{\sigma_{\bar{x}}} \qquad \textbf{gdje} \qquad \sigma_{\bar{x}} = \frac{\sigma}{\sqrt{n}}$$

Izračunatu vrijednost z na osnovu $\bar{x}$ iz izabranog uzorka, nazivamo i ***realizovana vrijednost statistike*** z ***testa***.

Koraci za testiranje hipoteza korišćenjem p–vrijednosti

1. Formulisanje nulte i alternativne hipoteze.
2. Izbor raspodjele koja će se koristiti.
3. Izračunavanje p–vrijednosti.
4. Donošenje odluke.

Primjer 9-1

U korporaciji Canon Food, novim radnicima je trebalo u prosjeku 90 minuta da nauče posao prerade hrane. Nedavno je kompanija instalirala novu mašinu za preradu hrane. Nadzornik kompanije želi da utvrdi da li se prosječno vrijeme potrebno novim radnicima da nauče postupak prerade hrane na ovoj novoj mašini razlikuje od 90 minuta. Uzorak od 20 radnika pokazao je da im je u prosjeku trebalo 85 minuta da nauče postupak prerade hrane na novoj mašini. Poznato je da vrijeme učenja za sve nove radnike ima normalnu raspodjelu sa standardnom devijacijom osnovnog skupa od 7 minuta. Odrediti p–vrijednost za test da se prosječno vrijeme učenja procesa prerade hrane na novoj mašini razlikuje od 90 minuta. Koji bi bio vaš zaključak ako je $\alpha = 0.01$?

Primjer 9-1: Rješenje

- Korak 1: H_0: $\mu = 90$ H_1: $\mu \neq 90$
- Korak 2: Standardna devijacija osnovnog skupa σ je poznata, uzorak je mali ($n < 30$), ali raspodjela osnovnog skupa je normalna. Koristićemo normalnu raspodjelu da odredimo p–vrijednost i sprovedemo test.

Primjer 9-1: Rješenje

- Korak 3:

$$\sigma_{\bar{x}} = \frac{\sigma}{\sqrt{n}} = \frac{7}{\sqrt{20}} = \mathbf{1.56524758 \ \ min\mathit{utes}}$$

$$z = \frac{\bar{x} - \mu}{\sigma_{\bar{x}}} = \frac{85 - 90}{1.56524758} = -3.19$$

p-vrijednost = 2(0.0007) = **0.0014**

Slika 9-7 p-vrijednost za dvostani test.

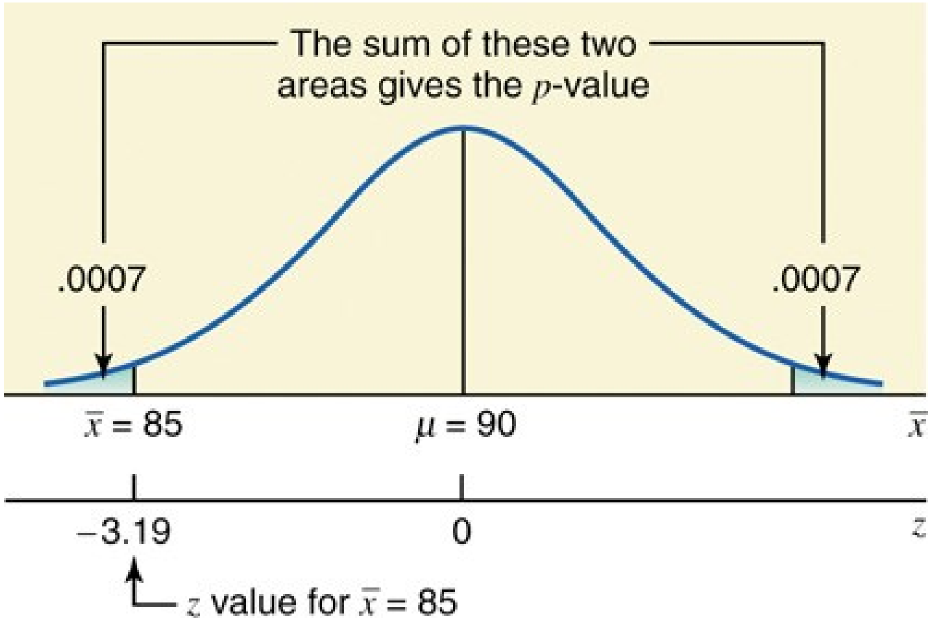

Primjer 9-1: Rješenje

- Korak 4: Pošto je $\alpha = 0.01$ veće od p-vrijednosti od 0.0014, odbacujemo nultu hipotezu za ovaj nivo pouzdanosti.

  Stoga, zaključujemo da se prosječno vrijeme potrebno za učenje postupka prerade hrane na novoj mašini razlikuje od 90 minuta.

TESTIRANJE HIPOTEZA O μ: σ JE POZNATA

Statistika testa

Prilikom testiranja hipoteze o μ primjenom normalne raspodjele, slučajna promjenljiva

$$z = \frac{\bar{x} - \mu}{\sigma_{\bar{x}}} \; gdje \; je \; \sigma_{\bar{x}} = \frac{\sigma}{\sqrt{n}}$$

se naziva ***statistika testa***. Statistika testa se može definisati kao pravilo ili kriterijum koji koristimo pri donošenju odluke da li da odbacimo nultu hipotezu ili da je ne odbacimo.

TESTIRANJE HIPOTEZA O μ: σ JE POZNATA

Etape u testiranju hipoteze primjenom pristupa zasnovanog na kritičnoj vrijednosti

1. Formulisanje nulte i alternativne hipoteze.
2. Izbor raspodjele koja će se koristiti.
3. Određivanje oblasti odbacivanja i neodbacivanja.
4. Izračunavanje vrijednosti statistike testa.
5. Donošenje odluke.

Primjer 9-3

Telefonska kompanija TIV pruža usluge međunarodnih razgovora u jednoj oblasti. Na osnovu raspoloživih informacija utvrđeno je da je prosječna dužina međunarodnih razgovora koji su preko ove kompanije obavljeni u 2009. godini bila 12.44 minuta. Uprava kompanije je željela da provjeri da li se prosječna dužina aktuelnih telefonskih razgovora razlikuje od 12.44 minuta. U uzorku od 150 takvih razgovora prosječna dužina iznosila je 13.71 minuta. Standardna devijacija svih razgovora je 2.65 minuta. Da li na nivou značajnosti od 2%, možete da zaključite da se prosječna dužina aktuelnih međunarodnih razgovora razlikuje od 12.44 minuta?

Primjer 9-3: Rješenje

- Korak 1: $H_0 : \mu = 12.44 \quad H_1 : \mu \neq 12.44$
- Korak 2: Standardna devijacija skupa σ je poznata, a uzorak veliki (n > 30). Po centralnoj graničnoj teoremi, koristićemo normalnu raspodjelu da sprovedemo test.

Primjer 9-3: Rješenje

- Korak 3: $\alpha = 0.02$
- Znak $\neq$ u alternativnoj hipotezi ukazuje da je test dvostrani
- Površina na svakom kraju = α / 2= 0.02 / 2 = 0.01
- Vrijednosti z za dvije kritične tačke su -2.33 i 2.33

Slika 9.9

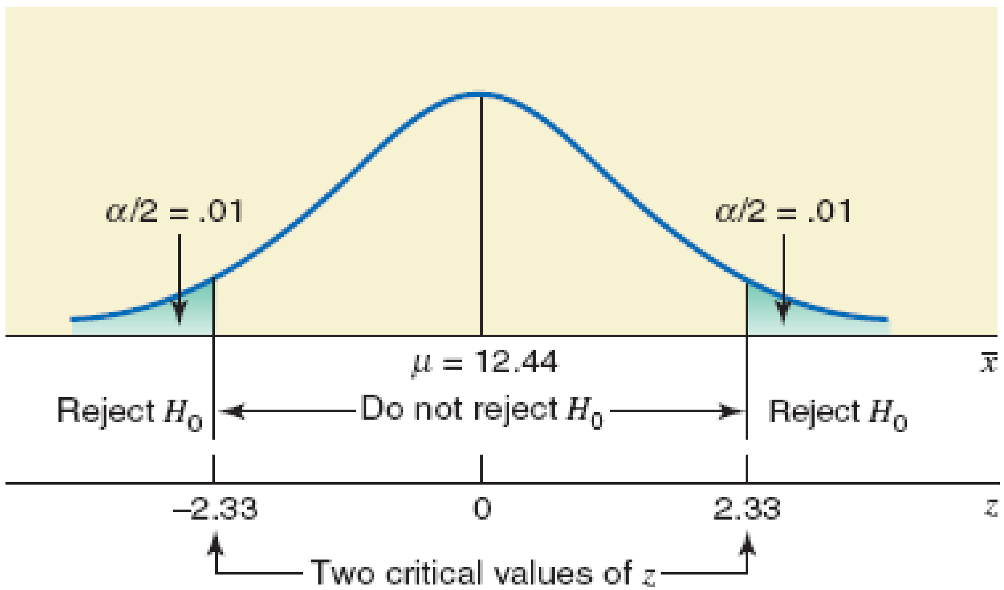

α/2 = .01
α/2 = .01
μ = 12.44
x̄
Reject H0
Do not reject H0
Reject H0
–2.33
0
2.33
z
Two critical values of z

Izračunavanje vrijednosti statistike testa

Kada pri testiranju hipoteze o μ koristimo normalnu raspodjelu, realizovanu ***vrijednost statistike testa z*** za vrijednost $\overline{x}$ izabranog uzorka izračunavamo na sledeći način:

$$z = \frac{\bar{x}-\mu}{\sigma_{\bar{x}}} \; gdje \; je \; \sigma_{\bar{x}} = \frac{\sigma}{\sqrt{n}}$$

Izračunata vrijednost z za dato $\overline{x}$ se takođe naziva ***realizovana vrijednost statistike z testa***.

Primjer 9-3: Rješenje

- Korak 4:

$$\sigma_{\bar{x}} = \frac{\sigma}{\sqrt{n}} = \frac{2.65}{\sqrt{150}} = .21637159$$

$$z = \frac{\bar{x} - \mu}{\sigma_{\bar{x}}} = \frac{13.71 - 12.44}{.21637159} = 5.87$$

Primjer 9-3: Rješenje

- Korak 5: Ova vrijednost $z = 5.87$ je veća od kritične vrijednosti $z = 2.33$, i nalazi se u oblasti odbacivanja na desnom kraju krive raspodjele na slici 9.9. Slijedi da odbacujemo H_0 i zaključujemo da, na osnovu podataka o uzorku, prosječna dužina svih telefonskih razgovora nije jednaka 12.44 minuta.

9.3 TESTIRANJE HIPOTEZA O μ: σ NIJE POZNATA

Tri moguća slučaja

Slučaj I. Ako su ispunjena sledeća tri uslova:

1. Standardna devijacija osnovnog skupa σ nije poznata
2. Uzorak je mali (tj., $n < 30$)
3. Osnovni skup iz koga se bira uzorak ima normalnu raspodjelu.

TESTIRANJE HIPOTEZA O μ: σ NIJE POZNATA

Tri moguća slučaja

Slučaj II. Ako su ispunjena sledeća dva uslova:

1. Standardna devijacija osnovnog skupa σ nije poznata
2. Uzorak je veliki (tj., $n \geq 30$)

TESTIRANJE HIPOTEZA O μ: σ NIJE POZNATA

Tri moguća slučaja

Slučaj III. Ako su ispunjena sledeća tri uslova:

1. Standardna devijacija osnovnog skupa σ nije poznata
2. Uzorak je mali (tj., $n < 30$)
3. Osnovni skup iz koga se bira uzorak nema normalnu raspodjelu (ili oblik raspodjele nije poznat).

TESTIRANJE HIPOTEZA O μ: σ NIJE POZNATA

Tri moguća slučaja

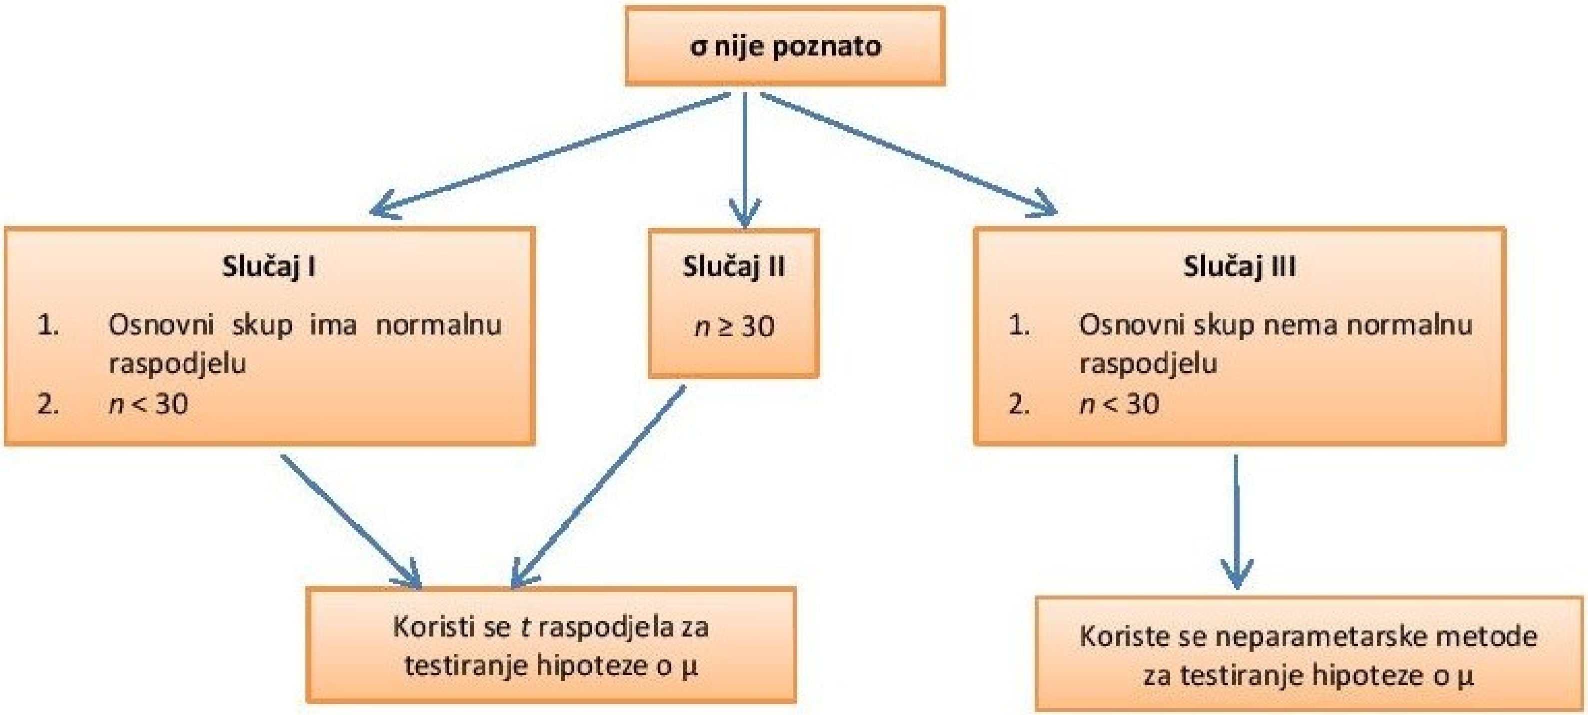

TESTIRANJE HIPOTEZA O μ: σ NIJE POZNATA

Statistika testa

Vrijednost ***statistike t testa*** za aritmetičku sredinu uzorka $\overline{x}$ izračunava se kao

$$t = \frac{\bar{x} - \mu}{s_{\bar{x}}} \; gdje \; je \; s_{\bar{x}} = \frac{s}{\sqrt{n}}$$

Vrijednost t izračunate za $\overline{x}$ primjenom ove formule se takođe naziva ***realizovana vrijednost statistike t testa***.

Primjer 9-5

Psiholog tvrdi da je aritmetička sredina starosti djece koja prohodaju 12.5 mjeseci. Karol je željela da provjeri da li je ovo tvrđenje tačno. Izabrala je slučajan uzorak od 18 djece i utvrdila da je aritmetička sredina starosti djece koja su prohodala 12.9 mjeseci, sa standardnom devijacijom 0.80 mjeseci. Poznato je da starost djece koja prohodaju ima približno normalnu raspodjelu. Odrediti p-vrijednost za testiranje hipoteze da se aritmetička sredina starosti djece koja prohodaju razlikuje od 12.5 mjeseci. Šta ćete zaključiti ako je nivo značajnosti 1%?

Primjer 9-5: Rješenje

- Korak 1: $H_0 : \mu = 12.5$
  $H_1 : \mu \neq 12.5$
- Korak 2: Standardna devijacija osnovnog skupa σ nije poznata, uzorak je mali (n < 30), a osnovni skup ima normalnu raspodjelu. Prema tome, koristićemo t raspodjelu da odredimo p-vrijednost za test.

Primjer 9-5: Rješenje

- Korak 3: Znak ≠ u alternativnoj hipotezi ukazuje da je test dvostrani

$$s_{\bar{x}} = \frac{s}{\sqrt{n}} = \frac{.80}{\sqrt{18}} = .18856181$$

$$t = \frac{\bar{x} - \mu}{s_{\bar{x}}} = \frac{12.9 - 12.5}{.18856181} = 2.121$$

i $df = n - 1 = 18 - 1 = 17$

$$0.02 < \text{p-vrijednost} < 0.05$$

Slika 9.11 Tražena *p*-vrijednost

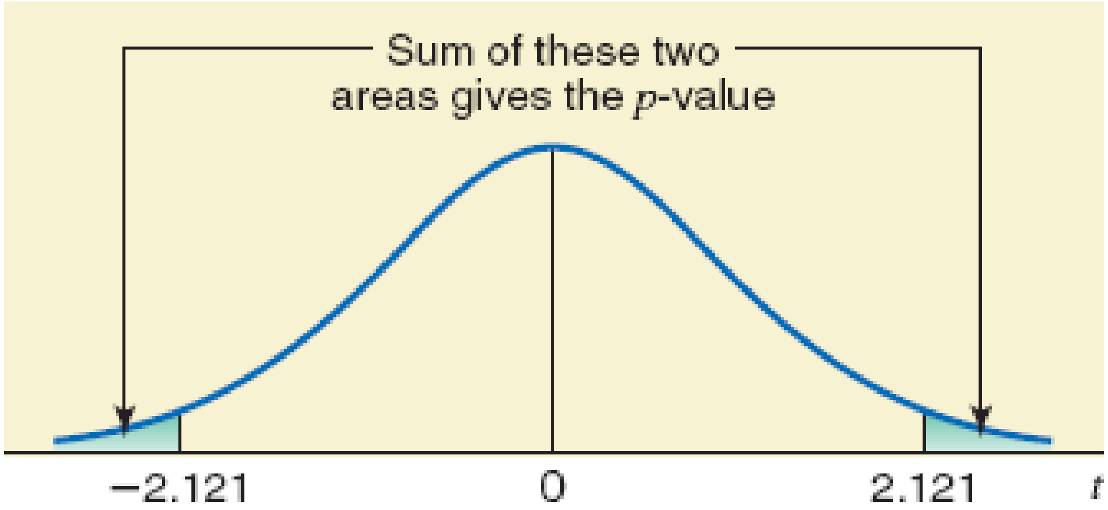

Primjer 9-5: Rješenje

- Korak 4: Za bilo koje α veće od 0.05, odbacićemo nultu hipotezu. Za bilo koje α manje od 0.02, nećemo odbaciti nultu hipotezu. U našem primjeru, $\alpha = 0.01$, što je manje od 0.02, donje granice intervala u kome se nalazi *p*-vrijednost. Zato ne možemo odbaciti H_0 i zaključujemo da se aritmetička sredina starosti djece kada prohodaju razlikuje od 12.5 mjeseci.

Testiranje hipoteza za μ korišćenjem *t* raspodjele

Šta se dešava ako je uzorak preveliki?

1. Koristiti kritične vrijednosti *t* iz poslednjeg reda (red ∞) Tablice V u Dodatku C.

2. Koristiti normalnu raspodjelu kao aproksimaciju *t* raspodjele.

TESTIRANJE HIPOTEZE O PROPORCIJI OSNOVNOG SKUPA: VELIKI UZORCI

Statistika testa

Statistika testa z za proporciju uzorka, $\hat{p}$, izračunava se kao

$$z = \frac{\hat{p} - p}{\sigma_{\hat{p}}} \ gdje\ je\ \sigma_{\hat{p}} = \sqrt{\frac{pq}{n}}$$

Vrijednost p u ovoj formuli je ona koja se koristi u nultoj hipotezi. Vrijednost q je jednaka 1-p. Vrijednost z koja se izračunava za $\hat{p}$ primjenom gore navedene formule naziva se realizovana vrijednost z.

Primjer 9-9

Prema anketi „*Vožnja tokom rasijanosti*" nacionalne kompanije za uzajamno osiguranje sprovedenoj u 2008. godini, 81% intervjuisanih vozača reklo je da su razgovarali na mobilnim telefonima tokom vožnje (*The New York Times*, 19. jul, 2009). Anketa je obuhvatila vozače starosti od 16 do 61 godina odabrane iz 48 država. Pretpostavimo da ovaj rezultat važi za populaciju svih takvih vozača u SAD-u u 2008. godini. U nedavnom slučajnom uzorku od 1600 vozača starih od 16 do 61 godina izabranih iz SAD-a, 83% reklo je da su razgovarali na mobilnim telefonima tokom vožnje.

Primjer 9-9

Odrediti p-vrijednost za test hipoteza da se sadašnji procenat svih vozača koji su razgovarali na mobilnom telefonu tokom vožnje razlikuje od 81%. Šta možemo zaključiti uz nivo značajnosti od 5%?

Primjer 9-9: Rješenje

- Korak 1: $H_0 : p = 0.81$

  $H_1 : p \neq 0.81$
- Korak 2: da bismo provjerili da li je uzorak veliki, izračunavamo vrijednosti np i nq:

  $np = 1600(.81) = 1296 > 5$

  $nq = 1600(.19) = 304 > 5$

  Prema tome, koristimo normalnu raspodjelu da odredimo p-vrijednost za test.

Primjer 9-9: Rješenje

- Korak 3: Znak ≠ u alternativnoj hipotezi ukazuje da je test dvostrani.

$$\sigma_{\hat{p}} = \sqrt{\frac{pq}{n}} = \sqrt{\frac{(.81)(.19)}{1600}} = .00980752$$

$$z = \frac{\hat{p} - p}{\sigma_{\hat{p}}} = \frac{.83 - .81}{.00980752} = 2.04$$

p-vrijednost = 2(0.0207) = 0.0414

Slika 9.15 Tražena p-vrijednost

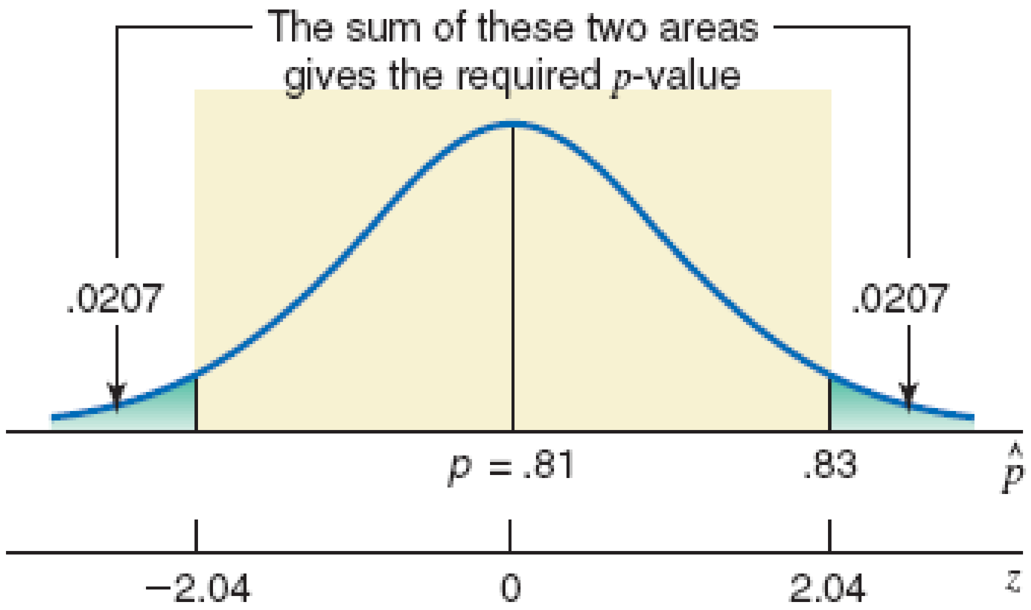

Primjer 9-9: Rješenje

- Korak 4: Možemo konstatovati da za bilo koju vrijednost α veću od 0.0414 ćemo odbaciti nultu hipotezu. U našem primjeru, $\alpha = 0.05$, što je veće od p-vrijednosti od 0.0414. Zbog toga odbacujemo H_0 i zaključujemo da se trenutni procenat svih američkih vozača starosti od 16 do 61 godina koji su razgovarali na mobilnom telefonu tokom vožnje razlikuje od 0.81.

Primjer 9-11

Razmotrimo ponovo primjer 9-9. Prema anketi „*Vožnja tokom rasijanosti*“ nacionalne kompanije za uzajamno osiguranje sprovedenoj u 2008. godini, 81% intervjuisanih vozača reklo je da su razgovarali na mobilnim telefonima tokom vožnje (*The New York Times*, 19. jul, 2009). Anketa je obuhvatila vozače starosti od 16 do 61 godina odabrane iz 48 država. Pretpostavimo da ovaj rezultat važi za populaciju svih takvih vozača u SAD-u u 2008. godini. U nedavnom slučajnom uzorku od 1600 vozača starih od 16 do 61 godina izabranih iz SAD-a, 83% reklo je da su razgovarali na mobilnim telefonima tokom vožnje.

Primjer 9-11

Koristeći nivo značajnosti od 5%, da li možete da zaključite da se sadašnji procenat ovakvih vozača koji su razgovarali na mobilnom telefonu tokom vožnje razlikuje od 81%.

Primjer 9-11: Rješenje

- Korak 1: $H_0 : p = 0.81$

  $H_1 : p \neq 0.81$
- Korak 2: da bismo provjerili da li je uzorak veliki, izračunavamo vrijednosti np i nq:

  $np = 1600(.81) = 1296 > 5$

  $nq = 1600(.19) = 304 > 5$

Prema tome, koristimo normalnu raspodjelu za test.

Primjer 9-11: Rješenje

- Korak 3: Znak ≠ u alternativnoj hipotezi ukazuje da je test dvostrani. Nivo značajnosti je 0.05. Dakle, ukupna površina dvije oblasti odbacivanja iznosi 0.05.

  Površina na svakom kraju = $\alpha / 2 = 0.05 / 2 = 0.025$

  Kritične vrijednosti od z su -1.96 i 1.96.

Slika 9.17 Kritične vrijednosti od z

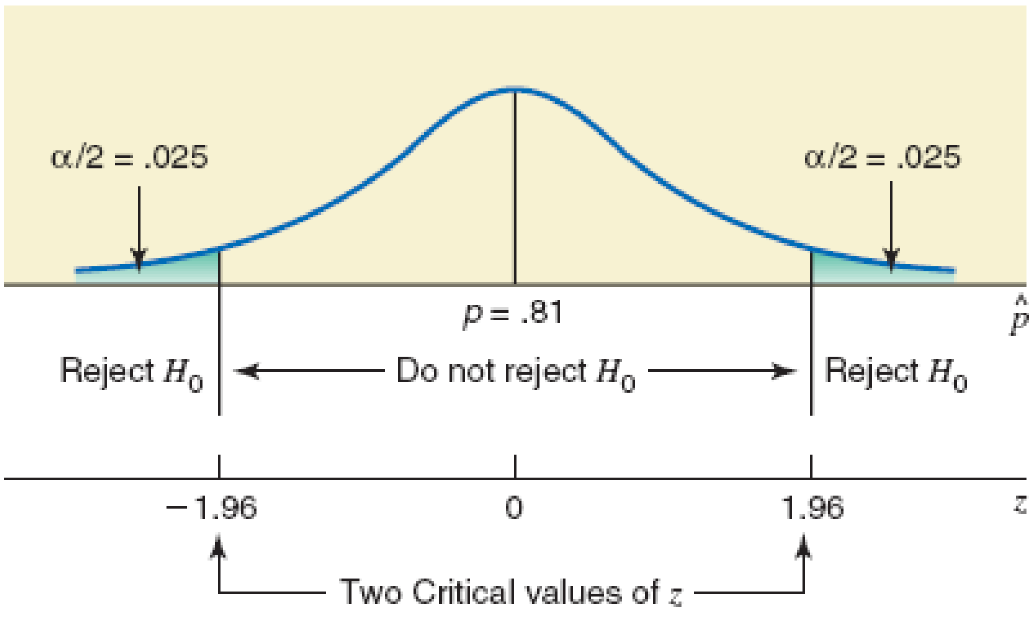

Primjer 9-11: Rješenje

- Korak 4:

$$\sigma_{\hat{p}} = \sqrt{\frac{pq}{n}} = \sqrt{\frac{(.81)(.19)}{1600}} = .00980752$$

$$z = \frac{\hat{p} - p}{\sigma_{\hat{p}}} = \frac{.83 - .81}{.00980752} = 2.04$$

Primjer 9-11: Rješenje

- Korak 5: Vrijednost statistike testa $z = 2.04$ nalazi se u oblasti odbacivanja. Zbog toga odbacujemo H_0 i zaključujemo da se sadašnji procenat ovakvih vozača koji su razgovarali na mobilnom telefonu tokom vožnje razlikuje od 81%.