



ANKETNA ISTRAŽIVANJA PUTEM INTERNETA: MOGUĆI IZVORI POGREŠAKA

Mirta GALEŠIĆ
Filozofski fakultet, Zagreb

UDK: 303.621:004.738.5
004.738.5:303

Pregledni rad

Primljeno: 3. 10. 2003.

Anketna istraživanja putem interneta sve su prisutnija u društvenim znanostima. Ovaj je rad cjelovit prikaz dosadašnjih spoznaja o *online* anketnim istraživanjima. Polazeći od modela ukupne anketne pogreške, prikazane su pogreške obuhvata, uzorka, neodziva i mjerenja koje se mogu javiti u *online* anketama. Predloženi su načini kontrole i/ili izbjegavanja ovih pogrešaka.



Mirta Galešić, Filozofski fakultet, Odsjek za psihologiju,
I. Lučića 3, 10000 Zagreb, Hrvatska.
E-mail: mgalesic@survey.umd.edu

UVOD

Internet je i u Hrvatskoj postao medij kojim se svakodnevno služi dobar dio stanovništva (16%, ili oko 700.000 prema istraživanju Pulsa iz ožujka 2003.). Brz rast broja korisnika interneta uzrokuje velike promjene na području znanosti, poslovanja, zabave i međuljudskih odnosa općenito. Prijateljske i poslovne veze stvorene na internetu više nisu rijetkost. Pojmovi kao što su e-pošta, e-poslovanje i e-učenje ulaze u svakodnevni rječnik i kod nas.

U znanosti internet ima vrlo široku primjenu. Upravo je znanstvena zajednica prva počela upotrebljavati internet za razmjenu ideja i novih spoznaja. Mogućnosti za međunarodnu, pa i interdisciplinarnu, suradnju danas su zahvaljujući internetu osjetno povećane. Brojne znanstvene publikacije i baze podataka, lako dostupne na internetu, omogućuju brzo širenje novih ideja i skraćuju proces pisanja znanstvenih publikacija. Internet se sve češće i u Hrvatskoj rabi kao dodatno nastavno sredstvo, a razvijaju se i sveučilišni kolegiji koji se najvećim dijelom održavaju *online*.

Ovaj rad pripremljen je u okviru projekta Q130406 (voditelj B. Sverko), što ga financira Ministarstvo znanosti, obrazovanja i športa Republike Hrvatske.

Posljednjih godina izvanredno se razvilo područje provedbe društvenih istraživanja putem interneta. U nekim zemljama (Njemačka, Velika Britanija, skandinavske zemlje, SAD) proširenost interneta već je tolika da se *online* istraživanja javljaju kao ravnopravni konkurent tzv. klasičnim oblicima istraživanja: telefonskim, poštanskim i istraživanjima licem-u-lice. U većini zemalja, pa tako i u Hrvatskoj, internet ne može potpuno zamijeniti klasične metode prikupljanja podataka, no u nekim slučajevima ipak se može uspješno upotrebljavati. Ovaj rad bavi se najproširenijom vrstom *online* istraživanja – *online* anketama.

O *online* anketnim istraživanjima izdani su već brojni ozbiljni radovi i više zapaženih knjiga (Birnbau, 2000.a; Couper, 2000.; Dillman, 2000.; Batinić i Bosnjak, 2001.; Reips i Bosnjak, 2001.; Batinić, Reips i Bosnjak, 2002.a). No rijetki su radovi u kojima se *online* ankete prikazuju u okviru neke opće teorije anketnoga procesa. Većina radova bavi se samo izdvojenim problemima, kao što su specifičnosti uzoraka koji se zahvaćaju internetom, grafička obilježja *web* upitnika ili neki pokazatelji kvalitete podataka. To otežava objektivno sagledavanje svih prednosti i mana *online* istraživanja te njihovu usporedbu s klasičnim istraživačkim metodama.

U ovom radu analizirat ćemo *online* anketna istraživanja sa stanovišta poznatoga modela ukupne anketne pogreške (Groves, 1989.), koji omogućuje analizu cjelokupnoga anketnog procesa te planiranje postupaka za izbjegavanje pogrešaka koje se mogu javiti u svakoj fazi toga procesa. Sličan pristup analizi *online* anketnih istraživanja rabili su Bosnjak (2002.), Couper (2000.) te Dillman i Bowker (2001.), no naš prikaz pogrešaka u *online* anketama mnogo je širi te uključuje brojne dodatne informacije i rezultate nekih najnovijih istraživanja.

Osnovna obilježja istraživanja putem interneta

Iako su prva *online* istraživanja proveli članovi akademske zajednice (Welch, 1995.; prema Reips, 2001.; Krantz, Ballard i Scher, 1997.), do sada se internet ponajviše rabio za potrebe tržišnih istraživanja. Međutim, iz godine u godinu raste broj izvornih znanstvenih istraživanja putem interneta, posebno na području psihologije, sociologije i srodnih znanosti. Do danas je provedeno ili se još uvijek vodi više stotina eksperimentalnih i anketnih istraživanja s različitih područja psihologije – od proučavanja uzroka stidljivosti do eksperimenata na području osjeta i percepcije (Krantz, 2003.).

Online istraživanja mogu se provoditi različitim internet-skim servisima, primjerice elektroničkom poštom, *webom*, *chat* sustavom, *news* grupama ili *online* forumima. Ciljna populacija koja se nastoji istražiti *online* mogu biti svi korisnici inter-

neta ili razne uže skupine: zaposlenici neke organizacije, članovi nekoga kluba, pretplatnici na neku uslugu, pripadnici neke profesije, posjetioci neke *web* stranice, čak i članovi neke demografske skupine koja je dobro zastupljena na internetu. *Online* istraživanja mogu se razlikovati i s obzirom na način pribavljanja sudionika, vremenski dodir istraživača i sudionika, broj sudionika, stupanj interakcije i znanje o sudjelovanju u istraživanju.

Pribavljanje sudionika. Potencijalni ispitanici mogu se na sudjelovanje pozivati internetom (e-pošta članovima nekih skupina, oglašavanje na *web* stranicama ili u *news* grupama), ali i na druge, "klasične", načine. Tako se potencijalni ispitanici o *online* istraživanju mogu obavijestiti plakatima, telefonom ili u osobnom kontaktu, pa i novinama, radijem i televizijom. Posebno uspješna tehnika pribavljanja ispitanika, koja se sve više rabi i u znanstvenim krugovima, jesu tzv. *online* paneli.

Vremenski dodir. S obzirom na vremenski dodir istraživača i ispitanika, razlikuju se dva osnovna načina komunikacije s ispitanicima: sinkroni i asinkroni. Sinkrona komunikacija – *online* prisutnost istraživača i ispitanika u istom vremenskom trenutku – može se odvijati, primjerice, *chat* servisom ili virtualnim svjetovima. Asinkroni način komunikacije, koji za sada dominira, odnosi se na situaciju u kojoj istraživač postavi anketu ili eksperiment na internet, a ispitanici sudjeluju u istraživanju kad im to najviše odgovara.

Broj sudionika. Većina istraživanja koja se danas provodi na internetu individualnog je karaktera, odnosno ispitanik komunicira samo s istraživačem. Sve se češće, međutim, provode i razni oblici *online* grupnih intervjua, u kojima više ispitanika komunicira međusobno. To mogu biti *online* fokus grupe (sinkrone) ili moderirane e-mail diskusije na zadanu temu (odložene, asinkrone).

Stupanj interakcije. U početnim fazama *online* istraživanja komunikacija između sudionika i istraživača bila je uglavnom jednosmjerna – sudionici su odgovarali na postavljena pitanja bez ikakve povratne informacije istraživača. S napretkom tehnologije *online* istraživanja postaju sve interaktivnija. U ovisnosti o prošlim odgovorima, istraživački se postupak – pitanja, podražaji, dodatne upute i objašnjenja – može mijenjati i prilagođavati svakom sudioniku. Ispituje se i mogućnost uvođenja tzv. virtualnih voditelja intervjua – inteligentnih agenata koji "razgovaraju" sa sudionicima poput ljudskih voditelja (Couper, 2002.).

Znanje o sudjelovanju. Sudionici *online* istraživanja mogu, ali i ne moraju, znati da se njihovo ponašanje opaža i mjeri (Batinic i Bosnjak, 2001.). Tzv. reaktivne tehnike jesu one u

kojima subjekti znaju da sudjeluju u istraživanju, npr. anketna istraživanja, *online* intervjui ili *web* eksperimenti. Kod neaktivnih tehnika subjekti ne znaju da sudjeluju u istraživanju. Takve su tehnike analiza log datoteka (analiza automatskih bilješki koje generira računalo pri svakom pristupu korisnika na *web* stranicu) te opažanje – primjerice, u virtualnim svjetovima ili na *chatu*.

Provedba istraživanja putem interneta ima brojne prednosti, od kojih su najvažnije brzina i ekonomičnost: *online* istraživanja mogu se provesti u osjetno kraćem roku i često uz osjetno niže troškove nego klasični oblici istraživanja. U *online* istraživanjima nema ni geografskih ograničenja, a neke skupine ispitanika mogu se lakše dohvatiti internetom nego klasičnim metodama. Internet omogućuje primjenu gotovo svih klasičnih istraživačkih metoda – anketa, eksperiment, intervju, studija opažanja – a moguć je i razvoj eksperimentalnih modela specifičnih za internet. Prijenos zvuka i/ili slike velikom broju ispitanika brz je i jeftin. Standardizacija istraživačkoga postupka u *online* istraživanjima često je bolja nego u klasičnim studijama (Reips, 2000.), jer svi ispitanici dobivaju potpuno jednaku uputu, nema interakcije s ispitivačem i drugim ispitanicima, a manualan unos podataka nije potreban, što skraćuje vrijeme i uklanja pogreške pri unosu. Neki podaci upućuju na povećanu iskrenost ispitanika u *online* istraživanjima, jer se nalaze u udobnosti svoga doma i imaju povećan dojam anonimnosti, što omogućuje opušteniji i otvoreniji razgovor i o osjetljivijim temama.

No, istraživanja putem interneta imaju i zamjetne nedostatke. Prvo, ograničena je reprezentativnost uzoraka. Populacija korisnika interneta nije i vjerojatno nikada neće biti po svojim svojstvima jednaka ukupnoj populaciji. No mnoga istraživanja i nemaju cilj generalizirati rezultate na cijelu populaciju, nego samo na neke subpopulacije koje se mogu dobro uzorkovati i internetom (na primjer, pripadnici određenih profesija, zaposlenici nekih organizacija, članovi nekih udruženja, posjetioci određenih *web* stranica i sl.). Drugi važan problem *online* istraživanja jest autoselekcija ispitanika. Osobe koje pristaju sudjelovati u *online* istraživanjima gotovo se sigurno razlikuju od onih koje na to ne pristaju. Ovaj je problem, posebno s trendom porasta stopa odbijanja anketa zabilježenim posljednjih desetljeća, prisutan i u klasičnim istraživanjima. Treće ograničenje istraživanja putem interneta jesu sumnje u pravi identitet ispitanika. Internet je medij koji omogućuje lako prikrivanje i/ili lažno prikazivanje vlastita identiteta. Ovaj veliki nedostatak pokušava se otkloniti upotrebom *online* panela, u kojima se identitet članova provjerava i na klasične načine (telefonom, osobno).

ONLINE ANKETNA ISTRAŽIVANJA U SVJETLU MODELA UKUPNE ANKETNE POGREŠKE

Groves (1989.) opisuje četiri osnovne vrste pogrešaka u anketnim istraživanjima: (1) pogreške obuhvata; (2) pogreške uzorka; (3) pogreške zbog neodziva i (4) pogreške mjerenja. Prve tri vrste pogrešaka nastaju zbog neopažanja dijela populacije, dok posljednja skupina pogrešaka nastaje tijekom opažanja, odnosno tijekom interakcije s ispitanikom. Ovaj pristup, naznačen već u radovima Kisha (1965.) te Hansena, Hurwitza i Madowa (1953.), širi je od klasičnoga psihometrijskog modela, koji se u osnovi bavi samo pogreškama mjerenja, a malo govori o procesima koji utječu na izbor i odziv sudionika ankete. Model ukupne anketne pogreške širi je i od statističkih tretmana anketnoga procesa, koji se bave samo izborom ispitanika, a ne i problemima koji proizlaze iz interakcije s njima. U nastavku ćemo prikazati moguće izvore četiriju vrsta pogrešaka u *online* anketama te mogućnosti njihova uklanjanja ili kontrole.

Pogreške obuhvata

Pogreška obuhvata nastaje zbog nepotpunoga podudaranja ciljne populacije – odnosno skupine koju se istraživanjem želi opisati – i okvira uzorka, odnosno skupine iz koje će se birati uzorak. Neki članovi ciljne populacije ponekad nisu uključeni u okvir uzorka, a neki su uključeni više puta. Na primjer, u okviru uzorka telefonskih anketa, kojima je cilj opisati neku pojavu u cijeloj populaciji Hrvatske, nisu zastupljena domaćinstva koja nemaju telefon, dok su domaćinstva koja imaju više telefonskih brojeva zastupljena višekratno. Rezultati ankete bit će više ili manje pristrani, ovisno o tome koliki je u okviru uzorka udio nezastupljenih ili višestruko zastupljenih članova ciljne populacije te koliko se oni razlikuju od ostalih.

Rezultati *online* anketnih istraživanja teško se mogu općiti na ukupnu populaciju upravo zbog nedovoljne proširenosti interneta i osjetnih razlika između korisnika i nekorisnika. Zato se *online* ankete u većini zemalja ne mogu upotrebljavati u istraživanjima koja zahtijevaju reprezentativne, probabilistički izabrane uzorke ukupnoga stanovništva. Međutim, o nekim je ciljnim populacijama sasvim opravdano zaključivati na osnovi rezultata *online* istraživanja. Isto vrijedi za istraživanja nekih pojava koje nisu povezane s upotrebom interneta. Za bolju prognozu pravoga rezultata u ciljnoj populaciji mogu se primijeniti razne tehnike ponderiranja.

Proširenost interneta. Jedan od najčešćih prigovora *online* istraživanjima proizlazi iz činjenice da velik broj ljudi nema pristup internetu. Iako više od pola milijarde svjetskoga stanovništva ima pristup internetu, to je još uvijek samo osam

postu ukupne svjetske populacije (U. S. Bureau of the Census, 2002.). Više od 90% korisnika interneta nalazi se u Europi, Sjevernoj Americi i na Dalekom istoku, dok ih je u Africi i na Bliskom i Srednjem istoku samo po jedan posto (Nua, 2003.). Dok se u SAD-u i u skandinavskim zemljama više od dvije trećine stanovništva služi internetom, u zemljama Istočne Europe taj je udio znatno manji. U BiH i Albaniji udio korisnika interneta iznosi otprilike samo 1% (GFK, 2003.). U Hrvatskoj trenutačno oko 20% stanovnika starijih od 14 godina upotrebljava internet (Puls, 2003.), po čemu smo slični Mađarskoj, Slovačkoj i Poljskoj. Od ostalih zemalja tzv. Srednje i Istočne Europe, po upotrebi interneta najrazvijenije su Slovenija (40%) i Estonija (39% stanovništva).

Razlike između korisnika i nekorisnika. Malen relativni udio korisnika interneta u populaciji ne bi bio problem za provedbu *online* istraživanja kada se ti korisnici ne bi značajno razlikovali od opće populacije. No korisnici interneta općenito su mlađi ljudi, boljih prihoda i bolje obrazovani od ostaloga stanovništva. Te se razlike sve više smanjuju (Pastore, 2001.), no čak i u zemljama u kojima je proširenost interneta velika, neke demografske skupine još su osjetno zapostavljene – npr. starije žene (Comley, 2002.). Opravdano je također pretpostaviti – iako su o tome istraživanja još vrlo rijetka – da se korisnici interneta razlikuju od ostatka populacije i po drugim karakteristikama, npr. stavovima, vrijednostima, životnim ciljevima, kupovnim navikama i sl. Ciljna populacija anketnih istraživanja putem interneta zato rijetko može biti ukupno stanovništvo neke zemlje.

Postoji, međutim, čitav niz uže definiranih populacija na kojima je opravdano ili čak poželjno provoditi upravo *online* istraživanja. To su, na primjer, korisnici određenih skupina proizvoda ili usluga (računala, internet bankarstvo), zaposlenici neke organizacije, pripadnici pojedinih profesija (menadžeri, liječnici, znanstvenici), određene demografske skupine (mladi visokoobrazovani ljudi) itd. Neke se ciljne populacije samo internetom mogu doseći uz razuman trošak i vrijeme – na primjer, osobe nekih posebnih, relativno rijetkih karakteristika ili interesa ili osobe iz raznih zemalja. Internet tako omogućuje provedbu interkulturalnih i drugih istraživanja koja ranije zbog visokih troškova za većinu istraživača nisu bila izvediva.

U nekim slučajevima *online* anketna istraživanja mogu se upotrijebiti i kada je ciljna populacija ukupno stanovništvo. To je moguće kada ispitivane pojave nisu u korelaciji s upotrebom interneta. Brojna temeljna znanstvena istraživanja u psihologiji bave se upravo takvim pojavama i do sada su se uglavnom provodila na vrlo ograničenim uzorcima studenata (ili, još češće, studentica) psihologije. *Online* istraživanjima

mogu se postići mnogo raznolikiji i veći uzorci, koji pružaju veću mogućnost poopćavanja rezultata, odnosno povećavaju vanjsku valjanost istraživanja.

U zaključivanju o široj populaciji na temelju *online* uzoraka često se primjenjuju metode ponderiranja (otežavanja, *weighting*) rezultata. Upotrebom pondera razvijenih na temelju usporednih "klasičnih" istraživanja pokušavaju se "izgladiti" razlike između onih koji imaju i onih koji nemaju pristup internetu. Metode ponderiranja uobičajene su u društvenim istraživanjima. Okvir uzorka rijetko je izjednačen s ciljnom populacijom, što uz nejednak odziv pojedinih skupina dovodi do podzastupljenosti nekih segmenata ciljne populacije. Da bi se struktura uzorka što bolje približila strukturi ciljne populacije, primjenjuje se ponderiranje: odgovori onih skupina ispitanika čiji je udio u uzorku podcijenjen u odnosu na opću populaciju "otežavaju" se tako da u ukupnom rezultatu imaju veće značenje od onoga koje bi imali na osnovi njihova udjela u uzorku.

Brojni su načini izračuna pondera. Jedna od, čini se, uspješnih metoda ponderiranja jest tzv. *propensity weighting*, koja se temelji na radovima Cochran i Coxa (prema Campbell i Stanley, 1963.). Osnovu ove metode čine tzv. *propensity scores*, odnosno procjene vjerojatnosti da neki sudionik, prema nizu karakteristika, pripada *online* ili klasičnom uzorku. Ovakvim načinom ponderiranja tvrtka Harris Interactive uspjela je dati vrlo precizne procjene rezultata na američkim izborima za Senat 1998. i predsjedničkim izborima 2000. Njihove su se prognoze, utemeljene na ponderiranim rezultatima ankete na *online* panelu, pokazale točnijima čak i od rezultata dobivenih klasičnim istraživačkim metodama – telefonskim i osobnim intervjuima na slučajnom uzorku opće populacije (Berrens i sur., 2003.).

Prilikom upotrebe statističkog otežavanja rezultata treba neprestano kontrolirati razinu pogreške koja se unosi u konačan rezultat. Naime, "pojačavajući" značenje odgovora pojedinih skupina ispitanika, istodobno se povećava i pogreška mjerenja koja se veže uz odgovore tih skupina. Što se barata većim ponderima, odnosno što su veće razlike između *online* i klasičnih uzoraka, to je i kumulacija količine pogreške veća. Otežavanje, osim toga, ne može kompenzirati nepostojanje ispitanika određenih karakteristika u uzorku. Ako u uzorku ne postoji niti jedna osoba starija od 80 godina, nikakvim ponderiranjem ne možemo "nadmjestiti" njezine odgovore (Taylor i Terhanian, 1999.).

Pogreške uzorka

Pogreške uzorka nastaju zato što se rezultati anketnih istraživanja obično temelje samo na dijelu ciljne populacije. Kako se članovi ciljne populacije gotovo uvijek međusobno raz-

likuju s obzirom na izraženost ispitivane pojave, rezultati dobiveni na jednom uzorku ne moraju se podudarati s rezultatima dobivenim na drugim uzorcima iz iste populacije. Načini uzorkovanja i pogreške koje iz njih proizlaze dobro su opisane u literaturi o anketnim istraživanjima i statističkim priručnicima. U mnogim anketama koje se susreću na internetu uzorak je prigodan – anketu može ispuniti svatko tko "naide". Takve ankete uglavnom služe za zabavu i privlačenje posjetioca na *web* stranice na kojima se nalaze. Ozbiljnije ankete nastoje iskoristiti probabilističke ili barem kvotne uzorke. Sve se češće rabe i tzv. *online* paneli.

Probabilističko uzorkovanje populacije korisnika interneta nije moguće. Nema potpuna popisa svih korisnika interneta, a čak i kada bi postojao, zbog stalnoga širenja interneta ubrzo bi zastario. Sličan problem javlja se i u klasičnim istraživanjima. Nema potpuna popisa korisnika telefona, a često ni popisa stanovnika neke zemlje ili on barem nije dostupan u istraživačke svrhe. Ipak, popisi koji se rabe kao okvir uzorka u telefonskim i osobnim istraživanjima potpuniji su i trajniji od eventualnih popisa korisnika interneta. Dodatan su problem vrlo stroga pravila privatnosti na internetu – tzv. *netiquette* – koja brane slanje elektroničke pošte osobama koje za to nisu dale izričit pristanak. U suprotnom može doći do ogorčenih odbijanja sudjelovanja u anketi i brojnih protesta s osobama s kojima se na taj način kontaktiralo (Kaye i Johnson, 1999.). Organizacije koje šalju takvu nepozvanu elektroničku poštu brzo dolaze na "crne liste" i brojni korisnici interneta automatski blokiraju primanje pošte koju takve organizacije šalju. Situacija je za istraživače mnogo povoljnija kod klasičnih načina kontakta s ispitanicima, jer se primanje nepozvanih telefonskih poziva, posjeta ili obične pošte više tolerira ili se barem teže sprečava.

Za mnoge ciljne populacije u *online* anketnim istraživanjima ipak se može upotrijebiti i probabilističko uzorkovanje. Ako su ciljna populacija svi zaposlenici neke organizacije, svi pretplatnici na neki časopis ili članovi nekoga kluba, njihovi su popisi obično dostupni i mogu se uzeti kao okvir uzorka. Važna prednost *online* istraživanja jest mogućnost relativno jeftinoga i brzoga prikupljanja velikih uzoraka. To u određenoj mjeri smanjuje pogrešku uzorka i omogućuje preciznije procjene obilježja populacije.

Većina ozbiljnih *online* istraživanja danas kao okvir uzorka rabi *online* panele. To su baze podataka s kontaktnim demografskim i drugim podacima korisnika interneta koji su unaprijed izjavili da žele sudjelovati u istraživanjima. Članovi panela elektroničkom ili običnom poštom dobivaju obavijesti o istraživanjima u kojima mogu sudjelovati. Istraživanja na *online* panelima imaju brojne prednosti pred uobičajenim an-

ketama, kojima korisnici slobodno pristupaju na *webu*. Paneli omogućuju precizno određivanje identiteta ispitanika, određivanje uzorka u skladu s ciljevima istraživanja, kontrolu jednokratnog ispunjavanja upitnika te precizniju projekciju rezultata s uzorka na ciljnu populaciju.

Članovi panela pribavljaju se na razne načine, o čemu ovisi i kvaliteta studija koje se na njima provode. Paneli se mogu "puniti" oglašavanjem na internetu ili klasičnim oglašavanjem, čime se dobivaju prigodni uzorci korisnika interneta. Bolji je način pribavljanje članova u sklopu osobnih ili telefonskih anketnih istraživanja na nacionalno reprezentativnim uzorcima (Couper, 2000.). Takvi paneli imaju obilježja probabilističkih uzoraka, jer se u svakoj fazi formiranja panela (telefonska ili osobna anketa, inicijalni poziv na sudjelovanje u panelu, stvarno sudjelovanje u istraživanjima na panelu) može izmjeriti ukupan anketni odziv te analizirati razlike između onih ispitanika koji se jesu i onih koji se nisu odazvali pozivu na članstvo u panelu. Neovisno o načinu pribavljanja, članovi panela obično se dodatno motiviraju intrinzičnim (mogućnost utjecanja na svijet oko sebe, mogućnost uvida u rezultate) i ekstrinzičnim poticajima (manjim nagradama za svaku ispunjenu anketu, sudjelovanjem u nagradnim igrama i sl.). Paneli ispitanika već se dugo rabe u klasičnim istraživanjima, pa su njihove prednosti i mane dobro istražene. Poznat je, na primjer, efekt "pristranosti panela" (Göritz, Reinhold i Batinic, 2002.), odnosno promjena stavova i ponašanja njegovih članova zbog svijesti o sudjelovanju u panelu i uzastopnom ispitivanju. Zbog toga se tehnika panela mora rabiti oprezno, a panel treba redovito obnavljati te najstarije članove zamjenjivati novima. Pri ispitivanju nekih osjetljivih društvenih pojava dijelovi panela se rotiraju, odnosno u određenom razdoblju anketira se samo dio članova panela, dok se ostali preskaču (kao, na primjer, u Current Population Survey, koju svaki mjesec provodi američki Department of Labour Statistics i Bureau of Census).

Kako je mogućnost pravoga probabilističkog uzorkovanja ograničena, a izgradnja kvalitetnih panela dugotrajna i skupa, u mnogim *online* anketnim istraživanjima rabi se kvotni uzorak. Nastoji se prikupiti unaprijed zadani broj osoba određenih karakteristika (spola, dobi, učestalosti upotrebe interneta i sl.), a kada se neka kvota popuni, daljnji se ispitanici takvih karakteristika odbijaju. Kvotni se uzorci vrlo često rabe i u klasičnim istraživanjima, pri čemu se osobama odgovarajućih karakteristika često pristupa na ulici i poziva na sudjelovanje u istraživanju. Pri tome se pretpostavlja da se osobe koje su uključene u istraživanje ne razlikuju od onih koje nisu uključene, s obzirom na ispitivanu pojavu ili s njom povezana svojstva. Na internetu je, međutim, takvu pretpo-

stavku teže obraniti zbog tri razloga. Prvo, osobe koje pristaju sudjelovati u *online* anketama često se razlikuju od ostalih po osobinama koje su povezane s pojavama što se obično istražuju na internetu. One mogu biti učestaliji korisnici interneta, tehnički obrazovanije, sklone ispunjavanju *online* anketa itd. Drugo, kod *online* anketa, koje su često odmah na početku djelomično ili potpuno vidljive ispitaniku, znatno je lakše unaprijed procijeniti što se anketom ispituje. To čini utjecaj autoselekcije zbog interesa za temu istraživanja vjerojatnijim nego kod osobnih ili telefonskih istraživanja. Treće, na internetu je teško provjeriti pravi identitet ispitanika. Ispitanici mogu lako dati krive podatke o svom spolu, dobi itd., pa je teško sa sigurnošću znati koliko se zaista poštovala zadana kvota.

Procjenjuje se da je takvo namjerno prikrivanje osobnih podataka rijetko (Reips, 2000.), no problem ostaje vrlo važan jer utječe na vjerodostojnost *online* istraživanja općenito. Razvijene su brojne metode za provjeru pravoga identiteta sudionika *online* anketa. Najčešći je način upotreba lozinke koju ispitanik mora unijeti u odgovarajući *online* obrazac da bi pristupio anketi. Lozinka se može i ugraditi u link kojim ispitanik dolazi na anketu, tako da je ne mora sam upisivati. Da bi dobio lozinku ili osobni link, mora se registrirati i ostaviti barem neki provjerljivi osobni podatak, obično barem ime i prezime te e-mail adresu. Jedna se lozinka može upotrijebiti za samo jedno ispunjavanje upitnika.

Pogreške zbog neodziva

Anketni neodziv odnosi se na izostanak dijela ili svih odgovora nekih članova planiranog uzorka. Ovisno o broju izostavljenih odgovora te o razlikama između osoba koje jesu i onih koje nisu odgovorile na pitanja, anketni neodziv utječe više ili manje na rezultate ankete. Obično se govori o dvije vrste anketnoga neodziva: jedinični ili "unit" neodziv označuje nepostojanje svih ili najvažnijih podataka za jednog ispitanika, dok se čestični ili "item" neodziv odnosi na nepostojanje odgovora na pojedina pitanja u anketi (Groves, 1989.).

U *online* anketama neodziv može nastati u raznim fazama prikupljanja podataka (Vehovar i sur., 2002.). Tako kod *online* anketa na koje se poziv članovima uzorka upućuje e-poštom jedan dio pozvanih osoba nikada ne primi poruku zbog pogrešno upisane adrese, zastarjele adrese, automatskih filtara ili drugih razloga. Neki od onih koji ipak prime poruke iz raznih je razloga nikada ne pročitaju. Od onih članova uzorka koji su dobili i pročitali poruku samo neki kliknu na link u poruci i dođe do početka upitnika. Neki od njih odmah odustanu, a dio počne ispunjavati upitnik. Od toga neki odu-

stanu prije kraja upitnika. Konačan broj onih koji potpuno ispune upitnik obično je, u odnosu na planirani uzorak, relativno malen (primjerice samo 35% od planiranog uzorka u Vehovar, Batagelj, Lozar Manfreda, 2000.).

Bosnjak (2001.; također Bosnjak i Tuten, 2001.) detaljnije opisuje anketni neodziv koji nastaje nakon što član uzorka jednom pristupi upitniku, odnosno čestični neodziv. Bosnjak razlikuje šest tipova neodziva u *online* anketama: jedinični neodziv (svi članovi planiranog uzorka koji nisu započeli ispunjavati upitnik), neodziv ispitanika koji su odustali tijekom odgovaranja, a prije odustajanja odgovorili su na sva pitanja, neodziv ispitanika koji su odustali tijekom odgovaranja, a prije odustajanja izostavili su odgovore na neka pitanja, čestični neodziv (ispitanici koji su prošli cijeli upitnik, ali nisu odgovorili na sva pitanja), neodziv ispitanika koji su prošli dio upitnika i odustali bez odgovaranja na pitanja te neodziv ispitanika koji su prošli cijeli upitnik, ali nisu odgovorili ni na jedno pitanje (tzv. njuškala ili engl. *lurkers*).

Pri analizi faktora koji utječu na neodziv u *online* anketa- ma dobro je razlikovati neodziv koji nastaje pri pokušaju uspostavljanja kontakta od neodziva koji nastaje nakon uspostavljanja kontakta s potencijalnim ispitanikom. Neuspjeh u ostvarivanju kontakta izravno pridonosi jediničnom neodzivu, dok faktori koji utječu na suradnju ispitanika nakon kontakta djeluju i na jedinični i na čestični neodziv. U nastavku ćemo se najprije ukratko osvrnuti na faktore koji djeluju na neodziv prije, a zatim opširnije na one koji utječu na neodziv nakon uspostavljenoga kontakta s potencijalnim ispitanikom.

Problem uspostavljanja kontakta s potencijalnim ispitanicima u *online* anketama, u odnosu na klasične metode prikupljanja podataka, posebno je izražen. U osobnim, pa i u telefonskim, anketama prostor i vrijeme prvoga kontakta uglavnom se mogu unaprijed predvidjeti. U poštanskim anketama uglavnom se može odrediti prostor prvoga kontakta (obično domaćinstvo ili ured ispitanika). No u *online* anketama istraživač ima vrlo malo kontrole i nad prostorom i nad vremenom uspostavljanja prvoga kontakta. Zbog toga se mnogi postupci koji se redovito upotrebljavaju u klasičnim istraživanjima radi povećanja uspješnosti prvoga kontakta (dolazak u prikladnije vrijeme, biranje prikladnog mjesta i uvjeta za intervju, prilagodba poziva okolinskim uvjetima i osobinama ispitanika u osobnim anketama) u *online* anketama ne mogu upotrijebiti.

U većini *online* anketa sudionici se još prikupljaju na relativno pasivan način. Upitnik se postavi na *web* i čeka se da ispitanici sami dođu. Takav način pribavljanja obično dovodi

do uzorka pristranog u smjeru osoba koje su uobičajeni posjetioци *web* stranice na kojoj se upitnik nalazi i/ili koji su posebno zainteresirani za sadržaj ankete. Zbog bogatstva sadržaja na internetu, mnogi potencijalni sudionici nikada i ne zamijete takvu anketu u kojoj bi inače sudjelovali. Moguć je i "efekt snježne grude", koji nastaje kada pojedini ispitanici preporučuju anketu svojim prijateljima, što može dovesti do smanjenoga varijabiliteta i pristranosti rezultata. Zato se u ozbiljnijim studijama rabi čitav niz aktivnijih načina pozivanja ispitanika, kojima se pokušava bolje kontrolirati identitet ispitanika i način uspostavljanja prvoga kontakta.

Tako se osim/umjesto *webom*, potencijalne sudionike može pozivati plakatom, tiskom i drugim medijima te izravno elektroničkom i običnom poštom, u osobnom ili telefonskom kontaktu. Što je način pribavljanja ispitanika aktivniji te što se rabi više medija, to bi uspješnost kontaktiranja članova planiranog uzorka trebala biti veća – odnosno jedinični neodziv manji. Aktivnijim načinima pribavljanja postiže se i veća kontrola nad sastavom uzorka, jer se smanjuje mogućnost autoselekcije, prikrivanja pravog identiteta i višestrukog ispunjavanja upitnika.

Nakon uspostavljanja kontakta s potencijalnim ispitanicima niz faktora utječe na udio onih koji će započeti i potpuno ispuniti upitnik. Dio kontaktiranih članova planiranog uzorka uvijek odbija sudjelovati u anketi. Na spremnost za sudjelovanje može se utjecati odgovarajućim motiviranjem ispitanika, i to ekstrinzičnim poticajima kao što je materijalna naknada za ispunjeni upitnik ili mogućnost sudjelovanja u nagradnoj igri, i/ili intrinzičnim poticajima, kao što su mogućnost uvida u vlastite rezultate i naglašavanje korisnosti ispitanikovih odgovora za zajednicu (Bosnjak i Batinic, 2002.). Pri odabiru i upotrebi takvih poticaja treba, međutim, voditi računa o mogućnosti selektivnog odziva ispitanika koji su posebno zainteresirani za određenu vrstu nagrade. Već i samo naglašavanje određene teme ankete može dovesti do značajnih razlika u strukturi dobivenog uzorka te do pristranosti rezultata (npr. Groves, Singer i Corning, 2000.; Groves, Presser i Dipko, 2004.). Čini se nadalje da neke dokazano uspješne metode motiviranja potencijalnih sudionika u klasičnim anketama ne vrijede i za *online* ankete. Tako su Bosnjak i Tuten (2002.) ispitivali utjecaj različitih oblika ekstrinzičnoga motiviranja potencijalnih sudionika *online* ankete: novčanim nagradama danim unaprijed, novčanim nagradama obećanim nakon ispunjavanja ankete te nagradnom igrom. Iako su se kod klasičnih poštanskih anketa novčane nagrade dane unaprijed pokazale daleko najboljim načinom motivacije potencijalnih sudionika, u situaciji *online* ankete nagradna igra pokazala se znatno uspješnijom metodom.

Čak i kod vrlo uspješnoga inicijalnog odziva, tijekom ispunjavanja upitnika jedan dio ispitanika odustane od odgovaranja na neka pitanja ili od sudjelovanja uopće. U *online* istraživanjima odustajanje je posebno velik problem iz više razloga. *Online* ankete za većinu ispitanika prate izravni materijalni troškovi (telefonski impulsi). Manje su prikladne za primjenu poticaja koji su se pokazali naročito uspješnim u klasičnim anketama, poput ponovljenoga kontakta ili novčane nagrade dane unaprijed. Između istraživača i ispitanika nema neposrednoga osobnog kontakta, što smanjuje socijalni pritisak na ispitanika da dovrši anketu. Na internetu se, osim toga, nalaze brojni drugi sadržaji koji su potencijalno zanimljiviji od ispunjavanja ankete. Na odluku ispitanika da (ne) odustane od ispunjavanja upitnika zajednički utječu obilježja ankete i obilježja ispitanika.

Od obilježja *online* anketa – kao i kod klasičnih anketnih istraživanja – na stopu odustajanja značajno djeluje sadržaj upitnika (zanimljivost i relevantnost teme, socijalna osjetljivost pitanja), formalna obilježja upitnika (izgled, način unošenja odgovora, broj pitanja na jednoj stranici) te prisutnost dodatnih poticaja za sudjelovanje u anketi. U *online* anketama na stopu odustajanja još više nego u klasičnim anketama djeluje dužina upitnika. Upitnik ne smije biti predug i dobro je da na jednoj stranici upitnika ima onoliko pitanja koliko stane na ekran. Optimalan broj pitanja ovisi o nizu faktora – zanimljivosti i relevantnosti teme, načinu pribavljanja i dodatnom motiviranju ispitanika te drugim obilježjima ispitanika i konteksta ankete – no obično se smatra da vrijeme ispunjavanja ne bi smjelo prijeći 10-15 minuta. Upotreba grafičkoga ili brojčanoga indikatora napredovanja kroz anketu česta je u *online* anketama i obično se smatra elementom koji motivira ispitanika da ne odustane. No neka istraživanja pokazuju da indikatori koji pokazuju prespor napredak mogu izazvati obrnut učinak (Couper, Traugott i Lamias, 2000.; prema Conrad 2002.).

Od obilježja ispitanika u *online* anketama na odustajanje posebno utječu iskustvo, stavovi i motivi povezani s upotrebom računala i interneta. Ispitanici koji se slabije snalaze u računalom podržanoj komunikaciji morat će uložiti veći napor da bi ispunili *online* upitnik, što povećava vjerojatnost njihova odustajanja u toku ankete. Ispitanici koji imaju negativan stav prema računalima, pa i strah od upotrebe računala, doživjeti će sudjelovanje u *online* anketi težim od onih koji su naklonjeniji računalima i internetu. Konačno, motivi upotrebe interneta mogu osjetno utjecati na odustajanje od ankete – ispitanici kojima internet služi za zabavu i/ili učenje vjerojatno će biti motiviraniji za ispunjavanje *online* anketa od onih koji internet rabe, primjerice, isključivo u poslovne svrhe.

Pogreške mjerenja

Dok prethodno opisane pogreške nastaju prije nego što je mjerenje uopće započelo, pogreške mjerenja nastaju u procesu prikupljanja podataka od ispitanika. Taj se proces može podijeliti na četiri faze: razumijevanje pitanja, znanje relevantnih informacija, upotreba tih informacija za donošenje potrebnih prosudbi te odabir, uređivanje i davanje odgovora (Tourangeau, Rips i Rasinski, 2000.). U svakoj od faza pogreške mjerenja u klasičnim anketnim istraživanjima mogu proizaći iz četiri osnovna izvora: obilježja ispitanika, anketara, upitnika – mjernog instrumenta te načina – medija prikupljanja podataka (Groves, 1989.). U uočavanju i razumijevanju pogrešaka mjerenja važnu ulogu imaju spoznaje iz kognitivne i socijalne psihologije. Kognitivni i komunikacijski procesi koji se odvijaju u svakoj fazi utječu na pouzdanost i valjanost istraživanja. U literaturi su detaljno opisani brojni izvori pogrešaka mjerenja u klasičnim anketnim istraživanjima, pa ih ovdje nećemo posebno navoditi (npr. Groves, 1989.; Tourangeau, Rips, i Rasinski, 2000.). U *online* anketnim istraživanjima postoje neki specifični izvori pogrešaka mjerenja: obilježja računala i veze s internetom, okolinski uvjeti, formalna obilježja *online* anketnog upitnika te posebnosti računalom podržane komunikacije.

Obilježja računala i veze s internetom. Računala se već dugo rabe kao podrška provedbi društvenih istraživanja. Primjeri su računalom podržano telefonsko (CATI) i osobno anketiranje (CAPI) te brojni eksperimenti u psihologiji koji se provode računalom. Računalom podržana istraživanja imaju niz prednosti, među kojima su jednostavnost primjene, standardizirana prezentacija podražaja, automatsko grananje upitnika u ovisnosti od prethodnih ispitanikovih odgovora i eliminacija pogrešaka unosa podataka. *Online* istraživanja, uza sve opisane prednosti, imaju i velik nedostatak: računalna oprema svakog sudionika istraživanja različita je. Tehnički varijabilitet opreme – posebno obilježja monitora, druga obilježja računala te karakteristike internetske veze – može osjetno povećati pogrešku mjerenja.

Računalni monitori koje upotrebljavaju sudionici *online* anketa mogu se zamjetno razlikovati po nizu tehničkih obilježja (veličina, rezolucija, broj boja, osvjetljenje). Neka obilježja prikaza (osvjetljenje, kontrast) može se znatno razlikovati i kod monitora istoga proizvođača, čak i kod jednog te istog monitora u različitim vremenskim točkama (Krantz, 2001.). Slika na monitoru k tome ovisi o vanjskim uvjetima – jačini osvjetljenja prostorije, direktnom svjetlu itd. Sve to ograničuje raspon podražaja koji se mogu prenijeti *webom* na jednostavne grafičke elemente u nekoliko osnovnih boja i s omje-

rom kontrasta figure i pozadine od barem 3:1. Podražaji koji se rabe u pojedinim anketama mogu nadalje zahtijevati neka druga obilježja računala – posebno dobru grafičku karticu, zvučnu karticu, visoku procesorsku brzinu – koje dio ispitanika nema. Karakteristike internetske veze između računala ispitanika i istraživača osjetno utječu na raspon podražaja koji se mogu uključiti u *online* ankete. Kompleksni grafički prikazi, ukrasni dizajnerski elementi i sl. mogu zahtijevati predugo vrijeme prijenosa, što mnogim ispitanicima može otežati sudjelovanje u anketi.

Okolinski uvjeti. U *online* anketama ima niz okolinskih faktora koji mogu utjecati na rezultate, a na koje istraživač, zbog prostorne udaljenosti i uglavnom asinkrone komunikacije s ispitanikom, ima vrlo malen ili nikakav utjecaj (Buchanan, 2000.; Reips, 2000.; Entin i sur., 2001.). Okolnosti u kojima ispitanik sudjeluje u istraživanju mogu biti vrlo različite – primjerice, razina osvjetljenja prostorije, buka, prisutnost drugih osoba. Na rezultate mogu utjecati i razna privremena psihofiziološka stanja ispitanika, poput umora, stresa ili utjecaja droga. No opravdano je pretpostaviti da svi ti faktori nemaju sistematski utjecaj na rezultate, nego da se njihovi utjecaji na većem uzorku poništavaju. Različitost situacija u kojima se provodi mjerenje može zapravo povećati eksternu valjanost rezultata (Reips, 2000.).

Formalna obilježja online upitnika. U *online* anketama mogu se rabiti razni obrasci za unos odgovora koji su samo djelomično slični onima u klasičnim "papirnatim" anketama. To mogu biti razni gumbi za označavanje, grafičke skale procjene, liste s padajućim izbornicima, veći ili manji prostori za unošenje verbalnih odgovora itd. Neki od tih obrazaca pokazali su se lošijima od drugih, jer od ispitanika traže ulaganje više napora pri označavanju odgovora. Tako kod lista s padajućim izbornikom ispitanik treba najprije kliknuti na gumb pored izbornika da bi otvorio izbornik, a zatim još jednom kliknuti da bi označio odabrani odgovor. Kad god lista mogućih odgovora nije predugačka, gumbi za označavanje bolji su izbor jer zahtijevaju samo jedan klik za odabir odgovora (Dillman i Bowker, 2001.). Tzv. matriks pitanja – odnosno više pitanja s istim ponuđenim odgovorima postavljenih u istoj tabličnoj formi – također traže od ispitanika više napora nego jednostavna pitanja. Ispitanik mora pročitati tekst pitanja na lijevoj strani i upamtiti ga dok na desnoj strani traži odgovarajući odgovor, pri čemu se često mora vraćati i na tekst kategorija odgovora koji se nalazi na vrhu tablice. Zatim mora mišem odabrati točan odgovor. Sve to zahtijeva ulaganje povećana napora, pa mnogi ispitanici odustaju ili odgovaraju istim odgovorima na sva pitanja u takvoj matriks formi (Gräf, 2002.).

Programska osnova *online* upitnika može utjecati na rezultate. Iako svi *web* preglednici mogu prepoznati jednostavan html zapis, ovisno o načinu na koji su im namještene razne opcije, dodatnim instaliranim programima te o karakteristikama računala i monitora, može doći do problema s ispravnim prikazom nekih oblika upitnika ili čak s pristupom upitniku. Tipičan primjer su java skripta, koja omogućuju napredne mogućnosti interakcije s ispitanikom, ali kod brojnih korisnika interneta nisu podržana. No već i kod jednostavnih html upitnika može doći do zamjetnih distorzija. Dillman i Bowker (2001.), primjerice, opisuju nesistematsku promjenu udaljenosti među uporištima skala procjene zbog zajedničkog utjecaja različite rezolucije zaslona, prikaza u malom umjesto velikom prozoru te upotrebe starije verzije *web* preglednika. Srećom, većina ovih problema lako se otklanja primjenom odgovarajućih programskih rješenja.

U *web* anketama lako je dodati razne grafičke elemente. Oni mogu biti sastavni dio pitanja, odnosno podražaja (primjerice, neki oglas, logo, slika osobe i sl.); mogu služiti kao dodatak tekstu pitanja (kao dodatna uputa – npr. slika onoga o čemu se u pitanju govori), mogu imati motivacijsku ulogu (pobuđivanje interesa, estetski dojam) ili mogu biti potpuno irelevantni za anketu (npr. *banneri* pri vrhu stranice) (Couper, 2002.). Uz ispunjavanje osnovne namjene, upotrijebljene slike, boje, oblici slova, dijagrami i sl. mogu ispitanicima slati i neplanirane poruke, promijeniti mjerna svojstva pitanja i tako utjecati na rezultate na neplanirane načine. Poznati su, na primjer, eksperimenti utjecaja vizualne fluentnosti na procjenu istinitosti tvrdnji (Reber i Schwarz, 1999.; prema Couper, 2002.). Lakše čitljive tvrdnje (napisane tamnoplavom ili crvenom) češće se procjenjuju istinitima od teže čitljivih tvrdnji (napisanih zelenim, žutim ili svijetlo plavim fontom).

Online ankete omogućuju upotrebu interaktivnih tehničkih rješenja kojima se neke pogreške mjerenja, koje se u klasičnim anketama teško otkrivaju, mogu kontrolirati ili spriječiti. Može se precizno kontrolirati redoslijed prezentacije pitanja te selektivno postavljati pitanja u ovisnosti o prethodnim odgovorima ispitanika. Konzistentnost ispitanikovih odgovora može se automatski provjeravati i, ako je potrebno, upozoriti ispitanika na pogrešku. Posebnim softverskim rješenjima može se pratiti ponašanje ispitanika pri odgovaranju, npr. izmjena odgovora, redoslijed odgovaranja na pitanja na istoj stranici upitnika te vrijeme provedeno odgovarajući na pojedino pitanje (Heerwegh, 2002.). Ovi metapodaci omogućuju dodatne analize i objašnjenja anketnih rezultata, što u klasičnim istraživanjima nije moguće.

Obilježja računalom podržane komunikacije. Komunikacija se u *online* anketama uvijek odvija računalom. Pitanja i ostali

podražaji zadaju se ispitanicima na računalnom zaslonu, a ispitanik mora svoj odgovor upisati tipkovnicom ili označavanjem odgovora mišem ili sličnim upravljalom (Fuchs, 2002.). Taj način komuniciranja zamjetno se razlikuje od onoga uobičajenog u svakodnevnom životu, pa i u klasičnim anketama. Neka istraživanja pokazuju da su računalom podržana istraživanja ispitanicima većinom zanimljivija (Entin i sur., 2001.) te da prema njima imaju pozitivniji stav nego prema klasičnim oblicima testiranja, jer smatraju da je računalno testiranje znanstvenije, točnije i sigurnije (Couper i Burt, 1994.). No anketiranje putem interneta ima i niz specifičnosti koje mogu – pozitivno ili negativno – djelovati na pogreške u mjerenju.

U odnosu na klasične ankete, u *online* anketama ispitanik osjeća veći vremenski pritisak, odnosno pritisak da što prije dovrši anketu. Ljudi većinom ne idu na *online* da bi ispunili anketu, nego da bi obavili nešto drugo (npr. poslali e-poštu, pogledali vijesti), u čemu ih ispunjavanje ankete zapravo ometa. Dužina upotrebe interneta k tome je za većinu korisnika linearno povezana s troškovima, kao i s eventualnim problemima zbog zauzimanja telefonske linije koja je često jedina u kućanstvu (trebaju je drugi ukućani, netko može nazvati i sl.). Sve to može navesti sudionika *online* ankete da upitnik ispunjava što brže, a samim tim i relativno manje kvalitetno nego u klasičnoj anketi.

Razumijevanje pitanja može u *online* istraživanjima biti otežano jer nije prisutan ispitivač koji bi mogao objasniti pitanje, nema uobičajenih neverbalnih znakova, a komunikacija između ispitanika i istraživača uglavnom je asinkrona. Zato je u *online* anketama dobro rabiti nešto opsežnije upute i tekst pitanja (Entin i sur., 2001.). Opsežnije upute mogu biti dostupne uvijek ili samo na zahtjev ispitanika (klikom na link za dodatna pojašnjenja). Dodatne upute mogu se pojaviti i automatski, primjerice odmah nakon isteka prosječnoga vremena odgovaranja na pitanje (Conrad, 2002.). Istraživanja o pravilnoj upotrebi dodatnih uputa još traju.

Mnoga istraživanja pokazuju da je u računalom podržanim istraživanjima smanjena učestalost davanja socijalno poželjnih odgovora (Martin i Nagao, 1989.; prema Musch i Reips, 2000.; Entin i sur., 2001.) i povećana vjerojatnost pružanja socijalno osjetljivijih i/ili intimnijih podataka (Moon, 2000.; Entin i sur., 2001.). Čini se da subjektivni doživljaj anonimnosti ispitanika u *online* istraživanjima pozitivno utječe na iskrenost u odgovaranju i rjeđe davanje socijalno poželjnih odgovora. Pri tome doživljaj anonimnosti vjerojatno proizlazi iz veće fizičke udaljenosti između ispitanika i istraživača, a ne iz uvjerenja ispitanika o nemogućnosti otkrivanja njihova identiteta.

U većini današnjih *online* istraživanja neverbalni znakovi komunikacije ostaju nezabilježeni. To može dovesti do niza problema u razumijevanju značenja pitanja i odgovora, podjednako za ispitanika kao i za istraživača. No u individualnim intervjuima takva situacija nije novost – slično je kod telefonskih, a posebno poštanskih, anketa. No u skupnim intervjuima putem interneta, posebno sinkronima, manjak neverbalne komunikacije posebno je izražen i može omesti komunikaciju koja bi u realnim uvjetima tekla glatko. Nije lako samo na osnovi pisanoga teksta zaključiti kada je koji od sudionika završio sa svojim izlaganjem, odnosno kada je "pristojno" uključiti se u diskusiju. U sinkronim grupama diskusija može teći prebrzo, s nekoliko članova grupe koji istodobno odgovaraju na pitanja moderatora. Tada je gotovo nemoguće pratiti diskusiju i na vrijeme reagirati na sve potencijalno vrijedne izjave sudionika. Međutim, s napretkom tehnologije, posebno s povećanjem brzine prijenosa podataka putem interneta, sve će se češće moći održavati tzv. videokonferencije, odnosno intervjui u kojima se svi članovi međusobno mogu vidjeti uz pomoć *web* kamera. Time se velik nedostatak *online* istraživanja – nedostatak neverbalne komunikacije sudionika – najvećim dijelom uklanja.

Važan izvor pogrešaka mjerenja u klasičnim istraživanjima – anketar – nije prisutan u *online* anketama. Anketar može utjecati na kvalitetu prikupljenih podataka na niz načina: pogreškama u kodiranju ispitanikovih odgovora, davanjem povratnih informacija koje nisu planirani dio procesa ispitivanja, nesvjesnim utjecajem na rezultate zbog očekivanja o rezultatima ankete te različitim efektima interakcije demografskih i drugih obilježja ispitivača i ispitanika. Usprkos nedostacima, prisutnost anketara ima i nekih pozitivnih strana: on može ispitaniku dati dodatna objašnjenja i motivirati ispitanika da ne odustane od sudjelovanja tijekom ankete. Zato se u posljednje vrijeme i u *online* anketama istražuje mogućnost uvođenja nekog oblika "socijalne prisutnosti", kako bi se s ispitanikom ostvarila bolja interakcija i omogućila komunikacija što sličnija onoj u svakodnevnom životu (Couper, 2002.).

Istraživanja o razlikama rezultata *online* anketa i drugih anketnih metoda

Najvažniji nalaz brojnih istraživanja o razlikama između telefonskih i osobnih anketa jest – da među njima nema razlike (Groves, 1989.). Čini se da se slično može reći i za razlike između *online* i "klasičnih" anketnih istraživanja. Tako su još Kiesler i Sproull (1986.) te kasnije Mehta i Sivadas (1995.) usporedili rezultate anketa provedenih elektroničkom i o-

bičnom poštom. Utvrdili su da su prosječne vrijednosti i raspon odgovora na skalama Likertova tipa bili slični u obje metode. Berrens i sur. (2003.) usporedili su rezultate istraživanja stavova o globalnoj promjeni klime i Sporazumu u Kyotu, provedenim na dva komercijalna *online* panela i telefonski na nacionalnom uzorku. Rezultati dobiveni na *online* uzorcima i telefonskom anketom bili su vrlo slični. Već su spomenute izvrsne prognoze tvrtke Harris Interactive u pogledu rezultata američkih predsjedničkih i parlamentarnih izbora, utemeljene na ponderiranim rezultatima *online* ankete (Berrens i sur., 2003.). Kod nas su Šverko, Arambašić i Galešić (2002.) proveli istraživanje o utjecaju produženoga vremena rada na subjektivnu dobrobit osobnim intervjuima i anketom na *online* panelu te također nisu našli značajne razlike u rezultatima. Usporedba velikoga broja klasičnih i *online* anketnih studija s obzirom na anketni odziv, brzinu odgovaranja i kvalitete podataka koju su proveli Tuten, Urban i Bosnjak (2002.) pokazala je da *online* ankete – osim u pogledu anketnog odziva – imaju usporediva ili bolja svojstva od klasičnih anketa.

Razlike nisu pronađene ni između *online* i klasičnih verzija drugih istraživačkih metoda. Krantz i Dalal (2000.) saželi su rezultate devet eksperimentalnih studija provedenih na *webu*. U svim slučajevima rezultati dobiveni *webom* bili su vrlo slični rezultatima dobivenim u klasičnom laboratoriju te u skladu s teoretskim očekivanjima. U jednoj studiji (Birnbam, 2000.b) rezultati *web* eksperimenta bili su čak sličniji teoretski očekivanim rezultatima nego laboratorijski nalazi. Buchanan i Smith (1999.) prilagodili su Self Monitoring Scale Gangestada i Snydera za *web* primjenu. Faktorska struktura rezultata prikupljenih *online* bila je vrlo slična onoj dobivenoj na laboratorijskom uzorku, kao i onoj opisanoj u literaturi.

ZAKLJUČAK

Anketna istraživanja putem interneta sve su prisutnija u društvenim znanostima. Polazeći od modela ukupne anketne pogreške, prikazali smo pogreške obuhvata, uzorka, neodziva i mjerenja koje se mogu javiti u *online* anketama. Kako se korisnici interneta značajno razlikuju od ostatka ukupne populacije, ciljna populacija *online* anketa uglavnom je ograničena na sve korisnike interneta ili na razne uže skupine, kao što su zaposlenici neke organizacije, članovi nekoga kluba, pretplatnici na neke usluge, pripadnici neke profesije ili posjetioци neke *web* stranice. Probabilističko uzorkovanje svih korisnika interneta nije moguće, jer nema njihova jedinstvenoga popisa, no mnoge uže populacije mogu se popisati i uzorkovati po slučaju. Sve se češće rabe *online* paneli, baze podataka s kontaktnim demografskim i drugim podacima korisnika interne-

ta koji su unaprijed izjavili da žele sudjelovati u istraživanjima. Takvi paneli imaju niz nedostataka, ali i važne prednosti.

Nepotpun i selektivan anketni odziv može biti velik problem u *online* istraživanjima kao i u drugim vrstama anketa. Razni načini intrinzičnoga i ekstrinzičnoga motiviranja, upotrijebljeni s oprezom, mogu ublažiti taj problem (Bosnjak i Tuten, 2002.; Galešić, 2004.; Tuten, Galešić i Bosnjak, 2004.). Pri planiranju i provedbi *online* anketa treba voditi računa i o nekim specifičnim pogreškama mjerenja koje mogu proizaći iz obilježja računala i veze s internetom, okolinskih uvjeta, formalnih obilježja *online* upitnika te posebnosti računalom podržane komunikacije.

Zaključno, *online* istraživanja postaju ravnopravna drugim metodama prikupljanja podataka u društvenim znanostima. Većina opisanih izvora pogrešaka u *online* anketnim istraživanjima može se kontrolirati, ukloniti ili zaobići. S proširenjem interneta i napretkom računalne tehnologije te daljnjim usavršavanjem metodologije *online* ankete sve će se češće rabiti i u komercijalnim i u akademskim istraživanjima.

LITERATURA

Batinic, B. & Bosnjak, M. (2001.), Fragebogenuntersuchungen im Internet. U: B. Batinic (ur.), *Internet für Psychologen* (str. 287-317). Göttingen: Hogrefe-Verlag.

Batinic, B., Reips, U.-D. & Bosnjak, M. (ur.) (2002.), *Online Social Sciences*. Seattle, WA: Hogrefe & Huber Publishers.

Berrens, R. P., Bohara, A. K., Jenkins-Smith, H., Silva, C. & Weimer, D. L. (2003.), The Advent of Internet Surveys for Political Research: A Comparison of Telephone and Internet Samples. *Political Analysis*, 11, 1-22.

Birnbaum, M. H. (ur.) (2000.a), *Psychological Experiments on the Internet*. San Diego: Academic Press.

Birnbaum, M. H. (2000.b), Decision Making in the Lab and on the Web. U: M. H. Birnbaum (ur.), *Psychological Experiments on the Internet* (str. 3-34). San Diego: Academic Press.

Bosnjak, M. (2001.), Participation in Non-Restricted Web-Surveys: A Typology and Explanatory Model for Item-Nonresponse. U: U.-D. Reips & M. Bosnjak (ur.), *Dimensions of Internet-Science* (str. 193-207), Lengerich: Pabst Science Publishers.

Bosnjak, M. (2002.), *(Non)Response bei Web-Befragungen*. Aachen: Shaker Verlag.

Bosnjak, M. & Batinic, B. (2002.), Understanding the Willingness to Participate in *Online-Surveys*. U: B. Batinic, U.-D. Reips & M. Bosnjak (ur.), *Online Social Sciences* (str. 81-92). Seattle, WA: Hogrefe & Huber Publishers.

Bosnjak, M. & Tuten, T. L. (2002.), *Prepaid and Promised Incentives in Web Surveys – An Experiment*. Paper presented at the 57th American Association for Public Opinion Research Annual Conference, St. Pete Beach, FL, USA.

DRUŠ. ISTRAŽ. ZAGREB
GOD. 14 (2005),
BR. 1-2 (75-76),
STR. 297-320

GALEŠIĆ, M.:
ANKETNA ISTRAŽIVANJA...

Buchanan, T. (2000.), Potential of the Internet for Personality Research. U: M. H. Birnbaum (ur.), *Psychological Experiments on the Internet* (str. 121-140). San Diego: Academic Press.

Buchanan, T. & Smith, J. L. (1999.), Research on the Internet: Validation of a World-Wide Web mediated personality scale. *Behavior Research Methods, Instruments, & Computers*, 31 (4), 565-571.

Campbell, D. T. & Stanley, J. C. (1963.), *Experimental and Quasi-experimental Designs for Research*. Chicago: Rand McNally & Company.

Comley, P. (2002.), *Online surveys and Internet research*. URL: http://www.virtualsurveys.com/papers/paper_1.asp [8. 4. 2003].

Conrad, F. G. (2002.), *Interactive Aspects of Web Surveys: Lack of Use, Ease of Use and User Models*. Paper presented at the International Workshop on Websurveys, Mannheim, Germany.

Couper, M. P. (2000.), Web surveys. A review of issues and approaches. *Public Opinion Quarterly*, 64, 464-494.

Couper, M. P. (2002.), *Visual design effects in web surveys*. Paper presented at the International Workshop on Websurveys, Mannheim, Germany.

Couper, M. P. & Burt, G. (1994.), Interviewer attitudes toward computer-assisted personal interviewing (CAPI). *Social Science Computer Review*, 12, 38-54.

Dillman, D. A. (1978.), *Mail and telephone surveys: The Total Design Method*. New York: Wiley.

Dillman, D. A. (2000.), *Mail and Internet surveys: The tailored design method*. NY: Wiley.

Dillman, D. A. & Bowker, D. K. (2001.), The Web questionnaire challenge to survey methodologists. U: U. D. Reips & M. Bosnjak (ur.), *Dimensions of Internet science* (str. 159-178). Lengerich: Pabst Science Publishers.

Entin, E. E., Kerrigan, C., Berbaum, M., Lancey, P., McCallum, D. (2001.), *Issues of Adaptive Automated Surveys in a Computer Network Environment*. United States Army Research Institute for the Behavioral and Social Sciences.

Fuchs, M. (2002.), *Cognitive processes in web surveys*. Paper presented at the International Workshop on Websurveys, Mannheim, Germany.

Galešić, M. (2004.), *Donošenje odluke o ponašanju u anketnoj situaciji: Utjecaj dužine upitnika na anketni odziv i kvalitetu odgovora u istraživanjima putem Interneta*. Doktorska disertacija. Odsjek za psihologiju Filozofskog fakulteta u Zagrebu.

Galešić, M. (2002.b), Effect of questionnaire length on response rates in online surveys: review of findings and guidelines for future research (poster). Stuttgart: German Online Research Society Conference. URL: <http://www.dgof.de/gor02/poster.htm> [8. 4. 2003].

Galešić, M. & Šverko, B. (2003.), Iskustva u pripremi i provedbi online kolegija uz pomoć courseware alata WebCT. U pripremi.

GFK (2003.), *Internet-homepage 2003*. URL: http://www.gfk.at/research_data/free_download/files/DATA/Internet-homepage%202003.ppt [8. 4. 2003].

Göriz, A. S., Reinhold, N. & Batinic, B. (2002.), Online Panels. U: B. Batinic, U. Reips & M. Bosnjak (ur.), *Online Social Sciences* (str. 27-47). Seattle: Hogrefe & Huber.

Gräf, L. (2002.), Assessing Internet questionnaires: The online pretest lab. U: B. Batinic, U. Reips & M. Bosnjak (ur.), *Online Social Sciences* (str. 49-68). Seattle: Hogrefe & Huber.

Groves, R. M. (1989.), *Survey errors and survey costs*. New York: Wiley.

Groves, R. M., Cialdini, R. B. & Couper, M. P. (1992.), Understanding the decision to participate in a survey. *Public Opinion Quarterly*, 56, 475-495.

Groves, R. M., Presser, S. & Dipko, S. (2004.), The role of topic interest in survey participation decisions. *Public Opinion Quarterly*, 68, 2-31.

Groves, R., Singer, E. & Corning, A. (2000.), Leverage-Saliency Theory of Survey Participation: Description and an Illustration. *Public Opinion Quarterly*, 64, 299-308.

de Heer, W. (1999.), International response trends: Results of an international survey. *Journal of Official Statistics*, 15, 129-142.

Hansen, M. H., Hurwitz, W. N. & Madow, W. G. (1953.), *Sample survey methods and theory*. New York, Wiley.

Heerwegh, D. (2002.), *Describing response behavior in websurveys using client side paradata*. Paper presented at the International Workshop on Websurveys, Mannheim, Germany.

Kaye, B. K. & Johnson, T. J. (1999.), Research Methodology: Taming the Cyber Frontier – Techniques for Improving Online Surveys. *Social Science Computer Review*, 17 (3), 323-337.

Kiesler, S. & Sproull, L. S. (1986.), Response effects in the electronic survey. *Public Opinion Quarterly*, 50, 402-413.

Kish, L. (1965.), *Survey Sampling*. New York: Wiley.

Krantz, J. H. (2001.), Stimulus delivery on the Web: What can be presented when calibration isn't possible. U: U.-D. Reips & M. Bosnjak (ur.), *Dimensions of Internet-Science* (str. 113-130), Lengerich: Pabst Science Publishers.

Krantz, J. H. (2003.), Psychological Research on the Net. URL: <http://psych.hanover.edu/research/exponnet.html> [8. 4. 2003].

Krantz, J. H. & Dalal, R. (2000.), Validity of Web-Based Psychological Research. U: M. H. Birnbaum (ur.), *Psychological Experiments on the Internet* (str. 35-60). San Diego: Academic Press.

Krantz, J. H., Ballard, J. & Scher, J. (1997.), Comparing the results of laboratory and World-Wide-Web samples on the determinants of female attractiveness. *Behavioral Research Methods, Instruments & Computers*, 29, 264-269.

Mehta, R. & Sivadas, E. (1995.), Comparing response rates and response content in mail versus electronic mail surveys. *Journal of the Market Research Society*, 37, 429-439.

Moon, Y. (2000.), Intimate Exchanges: Using Computers to Elicit Self-Disclosure from Consumers. *Journal of Consumer Research*, 26 (4), 323-337.

Musch, J. & Reips, U. D. (2000.), A brief history of Web experimenting. U: M. H. Birnbaum (ur.), *Psychological Experiments on the Internet* (str. 61-88). San Diego: Academic Press.

DRUŠ. ISTRAŽ. ZAGREB
GOD. 14 (2005),
BR. 1-2 (75-76),
STR. 297-320

GALEŠIĆ, M.:
ANKETNA ISTRAŽIVANJA...

Nua (2003.), How many online? URL: http://www.nua.ie/surveys/how_many_online/index.html [8. 4. 2003].

Pastore, M. (2001.), Online Consumers Now the Average Consumer. Cyberatlas. URL: http://cyberatlas.internet.com/big_picture/demographics/article/0,,5901_800201,00.html#table [9. 9. 2001].

Puls (2003., ožujak), *Korištenje Interneta u Hrvatskoj*. Interni izvještaj. Zagreb.

Reips, U. D. (2000.), The Web Experiment Method: Advantages, Disadvantages, and Solutions. U: M. H. Birnbaum (ur.), *Psychological Experiments on the Internet* (str. 89-120). San Diego: Academic Press.

Reips, U. D. (2001.), The Web Experimental Psychology Lab: Five years of data collection on the Internet. *Behavioral Research Methods, Instruments & Computers*, 33 (2), 201-211.

Reips, U. D. (2002.), Theory and Techniques of Conducting Web Experiments. U: B. Batinic, U.-D. Reips & M. Bosnjak (ur.), *Online Social Sciences* (str. 229-250). Seattle, WA: Hogrefe & Huber Publishers.

Reips, U.-D. & Bosnjak, M. (ur.) (2001.), *Dimensions of Internet Science*. Lengerich: Pabst Science Publishers.

Šverko, B., Arambašić, L., Galešić, M. (2002.), Work-life balance among Croatian employees: Role time commitment, work-home interference, and well being. *Social Science Information*, 41, 281-301.

Taylor, H. & Terhanian, G. (1999.), Back to the Future of Online Polling: No Witchcraft Here. *Public Perspective*, 10 (4), 42-43.

Tourangeau, R., Rips, L. J., Rasinski, K. (2000.), *The psychology of survey response*. Cambridge University Press.

Townsend, J. T. & Busemeyer, J. (1995.), Dynamic representation of decision-making. U: R. F. Port & T. van Gelder (ur.), *Mind as motion* (str. 101-120). Cambridge, MA: MIT Press.

Tuten, T. L., Galešić, M. & Bosnjak, M. (2004.), Effects of immediate versus delayed notification of prize draw results on response behavior in web surveys – An experiment. *Social Science Computer Review*, 21, 208-217.

Tuten, T. L., Urban, D. J. & Bosnjak, M. (2002.), Internet Surveys and Data Quality – A Review. U: B. Batinic, U.-D. Reips & M. Bosnjak (ur.), *Online Social Sciences* (str. 7-26). Seattle, WA: Hogrefe & Huber Publishers.

U.S. Bureau of the Census (2002.), Total Midyear Population for the World: 1950-2050. URL: <http://www.census.gov/ipc/www/world-pop.html> [8. 4. 2003].

Vehovar, V., Batagelj, Z., Lozar Manfreda, K. (2000.), Participation in Solicited Web Surveys: Who Comes Farthest? Fifth International Conference on Social Science Methodology, Cologne, Germany. URL: http://www.ris.org/si/ris2000/pub/Cologne2000_finalx.ppt

Vehovar, V., Batagelj, Z., Lozar Manfreda, K., Zaletel, M. (2002.), Non-response in web surveys. U: R. M. Groves, D. Dillman, J. L. Eltinge, J. A. R. Little (ur.), *Survey nonresponse*, 229-242. New York, Wiley.

DRUŠ. ISTRAŽ. ZAGREB
GOD. 14 (2005),
BR. 1-2 (75-76),
STR. 297-320

GALEŠIĆ, M.:
ANKETNA ISTRAŽIVANJA...

Online Surveys: Possible Sources of Errors

Mirta GALEŠIĆ
Faculty of Philosophy, Zagreb

The Internet is being used ever often for conducting surveys in social sciences. This paper gives a comprehensive overview of the current state of online surveys. Within the framework of the total survey error model, the paper describes coverage, sample, non-response and measurement errors that are possible in online surveys. Various ways of control and/or avoidance of these errors are proposed.

Online-Umfragen und mögliche Fehlerquellen

Mirta GALEŠIĆ
Philosophische Fakultät, Zagreb

Im Bereich der Gesellschaftswissenschaften greift man zu Forschungszwecken immer mehr auf Online-Umfragen zurück. Dieser Artikel gibt einen umfassenden Überblick über die bisherigen Erkenntnisse in diesem Bereich. Die Verfasserin geht von einem Modell systematischer Umfrage-Fehlschlüsse aus und zeigt Fehler auf, die im Bereich des durch die Fragestellung abgedeckten Problemfeldes, ferner im Bereich der Umfrageteilnehmer, der Nichtteilnahme und der angewandten Maßstäbe liegen. Es werden Möglichkeiten aufgezeigt, wie man die Kontrolle verbessern und/oder solche Fehler vermeiden kann.