Standardna pogreška: značenje i interpretacija

Standard error: meaning and interpretation

Mary L. McHugh

Fakultet sestrinstva, Sveučilište Indianapolisa, Indianapolis, Indiana, SAD

School of Nursing, University of Indianapolis, Indianapolis, Indiana, USA

Sažetak

Statistika standardne pogreške je vrsta inferencijalne statistike koja donekle funkcionira kao opisna statistika po tome što istraživaču dozvoljava sastavljanje intervala pouzdanosti o dobivenoj statistici uzorka. Tako načinjen interval pouzdanosti pruža procjenu intervala u kojem će se nalaziti populacijski parametar. Dvije statistike standardne pogreške koje su najčešće u uporabi su standardna pogreška srednje vrijednosti i standardna pogreška procjene.

Standardna pogreška srednje vrijednosti istraživaču omogućava sastavljanje intervala pouzdanosti u kojem će se vjerojatno nalaziti srednja vrijednost populacije. Formula (1-P) (najčešće $P < 0,05$) predstavlja vjerojatnost da će se srednja vrijednost populacije nalaziti u izračunanom intervalu (obično 95%).

Standardna pogreška procjene jest druga statistika standardne pogreške kojom se istraživači najčešće koriste. Ta se statistika primjenjuje s mjerom korelacije, Pearsonovim *R*, koja istraživaču može omogućiti stvaranje intervala pouzdanosti unutar kojeg će se nalaziti stvarna korelacija populacije. Izračuni dobiveni temeljem *R* i standardne pogreške procjene mogu se primijeniti da bi odredilo koliko je točna procjena korelacije za populaciju kao statistika korelacije uzorka.

Standardna pogreška je važan pokazatelj koliko statistika uzorka predstavlja točnu procjenu populacijskog parametra. Razmotrena zajedno s takvim mjerama kao što su veličina učinka, vrijednost *P* te veličina uzorka, veličina učinka može biti korisno pomagalo istraživaču koji želi razumjeti točnost statistike koja se izračunava na slučajnim uzorcima.

Ključne riječi: statistika, standardna pogreška

Abstract

Standard error statistics are a class of inferential statistics that function somewhat like descriptive statistics in that they permit the researcher to construct confidence intervals about the obtained sample statistic. The confidence interval so constructed provides an estimate of the interval in which the population parameter will fall. The two most commonly used standard error statistics are the standard error of the mean and the standard error of the estimate.

The standard error of the mean permits the researcher to construct a confidence interval in which the population mean is likely to fall. The formula, (1-P) (most often $P < 0.05$) is the probability that the population mean will fall in the calculated interval (usually 95%).

The Standard Error of the estimate is the other standard error statistic most commonly used by researchers. This statistic is used with the correlation measure, the Pearson *R*. It can allow the researcher to construct a confidence interval within which the true population correlation will fall. The computations derived from the r and the standard error of the estimate can be used to determine how precise an estimate of the population correlation is the sample correlation statistic.

The standard error is an important indicator of how precise an estimate of the population parameter the sample statistic is. Taken together with such measures as effect size, p-value and sample size, the effect size can be a useful tool to the researcher who seeks to understand the accuracy of statistics calculated on random samples.

Key words: statistics, standard error

Pristiglo: 16. listopada 2007. *Received: October 16, 2007*

Prihvaćeno: 14. studenoga 2007. *Accepted: November 14, 2007*

Što je standardna pogreška?

Statistika standardne pogreške predstavlja vrstu statističkih podataka koji se u mnogim inferencijalnim statistikama prikazuju kao izlazni podatci, no funkcioniraju kao opisna statistika. Izraz standardna pogreška specifično se odnosi na skupinu statističkih podataka koji pružaju informacije o raspršenju vrijednosti unutar nekog skupa. Kod primjene standardne pogreške pretpostavlja se da je korisnik upoznat sa središnjim graničnim teoremom i pretpostavkama o skupu podataka s kojim istraživač radi.

Središnji granični teorem je temeljna pretpostavka cjelokupne parametarske inferencijalne statistike. Za njegovu je primjenu nužno da uzorak bude slučajan te da su zapažanja o svakom pojedinom ispitaniku neovisna o zapažanjima o bilo kojem drugom ispitaniku. Teorem ustvrđuje da će razdioba uzorkovanja srednjih vrijednosti dobivenih iz velikog broja slučajnih uzoraka uzetih iz ishodišne populacije pokazivati normalnu razdiobu bez obzira na oblik ishodišne populacije (1).

Točnije, premda mali broj uzoraka može stvoriti nenormalnu razdiobu, s povećanjem broja uzoraka (tj. povećanjem *n*) oblik razdiobe srednjih vrijednosti uzoraka ubrzano će se približavati obliku normalne razdiobe. Druga generalizacija na temelju središnjega graničnog teorema jest da kako raste *n*, tako se smanjuje varijabilnost srednje vrijednosti uzoraka (2). To je važno jer pojam razdiobe uzoraka tvori teorijsku osnovu za matematiku koja istraživačima omogućava da donose zaključke o populaciji iz uzoraka.

Istraživači obično uzimaju samo jedan uzorak jer im nije moguće mjeriti čitavu populaciju. Za to nemaju ni vremena ni novca. Iz istih razloga istraživači ne mogu uzeti mnogo uzoraka iz populacije koja im je zanimljiva. Za njih je stoga osnovno da mogu odrediti vjerojatnost da mjere njihova uzorka pouzdano predstavljaju cjelokupnu populaciju o kojoj onda mogu izraziti predviđanja. Određivanje reprezentativnosti određenog uzorka temelji se na teorijskoj raspoređenosti uzoraka čije ponašanje opisuje središnji granični teorem. Statistika standardne pogreške predstavlja procjene intervala u kojem je moguće utvrditi parametre populacije, a time i stupanj preciznosti u kojem statistika uzorka predstavlja parametar populacije. Što je standardna pogreška manja, tim je statistika uzorka bliža parametru populacije. Standardna pogreška statistike je stoga standardno odstupanje razdiobe uzorka za tu statistiku (3).

Možemo se zapitati kako se standardna pogreška razlikuje od standardnog odstupanja? Ta se dva pojma čine vrlo sličnima. Oni i jesu sasvim slični, no koriste se različito. Standardno odstupanje je mjera promjenljivosti uzorka. Standardna pogreška je mjera promjenljivosti razdiobe uzorkovanja. Baš kao što je standardno odstupanje mjera *raspršenja* vrijednosti u uzorku, tako je standardna pogreška mjera *raspršenja* vrijednosti u razdiobi uzorkovanja. To

What is the standard error?

Standard error statistics are a class of statistics that are provided as output in many inferential statistics, but function as descriptive statistics. Specifically, the term standard error refers to a group of statistics that provide information about the dispersion of the values within a set. Use of the standard error statistic presupposes the user is familiar with the central limit theorem and the assumptions of the data set with which the researcher is working.

The central limit theorem is a foundation assumption of all parametric inferential statistics. Its application requires that the sample is a random sample, and that the observations on each subject are independent of the observations on any other subject. It states that regardless of the shape of the parent population, the sampling distribution of means derived from a large number of random samples drawn from that parent population will exhibit a normal distribution (1). Specifically, although a small number of samples may produce a non-normal distribution, as the number of samples increases (that is, as *n* increases), the shape of the distribution of sample means will rapidly approach the shape of the normal distribution. A second generalization from the central limit theorem is that as *n* increases, the variability of sample means decreases (2). This is important because the concept of sampling distributions forms the theoretical foundation for the mathematics that allows researchers to draw inferences about populations from samples.

Researchers typically draw only one sample. It is not possible for them to take measurements on the entire population. They have neither the time nor the money. For the same reasons, researchers cannot draw many samples from the population of interest. Therefore, it is essential for them to be able to determine the probability that their sample measures are a reliable representation of the full population, so that they can make predictions about the population. The determination of the representativeness of a particular sample is based on the theoretical sampling distribution the behavior of which is described by the central limit theorem. The standard error statistics are estimates of the interval in which the population parameters may be found, and represent the degree of precision with which the sample statistic represents the population parameter. The smaller the standard error, the closer the sample statistic is to the population parameter. The standard error of a statistic is therefore the standard deviation of the sampling distribution for that statistic (3)

How, one might ask, does the standard error differ from the standard deviation? The two concepts would appear to be very similar. They are quite similar, but are used differently. The standard deviation is a measure of the variability of the sample. The standard error is a measure of the variability of the sampling distribution. Just as the standaznači da je ta pogreška mjera raspršenja srednjih vrijednosti uzoraka ukoliko se iz populacije uzelo mnogo različitih uzoraka.

Standardna pogreška srednje vrijednosti

Standardnu pogrešku srednje vrijednosti uzorka predstavlja sljedeća formula:

$$SE = \frac{\sigma}{\sqrt{n}}$$

Formula pokazuje da je standardna pogreška jednaka standardnom odstupanju podijeljenom s kvadratnim korijenom iz *n*. To ujedno ukazuje da što je veličina uzorka veća, to je manja standardna pogreška (pod uvjetom da što je veći djelitelj, to je manji rezultat, a što je manji djelitelj, veći je rezultat). Znak za standardnu pogrešku srednje vrijednosti je σ_M ili, kad je znakove teže upisati, često se prikazuje kao „S.E. srednje vrijednosti“, ili jednostavnije SEM (engl. *standard error of the mean*).

Standardna pogreška srednje vrijednosti može pružiti grubu procjenu intervala kojem će vjerojatno pripadati srednja vrijednost populacije. SEM treba kao standardnu devijaciju pomnožiti s 1,96 da bi se dobila procjena mjesta gdje se očekuje da će pasti 95% srednjih vrijednosti uzorka populacije u teorijskoj razdiobi uzoraka. Da bi se dobio 95%-tni interval pouzdanosti, SEM treba pomnožiti s 1,96 i rezultat dodati srednjoj vrijednosti uzorka kako bi se dobila gornja granica intervala u koji će pasti parametar populacije. Dobiveni će interval pružiti procjenu raspona vrijednosti kojem će vjerojatno pripadati srednja vrijednost populacije. Zapravo, razina vjerojatnosti odabrana za istraživanje (obično $P < 0,05$) je procjena vjerojatnosti da će srednja vrijednost biti u tom intervalu. Taj je interval gruba procjena intervala pouzdanosti unutar kojega će vjerojatno biti srednja vrijednost populacije. Precizniji interval pouzdanosti treba izračunati pomoću percentila dobivenih t-razdiobom.

Sljedeća primjena vrijednosti 1,96 ± SEM jest kod određivanja iznosi li srednja vrijednost populacije nula. Ako gore izračunani interval uključuje vrijednost „0“, onda postoji jaka vjerojatnost da je srednja vrijednost populacije nula ili blizu ništice. Razmotrimo, primjerice, istraživača koji istražuje dekubitus u populaciji bolesnika koji su imali otvorenu operaciju srca koja je trajala više od 4 sata. Pretpostavimo da je srednji broj dekubitusa bio 0,02 u uzorku od 500 bolesnika, što znači da je dekubitus nastao u 10 bolesnika. Ako je standardna pogreška srednje vrijednosti 0,011, onda srednji broj dekubitusa u populaciji pada približno između 0,04 i 0,0016. To se tumači na sljedeći način: srednja vrijednost populacije je negdje između nula i 20 dekubitusa. S obzirom da srednja vrijednost populacije može biti ništica, istraživač bi mogao zaključiti da 10-oro bolesnika u kojih se razvio dekubitus spada u izuzetke. To

rd deviation is a measure of the *dispersion* of values in the sample, the standard error is a measure of the *dispersion* of values in the sampling distribution. That is, of the dispersion of means of samples if a large number of different samples had been drawn from the population.

Standard error of the mean

The standard error of a sample mean is represented by the following formula:

$$SE = \frac{\sigma}{\sqrt{n}}$$

That is, the standard error is equal to the standard deviation divided by the square root of the sample size, *n*. This shows that the larger the sample size, the smaller the standard error. (Given that the larger the divisor, the smaller the result and the smaller the divisor, the larger the result.) The symbol for standard error of the mean is σ_M or when symbols are difficult to produce, it may be represented as, S.E. mean, or more simply as SEM.

The standard error of the mean can provide a rough estimate of the interval in which the population mean is likely to fall. The SEM, like the standard deviation, is multiplied by 1.96 to obtain an estimate of where 95% of the population sample means are expected to fall in the theoretical sampling distribution. To obtain the 95% confidence interval, multiply the SEM by 1.96 and add the result to the sample mean to obtain the upper limit of the interval in which the population parameter will fall. Then subtract the result from the sample mean to obtain the lower limit of the interval. The resulting interval will provide an estimate of the range of values within which the population mean is likely to fall. In fact, the level of probability selected for the study (typically $P < 0.05$) is an estimate of the probability of the mean falling within that interval. This interval is a crude estimate of the confidence interval within which the population mean is likely to fall. A more precise confidence interval should be calculated by means of percentiles derived from the t-distribution.

Another use of the value, 1.96 ± SEM is to determine whether the population parameter is zero. If the interval calculated above includes the value, “0”, then it is likely that the population mean is zero or near zero. Consider, for example, a researcher studying bedsores in a population of patients who have had open heart surgery that lasted more than 4 hours. Suppose the mean number of bedsores was 0.02 in a sample of 500 subjects, meaning 10 subjects developed bedsores. If the standard error of the mean is 0.011, then the population mean number of bedsores will fall approximately between 0.04 and -0.0016. This is interpreted as follows: The population mean is somewhere between zero bedsores and 20 bedsores. Given that the population mean may be zero, the researcher might conbi, pak, nadalje moglo istraživača dovesti do pitanja je li se dekubitus razvio kao funkcija nekog drugog stanja, a ne kao funkcija podvrgavanja operaciji srca koja je trajala dulje od 4 sata.

Standardna pogreška procjene

Standardna pogreška procjene (S.E.est) je mjera promjenljivosti predviđanja kod regresije. Točnije, ona se računa primjenom sljedeće formule:

$$\sigma_{est} = \sqrt{\frac{\sum (Y - Y^{'})^2}{N}}$$

gdje je Y zbirna vrijednost uzorka, a Y’ je predviđeni rezultat.
Zbog toga je standardna pogreška procjene mjera raspršenja (ili promjenljivosti) predviđenih rezultata kod regresije. Ujedno bismo stoga u dijagramu raspršenja u kojem je *S.E. est* mali mogli očekivati da vidimo kako je većina zapaženih vrijednosti okupljena prilično blizu crte regresije. Kad je *S.E. est* velik, možemo očekivati da su mnoge od zapaženih vrijednosti daleko od crte regresije, kao na slikama 1 i 2.

clude that the 10 patients who developed bedsores are outliers. That in turn should lead the researcher to question whether the bedsores were developed as a function of some other condition rather than as a function of having heart surgery that lasted longer than 4 hours.

Standard error of the estimate

The standard error of the estimate (S.E.est) is a measure of the variability of predictions in a regression. Specifically, it is calculated using the following formula:

$$\sigma_{est} = \sqrt{\frac{\sum (Y - Y^{'})^2}{N}}$$

Where Y is a score in the sample and Y’ is a predicted score.
Therefore, the standard error of the estimate is a measure of the dispersion (or variability) in the predicted scores in a regression. In a scatterplot in which the S.E.est is small, one would therefore expect to see that most of the observed values cluster fairly closely to the regression line. When the S.E.est is large, one would expect to see many

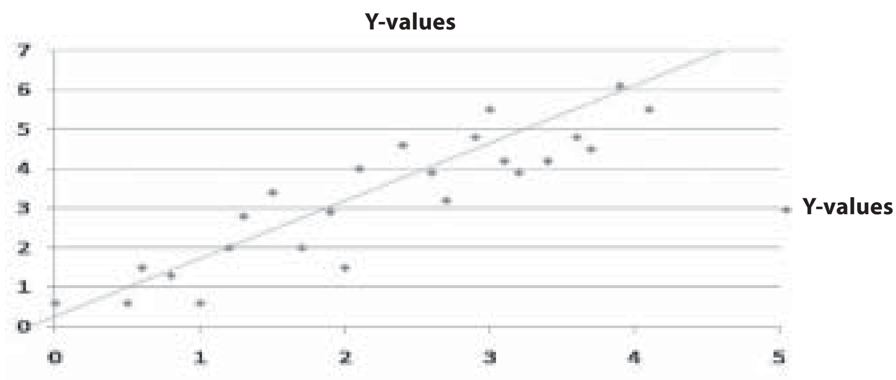

Slika 1. Niska standardna pogreška procjene – predviđene vrijednosti ordinate su blizu crte regresije

Figure 1. Low S.E. estimate – Predicted Y values close to regression line

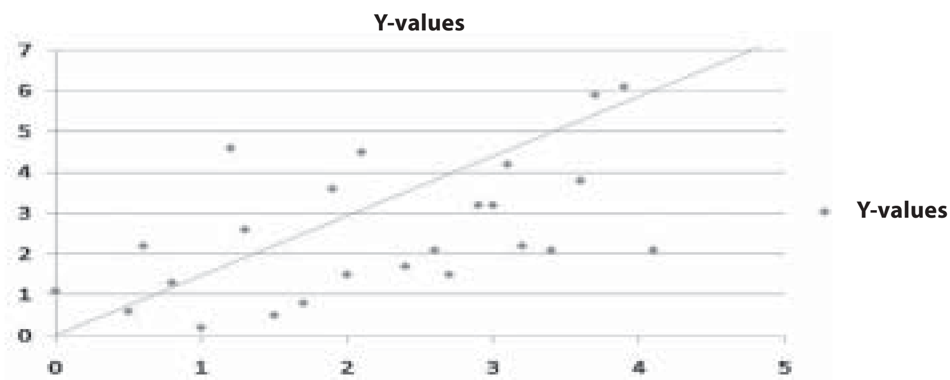

Slika 2. Velika standardna pogreška u procjeni – predviđene vrijednosti ordinate raspršene su širom iznad i ispod crte regresije

Figure 2. Large S.E. estimate – Predicted Y values scattered widely above and below regression line

Ostale standardne pogreške

Svaka inferencijalna statistika ima pridruženu standardnu pogrešku. Premda se uvijek ne prikazuje, standardna pogreška je važan statistički podatak jer pruža informaciju o točnosti statistike (4). Kao što je razmatrano ranije, što je standardna pogreška veća, tim je širi interval pouzdanosti statistike. Interval pouzdanosti može, zapravo, biti tolikog razmjera da je velik kao puni raspon vrijednosti ili čak veći. U tom slučaju statistika daje informaciju o položaju parametra populacije. A to znači da je statistika male točnosti jer ona nije dobra procjena parametra populacije.

Na taj je način standardna pogreška statistike povezana s razinom značajnosti rezultata. Kad je standardna pogreška velika u odnosu na statističke podatke, onda je statistika obično bez značajnosti. Međutim, ako je veličina uzorka vrlo velika, primjerice veličine uzorka su veće od 1000, onda je za skoro svaki statistički podatak izračunan za taj uzorak vjerojatno da će biti statistički značajan. Na primjer, korelacija 0,01 biti će statistički značajna za svaku veličinu uzorka veću od 1500. Međutim, tako mala korelacija nije klinički ili znanstveno značajna. Kada su veličine učinka (mjerene kao statistika korelacije) relativno male no statistički značajne, standardna je pogreška vrijedno pomagalo u određivanju je li ta značajnost posljedica dobrog predviđanja ili je samo rezultat tako velike snage da će bilo kakva statistika biti značajna. Odgovor na pitanje o važnosti rezultata moguće je naći korištenjem standardne pogreške za izračun intervala pouzdanosti za statistički podatak. Ako je nalaz statistički značajan, no standardna pogreška stvara tako veliki interval pouzdanosti da on uključuje preko 50% raspona vrijednosti u skupu podataka, onda bi istraživač trebao zaključiti da je nalaz *klinički* beznačajan (ili nevažan). Takav je zaključak istinit jer raspon vrijednosti u koju spada parametar populacije tako velik da istraživač jedva da ima išta bolju predodžbu o tome gdje zaista spada parametar populacije, nego što je imao prije provedbe istraživanja.

Kada izračunani statistički podatak uključuje dvije ili više varijabli (kao što su regresija, t-test), postoji još jedan statistički podatak koji se može uporabiti za određivanje važnosti nalaza. Taj je statistički podatak *veličina učinka* povezanosti koja se statistikom ispituje. Razmotrimo, primjerice, regresiju. Pretpostavimo da je veličina uzorka 1500, a značajnost regresije 0,001. Dobivena razina *P* je vrlo značajna. Međutim, preostaje pitanje koliko su točna i pouzdana predviđanja koja se temelje na regresiji? Veličina učinka daje odgovor na to pitanje. Kod regresije, statistički podatak o veličini učinka je Pearsonov *Product Moment* koeficijent korelacije (što je puni i točan naziv za Pearsonovu R-korelaciju, često jednostavno navedenu kao *R*). Ako je Pearsonova vrijednost *R* ispod 0,30, onda je odnos slab bez obzira na to koliko je značajan rezultat. Vrijednost *R* od 0,30 znači da je neovisna varijabla uzrokom samo

of the observed values far away from the regression line as in Figures 1 and 2.

Other standard errors

Every inferential statistic has an associated standard error. Although not always reported, the standard error is an important statistic because it provides information on the accuracy of the statistic (4). As discussed previously, the larger the standard error, the wider the confidence interval about the statistic. In fact, the confidence interval can be so large that it is as large as the full range of values, or even larger. In that case, the statistic provides no information about the location of the population parameter. And that means that the statistic has little accuracy because it is not a good estimate of the population parameter.

In this way, the standard error of a statistic is related to the significance level of the finding. When the standard error is large relative to the statistic, the statistic will typically be non-significant. However, if the sample size is very large, for example, sample sizes greater than 1,000, then virtually any statistical result calculated on that sample will be statistically significant. For example, a correlation of 0.01 will be statistically significant for any sample size greater than 1500. However, a correlation that small is not clinically or scientifically significant. When effect sizes (measured as correlation statistics) are relatively small but statistically significant, the standard error is a valuable tool for determining whether that significance is due to good prediction, or is merely a result of power so large that any statistic is going to be significant. The answer to the question about the importance of the result is found by using the standard error to calculate the confidence interval about the statistic. When the finding is statistically significant but the standard error produces a confidence interval so wide as to include over 50% of the range of the values in the dataset, then the researcher should conclude that the finding is clinically insignificant (or unimportant). This is true because the range of values within which the population parameter falls is so large that the researcher has little more idea about where the population parameter actually falls than he or she had before conducting the research.

When the statistic calculated involves two or more variables (such as regression, the t-test) there is another statistic that may be used to determine the importance of the finding. That statistic is the effect size of the association tested by the statistic. Consider, for example, a regression. Suppose the sample size is 1,500 and the significance of the regression is 0.001. The obtained P-level is very significant. However, one is left with the question of how accurate are predictions based on the regression? The effect size provides the answer to that question. In a regression, the effect size statistic is the Pearson Product Moment

9% varijance u ovisnoj varijabli. 9%-tna vrijednost je statistički podatak koji se naziva koeficijent determinacije, a računa se kvadriranjem Pearsonovog *R*. To je još vrijedniji statistički podatak od Pearsona jer je mjera preklapanja ili povezanosti između neovisnih i ovisnih varijabli (v. Sliku 3).

Značajna vrijednost koeficijenta determinacije jest da primjenom Pearsonovog *R* statističkog podatka i standardne pogreške procjene istraživač može načiniti točnu procjenu intervala u kojem će se nalaziti stvarna korelacija populacije. Ta je mogućnost ostvariva za sve parametarske korelacijske statistike i povezane statistike standardne pogreške. U stvari, čak se i kod neparametarskih koeficijenata korelacije (tj. statistike veličine učinka) može načiniti gruba procjena intervala u koji će pripasti veličina učinka populacije pomoću iste vrste izračuna.

Međutim, mnoge statistike dobivene pomoću računalnog statističkog paketa (kao SAS, STATA ili SPSS) ne daju automatski i statistički podatak o veličini učinka. U većini slučajeva statistički podatak o veličini učinka moguće je dobiti dodatnom naredbom. Primjerice, statistika za veličinu učinka kod ANOVA je *ETA-square*. Naredba SPSS ANOVA automatski ne daje podatke o statistici *Eta-square*, no istraživač može *Eta-square* dobiti kao alternativan test na izborniku ANOVA. Kod nekih statistika, međutim, takav povezani statistički podatak o veličini učinka nije dostupan. Kad statistika o veličini učinka nije dostupna, onda je statistika standardne pogreške za statistički test koji se provodi korisna alternativa u određivanju koliko je statistika točna, te stoga i koliko je precizno predviđanje zavisne na temelju nezavisne varijable.

Correlation Coefficient (which is the full and correct name for the Pearson r correlation, often noted simply as, *R*). If the Pearson *R* value is below 0.30, then the relationship is weak no matter how significant the result. An *R* of 0.30 means that the independent variable accounts for only 9% of the variance in the dependent variable. The 9% value is the statistic called the coefficient of determination. It is calculated by squaring the Pearson *R*. It is an even more valuable statistic than the Pearson because it is a measure of the overlap, or association between the independent and dependent variables. (See Figure 3).

The great value of the coefficient of determination is that through use of the Pearson *R* statistic and the standard error of the estimate, the researcher can construct a precise estimate of the interval in which the true population correlation will fall. This capability holds true for all parametric correlation statistics and their associated standard error statistics. In fact, even with non-parametric correlation coefficients (i.e., effect size statistics), a rough estimate of the interval in which the population effect size will fall can be estimated through the same type of calculations.

However, many statistical results obtained from a computer statistical package (such as SAS, STATA, or SPSS) do not automatically provide an effect size statistic. In most cases, the effect size statistic can be obtained through an additional command. For example, the effect size statistic for ANOVA is the Eta-square. The SPSS ANOVA command does not automatically provide a report of the Eta-square statistic, but the researcher can obtain the Eta-square as an optional test on the ANOVA menu. For some statistics, however, the associated effect size statistic is not availab-

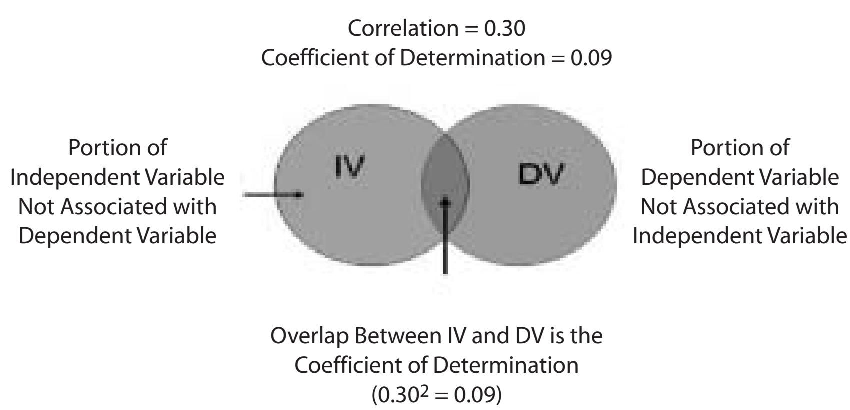

SLIKA 3. Koeficijent determinacije

FIGURE 3. Coefficient of determination

Sažetak i zaključci

Standardna pogreška je mjera raspršenja slična standardnom odstupanju. Dok, međutim, standardno odstupanje pruža informaciju o raspršenju vrijednosti uzorka, standardna pogreška daje informaciju o raspršenju vrijednosti u razdiobi uzorkovanja povezanoj s populacijom od interesa iz koje je uzet uzorak. Statistika standardne pogreške mjeri koliko je uzorak točan ili pouzdan kao procjena parametra populacije. Osobito je važno koristiti standardnu pogrešku za procjenu intervala parametra populacije kada statistički podatak o veličini učinka nije dostupan.

Standardna pogreška nije samo mjera raspršenja i točnosti statistike uzorka. Ona je također važan pokazatelj koliko je statistika uzorka pouzdana procjena parametra populacije. Razmatrajući zajedno takve mjere kao što su veličina učinka, vrijednost *P* te veličina uzorka, veličina učinka može biti vrlo korisno sredstvo istraživaču koji nastoji razumjeti pouzdanost i točnost statistike izračunane za slučajne uzorke.

le. When an effect size statistic is not available, the standard error statistic for the statistical test being run is a useful alternative to determining how accurate the statistic is, and therefore how precise is the prediction of the dependent variable from the independent variable.

Summary and conclusions

The standard error is a measure of dispersion similar to the standard deviation. However, while the standard deviation provides information on the dispersion of sample values, the standard error provides information on the dispersion of values in the sampling distribution associated with the population of interest from which the sample was drawn. Standard error statistics measure how accurate and precise the sample is as an estimate of the population parameter. It is particularly important to use the standard error to estimate an interval about the population parameter when an effect size statistic is not available.

The standard error is not the only measure of dispersion and accuracy of the sample statistic. It is, however, an important indicator of how reliable an estimate of the population parameter the sample statistic is. Taken together with such measures as effect size, p-value and sample size, the effect size can be a very useful tool to the researcher who seeks to understand the reliability and accuracy of statistics calculated on random samples.

Adresa za dopisivanje:
Mary L. McHugh, PhD, RN, BC
School of Nursing
161A Martin Hall
University of Indianapolis
1400 E. Hanna Avenue
Indianapolis
Indiana 46227
USA
e-pošta: Mary.McHugh@uchsc.edu
tel: +1 317 788 3206

Corresponding author:
Mary L. McHugh, PhD, RN, BC
School of Nursing
161A Martin Hall
University of Indianapolis
1400 E. Hanna Avenue
Indianapolis
Indiana 46227
USA
e-mail: Mary.McHugh@uchsc.edu
phone: +1 317 788 3206

Literatura/References

1. *Glass GV, Hopkins KD. (1996). Statistical Methods in Education and Psychology. 3rd ed. Needham Heights, Massachusetts: Allyn and Bacon, 1996.*
2. *Larsen RJ, Marx ML. An Introduction to Mathematical Statistics and Its Applications. 4th ed. Upper Saddle River, New Jersey: Pearson-Prentice Hall, 2006.*
3. *Standard error. Lane DM. HyperStat Online. Available at: http://damidmlane.com/hyperstat/A103397.html. Accessed September 10, 2007.*
4. *Standard error. Allison PD. Available at: http://www.scc.upenn.edu/~Allison4.html. Accessed: October 3, 2007*