

UDK 68.008.311.17

Primljeno 10. 3. 2005.

Primjena statistike u građevinarstvu

Barbara Medanić, Ksenija Čulo

Ključne riječi

statistika,
građevinarstvo,
statističke metode,
istraživanje,
statističke analize

Key words

statistics,
civil engineering,
statistical methods,
research,
statistical analyses

Mots clés

statistique,
génie civil,
méthodes statistiques,
recherches,
analyses statistiques

Ключевые слова

статистика,
строительство,
статистические
методы,
исследование,
статистические
анализы

Schlüsselworte

Statistik,
Bauwesen,
statistische Methoden,
Forschung,
statistische Analysen

B. Medanić, K. Čulo

Stručni rad

Primjena statistike u građevinarstvu

Polazeći od tvrdnje da se statističke metode malo primjenjuju, a ponekad, i pogrešno u članku se upozorava na potrebu populariziranja i jače edukacije o primjeni suvremenih statističkih metoda u građevinarstvu. Navode se primjeri neodgovarajuće primjene statističkih proračuna naročito u nekim eksperimentalnim istraživanjima, iz čega proizlaze i neadekvatni zaključci. Ističe se potreba promjene odnosa prema primjeni suvremenih statističkih analiza u građevinskoj znanosti i struci.

B. Medanić, K. Čulo

Professional paper

Use of statistics in civil engineering

Starting from the assertion that statistical methods are used quite seldom, and sometimes rather inadequately, in the field of civil engineering, the authors caution that a greater attention should be placed on the popularization and education activities favouring the use of modern statistical calculations in this field. Practical examples are given of inadequate use of statistical calculations, particularly in some experimental research operations, where this may be the cause of inadequate conclusions. The need to change the current perception with respect to the use of modern statistical analysis in the scientific and practical fields of civil engineering is emphasized.

B. Medanić, K. Čulo

Ouvrage professionnel

Emploi de la statistique en génie civil

En partant de l'assertion que les méthodes statistiques sont utilisées assez rarement, et quelquefois de manière inadéquate, dans le domaine du génie civil, les auteurs soutiennent qu'une attention plus grande devrait être accordée à la popularisation et à l'étude des calculs statistiques modernes dans ce domaine. Les exemples pratiques sont donnés d'un emploi inadéquat des calculs statistiques, notamment dans les recherches expérimentales, où cela peut mener à des conclusions inadéquates. La nécessité de changer la perception courante par rapport à l'usage des analyses statistiques modernes dans les recherches et dans le travail pratique en génie civil est mise en relief.

B. Меданич, К. Чуло

Отраслевая работа

Применение статистики в строительстве

Исходя из утверждения о небольшом применении статистических методов, а часто и ошибочно, в работе обращается внимание на необходимость популяризации и лучшего обучения по применению современных статистических методов в строительстве. Приводятся примеры несоответствующего применения статистических расчётов особенно в некоторых экспериментальных исследованиях, из чего проистекают и неадекватные выводы. Подчёркивается необходимость изменения отношения к применению современных статистических анализов в строительной науке и отрасли.

B. Medanić, K. Čulo

Fachbericht

Anwendung der Statistik im Bauwesen

In Bezug zur Behauptung dass man statistische Methoden sehr spärlich anwendet, manchmal auch falsch, wird im Artikel darauf aufmerksam gemacht dass im Bauwesen die Anwendung zeitgemässer statistischer Methoden popularisiert und besser erklärt werden sollte. Angeführt sind Beispiele unentsprechender Anwendung statistischer Berechnungen, besonders in einigen experimentalen Forschungen, woraus auch unadäquate Schlüsse folgen. Hervorgehoben ist die Notwendigkeit der Änderung der Stellungnahme zur Anwendung zeitgemässer statistischer Analysen in der Bauwissenschaft und -Praxis.

Autori: Prof. dr. sc. **Barbara Medanić**, dipl. ecc.; prof. dr. sc. **Ksenija Čulo**, dipl. ecc., Građevinski fakultet Sveučilišta J. J. Strossmayera u Osijeku

1 Uvod

Dugogodišnje istraživačko i nastavno djelovanje u području strukturiranja i funkcioniranja građevinarstva kao djelatnosti općenito i građevinskih poslovnih tvrtki kao njezinih sastavnica učvrstilo je spoznaju kako je statistika ovdje malo znana i malo iskorištena.

Ako se njome i koristi, onda je to samo u području pripreme građevinske proizvodnje, projektiranja i građenju širokog spektra građevina, i u nešto manjoj mjeri pri ispitivanju njihovih konstruktivnih i drugih svojstava - odnosno obilježja.

Primjena statistike tada se obično svodi na tabelarno i grafičko prikazivanje određenih rezultata laboratorijskih mjerenja ili sondaža *in situ* i njihovu usporedbu s određenim modelima, odnosno teoretskim vrijednostima i krivuljama za promatranu pojavu (svojstva tla, stabilnost i dinamika konstrukcije, ponašanje ugrađenih materijala u različitim uvjetima i pri raznim opterećenjima i slično), koje kao teoretska rješenja vrlo često nude brojni računalni programi kojima se služe inženjeri.

U drugim se segmentima građevinske djelatnosti i poslovanja građevinskih poslovnih tvrtki statistika rabi veoma malo.

Nisu znani slučajevi iz recentne nacionalne prakse koji bi upućivali na zaključak da su statistika i njezine metode iskorištavani u području planiranja poslovanja, u području analize poslovanja i poslovnih rezultata, financiranja, iskorištavanja instaliranih strojnih kapaciteta, u području iskorištavanja raspoloživog fonda radnog vremena direktno i indirektno proizvodnih radnika, inženjerske kontrole kvalitete ili pak u području poslovnog odlučivanja i globalnog upravljanja kvalitetom građevinskog poslovanja, što je vrlo raširena praksa u građevinarstvu razvijenog dijela svijeta.

U našim se uvjetima može naići samo na uporabu odgovarajuće definirane statistike u području znanstvenog tretiranja specifičnih problema građevinske struke, iako se i tamo može naići na dokaze nepoznavanja geneze primijenjenih metoda, problematičnog prikupljanja podataka za statističku obradu rezultata područnih istraživanja, te sa stajališta statističke pouzdanosti problematično interpretiranje priskrbljenih rezultata.

Postavlja se pitanje zašto se statistika kao znanstvena disciplina ne rabi u većoj mjeri i zašto se i pri uporabi često ne iskorištava na pravi način?

Odgovor je moguće naći u manjkavoj izobrazbi tijekom prijediplomske, diplomske i poslijediplomske nastave u studiju građevinarstva, ali i u drugim studijima, čije će diplomirane studente građevinarstvo kao svoje buduće uposlenike uključiti u poslovanje ili upravljanje. Prvi

tijekom studija ne nauče statistiku, dok stručnjaci drugih profila angažirani u građevinarstvu njome teoretski ovlađuju, ali je mogu tek ograničeno primjenjivati jer ne poznaju posebnosti građevinske proizvodnje i građevinskog poslovanja.

Statistiku je stoga kao bitni element širih konceptijskih znanja za upravljanje i rukovođenje u većoj mjeri potrebno uključiti u obrazovne sadržaje prijediplomske, diplomske i poslijediplomske nastave na studiju građevinarstva. Samo će tako budući inženjeri - kao dobri poznavatelji građevinske struke - moći na pravi način upotrijebiti statistiku kao znanstvenu disciplinu pri izučavanju problema koji se pojavljuju u građevinskoj proizvodnji i pri odlučivanju o rješavanju upravljačko rukovodnih problema.

Statistiku za koju se ovim radom zauzimamo potrebno je pritom pojednostaviti i popularizirati, jer će se ona u praksi primjenjivati samo onda ako je u prethodnom edukacijskom procesu budućim korisnicima bila logično i razumljivo iznijeta i približena.

2 O statistici kao znanstvenoj disciplini

Mislimo na statistiku kao znanstvenu disciplinu koja najšire definirano proučava masovne pojave, njihova svojstva i uzroke.

To se proučavanje uglavnom odvija na dijelu relevantne masovne pojave - uzorku, da bi se onda, na određenoj razini pouzdanosti, izveli zaključci o cijeloj pojavi, odnosno osnovnom skupu. Dakle, masovna se pojava ne proučava iscrpnim nego reprezentativnim promatranjem.

U funkciji tako definirana globalnog zadatka statistika se koristi bogatim instrumentarijem, odnosno brojnim statističkim modelima i metodama, a u tome se uvelike oslanja na teoriju vjerojatnosti.

Oslanjanje na teoriju vjerojatnosti daje unaprijedenu definiciju moderne statistike, na koju se u sve većoj mjeri gleda kao i na znanost o donošenju odluka u uvjetima neizvjesnosti, koja je podjednako vezana uz induktivni i deduktivni proces, odnosno uz matematičke i znanstvene postupke u istraživanju.

Tako definirana, moderna je statistika zaokupljena (1) problemima planiranja i programiranja brojnih istraživanja, odnosno eksperimenata za koje je prethodno potrebno prikupiti relevantne podatke za zaključivanje, (2) problemima sređivanja i analiziranja prikupljenih podataka, (3) problemima odlučivanja o tome koje je interpretacije i zaključke moguće i dozvoljeno izvesti iz prikupljenih podataka, (4) problemima određivanja do koje su mjere izvedeni zaključci pouzdani i (5) problemima matematičke prosudbe statističkih metoda primijenjenih u fazama (1) do (4).

Pod tim se statističkim metodama razumijevaju postupci uporabljeni pri definiranju i planiranju istraživanja, odnosno planiranja eksperimenata, te postupci upotrijebljeni u prikupljanju, analizi i interpretiranju podataka. Riječ može biti o skupini deskriptivnih metoda i skupini metoda statističkog zaključivanja.

O suvremenoj je statistici prikladno razmišljati istodobno i kao o fundamentalnoj i kao o primijenjenoj znanstvenoj disciplini, koja je uključena u kreiranje, razvoj i primjenu istraživačkih postupaka na način da neizvjesnost zaključivanja bude procjenjivana u uvjetima vjerojatnosti.

Takav odnos prema neizvjesnosti zaključivanja ima sva obilježja znanstvenog pristupa istraživanim fenomenima, odnosno obilježja primjene znanstvenih metoda u najširem značenju.

3 Istraživački pristup fenomenima i mjesto statistike u njemu

Izvorište svakog istraživanja jest stvarnost koju istraživanjem želimo upoznati, o njoj izvesti odgovarajuće zaključke i donijeti odluke o tome kako na nju djelovati i kako ju mijenjati.

Upoznavanje te stvarnosti moguće je na dva glavna istraživačka načina: njezinim prevođenjem u teoretsku apstrakciju ili njezinim prevođenjem u eksperimentalnu apstrakciju.

Istraživanje stvarnosti prevedene u teoretsku apstrakciju pretpostavlja: prethodnu izgradnju matematičkog sustava, obavljanje matematičkih manipulacija, matematičko zaključivanje, teoretsku interpretaciju matematičkih zaključaka, logičko zaključivanje, indukciju i vraćanje u stvarnost.

Istraživanje stvarnosti prevedeno u eksperimentalnu apstrakciju pretpostavlja: izradu eksperimentalnog plana-modela, eksperimentiranje, promatranje, statističku interpretaciju rezultata eksperimentiranja, logičko zaključivanje, indukciju i vraćanje u stvarnost na određenoj razini pouzdanosti.

Mjesto moderne statistike pripada području znanstvenog pristupa istraživačkim fenomenima, istraživanju stvarnosti prevedene u eksperimentalnu apstrakciju, fazi statističke interpretacije rezultata eksperimentiranja s uporištem u teoriji vjerojatnosti.

4 Sadržaj suvremene statistike

Sadržaj suvremene statistike obuhvaća statističke metode prikupljanja, grupiranja i analize relevantnih podataka, te metode statističkog zaključivanja upotrebom statističkih modela za usporedbu stvarnog i očekivanog

stanja, računa vjerojatnosti, metode uzoraka za procjenu parametara osnovnog skupa na temelju uzorka i specifične metode statističkog testiranja eksperimentalnih hipoteza, na koje se u konačnici oslanja proces odlučivanja u najširem smislu.

Metode prikupljanja podataka najčešće su odgovarajuće konstruirane primarne tabele s pripadajućim brojem ulaza.

U njih unijeti podaci se za potrebe planirane statističke analize u odnosu na promatrana obilježja grupiraju u razrede različitih veličina, kako bi na površinu «isplivala» učestalost promatranog obilježja kod jedinica promatranog skupa fenomena. U svezi s ovim grupiranjem potrebno je ovladati pojmom razreda općenito, otvorenih i zatvorenih razreda, njihovom donjom i gornjom granicom te razrednom sredinom.

Kako se u razrede redovito grupiraju obilježja, potrebno je razlikovati kontinuirana i diskontinuirana obilježja.

Učestalost javljanja promatranih obilježja označava frekvenciju.

Frekvencije mogu biti apsolutne i relativne, ovisno o tome kako je definiran cilj statističke analize.

Grupirane podatke za statističku analizu uobičajeno je zbog prvog dojma prikazati i grafički - u obliku stupaca ili linijom koja dotiče sredinu svakog stupca.

Prvi oblik grafičkog prikazivanja grupiranih podataka naziva se histogramom, drugi pak poligonom frekvencija.

Iz grupiranih se podataka izračunavaju parametri preko kojih će se bolje upoznati svojstva promatranog fenomena.

Riječ će biti o srednjim vrijednostima, o mjerama disperzije, o mjerama zaobljenosti ili o mjerama asimetrije.

U grupi srednjih vrijednosti naći će se obična aritmetička sredina, aritmetička sredina grupiranih podataka, aritmetička sredina relativnih brojeva, vagana ili ponderirana aritmetička sredina, geometrijska sredina, zatim medijan kao pozicijska srednja vrijednost (s kvartilima i percentilima) i mod kao najčešća vrijednost obilježja unutar promatranog fenomena.

U odnosu prema izračunatoj srednjoj vrijednosti obilježja nekog osnovnog skupa prisutna su veća ili manja odstupanja.

Ta se odstupanja od izračunane srednje vrijednosti mjere standardnim devijacijama i preko njih zaključuje u obilježjima, no prije svega homogenosti analizirane distribucije u odnosu na promatrano obilježje.

Standardna se devijacija izvodi iz prethodno izračunane varijance kao kvadratnog odstupanja individualnih obilježja od izračunane srednje vrijednosti.

Standardna devijacija i varijanca imaju uporište u prvome i drugome svojstvu aritmetičke sredine (nula i minimum), pri čemu je na ovom drugom svojstvu razvijena metoda najmanjih kvadrata, kao kasnija podloga trendu i regresijskoj analizi koje se u okviru moderne statistike rabe za analiziranje vremenskih serija, odnosno vremenski definiranih varijabli. U vezi s tim segmentom statističke analize potrebno je ovladati metodom linearnoga, krivolinijskoga i eksponencijalnoga trenda te metodama linearne i multiple regresije.

Na ovaj se smjer statističke analize nastavlja korelacijska analiza, u svezi s kojom je potrebno ovladati metodom jednostavne i multiple korelacije, koja –izražena kao oblik, smjer i intenzitet zavisnosti analiziranih varijabli– može biti stvarna i prividna. Mjeri se koeficijentom korelacije koji odražava ukupno registriranu povezanost varijabli, a obuhvaća dio veze koji je moguće pripisati uzročno-posljedičnom odnosu među varijablama i dio veze koji je posljedica djelovanja slučajnih čimbenika. Uzročno posljedično determinirana veza među varijablama mjeri se koeficijentom determinacije.

Utjecaj se slučajnih čimbenika mjeri razlikom između koeficijenta korelacije i koeficijenta determinacije.

Kako je predmet izučavanja u okviru statistike uvijek neka masovna pojava, unaprijed je znano da se zbog mnogo razloga ispitivanje njezinih svojstava neće moći obaviti obuhvatom svih njezinih elemenata, tj. iscrpnim statističkim promatranjem. Zbog nemogućnosti obuhvata svih tih elemenata, potrebnog vremena i pratećih troškova bit će potrebno primijeniti reprezentativno statističko promatranje, koje će omogućiti zaključivanje o obilježjima masovne pojave.

Reprezentativno statističko promatranje omogućuje točno primijenjena metoda uzoraka, što pretpostavlja slučajno izabrani uzorak kao dio cjeline, čija veličina ovisi o željenoj razini pouzdanosti zaključivanja o svojstvima osnovnog skupa na temelju karakteristika izračunanih iz uzorka.

Pri zaključivanju o svojstvima osnovnog skupa na temelju uzorka čini se pogriješka procjene. Ta se pogriješka izražava u standardnim devijacijama, tako da procjene na temelju uzorka nisu jedna vrijednost, nego raspon u kojem će se sa željenom pouzdanosti sigurno nalaziti odgovarajuća karakteristika osnovnog skupa.

Uporabom metode uzoraka obavlja se (a) procjena parametara osnovnog skupa iz kojeg je uzorak izabran (njegova aritmetička sredina, medijan, mod, standardna devijacija, odnosno standardna pogriješka, mjera asimetrije i mjera zaobljenosti) i (b) testiranje hipoteza o karakteristikama nepoznatoga osnovnoga skupa iz kojeg je analizirani uzorak najvjerojatnije izabran (nul-hipoteza, hi-kvadrat test, T-test i drugo).

Pravilo je pritom da se u statističkoj analizi s uzorkom postupa kao s osnovnim skupom, a zatim se dobiveni analitički rezultati u odnosu na željenu pouzdanost zaključivanja i toleriranu pogriješku procjene testiraju.

5 Najčešći promašaji pri uporabi metoda suvremene statistike

Prevođenje stvarnosti u eksperimentalnu apstrakciju pristanje je na svim znanstvenim područjima.

Ta se stvarnost u okviru odgovarajuće kreiranih eksperimenata uvijek nastoji upoznati reprezentativnim statističkim promatranjem, na temelju kojeg se nakon okončanoga eksperimenta izvode zaključci o obilježjima konačnih, a vrlo često i beskonačnih osnovnih skupova.

U okviru kreiranog se eksperimenta različitim intenzitetom obavljaju promatranja (kvantitativna ili kvalitativna mjerenja), bilježe se, grupiraju i analiziraju, te na temelju tako izvedenog eksperimenta izvode zaključci o svojstvima masovne pojave koju se u okviru kreiranog eksperimenta nastojalo upoznati.

Problemi zaključivanja nastaju međutim u početnoj fazi kreiranja eksperimenta. Primjerice, kada se u građevinarstvu želi ispitati svojstva tla prije temeljena, opterećenje neke konstrukcije, kvaliteta i otpornost betona ili opeke i drugo, prva se pogriješka u budućem zaključivanju čini odabirom «uzorka» koji to po svojim obilježjima najčešće nije.

U eksperiment se vrlo često uključuje određeni dostupni broj jedinica opažanja, one se mjere ili analiziraju, zatim se «uspoređuju» u odnosu na neki standard ili normativ te tako izvode zaključci o osnovnom skupu iz kojeg naš «uzorak» uopće nije bio izabran.

Svrha eksperimentiranja na taj je način promašena.

Uzorak na temelju kojeg će se u okviru eksperimenta pokušati upoznati svojstva osnovnog skupa - bez obzira na njegov sadržaj- mora biti slika toga osnovnoga skupa u malom, on dakle mora biti reprezentativan.

Reprezentativnost uzorka ovisi o načinu izabiranja jedinica osnovnog skupa u uzorak, a to izabiranje mora biti slučajno, kako bi svaka jedinica osnovnog skupa imala isti izgled da bude izabrana u uzorak.

Slučajnom izabiranjem jedinica osnovnog skupa u uzorak prethodi izračunavanje potrebne veličine uzorka za željenu razinu pouzdanosti zaključivanja o karakteristikama osnovnog skupa na temelju karakteristika uzorka.

Tek kada je izračunatu potrebna veličina uzorka za željenu razinu pouzdanosti zaključivanja, pristupa se slučajnom odabiru jedinica (konačnog ili beskonačnog) osnovnog skupa u uzorak.

Na raspolaganju su nam tablice slučajnih brojeva, ni u kom slučaju rješenja kojima se u praksi pribjegava (svaka 50. jedinica, očitavanje rezultata mjerenja svaki dan u isto vrijeme i slično).

Ako se metodom uzoraka želi ispitati otpornost nekoga građevnoga materijala (opeke, betonskih blokova, na primjer), svojstva tla na kojem će se graditi, iskorištavanje radnog vremena radnika na gradilištu, iskorištavanje radnog vremena strojeva, ili što drugo, prvi je posao odrediti razinu pouzdanosti odlučivanja na temelju uzorka, izračunati za to potrebnu veličinu uzorka, osigurati uvjete za slučajni odabir potrebnog broja jedinica osnovnog skupa u uzorak te identificirati jedinice osnovnog skupa koje su izabrane u uzorak.

U navedenom primjeru, pri ispitivanju otpornosti ili nekih drugih svojstava građevnih materijala to znači odluku koja opeka iz ukupne količine proizvedenih opeka ili betonskih blokova ide u uzorak - to ni u kom slučaju nisu one opeke ili betonski blokovi koje proizvođači tko zna kakvim kriterijima izbora zbog atesta dostavljaju na ispitivanje u stručnu ili znanstvenu ustanovu.

Ista je stvar i s ispitivanjem svojstava tla.

Uzorci tla moraju na gradilištu biti uzeti odgovarajućom procedurom.

Površina gradilišta mora za tu svrhu biti prikazana u uvjetima mreže na kojoj će se unaprijed, također s pomoću slučajnih brojeva, odrediti potreban broj mjesta i dubina bušenja - dakle, to ne mogu biti uzorci tla koje bez nadzora znalca statistike i početnog nadzora inženjera na terenu uzmu sami «bušači». Tek ispunjavanjem ovih prethodnih uvjeta može se obaviti pouzdana inženjerska analiza na koju će se osloniti buduće temeljenje određene objekta.

Za analizu iskorištavanja radnog vremena radnika i pojedinih vrsta strojeva na gradilištu, u prethodnom je postupku također potrebno - ovisno o željenoj pouzdanosti zaključivanja o onome što se neprekidno događa na gradilištu - odrediti za to potrebnu veličinu uzorka, tj. broj potrebnih promatranja i njihova registriranja *in situ*.

Potrebni se broj promatranja mora realizirati slučajno, ali ne onako kako se to najčešće čini u praksi kada se svakih pola sata ili sat bilježi što nam rade radnici ili strojevi na gradilištu, a ako ne rade, zbog čega.

Ovisno o željenoj razini pouzdanosti zaključivanja o osnovnom skupu (ukupnoj godišnjoj proizvodnji opeke ili betonskih blokova, o svojstvima svakog centimetra površine i dubine tla na kojem će se graditi, o svakoj raspoloživoj minuti radnog vremena radnika i strojeva na gradilištu) izračunat će se potrebna veličina uzorka, a zatim taj potrebni broj jedinica osnovnog skupa koje

ulaze u uzorak i slučajno izabrati, kako se ne bi dovela u pitanje reprezentativnost uzorka i na startu ugradila sistematska pogreška procjene karakteristika osnovnog skupa na osnovi uzorka.

Izborom reprezentativnog uzorka iz osnovnog skupa i njegovom analizom omogućuje se (a) procjenjivanje parametara osnovnog skupa na temelju uzorka i procjena totala osnovnog skupa i (b) testiranje raznih modaliteta hipoteza (istinitih koje prihvaćamo i lažnih koje odbacujemo).

U obzir dolazi testiranje tzv. «nul-hipoteze» gdje pretpostavljamo da je razlika između aritmetičke sredine uzorka i aritmetičke sredine osnovnog skupa jednaka nuli, zatim testiranje gornje i donje granice intervala procjene ili samo jedne od tih granica, Hi-kvadrat test, Studentova distribucija i mnoge druge metode koje sadrži svaki suvremeni udžbenik moderne statistike.

Nakon izbora uzorka uobičajeno se primjenjuju metode inferencijalne statistike, kojima se testiraju pretpostavke o vrijednosti izabranih parametara osnovnog skupa.

Testiranja pretpostavki grupiraju se u dvije osnovne skupine: jednosmjerna i dvosmjerna testiranja, a uobičajeni test pokazatelj naziva se z-testom te se ovisno o njegovoj vrijednosti hipotezom zapisana pretpostavka prihvaća ili odbacuje na izabranoj razini signifikantnosti.

Osim z-test pokazatelja, inferencijalna statistika razumijeva i učestalu uporabu F-testa (analiza poznata pod nazivom ANOVA, tj. «analiza varijance»), te hi-kvadrat testa kao jedne od metoda neparametrijske statistike, koja se učestalo rabi za istraživanje pretpostavki vezanih uz podatke prikazane u kontingencijskoj tablici, odnosno za analizu nominalnih i ordinalnih varijabli.

Sve se navedene metode ubrajaju u metode univarijatne statistike, dok se metode kojima se istodobno analiziraju podaci više varijabli nazivaju metode multivarijatne statistike (diskriminacijska analiza, *cluster* analiza, faktorska analiza itd.). Te su se metode osobito razgranale sredinom minulog stoljeća, te u recentnoj praksi svakodnevno doživljavaju sve širu primjenu i nadogradnju. Kako je njihova osnovna odlika otkrivanje latentnih struktura u podacima, njihovo bi izučavanje u građevinarstvu omogućilo poboljšanje ne samo građevinarstva kao struke, nego i nova otkrića u primjeni navedenih metoda u znanstvenim istraživanjima u području građevinarstva.

6 Uzroci promašaja u eksperimentiranju

Najčešći promašaji u eksperimentiranju vezani su uz način kreiranja samog eksperimenta, uz utvrđivanje potrebnog broja snimanja, mjerenja ili pokusa, uz način odabiranja jedinica osnovnog skupa u uzoraka, tj. okvire

eksperimenta, uz proces zaključivanja o obilježjima osnovnog skupa na temelju uzorka.

Tako koncipirani i izvedeni eksperimenti - odnosno eksperimentalna promatranja i mjerenja uzrok su neodgovarajućem izvođenju primarnih zaključaka o osnovnom skupu (ukupnoj godišnjoj proizvodnji, globalnoj otpornosti pojedinih vrsta građevnih materijala, stabilnosti određene konstrukcije, svojstvima površine i dubine tla s okolišem na kojem je pri građenju potrebno realiziranje građenja pojedinih vrsta objekata i drugo) na temelju eksperimenta.

Često se već u startu defektni zaključci o osnovnom skupu na temelju eksperimenata i eksperimentalnih hipoteza ili uopće ne testiraju ili se testiraju pogrešno, što u konačnici izvedene eksperimentalne zaključke pri prevođenju eksperimentalne apstrakcije u stvarnost čini još upitnijim, pogotovo onda ako bi trebali poslužiti za korigiranje stvarnosti, odnosno dotadašnje prakse i u nju uključenog rizika.

Stvarni uzrok takvu slijedu događaja jest nedostatak odgovarajućih općih znanja o statistici, statističkim modelima i metodama statističkog analiziranja fenomena, potenciranih uvjerenjem «ljudi od struke» da im ta znanja ne može pružiti nitko iz drugih struka, što je u osnovi pogrešno.

Kreiranje eksperimenta u svijetu je multidisciplinarni skupni posao. Ljudi «od struke» (u području tehnike, medicine, kemije i slično) znaju što eksperimentom žele saznati ili provjeriti, ali ne znaju kako.

To znaju poznavatelji principa i sadržaja statističke analize koji će ih informirati o tome na kojim principima mogu i trebaju kreirati pojedini eksperiment i na kojoj razini pouzdanosti (95% ili 99%) mogu na osnovi eksperimenta donositi zaključke o stvarnosti koju nastoje bolje upoznati na temelju odgovarajuće kreiranog i provedenog eksperimenta.

Ono što ovi drugi ne znaju vezano je uz područje i sadržaj promatranja ili mjerenja u okviru statističkog eksperimentiranja, što znači da će se kao članovi skupine odlično nadopunjavati.

LITERATURA

- [1] Artenjak, J.: *Poslovna statistika*, Ekonomska-poslovna fakulteta, Maribor, 1997.
- [2] Lowrenc, L. Lapin: *Statistic for Modern Business Desions*. San Diego, New York, Chicago, Austin, London, Sydney, Tokyo, Fourth edition, Toronto, 1987.

Osnovni su uvjeti za ovo nadopunjavanje odgovarajuća granična znanja, što znači da poznavatelji područja moraju ovladati stanovitim znanjima o statistici, a poznavatelji se statistike u pripreмноj fazi moraju potvrditi da ovladaju određenim znanjima o području na kojem će - nakon prevođenja stvarnosti u eksperimentalnu apstrakciju - biti provedeno eksperimentiranje i potom statistička analiza njime dobivenih rezultata.

S uporištem u njima bit će obavljeno statističko zaključivanje, indukcija i ponovno vraćanje u stvarnost na koju će -ovisno o cilju obavljenog istraživanja- biti potrebno djelovati, odnosno s uporištem u statističkoj analizi donositi čitav niz proizvodnih, poslovnih ili razvojnih odluka.

7 Potrebne mjere

Metodološku važnost i domet statističke analize u proučavanju stvarnosti na bilo kojem području, a posebice na području tehnike, tehnologije i menadžementa, potrebno je prije svega popularizirati u mnogo većoj mjeri nego što je to slučaj u našoj recentnoj obrazovnoj praksi.

Osnovna znanja o sadržaju moderne statistike i njezinim modelima i metodama potrebno je kao šira koncepcijska znanja usvojiti tijekom dodiplomske i diplomske nastave, a produbiti ih tijekom poslijediplomske nastave u kojoj se obavlja osposobljavanje i provodi eksperimentiranje oslonjeno na temelje metode uzoraka i metode testiranja polaznih hipoteza koje su kreiranju eksperimenta prethodile.

Osposobljavanje za multidisciplinarni skupni rad potrebno je provoditi u okviru specijalističkog studija kojem redovito pristupaju stručnjaci različitih područja, ali ujednačenog nivoa startnih temeljnih znanja o zajedničkim obilježjima suvremene statistike.

Tek afirmiranim skupnim radom na kreiranju i provođenju eksperimenta, te specijalističkim interpretiranjem dobivenih rezultata u kasnijim fazama, bit će moguće izvođenje zaključaka na određenoj razini pouzdanosti i držanje rizika odlučivanja s tim u svezi pod razložnom kontrolom.

- [3] Sikavica, P.; Skoko, H.; Tipurić, D.; Dalić, M.: *Poslovno odlučivanje. Teorija in praksa donošenja odluke*, Informator, Zagreb, 1994.
- [4] Hammond J. S.; Ralph, L. Keeney; Raiffa, H.: *Pametne odlučitve*. Ljubljana, Gospodarski vestnik, 2000.