Vjerojatnost u doba COVID-19

Boris Čulina[1]

Najteže je bilo raditi kada smo u Hrvatskoj svaki dan imali "bus umrlih", a u Split bi svaki tjedan "dolazio" jedan takav autobus. Bilo je previše nepotrebnog umiranja i takva vas situacija baca u depresiju i stalno sebi ponavljate jedno te isto pitanje:
Je li moguće da ljudi ne razumiju i da radije umiru negoli se cijepe?

A umirati od korone je grozno, mučno. Nije to smrt od infarkta gdje te "prikine" i gotovo, više te nema. Ovdje ljudi pate i umiru u strašnim mukama.

izv. prof. dr. sc. Ivo Ivić, predstojnik Klinike za infektologiju KBC-a Split i šef COVID bolnice na Križinama

Zašto se to dogodilo? Ovdje ćemo se baviti samo jednim uzrokom: nerazumijevanjem znanosti. I samo jednim nerazumijevanjem u tom uzroku: nerazumijevanjem pojma vjerojatnosti.

Determinizam i(ili) slučajnost

Kažemo da se proces odvija **deterministički** ako je njegovo buduće stanje posve određeno početnim stanjem. Na primjer, padanje predmeta s neke visine je determinirano početnim uvjetima: početni položaj i početna brzina težišta, te početni rotacijski položaj i početna kutna brzina, posve određuju položaj i brzinu težišta tijela, kao i svakog drugog njegovog djelića, u svakom trenutku padanja. Ako se uz iste uvjete proces odvija na različite načine tada govorimo o **slučajnoj pojavi**. Bacanje igraće kocke je primjer takve pojave.

Obično se smatra da su determiniranost i slučajnost međusobno oprečni pojmovi. Je li zaista tako? Kad pustimo tijelo s određene visine (uvijek isti početni uvjet), ako bismo dovoljno precizno mjerili vrijeme njegovog pada, uvijek bismo dobili nešto drugačiji rezultat, jer padanje ovisi o mnoštvu faktora koje ne možemo kontrolirati (otpor zraka, gibanje zračne mase, oblik tijela,...). Tako je ovdje i slučaj prisutan, mada je determinizam dominantan. S druge pak strane, ako bismo prilikom bacanja igraće kocke mogli točno odrediti početne uvjete (položaj i brzinu centra mase, početni rotacijski položaj i kutnu brzinu), po zakonima klasične fizike, gibanje igraće kocke je deterministički određeno. Tako je ovdje i determinizam prisutan, mada slučaj dominira. Determinizam i slučaj su uvijek prisutni, samo je pitanje što dominira. *Pitanje determiniranosti i slučaja je u osnovi pitanje opisa pojave: da li pojavu opisati na deterministički ili stohastički*[2] *način*. Zato ćemo nadalje govoriti o determinističkim i vjerojatnosnim (stohastičkim) modelima opisa pojava. U pojedinim situacijama treba odabrati model određenog tipa (ili kombinaciju modela raznih tipova) koji daje zadovoljavajući opis situacije. Po klasičnoj fizici, svijet je deterministički, a slučaj je rezultat naše nemogućnosti kontrole svih parametara procesa. Po kvantnoj fizici, u njenoj standardnoj interpretaciji, slučaj je nužan dio opisa svijeta: determinirati možemo samo

[1] Autor je profesor Visoke škole u trajnom zvanju na Veleučilištu Velika Gorica;
e-pošta: `borisculina@vvg.hr`.

[2] Stohastika: nauka o slučaju.

vjerojatnost da se nešto dogodi. Klasična fizika i kvantna fizika su dvije univerzalne teorije, dva velika modela kojima opisujemo svijet. Jedna se bazira na determinizmu, druga na slučajnosti.

Razmotrimo situaciju padanja tijela s visine h, tipičnu situaciju u kojoj primjenjujemo deterministički pristup. U školi smo naučili da će tijelo (preciznije: težište tijela) nakon vremena padanja t prijeći put s i imati brzinu v, koje određujemo po formulama

$$s = \frac{1}{2}gt^2, \quad v = gt$$

gdje je $g = 9.81\ \mathrm{ms}^{-2}$, konstanta slobodnog pada. Ali isto tako znamo iz škole da ove formule vrijede za slobodan pad u vakuumu. Za stvarni pad na Zemljinoj površini one vrijede tek približno, za teža tijela i padanje s nevelike visine. Ako su brzine veće tada više dolazi do izražaja otpor zraka. U takvim slučajevima se obično smatra da sila otpora zraka ovisi približno o kvadratu brzine pa je ukupna sila na tijelo $F = mg - kv^2$, gdje je k konstanta za dano tijelo i dane parametre zraka. Tada se brzina i prijeđeni put računaju po sljedećim formulama:

$$s = \frac{m}{k} \ln\cosh \frac{t}{\sqrt{\frac{m}{kg}}}, \quad v = \sqrt{\frac{mg}{k}} \operatorname{tgh} \frac{t}{\sqrt{\frac{m}{kg}}}.$$

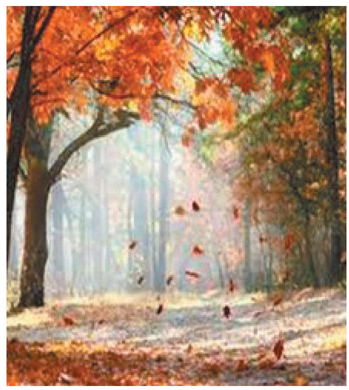

Ovdje nije važno poznavati funkcije cosh (kosinus hiperbolni) i tgh (tangens hiperbolni). Treba samo primijetiti da je model očigledno kompliciraniji. Ali i on daje tek približno rješenje. Model koji bi davao točnije rješenje trebao bi obuhvatiti i strujanje zraka, temperaturu, vlažnost, tlak, vibracije, oblik padajućeg tijela,... Sve točniji modeli bi bili sve kompliciraniji. No, ma kako bili komplicirani ne bismo njima uspjeli opisati najobičnije padanje lista u jesen pod naletom vjetra.

Deterministički model ovdje gubi snagu opisa jer se sad već radi o slučajnoj pojavi: pod istim početnim uvjetima koje možemo kontrolirati, listovi će padati na različite načine.

Iz ovog primjera možemo izvući opću pouku o tome što su deterministički modeli i kako ih primjenjujemo. Ugrubo govoreći, *deterministički modeli su skupovi funkcija koje determiniraju jedne veličine pomoću drugih. Zato je matematika determinističkih modela u osnovi matematika funkcija.* Matematika može ponuditi razne modele, no onaj koji ih primjenjuje mora odrediti koji su mu modeli dovoljno dobri. Modeli su sami po sebi matematički modeli, dio matematike, dok način njihove upotrebe nije više matematika već dio znanosti koja se bavi određenim područjem. Npr. u slučaju pada u zrakopraznom prostoru na površini Zemlje, matematika može ponuditi razne modele kako prijeđeni put s ovisi o vremenu padanja t:

$$s = kt, \quad s = kt^2, \quad s = kt^3, \quad s = \frac{k}{t^2}, \quad s = k\ln(at), \ldots$$

Fizika je odabrala koji model odgovara realnosti: $s = \frac{1}{2}gt^2$. No i ovaj model je aproksimacija jer g ovisi o mjestu na Zemljinoj površini.[3] Pošto on ovisi i o rasporedu

[3] Ovaj mali model se može teorijski izvesti iz "velikih" i "boljih" modela – iz Newtonova zakona gravitacije – ili još boljeg modela – opće teorije relativnosti. Ali i ti najbolji modeli klasične fizike imaju svoje uvjete primjenjivosti i eksperimentalno potvrđene točnosti.

masa u blizini tog mjesta i o udaljenosti od površine, najpreciznije ga možemo odrediti eksperimentalno. Ako pak analiziramo realnu situaciju, padanje stvarnog tijela u stvarnoj situaciji na Zemljinoj površini, tad možemo koristiti kompliciranije modele koji nam daju točnije rezultate, čak uključujući i vjerojatnosne modele, ako je potrebno. *Cilj svakog modeliranja je naći što jednostavniji model koji daje dovoljno točne rezultate za naše potrebe.* Kad napravimo neki model nastojimo ga testirati uspoređujući vrijednosti koje on predviđa s vrijednostima koje eksperimentalno utvrdimo. Ako je to podudaranje dovoljno dobro, odnosno ako sa stajališta problema koji želimo riješiti dobivena odstupanja nemaju važnost, tada prihvaćamo taj model. Ako nije tako tada tražimo bolji model, koji je često i kompliciraniji. Vidjet ćemo da isto vrijedi i za vjerojatnosne modele.

Vjerojatnosni modeli

Kao što determinističke modele koristimo u situacijama u kojima dominira determinizam, tako vjerojatnosne modele koristimo u situacijama kada dominira slučaj. U školi se obično familijariziramo s determinističkim modelima, dok su nam vjerojatnosni modeli manje poznati. Cilj je ovog odjeljka ukratko objasniti što su vjerojatnosni modeli i kako se primjenjuju.

Za primjer slučajne pojave uzet ćemo nepravilnu igraću "kocku", tijelo koje je približno oblika kocke, neravne površine i oštećenih rubova, napravljeno od nehomogenog materijala. Bacajući takvu "kocku" pod istim uvjetima (protresemo je u ruci i bacimo s određene visine na ravni pod) dobivat ćemo razne rezultate. ***Slučajna pojava** je određena određivanjem uvjeta pod kojima se odvija.* Promijenimo li te uvjete obično dobivamo drugu slučajnu pojavu. Nije svejedno bacamo li kocku tako da je prvo protresemo u ruci na određenoj visini ili tako da je bacamo nisko iz otvorene ruke nastojeći podešavati izbačaj s namjerom da dobijemo šesticu. Slučajnoj pojavi pridružujemo **prostor ishoda**, skup čije elemente nazivamo **ishodi**. U neutralnom (općem) kontekstu se prostor ishoda obično označava grčkim slovom Ω. Za prostor ishoda je važno jedino da će se u odvijanju slučajne pojave dogoditi točno jedan ishod. Istoj slučajnoj pojavi možemo pridružiti razne prostore ishoda, ovisi što nas zanima. Igraćoj kocki standardno pridružujemo za ishode brojeve koji prezentiraju njene strane: $\Omega = \{1, 2, 3, 4, 5, 6\}$. No, ako moramo na nogometnoj utakmici odrediti kome će pripasti početni udarac, a nemamo novčić već simetričnu kocku, tada za prostor ishoda možemo uzeti

$$\Omega = \{\text{paran broj}, \text{neparan broj}\}.$$

Kad bacamo igraću kocku može nas zanimati hoće li se nešto dogoditi ili ne, npr. hoće li pasti broj djeljiv s 3. Za ishode 3 i 6 taj će se događaj dogoditi (još kažemo da ishodi 3 i 6 realiziraju taj događaj), a za ostale ishode neće. Kako god događaj opisali, on je uvijek neki uvjet na ishode, i u konačnici nas samo zanima koji ishodi ispunjavaju taj događaj (koji ga realiziraju), a koji ne. Zato događaje modeliramo skupovima ishoda, odnosno "službena" definicija je da je **događaj** skup ishoda. Tako događaj D kojeg opisujemo riječima (uvjetom) "pao je broj djeljiv s 3" je skup $D = \{3, 6\}$.

Kako išta predvidjeti o događaju $D = \{3, 6\}$ kad ne možemo predvidjeti što će se dogoditi u jednom bacanju? Gledat ćemo koliko puta n_D će se dogoditi događaj D u nizu od n bacanja igraće kocke. Tu se pojavljuje pravilnost! Eksperimentalna je činjenica da *kad za svaki takav niz bacanja izračunamo tzv. relativnu frekvenciju* $\frac{n_D}{n}$*, one su približno iste. Što je veći broj bacanja, grupiranje relativnih frekvencija je izraženije.* Broj oko kojeg se grupiraju relativne frekvencije nazivamo **vjerojatnost događaja** D i označavamo $P(D)$ (jer je P početno slovo engleske riječi za vjerojatnost: *probability*). Taj broj nije jednoznačno određen tim grupiranjem već ga postuliramo! Smisao tog broja je da aproksimira (predviđa) relativnu frekvenciju događaja D u nizu ponavljanja:

$$P(D) \cong \frac{n_D}{n}.$$

Iz tog smisla proizlazi da funkcija vjerojatnosti P koja svakom događaju pridružuje njegovu vjerojatnost ne može biti proizvoljna funkcija. S obzirom da ona aproksimira relativne frekvencije mora imati svojstva relativnih frekvencija za dani niz bacanja. Takva su sljedeća svojstva, koja nazivamo **aksiomi vjerojatnosti**, jer se iz njih mogu izvesti ostala svojstva:

- $0 \leqslant P(D) \leqslant 1$
- $P(\emptyset) = 0,\ P(\Omega) = 1$
- $A \subseteq B \longrightarrow P(A) \leqslant P(B)$
- za A i B međusobno isključive događaje $P(A \cup B) = P(A) + P(B)$.

$\emptyset$ je oznaka za prazan skup, a $\cup$ je oznaka za operaciju unije skupova. Za događaje kažemo da su isključivi ako se ne mogu oba dogoditi istovremeno (ne postoji ishod koji realizira oba događaja). Skupovnom terminologijom rečeno, njihov presjek je prazan skup. Umjesto $P(A \cup B)$ ponekad pišemo intuitivnije $P(A \text{ ili } B)$ (vjerojatnost da se dogodi A ili B). Lako je vidjeti da navedena svojstva vrijede za relativne frekvencije. Npr. za zadnje svojstvo, ako su događaji isključivi, tada će se u nizu od n bacanja kocke događaj "A ili B" pojaviti koliko se puta pojavi događaj A plus koliko se puta pojavi događaj B: $n_{A \text{ ili } B} = n_A + n_B$. Podijelimo li ovu jednakost s n, vidimo da relativne frekvencije imaju zadnje navedeno svojstvo:

$$\frac{n_{A \text{ ili } B}}{n} = \frac{n_A}{n} + \frac{n_B}{n}.$$

Ako je igraća kocka simetrična tada bi relativne frekvencije pojedinih ishoda trebale biti približno jednake, pa bi tako vjerojatnosti pojedinih ishoda trebale biti iste. Iz tog uvjeta i gornjih aksioma slijedi (pokušajte dokazati) poznata klasična formula za računanje vjerojatnosti (koja vrijedi jedino kad su svi ishodi jednako vjerojatni):

$$P(A) = \frac{\text{broj ishoda koji realiziraju događaj } A}{\text{ukupan broj ishoda}}.$$

Modelirajući slučajnu pojavu bacanja nepravilne igraće "kocke" došli smo do općeg pojma modela slučajne pojave. **Konačni vjerojatnosni model** se sastoji od:

- nepraznog skupa Ω kojeg nazivamo **prostor ishoda**, njegove elemente **ishodima**, a podskupove **događajima**,
- i funkcije, koju nazivamo **vjerojatnost**, a koja svakom događaju pridružuje jedan broj, pri čemu moraju biti ispunjeni gore navedeni **aksiomi vjerojatnosti**.

Ovdje smo se ograničili na konačne modele jer beskonačni modeli (npr. slučajan odabir točke iz nekog lika) imaju nešto kompliciraniju matematiku, dok su osnovne ideje iste kao i za konačne modele.

Kao i kod determinističkih modela, matematika nam nudi razne vjerojatnosne modele. Izborom nekog nepraznog skupa i funkcije koja svakom podskupu pridružuje realan broj, pri čemu funkcija zadovoljava navedene aksiome, dobili smo jedan vjerojatnosni model. Osnovni problem je za danu slučajnu pojavu odabrati model koji dobro opisuje tu pojavu. Osnovni kriterij ispravnog odabira vjerojatnosnog modela je da se vjerojatnost P(D) događaja D mora dovoljno dobro podudarati s relativnim frekvencijama u nizu ponavljanja:

$$P(D) \cong \frac{n_D}{n}.$$

Koliko dobro? Odgovor je isti kao i kod determinističkih modela: sa stajališta problema koji želimo riješiti odstupanja moraju biti zanemariva. *Ova približna jednakost je osnovna veza između matematičkog modela i realnosti.* S jedne strane, ako znamo iz neke teorije ili eksperimenta vjerojatnost nekog događaja tada možemo po ovoj vezi procijeniti relativnu frekvenciju njegovog pojavljivanja u nizu ponavljanja slučajne pojave. Npr. za simetričnu kocku je prihvatljivo uzeti da su vjerojatnosti pojedinih ishoda jednake, pa je vjerojatnost da padne šestica jednaka $1/6$. Tako možemo procijeniti da će u nizu od 100 bacanja pasti oko 17 šestica. S druge strane, ako eksperimentiranjem utvrdimo relativne frekvencije događaja tada po ovoj vezi možemo procijeniti njihove vjerojatnosti. Npr. za nepravilnu igraću "kocku" možemo tako procijeniti vjerojatnosti i onda ih koristiti za daljnja predviđanja u slučajnim pojavama u kojima "sudjeluje" ova "kocka".

Vjerojatnosne modele i uvjete njihove primjene postavio je Andrej Kolmogorov 1933. godine.

Za daljnje razmatranje ključno je imati na umu sljedeće:

- *Vjerojatnost nam ne može reći što će se dogoditi u pojedinoj realizaciji slučajne pojave već samo može procijeniti relativne frekvencije događanja u cijelom mnoštvu realizacija slučajne pojave* (**problem pojedinog slučaja**).
- *Vjerojatnost nekog događaja ne ovisi samo o tom događaju nego i o slučajnoj pojavi u odnosu na koju promatramo taj događaj.* Npr. vjerojatnost da ćemo birajući nasumice osobu iz nekog mnoštva izabrati baš tebe, nije ista ako osobu biramo nasumice iz cijelog kvarta u kojem živiš, ili ako je biramo iz skupa ukućana s kojima živiš (**problem referentne slučajne pojave**).

Klađenje s igraćom kockom

Netko ti predloži sljedeću okladu. Bacit će se simetrična igraća kocka jednom. Ako padne šestica izazivaču ćeš dati 1000 eura. U protivnom ćeš ti dobiti 1000 eura. Vjerojatnost da će pasti šestica je $1/6$, a da neće $5/6$, dakle pet puta veća. Bi li prihvatio okladu? A da je ulog 10 000 eura? Razumijevanje pojma vjerojatnosti nam može pomoći u donošenju odluke. Vjerojatnost nam daje vrlo dobru procjenu što će se dogoditi u npr. 100 bacanja kocke. Šestica će pasti oko $1/6$ puta, dakle oko 17 puta, nekoliko puta više ili manje. Ali možeš biti siguran da neće pasti više od 30 puta (onaj tko poznaje binomnu distribuciju može izračunati da je vjerojatnost da se to dogodi nešto manja od tri desettisućnine). Tako će izazivač dobiti u najviše 30 bacanja, a ti u najmanje 70 bacanja. Zaradit ćeš najmanje 40 000 eura (očekivana zarada je približno 67 000 eura). Ja bih sigurno prihvatio okladu za 100 bacanja kocke. Ali izazivač nudi okladu za samo jedno bacanje kocke! Vjerojatnosti nam daju vrlo dobru procjenu što će se dogoditi u većem mnoštvu bacanja, ali nam ne mogu reći što će se dogoditi u jednom bacanju! *Za pojedino bacanje, vjerojatnosti nam samo mogu reći koji je izbor razumniji* (problem pojedinog slučaja). S obzirom da je 5 puta veća vjerojatnost da neće pasti šestica nego da će pasti, mogli bismo reći da je 5 puta razumnije kladiti se da neće pasti šestica nego da hoće. Međutim, ako prihvatiš okladu, bez obzira što je tvoja odluka 5 puta razumnija od izazivačeve, šestica će pasti ili neće pasti, i ti ćeš dobiti ili izgubiti 1000 eura. Za okladu u 10 eura prihvatio bih tu neizvjesnost. Za okladu u 1000 eura morao bih se posavjetovati sa suprugom. Na okladu u 10 000 eura sigurno ne bih pristao.

Klađenje sa Smrću

Ova igra je mnogo dramatičnija: okladu ne možeš izbjeći, izazivač je Smrt, a ulog je veoma visok – tvoj život. Međutim, unutar igre, Smrt ti daje izbor. Možeš izabrati između dvije kutije. Prva sadrži brojeve od 1 do 1000. Ako odabereš tu kutiju, Smrt će nasumice uzeti jedan broj iz nje. Ako izabere 1, uzet će ti život, inače će te poštedjeti. Druga kutija sadrži brojeve od 1 do 1 000 000. Ako odabereš tu kutiju, Smrt će nasumice uzeti jedan broj iz nje. Ako izabere 1, uzet će ti život, inače će te poštedjeti. Koju kutiju izabrati? Ako netko izabere prvu kutiju, vjerojatnost da će umrijeti je $1/1000$. Ako netko izabere drugu kutiju, vjerojatnost da će umrijeti je $1/1\,000\,000$. Kao i u igri kocke, u većoj populaciji, kao npr. u populaciji od 4 milijuna ljudi, koliko ih ugrubo ima u Hrvatskoj, ako svi izaberu prvu kutiju, umrijet će ih oko 4000, a ako svi izaberu drugu kutiju umrijet će ih oko 4. Tako je na nivou cijelog društva ispravno preporučiti ili čak narediti da se izabere druga kutija. Time će se na tisuće života spasiti. Ali što je s pojedincem? Izbor koji je dobar za cijelo društvo, ne mora biti dobar i za pojedinca. Je li druga kutija ispravan izbor i za pojedinca? Kao i kod oklade na kocki, u pojedinačnoj situaciji vjerojatnosti nas ne mogu sačuvati od neizvjesnosti. Vjerojatnosti ne mogu predvidjeti što će se dogoditi s pojedincem, hoće li umrijeti ili ne, bez obzira koju kutiju odabrao. Ali vjerojatnosti nam govore koji izbor je razumniji, čak i koliko puta je razumniji. Vjerojatnost da će netko umrijeti ako odabere drugu kutiju je tisuću puta manja nego ako odabere prvu kutiju. To je razlog zašto bih ja odabrao drugu kutiju.

Klađenje s Covid-19

Život i smrt u doba Covid-19 pandemije su mnogo kompleksniji od prethodne igre sa Smrću, ali ta igra je osnovni jednostavni model koji ugrubo predviđa što će se dogoditi društvu i pojedincu. Izabravši necijepljenje, osoba je izabrala prvu kutiju i vjerojatnost da će umrijeti od Covida je reda tisućnine. Izabravši cijepljenje, osoba je izabrala drugu kutiju i vjerojatnost da će umrijeti od cjepiva je reda milijuntnine. Složeniji modeli pridružuju osobama vjerojatnosti koje više odgovaraju njihovim posebnostima: dob, posebni zdravstveni problemi, pridržavanje epidemioloških mjera, procijepljenost i pridržavanje epidemioloških mjera društva u kojem živi, itd. Ne zaboravimo da vjerojatnost događaja ovisi i o slučajnoj pojavi u okviru koje promatramo događaj (problem referentne slučajne pojave). Što to znači za neku populaciju pogledajmo na jednom primjeru. Vjerojatnost da će pojedinac u Hrvatskoj u sljedećih godinu dana poginuti u prometnoj nesreći je reda desettisućnine. Ako pak voli brzu vožnju, za njega je ta vjerojatnost veća. Ona sada procjenjuje postotak ljudi iz te populacije koji će stradati, a ne iz cijele populacije. Ova vjerojatnost bolje opisuje šanse brzog vozača da strada nego vjerojatnost u odnosu na cijelu populaciju. Tako je i s vjerojatnošću smrti od COVID-19 za danog pojedinca – ona ovisi o referentnoj populaciji kojoj on pripada. Ako populaciju kojoj pripada ta osoba suzujemo postavljajući dodatne uvjete (dob, specifični zdravstveni problemi, ...) tada se ta vjerojatnost mijenja i sve više odgovara toj osobi. Na primjer, sljedeći grafikon pokazuje koliko je posto ljudi u svakoj dobnoj skupini u Hrvatskoj umrlo od COVID-19.[4]

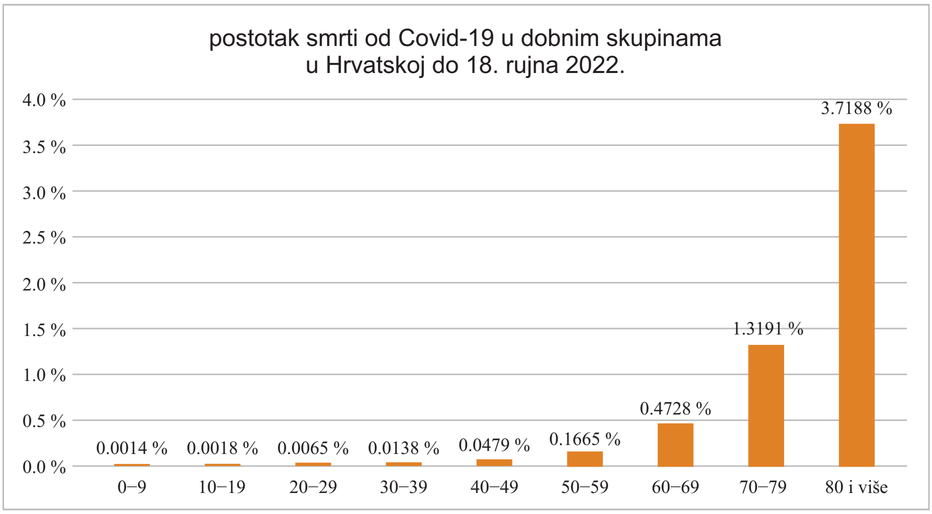

Po statističkoj interpretaciji, ti postotci procjenjuju vjerojatnosti da će netko iz dane dobne skupine umrijeti od COVID-19. Što se pak tiče odluke o cijepljenju, idealno bi bilo da je referentna populacija kojoj pripada pojedinac toliko uska da je vjerojatnost smrti od cijepljenja za osobu iz te grupe jednaka 1 (svatko iz te grupe će umrijeti ako se cijepi) ili 0 (nitko iz te grupe neće umrijeti ako se svi cijepe. Kad bi znanost za svaku osobu mogla naći tako usku grupu tada bismo točno znali tko smije, a tko ne smije primiti cjepivo. Međutim, previše je parametara uključeno i procesi su previše kompleksni da bismo imali potpuno razumijevanje i kontrolu nad ishodima. Može se reći da su vjerojatnosni modeli koje trenutno imamo ujedno i mjere našeg znanja: što su specifičniji modeli to je veće znanje. U kratkom vremenu koje je imala na raspolaganju, znanost je uspjela:

- odrediti vjerojatnosti smrti za ne naročito specifične grupe (jednostavni model igre sa Smrću je najgrublji takav model),
- dati opće upute o ponašanju,
- identificirati specifične grupe koje bi mogle biti izrazito ranjive na cijepljenje ili na COVID-19 bolest.

Znanost nije svemoćna, ali u situacijama poput COVID-19 pandemije ona je najbolje oruđe koje imamo. Zato se trebamo držati znanosti kad donosimo odluke, bez obzira da li nam ona daje posve određena predviđanja ili samo vjerojatnosti. *A znanost kaže da cijepiti se, ako nismo u nekoj izuzetno ranjivoj grupi za cijepljenje, i držeći se odgovarajućih epidemioloških mjera, štitimo sebe i one koje volimo, kao i društvo u cjelini*. Pogrešno je misliti da se, ako se cijepimo protiv COVID-19, nepotrebno izlažemo riziku. Rizik je već tu, a cijepljenje ga bitno reducira. Ne možemo izbjeći rizik, ali možemo djelovati razumno. Vjerojatnost nam pomaže da napravimo razuman izbor.

[4] Grafikon je dobiven na osnovi podataka iz popisa stanovništva 2021. godine koji se nalaze na stranicama Državnog zavoda za statistiku i podataka o smrti od Covid-19 koji se nalaze na stranicama Hrvatskog zavoda za javno zdravstvo.