

Što očekuje javnozdravstvena profesija od „big data“ tehnologije?

Silvije Vuletić

*Sveučilište u Zagrebu, Medicinski fakultet, Škola narodnog zdravlja „Andrija Štampar“, Zagreb
svuletic@snz.hr*

Javno zdravstvo je humanistička disciplina, štoviše, kulturološka i politička disciplina, a definiramo je kao vještina, umijeće i znanost o sprečavanju bolesti, produženju životnog tijeka populacije, te o unapređenju mentalnog i fizičkog života unutar složenih društveno-političkih procesa zajednice. Naime, javno zdravstvo ostvaruje svoje populacijske ciljeve putem složenih društveno-političkih procesa unutar ideologije i politike koji vladaju u određenom razdoblju evolucije zdravstvene zaštite neke zemlje ili zajednice.

Tradicionalna javnozdravstvena analitika većinom se temelji na organiziranju ‘*health survey*’-a, statičkim datotekama, strukturiranim matricama podataka, a osnova zaključivanja je u terminima signifikantnosti i teorije vjerojatnosti. To je danas vladajući znanstveni analitički model, ali ujedno jako ograničavajući u javnozdravstvenoj analitici. Javno zdravstvo traži sirove, nestrukturirane podatke ubikvitarno pohranjene u najrazličitijim medijima zdravstvene zaštite, od elektroničnih zapisa bolničke i izvanbolničke zdravstvene zaštite, tekstnih zapisa liječnika na bilo kojem radilištu zdravstvene zaštite, bolničkih i izvanbolničkih sestara, posebno patronažnih, zdravstvenog osiguranja te rizičnog ponašanja pojedinaca. Tradicionalnom analitikom na uzorcima kako bolesnih tako i zdravih nije moguća integracija, kategorizacija i analiza zdravstvenih podataka i informacija. Fokus javnozdravstvene analitike treba biti na masovnim, nestrukturiranim ubikvitarnim podacima i njihovom brzom dotoku.

Čini se da pojava nove informacijske tehnologije, tzv. ‘*big data*’ tehnologije koja se u razvijenim zemljama brzo i efikasno uvodi i testira, može stubokom promijeniti javnozdravstvenu analitiku. Od mnogih definicija za javnozdravstvenu analitiku prikladno glasi ova definicija pojma „*big data*“.

„*Big data*“ u javnom zdravstvu podrazumijeva veliku količinu podataka, bioloških i okolišnih te podataka o načinu života pojedinca i skupina u odnosu prema njihovom zdravstvenom stanju, kao i njihovu veliku raznolikost promatrano u jednoj ili više vremenskih točaka.

Predviđa se nova profesija, podatkovni znalac ili znanstvenik (engl. *Data Scientist*) u javnom zdravstvu koji poznae podatkovne tehnike primjenjive na strukturirane i nestrukturirane podatke, može dizajnirati jednostavne i učinkovite modele i algoritme, i poznae područje za koje radi, tj. javno zdravstvo. Radi se, dakle, o horizontalnom podatkovnim znalcu ili znanstveniku koji, za razliku od vertikalnog, ima vještine i znanja iz raznih područja. Naime, vertikalni podatkovni znalci ili znanstvenici imaju veliko znanje u uskom području, npr. statističari, programeri, matematičari, inženjeri, medicinari i sl. gdje svaki od njih ima ogromno znanje i vještine u uskom svom području za koje je bazično osposobljen.

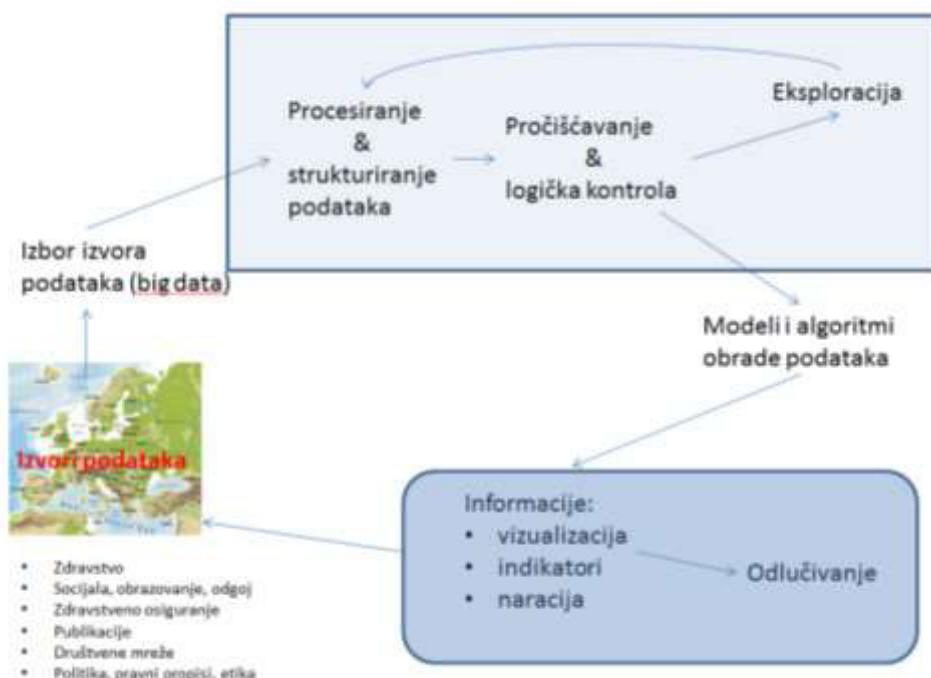
Prenesimo ovo razmišljanje na hrvatsku situaciju, status i javnozdravstvenu analitiku. Što bi to značilo?

To bi značilo prijeći s postojećih fragmentiranih i razasutih baza podataka na harmonizirane baze podataka, dodati nove suvremene izvore informacija poput društvenih mreža i sličnih

tehnoloških rješenja, inzistirati na brzom i efikasnom prenošenju nestrukturiranih podataka u strukturirane, te na permanentnoj prostornoj i vremenskoj analitici.

Prije svega, potrebno je postići konsenzus profesionalnih i edukacijskih institucija oko intersektorskih (npr. medicinski fakulteti i zdravstvena veleučilišta te zavodi za javno zdravstvo) i interdisciplinarnih djelovanja (npr. specijalizacije unutar javnog zdravstva, te preventivne i kurativne medicine). Edukacijske ustanove trebaju ugraditi osnove za buduće podatkovne znalce ili znanstvenike u svoje kurikule i, kroz specijalizacije, omogućiti njihovo usavršavanje.

U neposrednoj praksi, treba upoznavati javnozdravstvene profesionalce s projektima izabranih zemalja Europske unije. Hrvatsko javno zdravstvo treba početi s definiranjem potencijalnog programa u području „*big data*“ te pripremiti odgovarajuću znanstvenu aplikaciju. Osnovni edukacijski cilj bio bi upoznavanje i razumijevanje novog modela procesiranja javnozdravstvenih podataka, (Slika 1).



Slika 1. Model procesiranja javnozdravstvenih podataka

Referencije

- Vuletić S, Kern J, Džakula A, Lang Morović M, Miloš M (urednici). Fenomenologija profesija javno zdravstvo'. Zagreb: Vlastita naklada 2017.
- Davenport TH. Big data at work: dispelling the myths, uncovering the opportunities. Boston, Massachusetts: Harvard Business Review Press 2014.