DEFINICIJA APSOLUTNIH TEMELJA SPOZNAJNOG KONTINUUMA

Dobromir Bonacin

Uvod i problem

Rješenja brojnih znanstvenih problema u smislu utvrđivanja trajnih i postojanih fundamenatlnih solucija, često se u konačnici nađu izvan prihvatljivih granica, što umnogome otežava objektivno prepoznavanje fenomena koji nas zanimaju. Tipične situacije u kojima do takvih problema dolazi jesu one u kojima se znanstveni projekti omeđuju spoznajnim temeljima bez adekvatnih apsolutnih referenci. Poslijedice ovakvog pristupa su mnogostruke i neprihvatljive. Naime, bez apsolutne reference, praktično svaki lokalni rezultat u lokalnim istraživanjima može se bez nekog većeg rizika označiti kao vjerodostojan i istinit. To je, dakako neodrživo, jer se prečesto događa da u više eksperimenata, definiranim po različitim metodologijskim temeljima, međusobno isključivi rezultati egzistiraju kao istiniti.

A budući nema opće referentne skale, tako ispada da u mnogim situacijama imamo višestruke isključive znanstvene istine, koje otvoreno dolaze u koliziju. Ono što je najgore u svemu jest činjenica da svaka od tih lokalnih «istina» može ravnopravno egzistirati, jer naprosto nema mogućeg arbitriranja koja je prava ili barem koja je «istinitija». Još od Anaksimandra i Heraklita (Ur.:Grlić, 1967), preko Newtona, pa sve do Plancka i Heysenberga (Strnad 1990), ovaj problem se kontinuirano gura ustranu i pokušava relativizirati. Stoga je očito sazrelo vrijeme da se špekulacijama stane na kraj i jednom već definira objektivna apsolutna referentna skala. Dio takvih promišljanja može se pronaći u Bonacin i Rađo 2005. No pogotovo se spoznajnim kontinuumom bavio Bonacin 2005., iako je tako zadan temelj kontinuuma u smislu ovog članka nepotpun i relativno kompliciran, budući se određuje na bazi mehanizma najvišeg reda izvedenog iz prijedloga u Bonacin i Carev 2002., što za niz situacija postaje presloženo i teško se operacionalizira.

Zanimljiv pristup su ponudili Bonacin, Rađo i Blažević 2005.(a), potvrđujući vjerodostojnost i stabilnost pozicija objekata u različitim stanjima na praćenim razvojnim točkama, a nikako ne treba zanemariti ni ideju Bonacina, Rađe i Blaževića 2005.(b). o promjenama u strukturi polja događaja. U svakom slučaju, rečeni problem ostaje nedovoljno precizno artikuliran i u operacionalnom smislu neriješen, pa je jednostavnu apsolutnu skalu i dalje naizgled teško oformiti. Ovaj članak, bez imalo ograda ima pretenzije utemeljiti takvu skalu i to na krajnje jednostavni način.

Algoritam

Neka je iz populacije E izvučen slučajni uzorak objekata e_i *(i=1..x)* opisan skupom varijabli v_j *(j=1..y)* izvučenih iz populacije V. Hadamardovim pridruživanjem vrijednosti objektima dobija se matrica brutto podataka $B = E \otimes V$ s elementima $b_{i,j}$ *(i=1..x, j=1..y)*. Dalje se u postupcima obično vektori aritmetičkih sredina varijabli dobivaju kao $m = \Sigma\, b_j / x$, a standardnih devijacija kao $\sigma = \mathrm{sqrt}(\Sigma\, (b_{ij}-m_j)^2 / x)$. Ti parametri obično služe za dobivanje standardiziranih podataka koji se dobivaju izražavanjem u vrijednostima standardnih devijacija $z_{ij} = (b_{ij} - m_j) / \sigma_j$. U daljim postuipcima se obično pokušava utvrditi neka multivarijantna pravila i relacije. Međutim, ova skala, iako naizgled prirodna, neminovno (zbog same naravi takvih podataka i samog postupka) ne dovodi podatke svih entiteta u isti prostor. To niti ne može, jer se raspon rezultata pojedinih varijabli distribuira unutar različitih parametara ekstremnih pokazatelja, pa jedna varijabla ima raspon npr. -2.2 do +3.6, a neka druga npr. od -4.0 do +1.8 Z. Ovakva situacija očito svjedoči o loše definiranom problemu, jer je za zaključiti kako dio prostora podataka jedne varijable nema uporište u drugoj, što se sve dodatno usložnjava upotrebom većeg broja takvih varijabli (30, 40 ili više).

Očito je u opisanom slučaju nepoznat stvarni prostor registracije dijela primarne informacije (jer varijabla nije ništa drugo nego primarna registracija), pa se s razlogom postavlja pitanje: što se uopće registrira, odnosno mjeri, i koliko od čega!? I je li minimum stvarno minmum ili nije!?

Pretpostavimo li međutim, da je takva varijabla jednostavno skup artificijelnih pridruživanja rezultata objektu, i da nas u suštini čak niti ne zanima u kojoj je mjeri objektivna u smislu raspona, lako ćemo problem riješiti označimo li za sve varijable, bilo kakav (ali za sve varijable isti) raspon u kojima se primarni podaci pojavljuju. U konkretnim slučajevima se najočitijim i najrazumljivijim pokazao raspon rezultata od 1 – 5, pri čemu je najmanja vrijednost uvijek 1, a najviša uvijek 5. Za očuvanje konzistentnosti podataka, prije takve normalizacije, uvijek se provodi metrijska redirekcija podataka varijable u slučajevima obrnute metrijske orijentacije. Primjer: varijabla *trčanje na 20 metara*, jer je za takvu varijablu manji rezultat bolji rezultat, što u kasnijim fazama obrade (naročito viših mehanizama) može imati i neke ozbiljne reperkusije. U ovom slučaju dakle, nakon takve redirekcije, provedena je jednostavna procedura definiranja standardnog raspona u kojemu su svi podaci. Tako rezultat od 1.00 neke varijable zaista jest minimum, a jednako vrijedi i za neku drugu varijablu. Naravno da ovakvo standardiziranje nema nikakve poslijedice po konfiguriranje mahanizama viših redova osim što su u ponekim situacijama ti mehanizmi znatno jasniji i čišći, a usporedbe vrlo jednoznačne. Sad je očito minimalni rezultat minimalan i to vrijedi za sve varijable jednako (baš kao i kod maksimalnog rezultata). Jasno je i da je interna distribucija za svaku pojedinu varijablu ostala očuvana, jer ovakva normalizacija ne dira internu strukturu podataka. Ova situacija dobivena je vrlo jednostavnom operacijom u kojoj se prvo određuje δ vrijednost, odnosno raspon, u ovom slučaju $\delta = 5 - 1 = 4$. Zatim se pronalaze minimum i maksimum po svakoj varijabli posebno, te se izračunava ponder za multiplikaciju: $\Delta_j = (\max_j - \min_j)/\delta$. Konačno se cijela matrica B dovodi u položaj centririanja na ekstremne vrijednosti:

$$a_{ij} = (b_{ij} - \min_j) * \Delta_j^{-1} + 1.$$

Matrica A, naravno, u sebi nema negativnih vrijednosti, pa je omogućeno vrlo jednostavno utvrđivanje vektora v svih objekata, tj. pozicije svakog pojedinog objekta opisanog s više varijabli na krajnje jednostavan način:

$$v_i = \Sigma\, a_{ij}\,.$$

Numerički primjer

Opisanim postupkom dobiven je položaj svakog pojedinog objekta na univerzalnoj skali definiranoj uz pomoć svih podataka u modelu. Distribucija ovih podataka je, naravno, također normalna, ako se promatra u prostoru određenom standardnim parametrima $\mathcal{N}$(m,σ). Međutim, ako se promatra sortirano u rastućem nizu dobiva se savršeni opis apsolutne referentne skale kao trajektorije po kojoj svi pojedini objekti jednostavno napreduju unutar varijablama razapetog kontinuuma.

Primjer takvog kontinuuma dobiven je na temelju 747 objekata opisanih sa 26 primarnih inicijalnih varijabli pripremljenih na opisani način.(grafikon 1.).

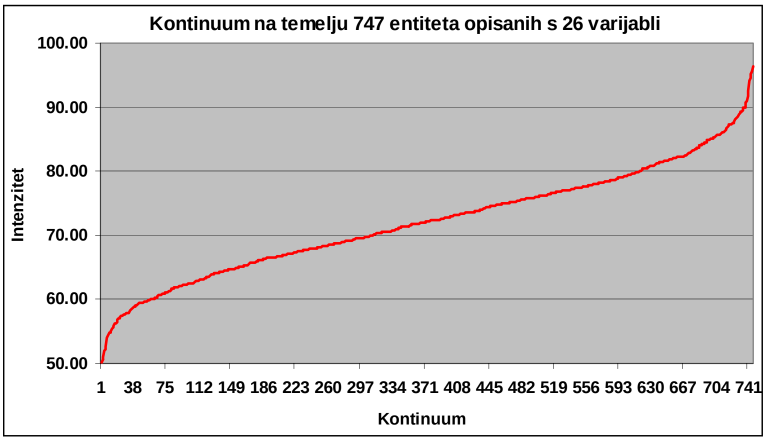

Grafikon 1. Kontinuum vektora v iz primjera

Budući su podaci sortirani u rastućem nizu, jasno je da pojedini objekti zauzimaju pozicije sukladno rezultatu u vektoru **v**, a time i određuju individualni intenzitet unutar razapetog prostora.

Ako se pretpostavi da varijable kojima su objekti opisani predstavljaju kompletni mogući arsenal ili da su barem reprezentativne s pozicije odabranih svojstava objekata, tada je jasno da će rezultat prema desnim krajnjim vrijednostima apsolutno značiti viši stupanj integracije inicijalnih informacija, a prema lijevim krajnjim vrijednostima značiti niži stupanj te iste integracije.

Ovu integraciju zvat ćemo spoznaja, jer je sigurno da kompleksitet objekata raste od 1 prema 747, što je potvrđeno inspekcijom individualnih rezultata objekata. Definirani kontinuum, sigurno predstavlja razvojnu skalu, koju na osobit i neponovljiv način prolaze svi objekti, upravo sukladno njihovim akumuliranim spoznajama vezanim uz spoznaje opisane pojedinim varijablama, te naročito kombinacijama varijabli, što je i bio cilj algoritma. I konačno, naravno da je jednostavno utvrditi relacije kontinuuma sa bilo kojim dimenzijama, od manifestnih do latentnih na najvišim razinama.

Zaključak

Definiran je i provjeren algoritam koji determinira apsolutnu referentnu skalu prema kojoj je moguće utvrditi lokaciju svakog pojedinog objekta opisanog većim brojem primarnih varijabli. Algoritam je pokazao da se ovaj postupak naprosto mora korisiti u svim situacijama kad se želi utvrditi objektivna pozicija, napredovanje ili bilo kakav drugi opis objekata kod kojih je teneljna intencija razvoj ili objektivizacija pozicije. Naročito se preporuča za parametrizaciju transformacijskih procesa.

Literatura

1. Bonacin, D., Rađo, I. (2006). Temeljne kvantitativne metode za analizu podataka. Fakultet sporta i tjelesnog odgoja, Sarajevo.
2. Bonacin, D. (2005) Comprehensive continuum. Homo Sporticus, 8, 2:16-20.
3. Bonacin, D., Rađo, I., Blažević, S. (2005) Simple identification of motor gifted child. IASK, Sport kinetics 2005 – Rimini, Proceedings, 45.
4. Bonacin, D., Rađo, I., Blažević, S. (2005) Changes of field structure. ECSS. 10th annual congress of the European college of sport science. Belgrade, Proceedings : 285.
5. Bonacin, D., Carev, Z. (2002). The universal methodology of process identification. Journal of Theoretics, vol 4, 2, Avaliable: http://www.journaloftheoretics.Com /Links/links-papers.htm.
6. Strnad, J. (1990). Mala kvantna fizika. Školska knjiga, Zagreb.
7. Grlić, D. Ur. (1967). Filozofija. (Školski leksikon), Panorama. Zagreb.