HOMO SPORTICUS

NAUČNO-STRUČNI ČASOPIS IZ OBLASTI SPORTA I TJELESNOG ODGOJA

GODINA [illegible] - BROJ [illegible] - 200[illegible]

Dobromir Bonacin[1] Izet Rađo[2]

Jednostavni algoritam za analizu kvantitativnih promjena na temelju projekcije parametara centroida

Ključne riječi: ***kvantitativne promjene, algoritam.***
Key words: ***quantitative changes, algorithm.***

Sažetak:

Ovaj rad je usmjeren ka definiranju jednostavnog i razumljivog algoritma koji je u stanju utvrditi stupanj kvantitativnih promjena koje su posljedica bilo kojeg transformacijskog neslučajnog procesa unutar jasno definiranog intervala omeđenog vremenskim tačkama i primjenom istih kontrolnih varijabli na istim entitetima.
Ponašanje algoritma je ispitano u tri različite situacije (razvojni problem, problem substruktura, problem u sportu). Kvantitativne promjene su u svim situacijama precizno identificirane na sve tri razine i mogle su se dosta jednostavno objasniti, što je potvrdilo snagu algoritma u svrhu operacionalne primjene.

Summary:

Simple algorithm for the analysis of quantitative changes based on the projection of centroid parameters
The objective of this study is to define a simple and understandable algorithm capable of establishing the level of quantitative changes that are consequences of any transformational process in a clearly defined interval marked by time points and the application of identical control variables used at the same subjects.
The algorithm was tested in a three different situations (problem of development, substructure problem and problem in sport). In each situation quantitative changes where precisely identified and quite simply explained at all three levels, which confirmed the strength of algorithm for the purpose of operational application.

Uvod

Kvantitativne promjene obilježja objekata jedan su od prvih načina uopće na koji se uočava efikasnost transformacijskih procesa u kineziologiji. Pod realnom pretpostavkom da je u nekom vremenskom intervalu djelovao najmanje jedan neslučajni proces, jednostavnim operacijama razlika između početnog i finalnog stanja po pojedinim varijablama (ili podacima entiteta na varijablama) mogla se pokušati utvrditi razlika koja je po statističkim modelima, u slučaju razlika većih intenziteta, mogla biti proglašena značajnom. Naravno da su u početku prevladavale univarijantne analize, koje su, kao takve, davale uvjerljive informacije o promjenama stanja objekata, pa su se mnogi problemi rješavali analizom varijance ili t-testom za zavisne uzorke. Međutim, univarijantna prezentacija razlika brzo je morala ustupiti mjesto znatno objektivnijim i informacijski moćnijim multivarijantnim modelima, jednostavno zato što se promjene izazvane nekin transformacijskim postupkom (ili ma kakvim procesom uopće) nisu mogle dovoljno precizno objasniti uvidom u samo jednu varijablu kojom su praćena stanja objekata. Čak i kad je primijenjeno više varijabli, kod univarijantnih analiza stalno su izostajale objektivne informacije o interakcijama, a posebno o globalnim parametrima promjena. Špekulativno povezivanje ovakvih univarijantnih rezultata bilo je, naravno, neopravdano jer je uglavnom ovisilo o stupnju znanja pojedinih istraživača, što je neminovno dovodilo do divergentnih zaključaka i nepotvrđenih konstatacija o relacijama multivarijantnih odnosa.
Razvojem kvantitativnih metoda, računala i primjenom matrične algebre, otvorile su se mogućnosti multivarijantne analize razlika, odnosno simultane analize interakcija među varijablama kojima su praćena kontrolna stanja objekata. U tom smislu razvijeno je nekoliko metoda za koje se već dugo drži kako predstavljaju antologijske i uvjerljive procedure u analizi kvantitativnih promjena. Među najpoznatijima je svakako model poznat pod imenom SSDIF (Pavičić, Momirović...), kao i njemu vrlo slični modeli DIFFG (Momirović i sur.) i slično. Ti modeli pretpostavljaju kako se iz razlika podataka entiteta na kontrolnim varijablama u dva stanja mogu konstruirati funkcije koje opisuju multivarijantne razlike, te kako su za te razlike odgovorni kvantitativni generatori u čijim temeljima stoje ekosenzitivne karakteristike objekata koji su izloženi ma kakvom neslučajnom procesu. Radi se očito o generalizaciji kanoničke diskriminativne analize u multivarijantnom prostoru za analizu promjena kod zavisnih uzoraka.

Nažalost, ovakve procedure, iako su zaživjele u praksi, pokazuju niz neuvjerljivosti i inkonzistentnosti, među kojima su dominantne one koje upućuju na imanentni dio strukturalnih i drugih promjena u samom modelu. Te strukturalne (i druge) promjene se ne mogu pod tim modelima objektivno izolirati, te su tako dobivene promjene dobrim dijelom kontaminirane svakojakim bremenom i inkorporirane u rezultate takvih analiza. Zato se osjeća potreba definicije čistih kvantitativnih procedura.

Problem i cilj istraživanja

Strukturalne promjene npr. po svojoj temeljnoj definiciji predstavljaju izmijenjene relacije među kontrolnim varijablama kojima se prate stanja objekata u najmanje dvije vremenske točke. To, dakako, dovodi i do različitih faktorskih struktura mehanizama višeg reda, pa se objektivnim uvidom u te mehanizme može zaključivati o stupnju i karakteru takvih promjena.

Kvantitativne promjene, međutim, pretpostavljaju istovjetnost, kako relacija među varijablama, tako i među strukturama viših razina od kojih i ovise manifestacije mjerenih varijabli. Na taj način gledano, očito se kod kvantitativnih promjena radi isključivo o pomacima hiperelipsoida podataka duž pojedinih kontrolnih varijabli. Matematički definirano, ovdje bi se radilo o translaciji podataka duž vektora svake od pojedinih varijabli, pod uvjetom da je skup relacija među varijablama ostao nepromijenjen.

[1]Split, Hrvatska [2] Fakultet sporta i tjelesnog odgoja, Univerzitet u Sarajevu

Ako ekstremiziramo ovu jasnu pretpostavku, utvrdit ćemo da kod kvantitativnih promjena postoje samo translativne karakteristike skupa podataka kojima su opisani objekti. Kako se ipak radi o promjenama, a varijabilitet podataka naravno utječe na karakter tih promjena, tada bi i varijance varijabli morale pokazivati konzistentna obilježja, jer u suprotnome ne možemo govoriti o kvantitativnim promjenama. Konačno, skup pojedinih translatornih pomaka, očito definira udaljenost centorida između tih dviju točaka, što nedvojbeno predstavlja parametar globalnog kvantitativnog pomaka.

Kako se vidi, za doslovni opis isključivo kvantitativnih promjena potreban je skup uvjeta koji se moraju osigurati, a sastoji se u:

1) jednakosti asocijacija (npr. korelacija) među varijablama u dva stanja, a time i faktorskih struktura između tih dviju točaka,
2) mogućnosti translativnog opisa pomaka po pojedinim varijablama i opis značajnosti tog pomaka,
3) očuvanom homoscedasticitetu, tj. istovrsnosti varijanci varijabli apliciranih u dvije vremenske točke i
4) mogućnosti utvrđivanja značajnosti globalne mjere promjene definirane pomakom centroida hiperelipsoida u dvije kontrolne točke.

Pod ovim uvjetima određen je i cilj ovog istraživanja, a sastoji se u definiciji jednostavnog i razumljivog algoritma koji je u stanju utvrditi stupanj kvantitativnih promjena koje je izazvao neki, ma kakav, transformacijski neslučajni proces unutar nekog jasno definiranog intervala omeđenog vremenskim točkama i primjenom istih kontrolnih varijabli na istim entitetima.

Takav algoritam bi, dakako, morao biti jednostavno primjenjiv u praktične svrhe i neosjetljiv na broj stupnjeva slobode, tj. na mali broj tretiranih entiteta i mali broj primijenjenih kontrolnih varijabli, da se može primjenjivati i u analizi efekata u sportu, gdje se redovito radi s malim grupama (n<30).

Algoritam

Neka je E $(e_i\ ;\ i=1,...,n)$ skup entiteta slučajno izabran iz neke populacije P, i neka je V $(v_j\ ;\ j=1,...,m)$ skup linearno nezavisnih, normalno distribuiranih kvantitativnih varijabli. Tada operacijom Hadamardovog pridruživanja vrijednosti iz V entitetima iz E dobijamo $X = E \otimes V$ $(x_{ij}\ ;\ i=1,...,n,\ j=1,...,m)$; $[n>m]$ matricu koja opisuje stanje skupa objekata E na skupu V u nekoj vremenskoj točki ***t***. Neka je u nekom intervalu (***t2-t1***) djelovao neki neslučajni proces, tada pridruživanjem vrijednosti iz V skupu E u točkama ***t1*** i ***t2*** imamo dvije matrice stanja X_1 i X_2. Vrijednosti centorida podataka po svakoj varijabli iz V dobijaju se jednostavno kao vektori m aritmetičkih sredina A_1 i A_2 $(a_{tj}\ ;\ j=1,..m)$ pri čemu je $a_{1j} = \Sigma x_{1i} / n$, i $a_{2j} = \Sigma x_{2i} / n$, u točkama ***t1*** i ***t2***. U vektorima S_1 i S_2 $(s_{tj}\ ;\ j=1,..m)$ nalaze se standardne devijacije varijabli iz V opisane u X_t $(s_{tj} = \mathrm{sqrt}(\Sigma\ (x_{ti} - A_j)^2)/n)$. Očito, čak i kad su tek slabo izražene kvantitativne promjene, elementi dijagonalne matrice D $(d_{jj}\ ;\ j=1,..m)$ bit će $D = (A_{t+1,j} - A_{t,j}) \neq 0$. No, ako elemente dijagonalne matrice D definiramo kao odnos elemenata vektora A_2 i A_1 dobit ćemo $D_j = (A_{t+1,j} / A_{t,j})$, tj. pojedinačni intenzitet promjene po svakoj od m varijabli, pa ako nikakvih lokalnih promjena nije bilo važit će $D_{jj} = (A_{t+1,j} / A_{t,j}) = 1$.

Problem definicije ukupnog kvantitativnog pomaka duž vektora pojedinih varijabli očito se svodi na određivanje matrice asocijacija u trenutku ***t2*** koja se ni po čemu ne razlikuje od takve matrice u trenutku ***t1***, što je, naravno, moguće samo pod pretpostavkom da su svi pomaci pojedinih entiteta upravo proporcionalni ukupnim pomacima po svakoj varijabli iz V. Očito, podatke svih entiteta iz X_1 treba srazmjerno projektirati sukladno pojedinim koeficijentima translacije u D, što se postiže jednostavnom operacijom $Y = X_1 * D$ $(y_{ij}\ ;\ i=1,...,n\ ,j=1,..m)$. Na taj način dobit će se projektirani podaci drugog mjerenja za koje je potpuno sigurno da proizvode potpuno istu matricu korelacija m varijabli, a time i istu faktorsku strukturu. Zatim, elemente dijagonalne matrice D orijentirat ćemo jednostavno tako da za sve elemente vektora Q $(q_j = d_{jj})$ važi $q_j >= 1.0$, pa su u vektoru Q sadržani relativni pomaci po svakoj od m varijabli, te je to upravo vektor pozitivno redirekcioniranih koeficijenata translacije (za $d_j < 1.0 \ => q_j = 1.0 / d_j$), odnosno lokalnih intenziteta promjena. Kako svaki i najmanji pojedinačni pomak opisan vektorom Q doprinosi globalnom opisu ukupnih promjena, jer je time u multidimenzionalnom sustavu opisana upravo redirekcionirana udaljenost centroida elipsoida mjerenja, tu udaljenost izračunat ćemo jednostavno kao $\Delta = (\Sigma\ (q_j * q_j))^{-1/2}$, $(q_j\ ;\ j=1,..m)$. Značajnost te udaljenosti može se testirati na različite načine, ali je možda najjednostavnije parametrom $(\Delta^2\text{-m})$ kao F omjerom za testiranje značajnosti globalnih kvantitativnih promjena uz df1 = m i df2 = n – m stupnjeva slobode, jer opisuje upravo vrijednosti multivarijantnih promjena u slučaju zavisnih uzoraka. Pojedinačne promjene jednostavno se testiraju po svakoj varijabli t-testom za zavisne uzorke. Homoscedasticitet varijanci je očuvan zahvaljujući projektiranju drugog stanja objekata temeljem linearnih kombinacija koeficijenata translacije stvarnih pomaka, pa su koeficijenti dilatacije (odnosi varijanci iz Y i X_t) ne samo proporcionalni koeficijentima translacije u D, već su upravo jednaki njima, što znači da je operator promjene proizveo kontinualno srazmjerno djelovanje.

Nadalje, ali samo u slučaju da je globalna promjena u Δ statistički različita od nule, od iznimnog interesa za interpretaciju je još i strukturni vektor K u kojemu su sadržani doprinosi pojedinih varijabli općoj funkciji kvantitativne promjene. Budući da su korelacije varijabli u prvom stanju identične onima u drugom stanju, a s obzirom da su rezultati u Y dobijeni na temelju projekcije centroida druge točke, tada je i struktura kvantitativnih promjena identična strukturi odnosa koji su zabilježeni u prvoj i, naravno, drugoj kontrolnoj točki, jer su tako zadržani isti generatori tih relacija, ali predznaci relacija varijabli promjena ne moraju biti isti kao u stanjima ***t1*** i ***t2***. Zato, neka su, dakle, u matrici Z_y $(z_{i,j}\ ;\ i = 1,...,n,\ j = 1,..m)$ sadržane standardizirane vrijednosti entiteta $(z_{i,j} = (x_{i,j} - A_j) / S_j)$, a u matrici R_y $(r_{i,j}\ ;\ i = 1,..m,\ j = 1,..m)$, pod kriterijem maksimalne vjerodostojnosti, sadržane korelacije varijabli razlika $(R_y = Z_y^T Z_y\ 1/n)$.
Vektor K $(k_j\ ;\ j=1,..m)$ tada se može dobiti na više načina, ali je vjerojatno najpogodniji model uz pomoć transformacije matrice korelacija R_y dijagonalnom matricom D. Ta transformacija vrši se na način

$$K = \alpha\ (D\ R_y), \quad \text{pri čemu } \alpha = (D\ R_y\ D)^{-1/2}$$

Očito je da se radi o spektralnoj dekompoziciji, tj. prvoj vrijednosti spektra matrice R_y pod pretpostavkom da je to matrica jediničnog ranga za skup uvjeta u D. Ako je taj skup uvjeta logički konzistentan, a pomaci po pojedinoj varijabli to jesu, tada bez obzira što je R_y gramianska matrica i nema jedinični rang, s pozicije uvjeta u D, sve ostalo osim prve vrijednosti spektra ne pripada skupu rješenja uz uvjete u D, odnosno u ovom algoritmu ne pripada kvantitativnim promjenama opisanih skupom pomaka.

Ovom operacijom uvažene su relacije između varijabli, budući da i od njih ovisi ukupni kvantitativni pomak. Kako su korelacije u R_y intenzitetom (ali ne nužno i predznakom) jednake onima u R_{t1} i u R_{t2}, vektor K je strukturni vektor kvantitativnih promjena. Stanje koje je "zatećeno" u $t1$, budući da do promjena u strukturi nije došlo, identično je stanju u $t2$. No kako su razlike stanja opisane samo pomacima u koeficijentima translacije (D), to je i globalna struktura matrice R_y identična onoj u R_{t1} ili R_{t2}, pa se u ovom modelu promjene mogu samo opisati intenzitetom, a ne i promjenom strukture. Taj intenzitet je, naravno, opisan u parametrima t-testa, Δ i D, s pojedinačnim satuacijama u K.

Konačno, budući da u općem slučaju matrice Y i X_2 ne moraju biti jednake, a najčešće i nisu, razlike proizašle iz stvarnih rezultata mjerenja (X_2) i projektiranih podataka (Y)

$$U = X_2 - Y, \quad (u_{i,j}\,;\, i = 1,...,n,\ j = 1,...,m)$$

predstavljaju mjeru pogreške pojedinih rezultata u kvantitativnom modelu. Ove razlike nije lako opisati kao strukturalne, jer predstavljaju kompozit svih vrsta promjena za koje je jedino sigurno da nisu kvantitativne.

Ipak, tim razlikama u U može se pridijeliti strukturalni karakter u onom dijelu za koji se mogu adekvatnom interpretacijom pronaći razumna objašnjenja faktora dobijenih spektralnom dekompozicijom iz matrice korelacija R_u ($r_{i,j}\,;\, i = 1,..m,\ j = 1,..m$) i uz primjenu neke od standardnih tehnika eksplikacije strukturalnih promjena.

Ponašanje algoritma (Primjer 1. – Transverzalni razvojni problem)

U svrhu provjere kvalitete algoritma analizirani su podaci 88 entiteta muškog spola uzrasta V razreda, 86 muških entiteta uzrasta VI razreda i 67 muških entiteta uzrasta VII razreda osnovne škole koji su svi u trajanju od jedne školske godine bili podrvgnuti sistematskim transformacijskim postupcima s ciljem potpore funkcijama rasta i razvoja. U dva navrata, na početku i na kraju školske godine, entiteti su izmjereni sa istih 13 varijabli zamišljenih da pokriju prostor morfoloških i motoričkih dimenzija. Od toga su bile 4 morfološke varijable: visina tijela (AVIT), tjelesna težina (AMAS), kožni nabor subskapularisa (AKNS) i kožni nabor tricepsa (AKNT), te 9 motoričkih varijabli: statička snaga (MSTA), taping (MTAP), skok u dalj (MEXP), snaga trupa (MSNT), kombinirano trčanje (MTRC), gipkost (MGIP), izdržaj u zgibu (MZGB), trčanje 20 m (M20M) i flamingo test ravnoteže (MFLA). Spoznajni problem u ovom radu postavljen je u maksimalno razapeti multidimenzionalni prostor, pa je i cijeli set varijabli promatran kao jedinstveni skup.

(Mean1,2 = aritmetičke sredine prvog i drugog mjerenja, Delta = razlika ar. sredina, D = koeficijenti translacije po varijablama, Q = redirekcionirani koeficijenti translacija, Var1,2 = varijance varijabli, DT = koeficijenti dilatacije po varijablama, K = strukturni vektor kvantitativnih promjena, t = t-test za pojedine varijable, p(t) = probabilitet za t-test).

Prema globalnom pokazatelju $\Delta^2 = 1.8268$, što za stupnjeve slobode D1 = 13 i D2 = 75, iskazuje vrijednost probabiliteta **p** = 0.0537, u intervalu između početka i kraja školske godine V razreda osnovne škole došlo je do globalnih kvantitativnih promjena koje su na samom pragu značajnosti. Na temelju podataka

	Mean1	Mean2	Delta	D	Q	Var1	Var2	DT	K	t	p(t)
AVIT	150.34	156.92	6.58	1.04	**1.09**	26.92	29.33	1.04	**0.44**	8.23	**0.00**
AMAS	42.31	47.57	5.26	1.12	**1.26**	93.80	118.55	1.12	**0.10**	3.38	**0.00**
AKNS	9.26	8.64	-0.61	0.93	**1.15**	30.11	26.24	0.93	**0.15**	0.77	0.55
AKNT	11.83	11.23	-0.60	0.95	**1.11**	24.41	21.99	0.95	**0.09**	0.83	0.59
MSTA	29.03	32.04	3.01	1.10	**1.22**	36.75	44.77	1.10	**0.63**	3.13	**0.00**
MTAP	15.39	14.20	-1.19	0.92	**1.17**	4.00	3.41	0.92	**0.85**	4.11	**0.00**
MEXP	162.24	168.64	6.40	1.04	**1.08**	349.01	377.08	1.04	**0.86**	2.23	**0.03**
MSNT	19.01	20.29	1.28	1.07	**1.14**	16.34	18.62	1.07	**0.82**	2.03	**0.04**
MTRC	21.74	21.14	-0.59	0.97	**1.06**	2.70	2.55	0.97	**0.75**	2.43	**0.02**
MGIP	16.21	16.29	0.07	1.00	**1.01**	22.48	22.68	1.00	**0.26**	0.11	0.92
MZGB	18.07	17.58	-0.49	0.97	**1.06**	198.01	187.49	0.97	**-0.21**	0.23	0.81
M20M	610.42	675.96	65.54	1.11	**1.23**	75589	92691	1.11	**0.59**	1.50	0.13
MFLA	12.12	13.57	1.45	1.12	**1.25**	32.40	40.65	1.12	**-0.24**	1.60	0.11

Tabela 1.
Podaci kvantitativnih promjena za V razred

	Mean1	Mean2	Delta	D	Q	Var1	Var2	DT	K	t	p(t)
AVIT	156.26	163.77	7.51	1.05	**1.05**	43.16	47.41	1.05	**-0.03**	7.32	**0.00**
AMAS	45.47	50.21	4.73	1.10	**1.10**	90.14	109.88	1.10	**-0.47**	3.10	**0.00**
AKNS	8.20	7.49	-0.71	0.91	**1.09**	16.60	13.85	0.91	**0.74**	1.19	0.24
AKNT	11.15	9.19	-1.96	0.82	**1.21**	18.85	12.81	0.82	**0.69**	3.23	**0.00**
MSTA	33.27	30.93	-2.34	0.93	**1.08**	40.86	35.31	0.93	**-0.15**	2.49	**0.01**
MTAP	14.66	13.61	-1.05	0.93	**1.08**	2.84	2.44	0.93	**0.86**	4.24	**0.00**
MEXP	166.47	172.62	6.15	1.04	**1.04**	335.23	360.46	1.04	**0.88**	2.16	**0.03**
MSNT	19.25	19.68	0.43	1.02	**1.02**	19.07	19.94	1.02	**0.83**	0.64	0.53
MTRC	21.58	21.30	-0.27	0.99	**1.01**	3.68	3.59	0.99	**0.86**	0.94	0.65
MGIP	16.66	16.18	-0.48	0.97	**1.03**	21.69	20.46	0.97	**-0.33**	0.68	0.50
MZGB	18.46	21.09	2.63	1.14	**1.14**	166.23	217.05	1.14	**0.68**	1.25	0.21
M20M	662.27	702.08	39.81	1.06	**1.06**	87295	98106	1.06	**0.82**	0.86	0.60
MFLA	13.09	13.56	0.47	1.04	**1.04**	35.56	38.16	1.04	**-0.66**	0.51	0.62

Tabela 2.
Podaci kvantitativnih promjena za VI razred

u **p** valjalo bi odbaciti hipotezu o značajnim globalnim kvantitativnim promjenama. Ipak, pošto se radi o graničnom slučaju, moguća je inspekcija ostalih podataka, pa se može primijetiti pomak za koji su najviše odgovorne sposobnosti inkorporirane u pokazatelje energetske regulacije. Ostali pokazatelji su u ovom slučaju manje aktivni.
Prema globalnom pokazatelju Δ^2 = 2.0140, što za stupnjeve slobode D1 = 13 i D2 = 73, iskazuje vrijednost probabiliteta **p** = 0.0310, u intervalu između početka i kraja školske godine VI razreda osnovne škole, došlo je do značajnih globalnih kvantitativnih promjena. Na temelju podataka u **p** valja prihvatiti hipotezu o značajnim globalnim kvantitativnim promjenama. Na temelju inspekcije pojedinačnih podataka u univarijantnom modelu (t-test), može se primijetiti pomak za koji su najviše odgovorne sposobnosti inkorporirane u promjene masnog tkiva i cijelog motoričkog sklopa. Strukturni vektor K pokazuje da u međudjelovanju različitih sposobnosti i u VI razredu još uvijek prevladava razvoj motorike.
Vidi se, također, i naizgled kontardiktorna situacija visine tijela, jer je lokalni pomak po t-testu značajan, ali u strukturnom vektoru visina ne igra značajnu ulogu. Ovo je jasan primjer situacije po kojoj pomaci u visini postoje, ali u multuvarijantnom kompozitu za te pomake u visini nisu odgovorni procesi koji se mogu opisati kvantitativnim pokazateljima. Ovo je razumljivo kad znamo da upravo u ovom uzrastu (adolescencija) započinje specifičan razvoj visine i mase tijela. Ti procesi sigurno nisu linearni ili monotoni, već se podvrgavaju strogo usmjerenim funkcijama koje su u ovom uzrastu izvan općeg pravila rasta i razvoja.

Temeljem podataka u tabelama 1. i 2. moguće je zaključiti kako učenici u ovom razdoblju pokazuju tendenciju adaptacije na transformacijske postupke na način da se sve više adaptiraju na sustav stimulusa koji aktiviraju kvantitativne adaptacijske karakteristike. Ovo također znači i kako je u ovim uzrastima moguće povećavati intenzitet primijenjenih zadataka, jer je organizam učenika već podosta pripremljen za pozitivan prihvat takvih zadataka u biološko-funkcionalnom smislu. Ono što pomalo začuđuje svakako je relativno niska razina globalnih kvantitativnih promjena u oba slučaja, što znači da je skup primijenjenih stimulusa bio jedva aktivirajući u smislu poticaja razvoja, te ga sigurno treba nadograđivati.

Prema globalnom pokazatelju Δ^2 = 1.6396, što za stupnjeve slobode D1 = 13 i D2 = 54, iskazuje vrijednost probabiliteta **p** = 0.1027, u intervalu između početka i kraja školske godine VII razreda osnovne škole, došlo je do globalnih kvantitativnih promjena koje su ispod praga značajnosti od 0.05. Na temelju podataka u **p** valja odbaciti hipotezu o značajnim globalnim kvantitativnim promjenama. Čak u univarijantnom modelu (t-test) tek nekoliko varijabli pokazuje značajne promjene, što dodatno potvrđuje takav zaključak, a jednako je i sa strukturnim vektorom kvantitativnih promjena K, u kojemu je osim razvoja mase niz osrednjih i malih vrijednosti.
Ova situacija dodatno potvrđuje zaključak iz prethodnih analiza (tabele 1. i 2.) prema kojima je došlo do specifičnih kvantitativnih promjena. Te promjene se očituju na način da je sa VI razredom najvjerojatnije u najvećem dijelu završen razvoj motorike, odnosno - formirane fiziološke strukture odgovorne za upravljanje gibanjem formirane su u dijelu koji je bilo moguće kvantitativno povećavati u ovom razvojnom razdoblju života. Njihov daljnji razvoj moguć je samo na temelju drugačijih stimulusa, a za takve utjecaje potrebno je ne samo vrijeme, već i znatno drugačiji skup zadataka.

Očito ukupnosti efekata sugeriraju kako se radi o kombinaciji dvaju procesa. Jedan sigurno predstavlja rast i razvoj potpomognut transformacijskim procesom koji ima minimalni upliv na sposobnosti učenika, dok drugi proces nesumnjivo teži strukturalnim i drugim promjenama, koje su apsolutno izvan kontrole generatora transformacijskog procesa, tj. učitelja tjelesnog vježbanja. Potpuno je sigurno da treba iz temelja mijenjati pristup tjelesnom vježbanju, i to kako u smislu povećanog angažmana i intenziteta, tako i u pravcu povećanja sposobnosti djece, koje bi svakako išlo u pravcu kvantitativnih pomaka većeg intenziteta. To što je došlo do povećanja nekih parametara, nipošto ne znači i da je to sustavni cjeloviti proces. Baš to ova precizna metodologija doslovno kristalno čisto otkriva.

Ponašanje algoritma (Primjer 2. – Problem promjena u substrukturama)

U svrhu provjere kvalitete algoritma analizirani su i podaci 249 entiteta muškog spola, svi uzrasta 7 godina +/- 2 mjeseca, učenika prvog razreda osnovne škole koji su u trajanju od jedne školske godine bili podvrgnuti sistematskim transformacijskim postupcima s ciljem potpore funkcijama rasta i razvoja. U dva navrata, na početku i na kraju tretmana entiteti su izmjereni sa 26 varijabli zamišljenih da pokriju prostor morfoloških i motoričkih dimenzija. Od toga je bilo 14 morfoloških varijabli za koje je sigurno da se koriste prema međunarodnom biološkom programu, ali i da su u stanju relativno dobro pokriti različite modele latentnih dimenzija dobijene u različitim istraživanjima: visina tijela (AVIT), duljina noge (ADUN), duljina ruke (ADUR), dijametar ručnog zgloba (ADRZ), dijametar koljena (ADIK), biakromijalni raspon (ASIR), bikristalni raspon (ASIK), tjelesna težina (ATEZ),

	Mean1	Mean1	Delta	D	Q	VAR-1	VAR-2	DT	K	t	p(t)
AVIT	163.93	171.20	7.27	1.04	**1.04**	54.17	59.08	1.04	**0.61**	5.59	**0.00**
AMAS	51.16	58.04	6.88	1.13	**1.13**	71.46	91.98	1.13	**0.27**	4.41	**0.00**
AKNS	7.25	6.79	-0.47	0.94	**1.07**	6.97	6.11	0.94	**0.38**	1.06	0.24
AKNT	9.27	7.99	-1.28	0.86	**1.16**	10.85	8.06	0.86	**0.47**	2.41	**0.02**
MSTA	39.81	38.84	-0.97	0.98	**1.03**	51.90	49.39	0.98	**-0.19**	0.79	0.56
MTAP	13.04	12.32	-0.71	0.95	**1.06**	3.30	2.95	0.95	**0.23**	2.34	**0.02**
MEXP	181.73	185.23	3.50	1.02	**1.02**	302.96	314.74	1.02	**0.24**	1.15	0.25
MSNT	21.50	20.90	-0.60	0.97	**1.03**	15.77	14.90	0.97	**0.18**	0.89	0.62
MTRC	20.55	20.70	0.16	1.01	**1.01**	2.50	2.54	1.01	**0.11**	0.57	0.58
MGIP	19.45	18.86	-0.59	0.97	**1.03**	26.15	24.59	0.97	**0.17**	0.68	0.51
MZGB	24.09	25.49	1.40	1.06	**1.06**	176.33	197.39	1.06	**0.03**	0.59	0.56
M20M	874.39	885.00	10.61	1.01	**1.01**	70892	72622	1.01	**-0.01**	0.23	0.81
MFLA	11.90	13.48	1.58	1.13	**1.13**	33.76	43.31	1.13	**0.16**	1.47	0.14

Tabela 3.
Podaci kvantitativnih promjena za VII razred

opseg podlaktice (AOPL), opseg potkoljenice (AOPK), srednji opseg grudnog koša (AOGK), kožni nabor nadlaktice (AKNN), kožni nabor leđa (AKNL) i kožni nabor trbuha (AKNT).

Također je korišteno i 12 motoričkih varijabli, također zamišljenih da dobro pokriju prostor primarnih motoričkih dimenzija (koordinacije, frekvencije pokreta, fleksibilnosti, ravnoteže, repetitivne snage, eksplozivnosti, statičke snage i izdržljivosti) prema različitim istraživanjima: koraci u stranu (MKUS), poligon natraške (MPOL), taping rukom (MTAP), taping nogom (MTAN), pretklon u sjedu raznožno (MPRR), stajanje na klupici za ravnotežu (MP2O), skok u dalj s mjesta (MSDM), bacanje loptice u daljinu (MBLD), trčanje 20 m s visokim startom (M20V), podizanje trupa iz ležanja (MDTS), izdržaj u visu zgibom (MVIS), trčanje tri minute (FT3M). Spoznajni problem u ovom radu postavljen u maksimalno razapeti multidimenzionalni prostor, pa je i cijeli set varijabli promatran kao jedinstveni skup.

Prema globalnom pokazatelju $\Delta^2 = 6.0779$, što za stupnjeve slobode D1 = 26 i D2 = 223, iskazuje vrijednost probabiliteta **p** = 0.0000, u intervalu između prve i druge kontrolne točke, došlo je do globalnih kvantitativnih promjena koje su važne na pragu značajnosti manjem od 0.01. T-testovi pokazuju značajne lokalne promjene po pojedinim varijablama u svim slučajevima osim kod bacanja loptice, a relativni pomaci u vektoru D pokazuju uglavnom male vrijednosti, koje se mahom kreću do 1.05, što može biti indikacija sitnijih pomaka, ali koji su zbog velikog broja entiteta daleko od slučajnih događaja.

Strukturni vektor K jasno potvrđuje kako su kvantitativne promjene uglavnom nastale kao plod djelovanja procesa u prostoru morfoloških dimenzija, dok je motorički sklop uglavnom intaktan. Ovo je izuzetno zanimljiva informacija za učenike I razreda osnovne škole, jer svjedoči o činjenici da u tom uzrastu treba očekivati relativno linearni rast i razvoj u općem morfološkom smislu.

(Mean1,2 = aritmetičke sredine prvog i drugog mjerenja, Delta = razlika ar. sredina, D = koeficijenti translacije po varijablama, Q = redirekcionirani koeficijenti translacija, Var1,2 = varijance varijabli, DT = koeficijenti dilatacije po varijablama, K = strukturni vektor kvantitativnih promjena, t = t-test za pojedine varijable, p(t) = probabilitet za t-test).

Pozicija motoričkih funkcija najvjerojatnije je rezultat većeg broja faktora koje svakako ne treba dominantno tražiti u prostoru podražaja s kvantitativnim efektima, već najvjerojatnije u skupu zadataka koji imaju sposobnost stimulacije najšireg skupa motoričkih funkcija centralnog nervnog sistema na način da se ovaj strukturalno i drugačije adaptira. Pomaci u motoričkom prostoru postoje, ali multivarijantno gledano nisu kvantitativnog tipa.

U slučaju da se eventualno u ovom uzrastu želi postići znatnije kvantitativne pomake, očito bi trebalo redefinirati programe rada u osnovnoj školi i ovoj zadaći znatno ozbiljnije pristupiti, jer povećani intenzitet nužno znači i bolju definiciju cijele serije socijalnih uvjeta koji se pri tome moraju zadovoljiti.

Ponašanje algoritma (Primjer 3. – Problem u sportu)

U svrhu provjere kvalitete algoritma analizirani su i podaci 29 entiteta muškog spola, svi uzrasta 7 godina, polaznika sportske

Tabela 4. Podaci kvantitativnih promjena za I razred osnovne škole

	Mean1	Mean2	Delta	D	Q	Var1	Var2	DT	K	t	p(t)
AVIT	128.43	129.57	1.14	1.01	**1.01**	29.43	29.95	1.01	**0.68**	11.75	**0.00**
ADUN	71.44	72.42	0.98	1.01	**1.01**	13.61	13.99	1.01	**0.63**	12.37	**0.00**
ADUR	53.00	52.69	-0.31	0.99	**1.01**	8.84	8.74	0.99	**0.61**	13.04	**0.00**
ADRZ	4.19	4.15	-0.04	0.99	**1.01**	0.07	0.07	0.99	**0.64**	15.69	**0.00**
ADIK	7.74	7.74	0.00	1.00	**1.00**	0.22	0.22	1.00	**0.66**	15.31	**0.00**
ASIR	27.24	26.80	-0.44	0.98	**1.02**	2.37	2.30	0.98	**0.65**	14.59	**0.00**
ASIK	20.30	18.16	-2.14	0.89	**1.12**	2.09	1.67	0.89	**0.65**	15.76	**0.00**
ATEZ	27.02	27.40	0.38	1.01	**1.01**	19.33	19.88	1.01	**0.86**	3.58	**0.00**
AOPL	17.79	17.78	-0.01	1.00	**1.00**	2.36	2.36	1.00	**0.69**	13.57	**0.00**
AOPK	25.76	25.34	-0.42	0.98	**1.02**	4.79	4.63	0.98	**0.77**	12.85	**0.00**
AOGK	60.68	59.46	-1.22	0.98	**1.02**	16.91	16.23	0.98	**0.75**	11.21	**0.00**
AKNN	11.44	11.01	-0.43	0.96	**1.04**	13.15	12.17	0.96	**0.57**	1.64	**0.10**
AKNL	7.01	6.25	-0.76	0.89	**1.12**	9.75	7.75	0.89	**0.51**	4.35	**0.00**
AKNT	7.43	6.03	-1.40	0.81	**1.23**	23.10	15.21	0.81	**0.60**	15.11	**0.00**
MKUS	16.23	13.22	-3.01	0.81	**1.23**	3.93	2.61	0.81	**-0.06**	14.41	**0.00**
MPOL	22.94	14.37	-8.57	0.63	**1.60**	41.55	16.30	0.63	**-0.01**	13.51	**0.00**
MP2O	1.73	1.94	0.21	1.12	**1.12**	0.49	0.62	1.12	**0.18**	9.55	**0.00**
MPRR	36.84	35.06	-1.79	0.95	**1.05**	71.28	64.54	0.95	**0.20**	7.40	**0.00**
MTAP	19.27	17.26	-2.01	0.90	**1.12**	8.16	6.55	0.90	**0.14**	9.50	**0.00**
MTAN	15.71	14.93	-0.78	0.95	**1.05**	3.82	3.45	0.95	**0.21**	12.24	**0.00**
MSDM	112.89	115.48	2.59	1.02	**1.02**	297.26	311.05	1.02	**0.10**	8.77	**0.00**
MBLD	10.45	11.48	1.02	1.10	**1.10**	9.19	11.08	1.10	**0.36**	1.25	0.21
M20V	4.93	4.30	-0.64	0.87	**1.15**	0.18	0.14	0.87	**-0.08**	17.44	**0.00**
MDTS	21.55	19.89	-1.65	0.92	**1.08**	44.34	37.80	0.92	**0.27**	8.42	**0.00**
MVIS	10.91	15.03	4.13	1.38	**1.38**	74.68	141.92	1.38	**0.02**	7.05	**0.00**
MT3M	443.98	511.06	67.09	1.15	**1.15**	3335.53	4419.77	1.15	**0.13**	10.26	**0.00**

škole koji su u trajanju od 9 mjeseci bili podvrgnuti sistematskim transformacijskim postupcima s ciljem potpore općim temeljnim funkcijama rasta i razvoja kao temelj pripreme za sportski angažman. U dva navrata, na početku i na kraju tretmana, entiteti su izmjereni sa 26 varijabli zamišljenih da pokriju prostor morfoloških i motoričkih dimenzija. Od toga je bilo 14 morfoloških varijabli za koje je sigurno da se koriste prema međunarodnom biološkom programu, ali i da su u stanju relativno dobro pokriti različite modele latentnih dimenzija dobijene u različitim istraživanjima: visina tijela (AVIT), duljina noge (ADUN), duljina ruke (ADUR), dijametar ručnog zgloba (ADRZ), dijametar koljena (ADIK), biakromijalni raspon (ASIR), bikristalni raspon (ASIK), tjelesna težina (ATEZ), opseg podlaktice (AOPL), opseg potkoljenice (AOPK), srednji opseg grudnog koša (AOGK), kožni nabor nadlaktice (AKNN), kožni nabor leđa (AKNL) i kožni nabor trbuha (AKNT).

Također je korišteno i 12 motoričkih varijabli, također zamišljenih da dobro pokriju prostor primarnih motoričkih dimenzija (koordinacije, frekvencije pokreta, fleksibilnosti, ravnoteže, repetitivne snage, eksplozivnosti, statičke snage i izdržljivosti) prema različitim istraživanjima: koraci u stranu (MKUS), poligon natraške (MPOL), taping rukom (MTAP), taping nogom (MTAN), pretklon u sjedu raznožno (MPRR), stajanje na klupici za ravnotežu (MP2O), skok u dalj s mjesta (MSDM), bacanje loptice u daljinu (MBLD), trčanje 20 m s visokim startom (M20V), podizanje trupa iz ležanja (MDTS), izdržaj u visu zgibom (MVIS), trčanje tri minute (FT3M). Spoznajni problem u ovom radu postavljen je u maksimalno razapeti multidimenzionalni prostor, pa je i cijeli set varijabli promatran kao jedinstveni skup.

Prema globalnom pokazatelju $\Delta^2 = 11.3433$, što za stupnjeve slobode $D1 = 26$ i $D2 = 3$, iskazuje vrijednost probabiliteta $p = 0.0348$, u intervalu između prve i druge kontrolne točke, došlo je do značajnih globalnih kvantitativnih promjena. T-testovi pokazuju značajne lokalne promjene u varijablama koje opisuju transverzalnu dimenzionalnost i intenzivan angažman donjih ekstremiteta. Relativni pomaci u vektoru D pokazuju male i ujednačene vrijednosti u morfološkom, te znatno većeg intenziteta u motoričkom sklopu.

Konačno, strukturni vektor kvantitativnih promjena K pokazuje da je došlo do niza značajnih promjena koje se doslovno moraju dovesti u vezu s provedenim transformacijskim postupkom, iz jednostavnog razloga što je tretman izazvao promjene duž cijelog seta promatranih svojstava entiteta. Rezultati su posebno razumljivi ako se uzme u obzir da se radi o djeci istog uzrasta kao u Primjeru 2. ovog teksta, pa se mora zaključiti kako je posebno programirani transformacijski postupak izazvao znatno kvalitetnije i poželjnije kvantitativne efekte od nastave u školi.

Zaključak

Napisan je i testiran algoritam za sveobuhvatnu analizu kvantitativnih promjena, s ciljem da pokrije tri segmenta tih transformacija: 1) globalni segment, 2) strukturu promjena u strukturnom vektoru globalnih promjena i 3) lokalni tj. po pojedinim varijablama. Temeljna ideja algoritma je da jedna grupa objekata transfor-

	Mean1	Mean2	Delta	D	Q	Var1	Var2	DT	K	t	p(t)
AVIT	129.66	133.36	3.70	1.03	**1.03**	26.39	27.92	1.03	**0.38**	0.51	0.62
ADUN	72.07	74.88	2.81	1.04	**1.04**	14.67	15.82	1.04	**0.26**	0.69	0.50
ADUR	53.91	55.23	1.32	1.02	**1.02**	7.61	7.98	1.02	**0.47**	0.64	0.54
ADRZ	4.25	4.37	0.12	1.03	**1.03**	0.07	0.08	1.03	**0.31**	6.16	**0.00**
ADIK	7.83	8.06	0.22	1.03	**1.03**	0.22	0.23	1.03	**0.64**	3.68	**0.00**
ASIR	27.73	28.90	1.17	1.04	**1.04**	1.85	2.01	1.04	**0.59**	2.27	**0.03**
ASIK	20.88	21.84	0.96	1.05	**1.05**	2.88	3.15	1.05	**0.36**	1.19	0.24
ATEZ	28.56	31.43	2.87	1.10	**1.10**	17.02	20.62	1.10	**0.41**	0.57	0.58
AOPL	18.25	19.01	0.75	1.04	**1.04**	2.27	2.46	1.04	**0.57**	1.19	0.24
AOPK	26.12	27.20	1.08	1.04	**1.04**	5.69	6.17	1.04	**0.57**	0.68	0.51
AOGK	62.89	64.13	1.24	1.02	**1.02**	16.75	17.41	1.02	**0.61**	0.27	0.78
AKNN	12.10	11.02	-1.08	0.91	**1.10**	18.70	15.51	0.91	**-0.03**	0.23	0.81
AKNL	7.49	6.80	-0.69	0.91	**1.10**	15.03	12.37	0.91	**0.08**	0.19	0.85
AKNT	8.88	6.97	-1.91	0.79	**1.27**	37.11	22.89	0.79	**0.01**	0.23	0.81
MKUS	15.77	13.61	-2.17	0.86	**1.16**	2.09	1.55	0.86	**0.45**	4.40	**0.00**
MPOL	21.38	15.13	-6.24	0.71	**1.41**	25.09	12.58	0.71	**0.32**	1.18	0.25
MP2O	1.81	2.17	0.36	1.20	**1.20**	0.68	0.98	1.20	**0.54**	1.59	0.12
MPRR	39.77	45.46	5.69	1.14	**1.14**	72.27	94.39	1.14	**0.16**	0.25	0.80
MTAP	19.98	22.93	2.95	1.15	**1.15**	8.12	10.70	1.15	**0.08**	1.16	0.25
MTAN	15.95	18.02	2.07	1.13	**1.13**	1.86	2.38	1.13	**0.36**	3.62	**0.00**
MSDM	121.82	141.23	19.41	1.16	**1.16**	238	320	1.16	**0.50**	0.26	0.79
MBLD	13.01	15.66	2.66	1.20	**1.20**	7.77	11.26	1.20	**0.58**	1.03	0.31
M20V	4.77	4.38	-0.39	0.92	**1.09**	0.17	0.15	0.92	**0.51**	9.16	**0.00**
MDTS	24.14	29.11	4.96	1.21	**1.21**	36.69	53.33	1.21	**0.24**	0.41	0.69
MVIS	12.31	29.76	17.45	2.42	**2.42**	89.04	520.56	2.42	**0.20**	0.17	0.86
MT3M	496.11	596.25	100	1.20	**1.20**	2707	3910	1.20	**-0.09**	0.11	0.91

Tabela 5. Podaci kvantitativnih promjena za uzorak od 29 djece

macijskim procesom biva prevedena u neko drugo stanje. To drugo stanje projektirano je funkcijom centroida stvarnih rezultata cijele grupe, te je tako cijela grupa entiteta tretirana u smislu prorporcionalnih pomaka, koji osiguravaju nepromijenjenost relacija varijabli u takva dva mjerenja. Za taj pomak centorida, tada je odgovoran neslučajni proces između dvije kontrolne točke koji se manifestira na kvantitativni način. Sve ostalo predstavlja grešku u odnosu na kvantitativnu mjeru. Intenzitet te greške transformacijskog procesa može se ispitati bilo kojim postupkom za analizu strukturalnih promjena, ili spektralnom dekompozicijom matrice razlika.

Ponašanje algoritma je ispitano u tri različite situacije (razvojni problem, problem substruktura, problem u sportu) na uzorcima učenika V, VI i VII razreda osnovne škole mjerenih s 13 varijabli, kao i s uzorkom učenika I razreda osnovne škole mjerenih s 26 varijabli u dvije kontrolne točke, između kojih su u svim tim situacijama primjenjivani opći transformacijski procesi provedeni s ciljem potpore rastu i razvoju, te na malom uzorku od 29 mladih sportaša uzrasta 7 godina, polaznika sportske škole mjerenih dva puta s 26 istih varijabli u razdoblju od 9 mjeseci, u kojemu je primijenjen transformacijski postupak radi podizanja općih sposobnosti i pripreme za sport.

Kvantitativne promjene su u svim situacijama precizno identificirane na sve tri razine i mogle su se dosta jednostavno objasniti, što je potvrdilo snagu algoritma u svrhu operacionalne primjene. Naročito je važno napomenuti da je algoritam napisan s idejom da barem rezultati dobijeni tim algoritmom budu lako razumljivi i primjenjivi, kako u školskom radu, tako i u radu u sportu. Iz tih razloga svi relevantni podaci saturirani su u samo jednu tabelu. Algoritam je pokazao veliku snagu identifikacije stvarnih kvantitativnih promjena i svakako bi ga trebalo preporučiti svima kojima takve promjene mnogo znače u cilju postizanja bilo kakvih mjerljivih rezultata.

Literatura

1. Bonacin, D., Carev, Z. (2002). Process identification. Kinesiology – new perspectives, III international scientific conference, Opatija, Proceedings: 632-635.
2. Cooley, W.W., Lohnes, P.R. (1971). Multivariate data analysis. John Wiley and sons. Inc, New York.
3. Fulgosi, A. (1979). Faktorska analiza. Školska knjiga, Zagreb.
4. Harman, H.H. (1970). Modern Factor Analysis. The University of Chicago.
5. Ivković, Z. A. (1980). Matematička statistika. Naučna knjiga, Beograd.
6. Johnson, A.R., Wichern, W.D. (1992). Applied Multivariate Statistical Anaysis. Prentice-Hall, Englewood Cliffs.
7. Kurepa, S. (1978). Uvod u linearnu algebru. Školska knjiga, Zagreb.
8. Momirović, K. (1984). Kvantitativne metode za programiranje i kontrolu treninga. FFK Sveučilišta u Zagrebu. Zagreb.
9. Momirović, K., Štalec, J., Prot, F., Bosnar, K., Viskić-Štalec, N., Pavičić, L., Dobrić, V. (1984). Kompjuterski programi za klasifikaciju, selekciju, programiranje i kontrolu treninga. FFK Sveučilišta u Zagrebu. Zagreb.
10. Momirović, K, Prot. F., Dugić, D., Knezović, Z., Bosnar, K., Erjavec, N., Gredelj, M., Kern, J., Dobrić, V., Radaković, J. (1987). Metode, algoritmi i programi za analizu kvantitativnih i kvalitativnih promjena. Institut za kineziologiju FFK Sveučilišta u Zagrebu. Zagreb.
11. Mulaik, S.A. (1972). The foundations of factor analysis. McGraw-Hill, New York.
12. Rađo, I., Wolf, B. (2002). Kvantitativne metode u sportu. Sarajevo.