

## MODEL OBJEKTIVNOG UTVRĐIVANJA INICIJALNIH SKUPINA, NJIHOVOG STATUSA I ŽELJENIH CILJNIH FUNKCIJA TRANSFORMACIJA

Mirna Andrijašević<sup>1</sup>, Dobromir Bonacin<sup>2</sup>, Ivan Prskalo<sup>3</sup>, Josip Babin<sup>4</sup>, Lidija Vlahović<sup>4</sup>

<sup>1</sup> Kineziološki fakultet Sveučilišta u Zagrebu

<sup>2</sup> Fakultet sporta i tjelesnog odgoja Univerziteta u Sarajevu

<sup>3</sup> Učiteljski fakultet Sveučilišta u Zagrebu

<sup>4</sup> Fakultet prirodoslovno-matematičkih znanosti i kineziologije Sveučilišta u Splitu

### Sažetak

Na uzorku od 249 učenika dobi 7 godina (+/- 2 mjeseca) koji su opisani sa 26 varijabli. Za potrebe ovog rada i ilustraciju funkcija cilja, definiran je uzorak kroz dvije varijante. U jednoj kao sposobnost istrajnog trčanja 3 minute (MT3M), a u drugoj kao sposobnost eksplozivnosti, koja je definirana kao kompozit od više varijabli: skok u dalj s mjesta, bacanje loptice u daljinu, trčanje 20 m iz visokog starta. Iz navedenih razloga, ponuđeni model u ovom radu omogućava objektiviziranje utvrđenih skupina unutar bilo kako definiranog uzorka. Rješenje je u odgovarajućoj metodološkoj interakciji, na način da se oblikuje takva solucija koja će uvažiti i funkcije cilja (a), i taksonomsku determinaciju (b). Takva varijanta, prije svega, uvažava multivarijantne zahtjeve po kojima se skupine prepoznaju. U tom smislu kreirana je Uditax procedura koja taksonomizira subjekte na temelju spektralne dekompozicije matrice udaljenosti samih subjekata u standardnom prostoru i nakon odlučivanja o broju realnih taksona entropijskom funkcijom, identificira reprezentativne subjekte takve strukture. Dobiveni se taksoni mogu bilo kojim postupkom analize redundancije skupova (regresijski ili kanonički postupci) dovesti u vezu s različito definiranim skupom kriterijskih parametara tj. funkcija cilja. To zaokružuje model na način da se taksoni svrstavaju na ciljane funkcije u skladu s multivarijantnim karakteristikama pojedine skupine. Procedurom, Uditax izdvojene su skupine i u skladu s normalnom distribucijom, hipotetski na ekstremnim stranama bili pozicionirani t.zv. nerazvijeni i atletici, uz njih krupni i nerazvijeni, te u sredini lagani entiteti.

Diskriminativna analiza taksonomskih dimenzija rezultirala je sa sve četiri značajne diskriminativne funkcije, lako uočljive i jednostavne za interpretaciju.

**Ključne riječi:** *inicijalna provjera, orijentacija, selekcija, sedmogodišnjaci, transformacija, taksoni*

### Uvod

Utvrdivanje zakonitosti kinezioloških transformacija iznimno je složen zadatak. Razlozi za to leže u činjenici kompleksnosti ljudskog organizma s nizom međusobno isprepletenih funkcija. Poznato je da djelovanje na jedan segment ljudskih sposobnosti i karakteristika neminovno utječe na cijeli niz drugih organskih sustava i segmenata (Mraković, 1992). Integriranost i uzajamno djelovanje očituje se u situacijama kad se traži dostizanje vrhunskih rezultata i postignuća u sportu (Malacko i Rađo 2004, Hardman, 2002), traže se optimalni modeli koji će u najranijoj dobi biti prihvatljivi i prepoznatljivi u funkciji organizacije cjelovitog ciklusa rada sa budućim sportašima (Persyn U. & V. Colman, 2003). Ali jednako i kad se radi o edukaciji, (Findak 1997), (Rokita, 2005), pri čemu je standardnu nastavu tjelesne i zdravstvene kulture potrebno stalno unapređivati i usklađivati s objektivnim potrebama (Douillard J. 2000). Sportska rekreacija obuhvaća najveći broj sudionika, gdje rana selekcija može unaprijediti kvalitetu rada sa djecom, ostavljajući otvorenu mogućnost „ulaska“ i „izlaska“ njenih korisnika iz rekreacijskog sustava vježbanja u natjecateljski, sportski sustav (Andrijašević, 1995, 2000, 2001). Mogućnost redovitog vježbanja posebno je značajno za djecu iz urbanih sredina, kao faktor optimalizacije sposobnosti djece i prevencije bolesti (Mader

S.S. 2002). Sve intenzivniji morbidni faktori u urbanim sredinama predstavljaju negativni čimbenik optimalnog razvoja djece (Stein P. L. & B. M. Rowe, 1996).

Iz tih razloga, zadaćama transformacijskih procesa već odavno se pristupa sistematično, uvažavajući pri tom znanstveno utemeljene spoznaje, pa i genetske čimbenike (Leland H. Hartwell, 2000), što uz ostale uvjete, vodi u planiranje i programiranje transformacijskih postupaka (Missitzi J. & V. Klissouras, 2003). Kvalitetno planiranje i programiranje nije moguće bez utvrđivanja **početnih obilježja i karakteristika subjekata** koji su obuhvaćeni transformacijskim postupkom, jer od inicijalnih obilježja direktno ovisi orijentacija i selekcija odnosno modeliranje trenažnih, sportsko rekreacijskih ili edukacijskih programa te konačni učinak i rezultat. Kako je individualizacija maksimalno približavanje programa tjelesnog vježbanja individualnim obilježjima nekog subjekta za unaprijed određene ciljeve onda je poznavanje antropološkog statusa bitna pretpostavka za provođenje individualnog oblika rada (Findak 1999).

Međutim, dok je u teorijskim postavkama sve jasno, kad se prilazi realizaciji ovih postavki, nastupaju brojni situacijski problemi. Neki od njih su vezani uz realne organizacijske i tehničke pretpostavke (materijalne uvjete, osposobljenost stručnjaka i sl.), ali jedan od većih problema je objektivno utvrđivanje inicijalnog statusa skupina subjekata. Iako su ponuđeni različiti modeli za rješavanje ovih zadaća, teško se složiti s tvrdnjom da je problem objektivno riješen, pa je programiranje, najčešće u samoj provedbi, opterećeno kontinuiranim intervencijama koje nisu uvijek i optimalne. Dio neriješenih zadaća javlja se iz razloga što je „homogenost“ skupina teško objektivno utvrditi, jer uvažavanje samo jednog parametra ili varijable često mijenja skupnu determinaciju. Tako pitanja objektivnih modela i dalje ostaju djelomice neriješena i otvorena. Posljedica ovakve situacije je divergentnost realizacije skupnih i individualnih programskih sadržaja, što neminovno dovodi do izostajanja optimalnih efekata. Iz navedenih razloga, ponuđeni model u ovom radu omogućava objektiviziranje utvrđenih skupina unutar bilo kako definiranog uzorka.

## Metode

### *Model*

Modeli bilo koje vrste koji se mogu primijeniti za definiciju objektivizacije kinezioloških pokazatelja nužno se oslanjaju na metode za analizu podataka, jer bez objektivne parametrizacije nije moguće utvrditi objektivne činjenice. Postojeće metode, za utvrđivanje grupnih determinanti mogu se načelno podijeliti u dvije skupine: a) metode s poznatom funkcijom cilja, i b) taksonomske metode. Kod metoda s **poznatom funkcijom cilja**, obično se ukupni uzorak razdjeljuje u skupine obzirom na rezultate, postignute na najmanje jednoj kriterijskoj varijabli. Ovaj pristup, ma kako izgledao objektivno, u prevelikoj mjeri zapostavlja multivarijabilnost relacija segmenata organizma. Tako preveliko značenje daje funkciji cilja, što za posljedicu generira nedovoljno objektivne transformacijske programe u kojima su nedovoljno inkorporirana brojna krucijalna antropološka obilježja od kojih ovisi, kako skupna determinacija, tako i individualni pristup transformacijama. Kod poznatih **taksonomskih** metoda problemi se javljaju zbog dva razloga: 1) kod distinktnih taksona ne postoje objektivni markeri koji bi osiguravali, kako broj, tako jednako i strukturu taksona, a niti individualnu lociranost pojedinih subjekata, i 2) kod polarnih taksona točno svrstavanje u skupine je onemogućeno samom činjenicom da se takvim pristupom dopušta lociranje subjekata na više od jednog taksona, čime je skupna identifikacija jasno derogirana. Rješenje je očito u odgovarajućoj metodološkoj interakciji, na način da se oblikuje takva solucija koja će uvažiti i funkcije cilja (a), i taksonomsku determinaciju (b). Takva varijanta, prije svega, uvažava multivarijantne zahtjeve po kojima se skupine prepoznaju. U tom smislu kreirana je Uditax procedura (Bonacin 2004.) koja taksonomizira subjekte na temelju spektralne dekompozicije matrice udaljenosti samih subjekata u standardnom prostoru i nakon odlučivanja o broju realnih taksona entropijskom funkcijom, identificira reprezentativne subjekte takve strukture. Oko njih, prirodno, gradi čvrste i vjerodostojne clusterne. Opis strukture je precizan i jasan, jer su rezultati taksona projicirani na vrijednosti početnih varijabli, čime se taksoni lako prepoznaju. Opis je

upotpunjen diskriminativnom analizom taksona radi konačne interpretacije. Ovaj postupak je u fazama testiranja pokazao izrazitu superiornost u odnosu na sve do sada poznate taksonomske ili cluster analize. Nakon što su tako objektivno utvrđeni markeri (parametri) identifikacije taksona, diskriminacija taksona, kao i pozicija svakog pojedinog subjekta, u model se, prirodno, može uključiti i funkcija cilja i to na vrlo jednostavan način.

Dobiveni se taksoni mogu bilo kojim postupkom analize redundancije skupova (regresijski ili kanonički postupci) dovesti u vezu s bilo kako definiranim skupom kriterijskih parametara tj. funkcija cilja. To zaokružuje model na način da se taksoni svrstavaju na ciljane funkcije u skladu s multivarijantnim karakteristikama pojedine skupine. Konačni opis funkcije cilja definiran je redundancijom karakteristika skupine i ciljnih funkcija. Naravno, modelu je pridružena i opcija po kojoj se broj taksona može utvrditi i proizvoljno, u skladu s realnim potrebama, pa tada sam model optimizira grupe obzirom na njihov broj. Također, ciljane funkcije mogu biti bilo koje varijable, pa čak i one koje služe za opći multivarijantni antropološki opis samog uzorka, što omogućava iznimnu fleksibilnost pri utvrđivanju inicijalnog statusa. Kad su svi ovi pokazatelji poznati, poznat je i inicijalni status skupina subjekata, pa je programiranje transformacijskih procesa toliko olakšano, da se gotovo može pristupiti individualnom programiranju,

### ***Uzorak i varijable***

Za ilustraciju modela, i za potrebe ovog rada, odabrana su dva primjera iz istog uzorka od 249 učenika uzrasta 7 godina (+/- 2 mjeseca) koji su opisani sa 26 varijabli prilikom samog početka prvog razreda osnovne škole, a mjerenja su izvršena u sklopu projekta „Efikasnost kinezioloških tretmana u periodu od 7. do 10. godine“ (MZT RH: 5-10-219). Za potrebe ovog rada i ilustraciju funkcija cilja, definirati će se uzorak kroz dvije varijante. U jednoj kao sposobnost istrajnog trčanja 3 minute (MT3M), a u drugoj kao sposobnost eksplozivnosti, koja je definirana kao kompozit od više varijabli: skok u dalj s mjesta (MSDM), bacanje loptice u daljinu (MBLD), trčanje 20 m iz visokog starta (M20V). Ostale primijenjene varijable bile su: visina tijela (AVIT), duljina noge (ADUN), duljina ruke (ADUR), dijametar ručnog zgloba (ADRZ), dijametar koljena (ADIK), širina ramena (ASIR), širina zdjelice (ASIK), tjelesna težina (ATEZ), opseg podlaktice (AOPL), opseg potkoljenice (AOPK), opseg grudnog koša (AOGK), kožni nabor nadlaktice (AKNN), kožni nabor leđa (AKNL), kožni nabor trbuha (AKNT), koraci u stranu (MKUS), poligon natraške (MPOL), taping rukom (MTAP), taping nogom (MTAN), pretklon u sijedu raznožno (MPRR), stajanje na klupici za ravnotežu (MP2O), podizanje trupa iz iz ležećeg položaja (MDTS), izdržaj u visu zgibom (MVIS).

Primjena prvog postupka očito teži optimalizaciji selekcije za vrhunski sportski domet s naglaskom na eksplozivnost, a u drugom slučaju s istrajnim trčanjem s naglaskom na kvaliteti transportnog sustava za kisik i ekstrakciju metabolita mišićnog rada, što je značajno u području edukacije, sportske rekreacije ili u fazi kineziterapiji nakon saniranih ozljeda i sl.

### ***Rezultati***

Prvi ilustrativni primjer odnosi se na uzorak uzrasta 7 godina opisan s 23 navedene varijable u okviru općeg antropološkog statusa, te s 3 kriterijske varijable za procjenu opće eksplozivnosti.

Tabela 1. Uditax taxoni (GR01-05)

		GR01	GR02	GR03	GR04	GR05
Kako vidi	N	49	15	108	61	16
	%	19.68	6.02	43.37	24.50	6.43
		NRZV nerazvijeni	ADIP adipozni	LGNI lagani	KRUP krupni	ATLE atletici
	AVIT visina tijela	-1.28	0.29	0.12	0.90	-0.62
	ADUN duljina noge	-1.14	0.43	0.09	0.79	-0.54
	ADUR duljina ruke	-1.12	-0.08	0.12	0.86	-0.56
	ADRZ dijametar ručnog zgloba	-0.90	0.55	-0.11	0.78	0.00
	ADIK dijametar koljena	-0.89	0.63	-0.14	0.85	-0.21
	ASIR širina ramena	-1.07	0.89	0.01	0.70	-0.28
	ASIK širina zdjelice	-0.96	1.60	0.02	0.46	-0.45
	ATEZ tjelesna težina	-1.09	1.77	-0.25	1.00	-0.48
	AOPL opseg podlaktice	-0.80	1.20	-0.27	0.83	-0.03
	AOPK opseg potkoljenice	-0.90	1.13	-0.30	1.02	-0.16
	AOGK opseg grudnog koša	-0.86	1.67	-0.28	0.86	-0.34
	AKNN kožni nabor nadlaktice	-0.48	2.10	-0.34	0.59	-0.45
	AKNL kožni nabor leđa	-0.36	2.53	-0.34	0.36	-0.32
	AKNT kožni nabor trbuha	-0.49	2.37	-0.38	0.60	-0.42
	MKUS koraci u stranu	0.37	0.78	-0.20	-0.10	-0.14
	MPOL poligon natraške	0.20	0.85	-0.17	0.04	-0.42
	MP2O stajanje na klupici za ravnotežu	-0.07	-0.30	0.05	-0.07	0.46
	MPPR pretklon u sijedu raznožno	-0.11	-0.33	-0.21	0.37	0.62
	MTAP taping rukom	-0.17	0.45	0.08	-0.26	0.58
	MTAN taping nogom	-0.21	-0.13	0.08	-0.08	0.51
	MDTS podizanje trupa iz ležanja	-0.54	-0.31	0.10	0.04	1.15
	MVIS izdržaj u visu zglobom	-0.09	-0.92	0.05	-0.33	2.03
	MT3M istrajno trčanje 3 minute	-0.14	-0.13	0.06	-0.13	0.65

se  
iz

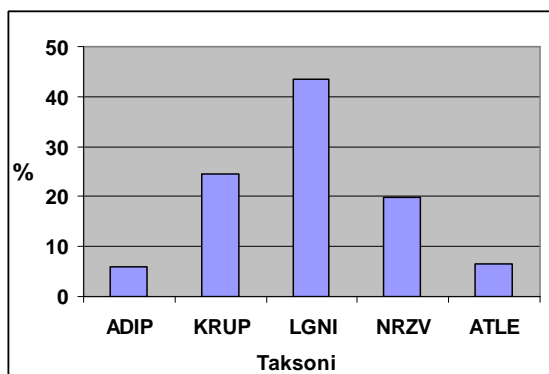
Tabele 1. dobiveni su izuzetno jasni taksoni, koji opisuju 5 tipova entiteta u uzorku. Najbrojniji su entiteti koji pripadaju trećem taksonu (43 %), a koji nedvojbeno opisuje entitete čije se vrijednosti kreću oko nule, dakle prosječno. Vidi se da je veći dio morfološkog sklopa blago negativno projiciran, te da su najniže vrijednosti u području voluminoznosti, longitudinalnost je pozitivna. Motorički je sličan s činjenicom da su vrijednosti motoričkih fenomena ipak uglavnom pozitivne. Iz ovoga slijedi zaključak, a taj govori da se radi o t.zv. „*laganim*“ entitetima (LGNI) kojima morfološki segment nije veći supresor u realizaciji gibanja.

Prvi takson (20 % uzorka) opisuje entitete izrazito niskih vrijednosti morfoloških mjera, a u motoričkom dijelu se ta situacija održava, uz nešto manje naglašene negativne vrijednosti. Kako se radi o potpunom prostoru opisanom sa svim varijablama, jasno je da se radi o t.zv. „*nerazvijanim*“ entitetima (NRZV) male mase i malih skeletnih dimenzija, sa skromnim motoričkim mogućnostima. Drugi takson (6 % uzorka) opisuje grupu sa naglašenom voluminoznošću, te prekomjernim dimenzijama masnog tkiva. U motoričkom prostoru, sve su dimenzije također negativne osim tapinga koji pokazuje suprotni predznak. Očito se radi o t.zv. „*adipozanim*“ entitetima (ADIP), što naravno potvrđuje i pozicija izdržaja u visu, te se može ustvrditi da je realizacija gibanja ove grupe jako ograničena, prije svega zbog veće balastne mase, ali i drugim s tim povezanim uzrocima. Četvrti takson (25 % uzorka) iskazuje veliku visinu i masu s dosta masnog tkiva, dok u motoričkom prostoru pokazuje vrijednosti, koje se uz manja odstupanja, kreću oko prosječnih.

Radi se o skupini izrazito t.zv. „*krupnih*“ i ne osobito motorički sposobnih entiteta (KRUP), kojima ukupne motoričke sposobnosti predstavljaju znatna ograničenja za uspješnu realizaciju općih obrazaca kretanja. Peti takson (6.43 % uzorka) pokazuje skupinu izrazito dominantnu u svim motoričkim sposobnostima, dok se kod morfoloških mjera pozicioniraju ispod prosjeka. Očito je da ovoj, relativno maloj, skupini u uzorku (ATLE) pripadaju t.zv. „*atletici*“ i da su njihove sposobnosti znatno veće od ostalih.

Procedurom, Uditax izdvojene su skupine i u skladu s normalnom distribucijom, hipotetski na ekstremnim stranama bili pozicionirani tzv. nerazvijeni i atletici, uz njih krupni i nerazvijeni, te u sredini lagani entiteti.

**Slika1. Pretpostavljena distribucija**



Diskriminativna analiza taksonomskih dimenzija rezultirala je sa sve četiri značajne diskriminativne funkcije (svi probabiliteti su bili manji od 0.0001), lako uočljive i jednostavne za interpretaciju.

**Tabela 2. Diskriminativne funkcije**

	F 1	F 2	F 3	F 4
AVIT visina tijela	0.72	0.50	-0.22	-0.13
ADUN duljina noge	0.66	0.40	-0.17	-0.13
ADUR duljina ruke	0.60	0.53	-0.24	-0.03
ADRZ dijametar ručnog zgloba	0.60	0.29	0.10	0.12
ADIK dijametar koljena	0.64	0.25	0.03	0.17
ASIR širina ramena	0.68	0.24	0.00	-0.15
ASIK širina zdjelice	0.69	-0.03	0.01	-0.36
ATEZ tjelesna težina	0.95	0.02	0.07	0.12
AOPL opseg podlaktice	0.70	0.06	0.19	0.23
AOPK opseg potkoljenice	0.79	0.14	0.14	0.34
AOGK opseg grudnog koša	0.82	-0.05	0.12	0.16
AKNN kožni nabor nadlaktice	0.69	-0.37	0.13	0.15
AKNL kožni nabor leđa	0.64	-0.55	0.23	-0.01
AKNT kožni nabor trbuha	0.74	-0.44	0.18	0.15
MKUS koraci u stranu	0.00	-0.39	0.06	0.15
MPOL poligon natraške	0.12	-0.34	-0.05	0.13
MP2O stajanje na klupici za ravnotežu	-	0.08	0.13	0.15
MPRR pretklon u sjedju raznožno	0.09	0.20	0.26	0.40
MTAP taping rukom	0.01	-0.05	0.28	-0.36
MTAN taping nogom	0.02	0.14	0.18	-0.19
MDTS podizanje trupa iz ležanja	0.05	0.37	0.43	-0.25
MVIS izdržaj u visu zgibom	0.33	0.37	0.73	-0.17
MT3M istrajno trčanje 3 minute	0.06	0.12	0.24	-0.17
	F 1	F 2	F 3	F 4
NRZV (nerazvijeni)	0.50	-0.17	-0.03	0.06
ADIP (adipozni)	0.25	-0.14	0.03	-0.02
LGNI (lagani)	0.18	0.14	-0.11	-0.12
KRUP (krupni)	0.52	0.12	-0.03	0.08
ATLE (atletici)	-	0.09	0.05	0.14
	0.09	0.05	0.14	0.00

Prva diskriminativna funkcija diskriminira taksonse/tipove isključivo prema morfološkim karakteristikama. Vidljivo je da su taksoni t.zv. „adipoznih“ (ADIP) i „krupnih“ (KRUP) pozitivno pozicionirani na tu dimenziju, a sva tri ostala taksona negativno.

Druga diskriminativna funkcija razlikuje entitete po dimenziji longitudinalnosti, tzv. „krupni“ i „lagani“ s jedne, a t.zv. „nerazvijeni“ i „adipozni“ s druge strane. Treća funkcija dominantno je definirana izraženom energetsom komponentom u kojoj se posebno ističe izdržaj u visu, (MVIS) prije svega u korist „atletika“, praktično nasuprot svima ostalima.

Četvrta funkcija razlikuje entitete s cijelim sustavom dobro uravnoteženih motoričkih funkcija kojima su pridružene mjere transverzalnosti, u korist „laganih“ entiteta, a na štetu „krupnih“. Kako se jasno vidi, Uditax taksoni su u punom smislu održali svoju jednostavnost i razumljivost, s nizom očitih i korisnih pokazatelja o grupama entiteta. Kako je već rečeno, funkcija cilja u ovom primjeru definirana je kao skup eksplozivnih motoričkih gibanja, pa je kanoničkom korelacijskom analizom taj skup doveden u vezu s dobivenim taksonima.

**Tabela 3. Kanonički faktori**

	KF1	KF2
<b>NRZV (nerazvijeni)</b>	<b>-0.23</b>	<b>0.99</b>
<b>ADIP (adipozni)</b>	<b>-0.16</b>	<b>-0.99</b>
<b>LGNI (lagani)</b>	<b>0.30</b>	<b>0.93</b>
<b>KRUP (krupni)</b>	<b>0.05</b>	<b>-0.98</b>
<b>ATLE (atletici)</b>	<b>0.57</b>	<b>0.83</b>
<b>Var.</b>	<b>0.10</b>	<b>0.96</b>
<b>Red.</b>	<b>0.03</b>	<b>0.05</b>
	KF1	KF2
<b>MSDM</b> skok u dalj s mjesta	<b>0.82</b>	<b>0.57</b>
<b>MBLD</b> bacanje loptice u daljinu	<b>0.80</b>	<b>-0.56</b>
<b>M20V</b> trčanje 20 m iz visokog starta	<b>-0.61</b>	<b>-0.07</b>
<b>Var.</b>	<b>0.56</b>	<b>0.21</b>
<b>Red.</b>	<b>0.18</b>	<b>0.01</b>
<b>Chi 2</b>	<b>112.04</b>	<b>15.75</b>
<b>df</b>	<b>15.00</b>	<b>8.00</b>
<b>p</b>	<b>0.000</b>	<b>0.046</b>

Rezultati kanoničke analize pokazuju da su dva kanonička faktora statistički značajna.

Prvi faktor objašnjava znatan dio redundantne varijance, kojeg je jednostavno interpretirati. Naime, u prostoru taksonomskih dimenzija ističu se dvije saturacije, one koje opisuju tzv. „lagane“ entitete i one koje opisuju „atletike“, dok su „nerazvijeni“ i „adipozni“ entiteti negativno projicirani. U prostoru kriterija, sve su varijable istog predznaka (trčanje na 20 m ima negativnu metrijsku orijentaciju). Ovdje se jasno prepoznaju sva eksplozivna gibanja, otprilike istog reda veličine, koja su svojstvena „atletskim“ tipovima, te nešto manje entitetima opisanim kao „lagani“. Isto tako je jasno da „adipozni“ i „nerazvijeni“ entiteti nemaju dispoicije za eksplozivna gibanja, ili imaju preveliku balastnu masu i druga ograničenja. Tako bi ovaj kanonički faktor opisivao opću eksplozivnost neovisno o njenom topološkom karakteru.

Drugi kanonički faktor izrazito visokim projekcijama jasno opisuje sve tipove (taksone), a u kriterijskom skupu skok u dalj s mjesta (MSDM) i bacanje loptice u daljinu (MBLD). Na negativnoj strani su „adipozni“ tipovi i tipovi velike tjelesne mase, te bacanje loptice u daljinu. Na pozitivnoj strani, nalaze se „nerazvijeni“, „lagani“ i „atletski“ tipovi, te skok u dalj s mjesta. Ove činjenice, pokazuju da je, nakon temeljnog opisa eksplozivnosti u prvom faktoru, moguće identificirati i eksplozivnost s obzirom na ukupnu masu. Tako entiteti manje mase lakše iskazuju inicijalne impulsne sile za pokretanje cijelog tijela, dok je entitetima velike mase lakše angažirati veću startnu silu za pokretanje ili izbacivanje lakših rekvizita, naprosto zato jer je relativna masa rekvizita mala u odnosu na njihovu. Iz ovoga se može zaključiti da predloženi model dobro opisuje i diferencira entitete.

Pod pretpostavkom da se na temelju dobivenih rezultata namjerava programirati sportski, edukacijski ili sportsko-rekreacijski transformacijski postupak, uz pomoć ovog modela, moguće je postaviti parametri takvog postupka. Prije svega, točno su prepoznate stvarno postojeće podskupine unutar ispitivanog uzorka, što znači da je moguće razviti precizne diferencijalne programe koji će omogućiti svakoj podskupini najbolje moguće efekte. Također, u skladu s funkcijom cilja

(maksimizacija eksplozivnosti), moguće je najprije identificirati pojedince za koje je moguće pretpostaviti maksimalan domet u svim aktivnostima s dominacijom eksplozivnih gibanja. Zatim je potrebno postaviti takve parametre transformacijskih procesa koji će omogućiti tim entitetima jasan i racionalan tretman, koji će se ovim postupkom precizno selektirati. Svima ostalima, moguće je ponuditi sadržaje i modalitete operatora koji će zadovoljiti neke druge njihove potrebe i sposobnosti. Time je proces modeliran na optimalan i kvalitetan način a ostvarena zadaća kvalitetne orijentacije i selekcije.

Drugi primjer, za ilustraciju modela, odnosi se na isti uzorak učenika uzrasta 7 godina opisan sa 25 navedenih varijable u okviru općeg antropološkog statusa, te s kriterijskom varijablom (hipotetska funkcija cilja) za procjenu istrajnog trčanja.

**Tabela 4. Uditax taksoni (GR01-05)**

	GR01	GR02	GR03	GR04	GR05
N	42	24	15	55	113
%	16.87	9.64	6.02	22.09	45.38
	NRZV	ADIP	ATLE	KRUP	LGNI
AVIT visina tijela	-1.30	0.33	0.43	0.99	-0.12
ADUN duljina noge	-1.14	0.43	0.15	0.88	-0.12
ADUR duljina ruke	-1.14	0.31	0.36	0.80	-0.08
ADRZ dijametar ručnog zgloba	-0.97	0.45	1.18	0.62	-0.19
ADIK dijametar koljena	-0.92	0.63	0.74	0.74	-0.25
ASIR širina ramena	-1.14	0.75	0.99	0.58	-0.15
ASIK širina zdjelice	-0.96	1.25	0.59	0.40	-0.18
ATEZ tjelesna težina	-1.12	1.62	0.76	0.78	-0.41
AOPL opseg podlaktice	-0.89	1.16	0.64	0.55	-0.27
AOPK opseg potkoljenice	-0.94	1.25	0.61	0.70	-0.34
AOGK opseg grudnog koša	-0.93	1.56	0.75	0.54	-0.35
AKNN kožni nabor nadlaktice	-0.43	1.97	-0.07	0.36	-0.43
AKNL kožni nabor leđa	-0.33	2.30	-0.28	0.06	-0.33
AKNT kožni nabor trbuha	-0.48	2.13	0.11	0.28	-0.42
MKUS koraci u stranu	0.47	0.30	-0.98	0.19	-0.20
MPOL poligon natraške	0.34	0.66	-0.99	0.28	-0.27
MP2O stajanje na klupici za ravnotežu	0.00	-0.29	0.67	-0.11	0.03
MPRR pretklon u sjedju raznožno	-0.13	-0.04	0.64	0.25	-0.15
MTAP taping rukom	-0.07	0.28	0.35	-0.39	0.11
MTAN taping nogom	-0.06	0.03	0.15	-0.26	0.12
MSDM skok u dalj s mjesta	-0.49	-0.47	1.37	-0.51	0.35
MBLD bacanje loptice u daljinu	-0.58	-0.06	1.57	-0.16	0.10
M20V trčanje 20 m iz visokog starta	0.40	0.27	-0.92	0.32	-0.24
MDTS podizanje trupa iz ležanja	-0.58	-0.08	0.90	-0.14	0.18
MVIS izdržaj u visu zgibom	-0.18	-0.89	0.73	-0.22	0.27

U Tabeli 4. su prikazani rezultati Uditax analize za drugi primjer u ovom radu. Vidi se da, iako je došlo do promjene seta varijabli, struktura taksona je ostala praktično identična. I dalje se radi o izuzetno jasnim taksonima, koji opisuju 5 tipova entiteta u uzorku. Najbrojniji su entiteti (45 %) koji kao i u prethodnom primjeru predstavljaju entitete «laganog» tipa. Njihov opis u potpunosti odgovara opisu iz prethodne analize. To isto vrijedi i za sve ostale taksone, pa ih nije potrebno još jednom definirati. Vide se i postoci koji su gotovo identični, što znači da promjena manjeg broja varijabli ne mijenja strukturu taksona, čime se Uditax postupak svrstava u vrh takvih procedura.

**Tabela 5. Diskriminativne funkcije**

	F 1	F 2	F 3	F 4
AVIT	0.68	0.39	0.45	0.21
ADUN	0.61	0.27	0.43	0.26
ADUR	0.57	0.34	0.35	0.23
ADRZ dijametar ručnog zgloba	0.61	0.34	0.07	-0.19
ADIK dijametar koljena	0.63	0.21	0.22	-0.12
ASIR širina ramena	0.69	0.28	0.02	0.04
ASIK širina zdjelice	0.69	0.01	-0.07	0.14
ATEZ tjelesna težina	0.94	-0.03	0.11	-0.08
AOPL	0.70	0.02	0.05	-0.03
AOPK opseg potkoljenice	0.77	0.01	0.14	-0.08
AOGK opseg grudnog koša	0.82	-0.08	-0.03	-0.08
AKNN kožni nabor nadlaktice	0.70	-0.48	0.00	-0.04
AKNL kožni nabor leđa	0.65	-0.64	-0.20	0.15
AKNT kožni nabor trbuha	0.74	-0.49	-0.12	-0.04
MKUS koraci u stranu	0.05	-0.39	0.33	-0.09
MPOL poligon natraške	0.09	-0.45	0.34	-0.07
MP2O stajanje na klupici za ravnotežu	0.04	0.18	-0.17	-0.21
MPRR pretklon u sijedu raznožno	0.15	0.13	0.05	-0.35
MTAP taping rukom	0.00	-0.01	-0.38	0.13
MTAN taping nogom	0.04	0.03	-0.22	0.15
MSDM skok u dalj s mjesta	0.04	0.50	-0.61	0.16
MBLD bacanje loptice u daljinu	0.20	0.42	-0.46	-0.13
M20V trčanje 20 m iz visokog starta	0.00	-0.34	0.41	-0.15
MDTS podizanje trupa iz ležanja	0.14	0.34	-0.32	0.17
MVIS izdržaj u visu zgibom	0.19	0.44	-0.21	0.04
	F 1	F 2	F 3	F 4
NRZV (nerazvijeni)	0.41	-0.20	0.00	-0.05
ADIP (adipozni)	0.32	-0.20	-0.05	0.01
ATLE (atletici)	0.11	0.13	-0.07	-0.03
KRUP (krupni)	0.30	0.08	0.19	-0.02
LGNI (lagani)	0.32	0.20	-0.07	0.09

Kao u prethodnom primjeru i u Tabeli 5, dobivene su sve četiri značajne diskriminativne funkcije (svi probabiliteti su bili manji od 0.003). Funkcije su jednostavne za interpretaciju, jer opisuju poznate pojave. Prva funkcija opet diskriminira taksone prema svim morfološkim karakteristikama, i to na način da razlikuje tipove velike (ADIP i KRUP) od tipova male ukupne mase (NRZV i LGNI). Druga funkcija očito razlikuje taksone prema mogućnosti energetske angažmana te longitudinalnosti i količini masnog tkiva. Entiteti, „Atletici“ i lagane konstitucije, su očito u prednosti za realizaciju gibanja pred „adipoznim“ i „nerazvijenim“ tipovima. Treća funkcija definirana je ukupnim negativnim motoričkim skupom koji ne ide u prilog taksonu koji opisuje „krupne“ entitete.

Četvrta diskriminativna funkcija sa relativno skromnim saturacijama varijabli razdvaja taksone na način da prednost pred ostalim tipovima imaju entiteti t.zv. lagane konstitucije, izražene longitudinalnosti i male mase, pri realizaciji frekventnih i eksplozivnih gibanja.

I ovim primjerom se pokazalo da je primijenjena taksonomska analiza, pokazuje efikasnost, jednostavnost i razumljivost, s nizom evidentnih pokazatelja o grupama entiteta. Kako je već rečeno, funkcija cilja u ovom primjeru definirana je kao sposobnost istrajnog trčanja na tri minute (MT3M), pa je regresijskom analizom dovedena u vezu s dobivenim taksonima.

#### **Tabela 6. Regresija varijable MT3M**



	R	BETA	p-level	F-beta
NRZV	0.01	-0.03	0.85	-0.11
ADIP	-0.15	-0.08	0.56	-0.28
ATLE	0.16	0.23	0.03	0.79
KRUP	-0.13	-0.09	0.52	-0.30
LGNI	0.20	0.12	0.42	0.41
R =	0.29			
$\Delta$ =	0.08			
df1 =	5			
df2 =	249			
p =	0.001			

U Tabeli 6. nalaze se podaci regresijske analize za kriterijsku varijablu istrajnog trčanja. Prediktorski taksonomski skup pokazuje statističku značajnost regresijske funkcije (p). Međutim, količina objašnjenog varijabiliteta je mala, pa je i multipla korelacija tek 0.29. Razlog za ovo treba tražiti u činjenici da je tek jedan takson producirao značajan beta koeficijent, a radi se o tzv. atletskim tipovima entiteta.

Značajnost svih ostalih beta koeficijenata je znatno manja. Ipak, i ovakav pokazatelj jasno govori o činjenici da atletski tipovi entiteta (već u uzrastu od 7 godina) pokazuju jako dobre sposobnosti transportnog sustava. Naravno da će t.zv. „adipozni“ i „krupni“ tipovi entiteta imati veće poteškoće kod sposobnostima istrajnog trčanja, zbog činjenice da im je transportni sustav opterećen pokretanjem veće tjelesne mase, za koju očito nemaju dovoljnih energetske potencijala dugotrajnog rada.

Slično vrijedi i za t.zv. „nerazvijene“ entitete, pa se može kazati i da su po svim parametrima u ovom radu skupina „nerazvijenih“ u punom smislu te riječi, što pred kineziologe postavlja jasan i važan zadatak. S entitetima lagane konstitucije nešto je drugačija situacija budući oni ipak pozitivno doprinose regresijskoj funkciji, makar je taj doprinos malen. Beta faktor (f-beta) točno pokazuje da su za istrajno trčanje u ovom primjeru pozitivno disponirani atletici i entiteti lagane konstitucije, dok svi ostali imaju manje ili više izražene probleme.

Na temelju istraživanja, može se zaključiti da je skup taksonomskih dimenzija ostao očuvan kao u prethodnom primjeru, usprkos promjeni određenog broja varijabli kao i funkcije cilja, te da su taksoni, uz neznatne razlike, identični taksonima iz prethodnog primjera. Ovo u velikoj mjeri potvrđuje i diskriminativna analiza. Može se istaknuti činjenica da je na takve, stabilne taksone, moguće primijeniti različite funkcije cilja, kako bi se omogućilo bolje programiranje transformacijskih procesa za različite ciljeve.

Rekapitulacija rezultata može se predložiti u dva pravca. Prvi predstavlja potvrdu vrijednosti predloženog modela, jer se pokazao konzistentan i uvjerljiv, omogućavajući objektivno utvrđivanje inicijalnih skupina entiteta i njihovog stvarnog statusa sukladno pripadnosti određenim taksonima. Drugi pravac promišljanja svakako trebaju biti dobiveni rezultati.

Kako su u dva primjera identificirani identični taksoni, to je za primijetiti da takson opisan kao entiteti *lagane* konstitucije (najbrojniji u uzorku), u skladu s dvije različite funkcije cilja, pokazuje posebne osobine. To su dobra opća eksplozivnost, sposobnost izvrsne aktivacije većeg broja mišićnih jedinica u kraćem vremenu u svrhu premještanja tijela u prostoru, i određenu pozitivnu sposobnost istrajnog trčanja. Takson koji opisuje *adipozne* entitete pokazuje svojstvo dobrog angažmana sile primijenjene na manje rekvizite, a izrazito je insuficijentan u eksplozivnim kapacitetima potrebnim za startno trčanje i premještanje u prostoru, što vrijedi jednako i za istrajno trčanje. Gotovo identična je situacija i s taksonom koji opisuje tzv. *krupne* entitete. Kod taksona koji definira *nerazvijene* entitete u uzorku primjetna je slaba opća eksplozivnost, ali jednokratni angažman sile tipa skoka je gibanje koje relativno lako izvode, dok istrajno trčanje također nije svojstvo koje im je u većoj mjeri imanentno, već naprotiv ne pokazuju u tom smislu odgovarajuće akumulacije. Konačno *atletski* tipovi entiteta jedini pokazuju dobru integritetnost morfoloških i

motoričkih dimenzija, pa ne začuđuje niti njihova vidljiva superiornost u općim eksplozivnim gibanjima, kao i gibanjima kojima se tijelo jednokratno premješta u prostoru, te posebno sposobnosti transportnog sustava, procjenjuje istrajnim trčanjem. Međutim, može se primijetiti njihova slabija sposobnost prenošenja impulsne energije na manje objekte, što je sigurno uvjetovano njihovom relativno malom masom.

Naravno, vjerojatno bi se dobilo još zanimljivih pokazatelja da su funkcije cilja bile drugačije definirane, ali je prikaz ova dva primjera bio generiran radi ilustracije kvalitete modela, bez pretenzija da se potpuno iscrpljuje kroz analizu eksplozivnih gibanja ili istrajnog trčanja.

### **Zaključak**

Predložen je i testiran model objektivnog utvrđivanja inicijalnih skupina entiteta kojima se inicijalno procjenjuju karakteristike i sposobnosti radi što kvalitetnije selekcije u svrhu provođenja programiranih transformacijskih postupaka. U predloženi model su integrirane: posebno kreirana taksonomska analiza (Uditax) koja objektivno identificira stvarno postojeće podskupine unutar odabranog uzorka; zatim diskriminativna analiza tako dobivenih taksona radi potpunog opisa tipova, te opće redundantne analize (kanonička, regresijska,...) kriterijskih funkcija cilja kojima se mogu utvrđivati ciljevi vezani za selekciju u smislu vrhunskog sporta ili parametri sportsko-rekreacijskih ili nastavnih postupaka.

Model u potpunosti dokazuje stabilnost, vjerodostojnost i kvalitetu u postavljanju paradigmatičkih temelja kinezioloških determiniranih programiranja transformacijskih procesa. Na temelju ovog modela moguće je identificirati veliki broj potrebnih preduvjeta za postizanje realnih operacionalnih efekata praktičnog rada. Zbog načina na koji je predloženi model utemeljen, jednako je primjenjiv kod velikih uzoraka (selekcija), ali i kod malih uzoraka (vrhunski sport), jer prema potrebi može locirati velike grupe – taksone, ili čak pojedince u vrlo malim uzorcima kakve su sportske ekipe u sportskim igrama ili skupine sportaša u npr. borilačkim vještinama. To mu daje mogućnost primjene rezultata u područjima kakvo je kineziologija, ali isto tako i za potrebe područja sociologije, medicine, psihologije i sl.

Predloženi bi model, značajniju vrijednost mogao iskazati prilikom definiranja skupina u okviru kineziologije. Takve se procjene mogu provesti uz pomoć različitih mjernih instrumenata, na temelju kojih se rezultata mogu ponuditi odgovarajući programi, odnosno sadržaji usmjereni u pravcu zadovoljenja individualnih potreba i mogućnosti. Kako je individualizacija maksimalno približavanje programa tjelesnog vježbanja individualnim obilježjima nekog subjekta za unaprijed određene ciljeve onda je poznavanje antropološkog statusa bitna pretpostavka djelotvorne individualizacije.

Predloženi model nije ograničen brojem subjekata koje može tretirati ili brojem i vrstama varijabli kojima su subjekti opisani, uključujući različite spolne i uzrasne kategorije, uzorke različitog antropološkog statusa, varijable različitih metrijskih skala i t.d.

Primjena ovog modela moguća je u situacijama kad je konačni cilj izrada odgovarajućih planova i programa transformacijskih procesa, a na temelju objektivno utvrđenih svojstava subjekata koji će biti obuhvaćeni tim transformacijskim postupkom.

### **Literatura**

1. Andrijašević, M. (1995).. Utjecaj medicinski programiranih aktivnih odmora na djelatnike različitih opterećenja pri radu, Kineziologija, Vol. 27. br.2, 2/95. Fakultet za fizičku kulturu, Zagreb., (61 – 70).
2. Andrijašević, M. (2001).. : The influence of exercising on the health perception in adult women, u Zborniku radova, Međunarodni kongres, Sport for all-health-tourism, (ur. Bartoluci M, Heimer S. i Ružić L.), Fakultet za fizičku kulturu, Zagreb, (153-159).
3. Andrijašević, M. (2000). Slobodno vrijeme i igra, Ur. Zbornika radova Znanstveno - stručnog savjetovanja, Zagrebački velesajam, Zagrebački sportski savez i Fakultet za fizičku kulturu, Zagreb.

4. Bonacin, D. (2004). Uvod u kvantitativne metode [*Introduction to quantity methods*]. Kaštela:Vlastito izdanje.
5. Bonacin, D., Rađo, I. (2005). Temeljne kvantitativne metode za analizu podataka [*Basic quantity methods for data analysis*]. Sarajevo:FASTO.
6. Douillard J. (2000). Body, Mind and sport, Dvostruka duga, Čakovec, str 18.
7. Findak, V. (1997). Programiranje u tjelesnoj i zdravstvenoj kulturi. [*Programming in PE teaching*]. Zagreb:Školske novine.
8. Findak, V. (1999). Metodika tjelesne i zdravstvene kulture. [*Methodology in PE teaching*]. Zagreb:Školska knjiga.
9. Hartwell, L. Hood L., Goldberg M. L., Reynolds A. E. Silver L.M. & Veres R. C. (2000). Genetics, From genes to genomes, McGraw-Hill Companies, New York, USA.
10. Hardman, K. (2003). School physical education in Europe – rhetoric and reality: curent and future perspectives. *Kinesiology*. 35 (1). Pp.97-107.
11. Malacko, J., Rađo, I. (2004). Tehnologija sporta i sportskog treninga [*Technology of sport and sport training*]. Sarajevo:FASTO.
12. Mader S.S. (2002). Human biology, McGraw-Hill Higer Education, New York, SAD.
13. Missitzi J. & V. Klissouras (2003). Like father, like son: Determinism in superior sport performans, 8th Annual congress European college of sport science, ECSS, Salzburg, 330.
14. Mraković, M. (1992). Uvod u sistematsku kineziologiju [*Introduction to systematic kinesiology*]. Zagreb:FFK.
15. Rokita A. (2005). The interest in sports activity among first year secondary school students in the years 1995 – 2001., *Kinesiology Vol 37*, 1:99-105, Zagreb.
16. Persyn U. V. Colman (2003). A model of diagnosing and performance prediction in the individual sports, 8th Annual congress European college of sport science, ECSS, Salzburg, 330.
17. Stein F. L. & B. M. Rowe (1996). Industrial societies and mating paterns, *Physical anthropology*, McGraw-Hill Higer Education, New York, SAD. Str. 518: 527.

# MODEL OF OBJECTIVE DETERMINATION OF INITIAL GROUPS, THEIR STATUS AND TARGETED FUNCTIONS OF TRANSFORMATION

Mirna Andrijašević, Dobromir Bonacin, Ivan Prskalo, Josip Babin, Lidija Vlahović

## Summary

A sample was used of 249 pupils at the age of 7 (+/- 2 months) who were described by 256 variables. For the needs of this paper and for an illustration of target functions, the sample was defined by two variants. In one variant, the sample was defined as the ability for continuous running for 3 minutes (MT3M), and in the other variant it was described as explosiveness, defined as a composite of many variables: long jump from a take-off point, throwing a ball into the distance, and running 20 metres from a standing start. For the stated reasons, the offered model in this paper enables the objectivising of determined groups within a sample defined in any way. The solution is a suitable methodological interaction, in a way that such a solution should be created to respect the target functions (a) and taxonomic determination (b). Such a variant primarily respects the multi-variant demands in which the groups are recognised. In this sense, we established a Uditax procedure which taxonomises the test subjects on the basis of the spectral decomposition of the matrix of distances of the subjects themselves in standard space and after determining the number of real taxa by the entropic function. This procedure also identifies the representative subjects of such structures. The obtained taxa may, through any analysis of set redundancy (by regression or canonical procedures), be brought into relation with a differently defined set of criteria-related parameters, i.e. the target function. This rounds up the model in a way that the taxa are grouped against the target functions in accordance with the multi-variant characteristics of individual groups. Using the Uditax procedure, groups were isolated, and, in accordance with normal distribution, the so-called underdeveloped and the athletic were hypothetically positioned on extreme sides, and along with them, the stocky and the underdeveloped, and in the middle the light entities. The discriminative analysis of taxonomic dimensions resulted in all four significant discriminative functions which were easily visualised and simple to interpret.

**Key words:** initial assessment, orientation, selection, seven-year-olds, transformation