RACIONALNA PROCEDURA ZA ODREĐIVANJE INDEKSA IDEALNE TJELESNE TEŽINE

PRETHODNO PRIOPĆENJE

RATKO GOSPODNETIĆ, MARIJAN GREDELJ I KONSTANTIN MOMIROVIĆ
Sveučilišni računski centar, Zagreb

Za procjenu idealne tjeesne težine predložen je polinomialni model drugog reda, definiran regresivnom jednadžbom

$$w = a_0 + a_1h + a_2a + a_3c + a_4h^2 + a_5a^2 + a_6c^2 + a_7ha + a_8hc + a_9ac + e$$

gdje je w = *procjena tjelesne težine,* h = *visina,* a = *biakromialni raspon,* c = *bikristalni raspon,* a_0 = *konstanta,* $a_1, \ldots, a_9$ = *koeficijenti parcijalne regresije, i* e = *pogreška procjene.*

Ponašanje modela ispitano je na jednom uzorku zdravih muškaraca, starih od 19 do 27 godina i razmotrena efikasnost različitih simplificiranih verzija ovog modela.

1. PROBLEM

Velika većina do sada predloženih indeksa idealne tjelesne težine temelji se na ovim implicitnim pretpostavkama:

1. Relacije između skeletalnih karakteristika, reprezentiranih visinom tijela, i mase tijela pripadaju kasi funkcionalnih relacija.
2. Funkcionalne relacije između visine i mase tijela su linearne, ili su linearne u određenim segmentima kronološke dobi.

Apsurdnost ovih pretpostavki nije teško dokazati (Momirović, 1964); ispitivanje empirijskog ponašanja gotovo svih indeksa idealne tjelesne težine jasno pokazuje da su te mjere besmislene i sa antropološke, i sa matematičke točke gledišta.

Ipak, neki su od predloženih indeksa konstruirani tako da je barem jedna od ovih pretpostavki napuštena. Tako, na primjer, Kaupov indeks, iako pretpostavlja funkcionalnu, ne pretpostavlja i linearnu relaciju između visine i mase tijela.* Indeks Buzine pretpostavlja, doduše, funkcionalne i linearne relacije skeletalnih karakteristika i mase tijela, ali u skeletalne karakteristike koje su nužne za procjenu idealne tjelesne težine ubraja i biakromialni i bikristalni raspon, što ga čini mnogo realnijim sa fizikalne točke gledišta. Regresioni indeks Momirovića također, osim visine, uzima u obzir biakromialni i bikristalni raspon i napušta besmislenu hipotezu o funkcionalnim odnosima skeletalnih karakteristika i mase tijela, ali i dalje pretpostavlja da su ti odnosi linearni.

Nažalost, ni jedan od predloženih indeksa, pa ni oni čija je osnovica manje besmislena od one na kojoj su konstruirani indeksi Broke, Lorenza i mnogih drugih**, nije utemeljen na empirijskoj analizi relacija morfoloških varijabli izvedenoj pod vidom nekog eksplicitnog fizikalnog modela. Zbog toga je ovdje predložen jedan morfološki i matematički model koji, kao argumente, tretira bazične skeletalne dimenzije koje određuju volumen tijela, i ne pretpostavlja ni funkcionalne ni linearne relacije između skeletalnih dimenzija i mase tijela.

2. MODEL

Predloženi regresivni polinomialni model rezultat je kibernetičkog promatranja modela prikazanog na slici 1. Osnovna pretpostavka modela je da postoji složeni mehanizam primarnog generatora G_0 koji upravlja rastom. Generatori G_i gdje je $i = 1, \ldots, n$ sinhronizirani su u svojem radu izlaznom funkcijom generatora G_0 i predstavljaju niz funkcija koje djeluju na težinu. Radi međusobnih zavisnosti, te dozvoljenih stupnjeva slobode u model je uvedena funkcija T_1 koja predstavlja transformator izlaznih veličina generatora G_i u skup izlaznih funkcija X_i gdje je $i = 1, \ldots, n$. Vrijednosti X_i su fizikalne mjere ljudskog tijela. Svaka funkcija X_i može se sa zadovoljavajućom točnošću predstaviti polinomom višeg reda. U ovom razmatranju pretpostavlja se da su generatori G_i, $i = 1, \ldots, n$ međusobno stohastički vezani preko polinoma drugog reda, koji sa dovoljnom točnošću aproksimira stvarnu vezu. Uvođenjem funkcije T_2, koja predstavlja transformator polinomialnog sustava u procjenjenu težinu, u model su ukomponirane međusobne ovisnosti i stupnjevi slobode.

Promotri li se ovako postavljeni model, može se zaključiti da je dozvoljeno pretpostaviti polinomialni regresivni model pri procjeni idealne tjelesne težine, jer je sam fizikalni proces (na kojem se model zasni-

* Ovo vrijedi i za indekse koje su predložili Rohrer, Livi,Hirati i Kaku (vidi u Medved, 1977 i Medved, 1966).

** Korektan pregled većine indeksa idealne tjelesne težine nalazi se u Medved (1977), a vrlo potpun pregled tih indeksa u Albonico (1970).

va) polinomialno sumacionog tipa. Kako prema predloženom modelu postoji veza između generatora G_i, $i=1,\dots,n$ i tjelesne težine w, tada se može pretpostaviti i navedena polinomialna veza između mjerljivih veličina X_i i težine w.

To implicira i pretpostavku da su generatori G_i, $i=1,\dots,n$ stohastički vezani sa težinom preko polinoma drugog reda koji sa dovoljnom točnošću aproksimira stvarnu vezu.

Pri tome se transformator T_2 sastoji od dva bazična funkcionalna bloka:

— blok za rotaciju i
— blok za sumaciju,

koji su odgovorni za formiranje ukupne tjelesne težine.

Iz rezultata mjerenja poznati su parametri modela koji opisuju međusobne veze mjera ljudskog tijela, te njihove veze sa tjelesnom težinom. Razmotrene su veze između samo tri mjere:

— visina
— biakromialni raspon
— bikristalni raspon

što je dovoljno za točnu procjenu karakteristika tijela.

Naravno, ovaj model pretpostavlja da raspodjele morfoloških karakteristika nisu, zapravo, normalne; kada bi te raspodjele bile zaista normalne, bio bi savršeno dovoljan obični linearni model, jer su relacije normalno distribuiranih varijabli nužno linearne.

gdje je

w = tjelesna težina
h = visina
a = biakromialni raspon
c = bikristalni raspon
a_0 = konstanta
$a_1,\dots,a_9$ = koeficijenti parcijalne regresije
e = pogreška procjene

Očito, pod ovim modelom, ako je w realna tjelesna težina, a

$$w^* = a_0 + a_1h + a_2a + a_9ac + a_7ha + a_8hc + a_5a^2 + a_6c^2 + a_3c + a_4h^2$$

razlika

$$e = w - w^*$$

je mjera odstupanja od idealne tjelesne težine procjenjene na temelju ovog modela.

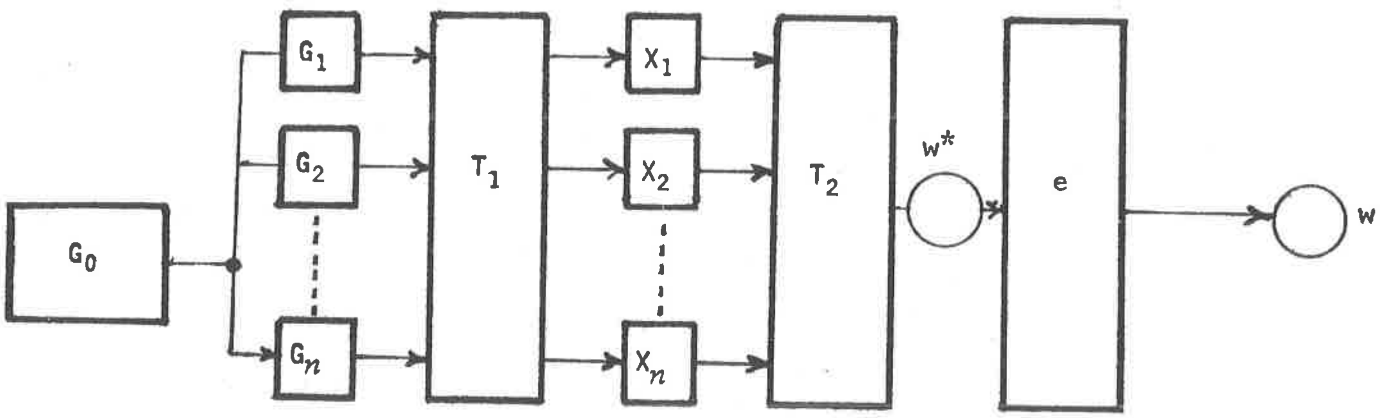

Slika 1. *Shematski prikaz modela*

Prema tome, model se može formalizirati u obliku

$$w = a_0 + a_1h + a_2a + a_3c + a_4h^2 + a_5a^2 + a_6c^2 + a_7ha + a_8hc + a_9ac + e$$

3. PROCJENA PARAMETARA MODELA

Neka je E_i neki entitet sa morfološkim karakteristikama

x_{i1} = visina, mjerena u milimetrima
x_{i2} = biakromialni raspon, mjeren u milimetrima
x_{i3} = bikristalni raspon, mjeren u milimetrima
$x_{i4} = x^2_{i1}$
$x_{i5} = x^2_{i2}$
$x_{i6} = x^2_{i3}$
$x_{i7} = x_{i1} x_{i2}$
$x_{i8} = x_{i1} x_{i3}$
$x_{i9} = x_{i2} x_{i3}$
$x_{i0} = 1$

Neka je

$$X_i^T = (x_{i0}, x_{i1}, \dots, x_{i9})$$

i neka je

$$X = (x_i^T)$$

matrica koja sadrži vektore X_i procjenjene na nekom slučajnom uzorku $U = \{E_i;\ i=1,\dots,n\}$ iz populacije π za koju treba procijeniti parametre modela.

Neka je w_i masa tijela eniteta E_i, procjenjena težinom mjerenom u gramima, i neka je

$$W^T = (w_1, \dots, w_i, \dots, w_n)$$

vektor mjera težine izmjerene na uzorku U.

Označimo sa m_j, $j=1,\dots,9$ aritmetičke sredine varijabli x_j, $j=1,\dots,9$; sa m aritmetičku sredinu tjelesne težine; sa o^2_j, $j=1,\dots,9$ varijance varijabli x_j, $j=1,\dots,9$; i sa o^2 varijancu tjelesne težine. Neka su aritmetičke sredine i varijance ovih varijabli za populaciju π procjenjene na temelju podataka iz uzorka U.

Standardizirane varijable z_j, $j=1,\dots,9$ i k definirajmo operacijama

$$z_{ij} = (x_{ij} - m_j) / 6_j \qquad j=1,\dots,9$$
$$k_i = (w_i - m)_j 6$$

i uvrstimo rezultate u matricu

$$Z = (z_{ij}) \qquad i=1,\dots,n \quad j=1,\dots,9$$

i vektor

$$K = (k_i) \qquad i=1,\dots,n$$

Pod generalnim linearnim modelom

$$W = XA + E$$

gdje je E vektor pogreške; otuda, pod kriterijem najmanjih kvadrata

$$A = (X^T X)^{-1} X^T W$$

pa vektor

$$A^T = (a_0, a_1, \dots, a_9)$$

sadrži parcijalne regresijske koeficijente za procjenu mase tijela na temelju polinomialnog modela koji, kao argumenta, sadrži visinu, biakromialni i bikristalni raspon.

Za standardizirane varijable generalni linearni model može se napisati u obliku

$$K = ZB + \varepsilon$$

gdje je ε vektor pogreške; otuda, pod kriterijem najmanjih kvadrata, ako sa

$$R = Z^T Z \frac{1}{n}$$

$$R = Z^T K \frac{1}{n}$$

označimo matricu korelacija standardiziranih varijabli $z_1, \dots, z_9$, i vektor korelacija varijabli $z_1, \dots, z_9$ sa varijablom k,

$$B = R^{-1} R$$

pa vektor

$$B^T = (b_1, \dots, b_9)$$

sadrži standardizirane parcijalne regresijske koeficijente za procjenu mase tijela, definirane standardiziranom varijablom u populaciji Π, na temelju polinomialnog modela koji, kao argumente, sadrži standardizirane varijable $z_1, \dots, z_9$ izvedene iz visine, biakromialnog i bikristalnog raspona.

Projekcija vektora W u prostoru što ga razapinju vektori iz X je, očito,

$$d^2 = W^T X (X^T X)^{-1} X^T W$$

pa je mjera pogreške modela

$$e^3 = o^2 - d^2$$

Kako je dobro poznato (vidi, na primjer, Momirović, 1979) matrica

$$C = e^2 (X^T X)^{-1}$$

sadrži kovarijance pogreške koeficijenata iz vektora A, pa je moguće testirati hipotezu da su neki od tih koeficijenata jednaki nuli, i da se, prema tome, model može uprostiti bez značajnog gubitka informacija.

Za standardizirane varijable, koeficijent determinacije je

$$\delta^2 = R^T R^{-1} R$$

pa je

$$\varepsilon^2 = 1 - \delta^2$$

varijanca pogreške,

$$H = \varepsilon^2 R^{-1}$$

matrica kovarijanci pogreške koeficijenata iz vektora B, a $\rho = \delta$ multipla korelacija između varijabli iz Z i mase tijela.

Ako je X_i vektor rezultata nekog eniteta E_i koji sadrži varijable $x_0 = 1, x_1, \ldots, x_9$, procjena njegove idealne tjelesne težine je

$$w_i^* = X_i^T A$$

sa standardnom pogreškom procjene e; zbog toga je zona u kojoj se, sa pouzdanošću $(1 - \alpha)$, može očekivati stvarna vrijednost tjelesne težine eniteta E_i

a odstupanje eniteta E_i od idealne tjelesne težine

$$e_i = w_i - w_i^*.$$

4. REZULTATI EMPIRIJSKE EVALUACIJE MODELA

Model je evaluiran na jednom uzorku od 540 zdravih muškaraca, starih od 19 do 27 godina. Visina (VISINA)*, biakrominalni raspon (BIAKRO), bikristalni raspon (BIKRIS), i težina (TEZINA) izmjereni su postupkom koga su predložili Stojanović, Solarić, Momirović i Vukosavljević (1975). Kvadrat visine označen je sa VISVIS, kvadrat biakromialnog raspona sa BIABIA, a kvadrat bikristalnog raspona sa BIKBIK. Sa VISBIA je označen produkt visine i biakromialnog raspona, sa VISBIK produkt visine i bikristalnog raspona, i sa BIABIK produkt biakromialnog i bikristalnog raspona. Iako su sve longitudinalne dimenzije mjerene u milimetrima, a masa u gramima, u tabelama su longitudinalne mjere, zbog preglednosti i ustupaka običajima, izražene u centimetrima, a tjelesna težina u kilogramima.

Analiza rezultata izvedena je regresionom analizom. Simplificirani modeli dobijeni su iterativnim regresionim procedurama; prvi inkluzijom, a drugi eliminacijom argumenata.**

4. 1. Deskriptivni parametri varijabli

TABELA 1

	m	σ^2	σ	min	max
1 VISINA	172.10	42.72	6.54	151.2	196.7
2 BIAKRO	38.89	3.32	1.82	33.2	46.0
3 BIKRIS	27.64	2.66	1.63	23.5	32.9
4 VISVIS	29661.00	$.50956*10^7$	2257.30	22866.00	38683.00
5 BIABIA	1515.70	$.20098*10^5$	141.77	1101.10	2114.50
6 BIKBIK	766.63	$.81837*10^4$	90.46	553.26	1080.80
7 VISBIA	6698.80	$.24301*10^6$	492.97	5084.60	8631.90
8 VISBIK	4762.80	$.16975*10^6$	412.01	3625.40	6241.90
9 BIABIK	1076.10	$.92151*10^4$	95.99	806.18	1443.90
10 TEZINA	69.21	61.27	7.83	50.26	96.56

U tabeli 1 su aritmetičke sredine (m), varijance (σ^2), standardne devijacije (σ), minimalne (min) i maksimalne (max) vrijednosti varijabli. U tabeli 2 je matrica interkorelacija varijabli.

Kako se vidi iz aritmetičkih sredina, standardnih devijacija i raspona varijabli koje su neposredno mjerene, uzorak dobro reprezentira jugoslavensku populaciju ove dobi i spola; vrlo slični rezultati dobijeni su i u mnogim dosadašnjim istraživanjima na uzorcima iz ove populacije. Naravno, numeričke vrijednosti izvedenih varijabli su znatne i ovo može činiti izvjesne teškoće kod primjene varijabli ako se za izračunavanje predloženih indeksa ne primjeni bar džepni elektronički kalkulator.

Matrica korelacija varijabli ima neka zanimljiva svojstva, posebno pod vidom potencijalnog učešća, definiranog uniknim komponentama varijanci, neposredno izmjerenih varijabli i njihovih kvadrata. Zbog praktičke kolinearnosti vektora varijabli i vektora kvadrata varijabli ova je matrica gotovo singularna; zato parcijalni koeficijenti punog polinomialnog modela ne mogu biti statistički značajni, niti, u reduciranim modelima, mogu sudjelovati, sa značajnim koeficijentima parcijalne regresije, istovremeno i neposredno izmjerene varijable i njihovi kvadrati.

* U zagradi su oznake varijabli, upotrebljene u tabelama.

** Analize su izvedene programom STEPREG 1 iz programskog paketa STATJOB na računalu UNIVAC 1110 Sveučilišnog računskog centra u Zagrebu.

TABELA 2

	1 VISINA	2 BIAKRO	3 BIKRIS	4 VISVIS	5 BIABIA	6 BIKBIK	7 VISBIA	8 VISBIK	9 BIABIK	10 TEZINA
1 VISINA	1.000	.493	.563	.999	.496	.564	.831	.825	.634	.650
2 BIAKRO	.493	1.000	.402	.492	.999	.403	.893	.493	.794	.569
3 BIKRIS	.563	.402	1.000	.563	.404	.999	.548	.931	.875	.575
4 VISVIS	.999	.492	.563	1.000	.496	.565	.831	.826	.634	.651
5 BIABIA	.496	.999	.404	.496	1.000	.406	.895	.496	.796	.570
6 BIKBIK	.564	.403	.999	.565	.406	1.000	.550	.932	.876	.578
7 VISBIA	.831	.893	.548	.831	.895	.550	1.000	.724	.836	.699
8 VISBIK	.825	.493	.931	.826	.496	.932	.742	1.000	.878	.680
9 BIABIK	.634	.794	.875	.634	.796	.876	.836	.878	1.000	.682
10 TEZINA	.650	.569	.575	.651	.570	.578	.699	.680	.682	

Ono što je bitno za ocjenu predloženog polinomialnog modela je to da su korelacije između produkata izmjerenih varijabli i tjelesne težine sistematski veće od korelacija tih varijabli, ili kvadrata tih varijabli, sa tjelesnom težinom. Kako su, osim toga, unikne mjere produkata varijabli sigurno različite od nule, argumenti modela koji su definirani produktima varijabli imaju potencijalno najveći značaj za procjenu idealne tjelesne težine.

4.2. Puni polinomialni model

Puni polinomialni model definira idealnu tjelesnu težinu ovom regresionom funkcijom:

$$w_i^* = -11.898 - 1.044^*h_i + 8.006^*a - 4.566^*c_i + \\ + 0.012^*h^2_i - 0.013^{*2}_i + 0.182^*c^2_i - \\ -0.041^*h_i^*a_i - 0.036^*h_i^*c_i + 0.049^*a_i^*c_i$$

Standardna pogreška procjene tjelesne težine na osnovu ovog modela je 5.27 kilograma, sa koeficijentom determinacije $\delta^2=0.55$ i koeficijentom multiple korelacije $\rho=0.7442$. U standardnoj metrici,

$$Zw_i = -0.87^*Zh_i + 1.86^*Za_i - 0.95^*Zc_i + 3.40^*Zh^2_i - \\ - 0.23^*Za^2_i + 2.10^*Zc^2_i - 2.60^*Zh_ia_i - \\ - 1.88^*Zh_ic_i + 0.60^*Za_ic_i$$

sa pogreškom prognoze $\varepsilon = 0.66$.

Već je iz ponašanja standardiziranih regresijskih koeficijenata vidljivo da, zbog jake tendence ka singularnosti, parametri punog polinomialnog modela nisu pouzdano određeni; uostalom, nijedan parcijalni regresijski koeficijent nije stitistički značajan, iako je, naravno, multipla korelacija između sustava standardiziranih varijabli i tjelesne težine značajno različita od nule.

Sa antropološke točke gledišta ovaj je model slabo interpretabilan. Zaista nije moguće naći nikakav jasan fizikalni ni antropometrijski razlog za strukturu ove regresijske jednadžbe. Čini se, da su zbog kolapsa predikatorskog prostora koeficijenti modela artefakt uzorka, što naravno ne znači da je polinomialni model neadekvatan, nego samo da je broj argumenata prevelik.

4.3. Model formiran inkluzijom varijabli

Operacijom sukcesivne inkluzije, koja je bila zaustavljena kada je značajnost doprinosa naredne varijable postala veća od 0.05, dobijena je, u realnoj metrici, regresiona jednadžba

$$w_i^* = -9.278247 + 0.006846^*h_i^*a_i + 0.006851^*h_i^*c_i$$

sa standardnom pogreškom procjene $e=5.28$, koeficijentom determinacije $\delta^2=0.5465$ i multiplom korelacijom $\delta=0.7393$.

U standardnoj metrici

$$Zw_i^* = 0.43^*Zh_ia_i + 0.36^*Zh_ic_i$$

sa pogreškom procjene $\varepsilon=0.67$.

Parcijalne korelacije varijabli iz ovako simpflicira-nog modela i tjelesne težine iznose, za konstantu, —0.13, za umnožak visine i biakromialnog raspona 0.40, a za umnožak visine i bikristalnog raspona 0.34, i sve su značajne na razini od 0.01.

Očito, model formiran inkluzijom, iako sadrži samo dva argumenta, praktički je ekvivalentan punom polinomialnom modelu.

Antropologijsko značenje ovog modela je očito, i sukladno je formalnom modelu pod kojim su interpretirani rezultati taksonomskih analiza provedenih pod modelom polarnih taksona (Hošek, 1978). Masa tijela je, pod tim modelom, stohastička funkcija dva argumenta, od kojih je prvi, nešto važniji, produkt velike longitudinalne osovine tijela i gornje transverzalne osovine, a drugi produkt velike longitudinalne osovine tijela i donje transverzalne osovine. Značaj ovih osovina u strukturi i kompoziciji tijela razmatrao je već Škerlj (1932), a kasnije, na vrlo konzisentan način, Behnke i Wilmore (1974).

4.4. Model formiran eliminacijom varijabli

Operacijom sukcesivne eliminacije varijabli, koja je zaustavljena kada je značajnost doprinosa naredne varijable postala manja od 0.05, dobijena je, u realnoj metrici, regresiona jednadžba

$$w_i^* = -33.061892 + 1.226721^* a_i + 0.00126^* h^2_i + 0.022205^* c^2_i$$

sa standardnom pogreškom e=5.28, koeficijentom determinacije $\delta^2=0.5481$, i multiplom $\rho=0.7404$.

U standardnoj metrici,

$$Zw_i^* = 0.29^* Za_i + 0.37^* Zh^2_i + 0.27^* Zc^2_i$$

sa pogreškom procjene $\varepsilon = 0.67$.

Parcijalne korelacije varijabli iz modela koji je simplificiran eliminacijom iznose —0.28 za konstantu, 0.34 za biakromialni raspon, 0.39 za kvadrat tjelesne visine, i 0.30 za kvadrat bikristalnog raspona. Sve su ove korealcije značajne na razini od 0.01.

I model formiran eliminacijom je praktički ekvivalentan punom polinomialnom modelu, i pod vidom efikasnosti predikcije tjelesne težine ekvivalentan modelu koji je dobijen iterativnom inkluzijom.

Međutim, ovaj je model ipak nepogodniji od modela dobijenog inkluzijom iz najmanje dva razloga. Prvi, i manje važan, je što sadrži tri argumenta, dakle jedan više od modela dobijenog inkluzijom, uz praktički jednaku efikasnost, pa je zato manje ekonomičan. Drugi, mnogo važniji, razlog je što je njegovo antropologijsko značenje prilično nejasno.

Dok model dobijen inkluzijom ima, pored jasnog antropometrijskog, i jasno fizikalno značenje, model dobijen eliminacijom, iako sadrži funkcije sve tri glavne osovine tijela, teško se može podvesti pod iste teoretske koncepcije, pogotovo zato što je njegovo fizikalno značenje nemoguće ustanoviti. Čini se, dakle, da je ovaj model statistički artefakt, i da nema mnogo razloga ni za njegovu praktičnu primjenu, ni za dalje analize njegova ponašanja.*

5. ZAKLJUČAK

Na temelju fizikalnih, antropometrijskih i statističkih argumenata čini se da je opravdano da se, u okviru reduciranog polinomialnog modela idealna tjelesna težina definira regresionom jednadžbom

$$w_i^* = a_0 + a_1^* h_i^* a_i + a_2^* h_i^* c_i$$

gdje je h_i=visina, a_i=biakromialni raspon, c_i=bikristalni raspon a a_0, a_1 i a_2 koeficijenti koje treba odrediti za uzorke određene dobi i spola.

* To, naravno, ne znači da je operacija eliminacije nepogodna za konstrukciju modela idealne tjelesne težine, već samo da je u ovom pokusu dala rezultat koga je teško prihvatiti.

6. LITERATURA

1. Albonico, C. *Mensch-Menschen Typen.* Birkhäusen, Basel 1970.
2. Behnke, A. R. and J. H. Wilmore. *Evalution and regulation of body and composition.* Prentice-Hall, Englewood Cliffs, 1974.
3. Hošek, A. *Povezanost morfoloških taksona sa manifestnim i latentnim dimenzijama koordinacije.* Disertacija, Fakultet za fizičku kulturu, Zagreb 1978.
4. Medved, R. *Osnovi sportske medicine.* Sportska biblioteka, Zagreb, 1966.
5. Medved, R. *Sportska medicina.* Sportska knjiga, Zagreb, 1977.
6. Momirović, K. *O antropometrijskim i matematičkim osobinama nekih indeksa »idealne« tjelesne težine.* IV Kongres antropologa Jugoslavije, Most na Soči, 1964.
7. Momirović, K. *Jednostavni algoritmi za analizu bilinearnih formi u biološkim, psihološkim i medicinskim istraživanjima.* U Primena na kompjuterite vo biomedicinskite oblasti, Skopje, 1979.
9. Viskić, N. *Faktorska struktura tjelesne težine.* Kineziologija, 2, 2, 45—49 (1972).

RATIONAL PROCEDURE FOR DETERMINING THE INDEX OF IDEAL BODY WEIGHT

RATKO GOSPODNETIĆ, MARIJAN GREDELJ AND KONSTANTIN MOMIROVIĆ
University Computing Centre, Zagreb

For estimation of the ideal body weight a polynomial model of second order is proposed, defined by a regression equation

$$w = a_0 + a_1h + a_2a + a_3c + a_4h^2 + a_5a^2 + a_6c^2 + a_7ha + a_8hc + a_9ac + e$$

where w = *estimation of body weight,* h = *height,* a = *biachromial span,* c = *bicrystal span,* a_0 = *constant,* $a_1, \dots, a_9$ = *coefficients of partial regression,* e = *estimation error.*

Model behavior has been studied on a sample of healthy men, between 19 and 27 years of age and the efficiency of various simplified versions of this model has been considered.