Konstantin Momirović

Fakultet za fizičku kulturu Zagreb

JEDNOSTAVNI POSTUPAK ZA ANALIZU ČINILACA KOJI UTJEČU NA REZULTATE NATJECANJA U JUDU

Konstantin Momirović

A SIMPLE METHOD FOR ANALYSING THE FACTORS RELATING WITH THE RESULTS IN JUDO COMPETITIONS

A simple procedure for analysis of factors relating with the results in judo competitions is described. The procedure is based on the Johnson's method for pairwise monotone regression. An algorithm synthetising the results of different analyses is proposed, consisting essentially in the determination of the first component vector of regression weights matrix.

Константин Момирович

ПРОСТОЙ МЕТОД ДЛЯ АНАЛИЗА ФАКТОРОВ, СВЯЗАННЫХ С РЕЗУЛЬТАТАМИ В СОРЕВНОВАНИЯХ ПО ДЗЮДО

Описана очень простая процедура для анализа факторов, которые связаны с результатами в соревнованиях по дзюдо. Эта процедура основана на методе монотонного регрессионного анализа Джонсона. Также предложен алгоритм для синтеза результатов, полученных на основании анализа различных соревнований, суть которого состоит в вычислении первого компонентного вектора матрицы регрессионных коэффециентов, полученных в результате анализа этих соревнований.

1. UVOD

Natjecanja u judu, a tako je i sa natjecanjima u karateu, boksu, rvanju i ostalim borilačkim sportovima, po postojećim su pravilima organizirana tako da njihovi rezultati imaju vrlo slaba metrička svojstva. Uspjeh takmičara definiran je rangom, relativno pouzdano određenim samo za prvih nekoliko mjesta; rangovi ispod četvrtog mjesta nedefinirani su, i takmičari su zapravo svrstani, uostalom na temelju malog broja borbi, u neku vrstu uređenih kategorija.

Ovo, naravno, znatno otežava primjenu uobičajenih multivarijatnih tehnika za analizu činilaca koji utječu na rezultate u judu. To pogotovo zato što su i mnoge prediktorske ili eksplanatorne varijable slabih metričkih svojstava; jer, osim mjera antropologijskih karakteristika, koje su u pravilu izražene u intervalnim, a ponekad i omjernim skalama, mjere ostalih činilaca, kao što je razina i tip primijenjenih tehnika, taktičke osobine i mnoge situacione varijable imaju slaba ordinalna, a ponekad i samo nominalna svojstva.

Ipak, neke nemetričke metode mogu biti vrlo pogodne za tretman ovakve vrste podataka. Ovdje je predložen postupak, osnovan pretežno na Johnsonovoj (Johnson, 1975) metodi monotone regresione analize, za analizu činilaca od kojih ovisi rezultat boraca u natjecanjima u judu.

2. MONOTONA REGRESIONA PROCEDURA

Neka je $X = (x_{ip})$, $i = 1, ., j, ., n$; $p = 1, m$ matrica obilježja n takmičara T_i, $i = 1, ., j, ., n$ definiranih s pomoću m varijabli V_p, $p = 1, m$. Varijable V_p mogu imati ma koja metrička svojstva; u pravilu, to će, premda rijetko, biti varijable intervalnog tipa, kao što su mjere morfoloških, motoričkih, kognitivnih ili konativnih dimenzija; ili, znatno češće, ordinalne varijable dobijene rangovanjem takmičara pod vidom različitih aspekata njihova ponašanja u borbi, tehničke, taktičke ili funkcionalne pripremljenosti; ili, još češće, uređene kategorijske varijable, dobijene uvrštavanjem takmičara u ordinalizirane kategorije, kao što je njihov Dan ili Kyu stupanj, ili stupanj tehničke, taktičke, odnosno funkcionalne pripremljenosti grubo ocijenjen ne mjerenjem ili rangovanjem, već uvrštavanjem u manji broj uređenih kategorija. Veoma često varijable V_p mogu biti, naprosto, binarne varijable, definirane prisustvom ili odsustvom nekog atributa, kao što su, na primjer, primjena određenih tehnika, upotreba određenih taktičkih varijanata, pripadanje pojedinim školama, klubovima, reprezentacijama i slično. Neke varijable mogu biti izmjerene prije natjecanja, a neke mogu biti registrirane za vrijeme samog natjecanja, po bilo kojem pogodnom postupku koji se primjenjuje za deskripciju njegova toka.

Očito, zbog odsustva jednoznačno definiranih metričkih svojstava, nije moguće učiniti nikakve pretpostavke o funkciji raspodjele varijabli iz X; a kako je n relativno mali broj, takve bi pretpostavke i onako bilo nemoguće testirati na zadovoljavajući način. Izostavimo, zbog toga, bilo kakve pretpostavke o funkciji raspodjele varijabli V_p i bilo kakve pretpostavke o prirodi njihovih međusobnih relacija. Jedina pretpostavka, koja je stvarno potrebna, jest da je drugi moment svake od njih različit od nule, tj. da su V_p zaista varijable barem slabog ordinalnog tipa, a ovaj uvjet zadovoljavaju i nominalne varijable ako se svaka od njih transformira u skup selektorskih binarnih varijabli.

Neka je $y = (y_i)$, $i = 1, ., j, ., n$ vektor definiran redoslijedom natjecatelja. Postojeća pravila natjecanja ne dozvoljavaju da y bude striktno ordinalna varijabla. U stvari, samo su prva 4 ranga distinktna; takmičari koji su se plasirali u četvrtfinale, sa ili bez repasaža, dijele 5 do 8 mjesto, a oni koji su dospjeli do osmine finala 9 do 16 mjesto. Ako je n dovoljno velik, broj takmičara koji su otpali do neke razine eliminatornog postupka je, u pravilu, dvostruko veći od broja koji je zaustavljen na neposredno nižoj razini tog postupka. Prema tome, y je slaba ordinalna varijabla sa znatnim brojem podjela ranga.

Priroda varijabli V_p iz X i varijable (K, recimo) iz y je očito takva da je primjena ma koje metričke tehnike za analizu činilaca koji utječu na uspjeh natjecatelja nemoguća ili neadekvatna. Zbog toga je nužno razmotriti neki nemetrički postupak za provođenje takve analize; a kako je model očito takav da dopušta neku nemetričku varijantu postupaka koji pripadaju generliziranom linearnom modelu, ispitajmo mogućnost da se u tu svrhu primijeni neka metoda monotone, tj. izotoničke regresione analize (Barlow, Bartholomew, Bremner i Brunk, 1972; Johnson, 1975).

Čini se, da je za to veoma pogodna Johnsonova (Johnson, 1975) metoda monotone regresije. Zbog toga će se predloženi postupak temeljiti na jednoj od mogućih modifikacija originalnog Johnsonovog postupka.

Neka je b m-dimenzionalni vektor, normiran, zbog pogodnosti, tako da je $b^T b = 1$. Izaberimo b tako, da varijabla, dobijena operacijom

$$(1) \qquad Xb = \hat{y}$$

ima što je moguće veći stupanj monotone povezanosti sa vrijednostima varijable K sadržanim u vektoru y.

Uvedimo mjeru stupnja monotonosti

$$\tau = 1 - u/v$$

gdje je u neka mjera odstupanja varijable $\hat{y}$ od monotone relacije sa varijablom y, a v faktor koji skalira τ tako da omeđi njegovo variranje između 0 (za striktno inverznu monotonu relaciju između y i y) i 1 (za striktno monotonu relaciju između $\hat{y}$ i y). Očito, u i v mogu biti izabrani tako, da je

$$\Theta^2 = u/v$$

baš Johnsonova (Johnson, 1973) mjera odsustva monotonosti.

Neka je, za ma koja dva takmičara Ti, Tj

$$d_{ij} = y_i - y_j$$

$$d_{ij} = \hat{y}_i - \hat{y}_j$$

i neka je

$$\sigma_{ij} = \text{predznak od } d_{ij}$$

a

$$\sigma_{ij} = \text{predznak od } d_{ij}$$

Dopustimo, osim toga, da (σ_{ij}), odnosno (σ_{ij}) poprime vrijednost 0 ako je d_{ij}, odnosno d_{ij} ravno nuli.

Uvedimo varijablu δ_{ij} koja ima slijedeća svojstva:

$$\delta_{ij} = 1 \text{ ako } \sigma_{ij} = \sigma_{ij}$$

$$\delta_{ij} = 0 \text{ ako } \sigma_{ij} = \sigma_{ij}$$

Sada je

$$u = \sum_i \sum_i \delta_{ij} d^2_{ij}$$

$$v = \sum_i \sum_j d^2_{ij}$$

pa maksimiziranje mjere τ odgovara minimiziranju Johnsonove mjere Θ^2.

Ta se mjera može minimizirati iterativnim postupkom koji je predložio Johnson (Johnson, 1973; Johnson 1975).

Neka je x_i vektor rezultata takmičara T_i u varijablama V_p, i neka je x_j vektor rezultata takmičara T_j. Parcijalna diferencijacija mjere Θ^2 u odnosu na b^*, gdje je b^* vektor na kome Θ^2 postiže minimum, daje

$$\partial \Theta^2/\partial b^* = v^{-2} (v(\partial u/\partial b^*) - u (\partial v/\partial b^*))$$

a kako je

$$\partial u/\partial b^* = 2 \sum_i \sum_j \delta_{ij} (x_i - x_j) d_{ij}$$

$$\partial v/\partial b^* = 2 \sum_i \sum_j (x_i - x_j) d_{ij}$$

gradijentni vektor g_a koji odgovara vetkoru b_a u svakoj iteraciji a je

$$g_a = 2 v^{-1} \sum_i \sum_j (\delta_{ij} - \Theta^2_a) (x_i - x_j) d_{ij}$$

Normirajmo, u svakoj iteraciji, g_a i b_a tako da je $g_a^T g_a = 1$ i $b_a^T b_a = 1$. Vektor b_{a+1}, određen na temelju rezultata u prethodnoj iteraciji a bit će

$$b_{a+1} = b_a - \Theta_a g_a$$

Odaberimo kao konačnu soluciju vektor b dobijen u interaciji u kojoj je $\Theta_a - \Theta_{a+1} \leqq \partial$, gdje je ∂ neki proizvoljno mali pozitivni broj, ili u iteraciji $a = a^*$, gdje je a^* unaprijed specificiran maksimalni broj iteracija. Vrijednosti b_p, $p = 1, m$ u vektoru b korespondiraju važnosti varijabli V_p za uspjeh takmičara u analiziranom natjecanju.

Inicijalni vektor b_0 može, naravno, biti proizvoljno izabran; pogodno je, međutim, da bude izabran tako da je svaki njegov element jednak $m^{-1/2}$. Proces možda brže konvergira ako se b_0 definira kao

$$b_0 = (x^T x)^{-1} x^T y$$

a zatim, eventualno, normira na 1.

Ako varijable Vp imaju komparabilnu metriku, kao što je to slučaj kada su sve Vp binarne varijable, ili varijable čija je priroda takva da se mogu standardizirati bez gubitka informacija, elementi b_p iz b su komparabilni direktno. Inače može, ali ne mora, biti pogodno da se na neki način standardiziraju, na pr. dijeljenjem sa nekom funkcijom drugog momenta varijabli Vp.

3. NEKE MOGUĆNOSTI EKSTENZIJE I GENERALIZACIJE

Pretpostavimo da je isti skup varijabli (V_p) analiziran u veećm broju natjecanja N_t, $t = 1, s$. Vektori b_t dobijeni analizom natjecanja N_t u nekoj će se mjeri međusobno razlikovati; razlikovat će se, naravno, i mjere stupnja monotonosti (τ_t), koje se mogu tretirati i kao mjera pouzdanosti kojom je određen neki vektor b_t.

Ako je potrebno donijeti neki sud o važnosti varijabli Vp za uspjeh u natjecanju uopće, korisno je sintetizirati na neki pogodan način informacije dobijene analizom pojedinih natjecanja. Pretpostavimo, stoga, da je skup natjecanja (N_t) dovoljno reprezentativan i nepristrasan uzorak iz univerzuma natjecanja, i razmotrimo neku pogodnu proceduru za određivanje takvog vektora ß koji u određenom smislu reprezentira vektore b_t.

Uočimo, međutim, da svi vektori b_t nisu dobijeni sa istim stupnjem pouzdanosti, i definirajmo koeficijente (τ_t), baš kao mjere te pouzdanosti. Prenormirajmo zato vektore (b_t) tako da im je norma upravo (τ_t); prenormirani vektori bit će

$$\tau_t^{1/2} b_t = \beta_t$$

Neka je $B = (\beta_t)$ matrica, reda m*s, tako prenormiranih vektora. Pogodno je, da bi se odredio traženi vektor β, pronaći najprije vektor β^* koji je, pod nekim kriterijem, najmanje udaljen od skupa vektora iz B. Odaberimo u tu svrhu kriterij najmanjih kvadrata, tz. nađimo vektor β^* tako da funkcija

$$\sum_t^s (\beta_t - \beta^*)^T (\beta_t - \beta^*) = p$$

bude minimum.

Problem se očito svodi na određivanje prve glavne komponente matrice B. Formirajmo zato matricu

$$C = B^T B$$

i odredimo λ, najveću svojstvenu vrijednost te matrice, i z, njoj pridruženi svojstveni vektor. Traženi vektor (β) bit će

$$\beta = Bz\lambda^{-1/2}$$

i sam normiran tako da je $\beta^T\beta=1$.

Vektor β može biti upotrijebljen u različite svrhe. Njegovi elementi β_p su proporcionalni važnosti varijabli Vp za uspjeh u univerzumu natjecanja, pa mogu biti upotrebljeni za postavljanje hipoteze o jednadžbi specifikacije juda, pa zato i kao informacije korisne pri programiranju treninga, usmjeravanju i izboru takmičara. Mjere τ_t, dobijene nakon operacije

$$X_t\beta = Y_t^*$$

mogu biti iskorištene u analizi odstupanja rezultata natjecanju N_t od očekivanih rezultata u univerzumu natjecanja; veličine u vektoru

$$w_t = b_t - \delta$$

neka su mjera odstupanja ponašanja varijabli V_p u natjecanju N_t od njihova ponašanja u univerzumu natjecanja, reprezentiranom uzorkom (N_t). Osim toga, ako je nekom skupu takmičara (T_i) moguće pridružiti vektore x^*_i dobijene nekom kondenzacijom vektora x_{ti}, operacije

$$\beta^T x_i^* = \hat{y}_i^*$$

izvedene nad skupom (T_i) mogu dati informacije od neke koristi za procjenu sportske vrijednosti takmičara.

LITERATURA

Barlow, R. E., D. I. Bartholomew, I. M. Bremmer, and *H. D. Brunk:* Statistical inference under order restrictions. Wiley, New York, 1972.

Johnson, R. M.: Pairwise nonmetric multidimensional scaling. Psychometrika, *38,* pp. 11—18 (1973)

Johnson, R. M.: A simple method for pairwise monotone regression. Psychometrika *40,* pp. 163—168 (1975)