the basic efficient solutions to problem (1). In Section 2 we show how the 0—1 hyperbolic programming problem has been solved by different authors, from Hammer and Rudeanu [4] to Grunspan and Thomas [3]. In Section 3 we show an algorithm similar to the one by Florian-Robbilard [2], by which problem (4) is reduced to solving series of linear problems (8).

Then, theorem 1 is proved, according to which the optimal solution to problem (8) is the efficient solution to the bicriterion linear problem. Thus, our algorithm, in each of its cycles, produces one efficient solution x^k. The last efficient solution x^*, and that is the optimal solution to the hyperbolic problem, can be treated as the best one, regarding the criterion expressed by the fractional objective function. Namely, according to this criterion, the investment programme x^* gives maximum present net value per payback unit. At the end of Section 3, a geometrical interpretation of the proposed algorithm is given.

In the last section, the algorithm from Section 3 is illustrated using a numerical example. In each cycle, Balas' additive method is applied to the problem (8). The results are two efficient solutions, x^1 and x^2, the last of which is the optimal solution to the hyperbolic problem.

EKONOMSKA ANALIZA,
2, XIV (1980), 287—304

UTJECAJ PROMJENA U TEHNOLOŠKOJ MATRICI NA PROIZVODNJU POJEDINIH SEKTORA

*Mate BABIĆ**

UVOD

U procesu izrade plana input-output model se integrira s drugim analitičkim modelima. Prednost je input-output modela, pred drugim modelima, u tome što input-output model povezuje parcijalne i globalne analitičke pristupe i na taj način omogućuju simultano planiranje međuzavisnih dijelova privrednog sistema, kao i pojedinih aspekata funkcioniranja cjelokupnog procesa reprodukcije. Na taj način input-output model daje cjelovitu kvantitativnu sliku o proizvodnim međuzavisnostima pojedinih dijelova procesa reprodukcije. Zbog toga input-output modeli predstavljaju nenadoknadiv okvir za koordinaciju razvojnih odluka pojedinih subjekata planiranja (OOUR-a).

Osim strukturnog usklađivanja i bilanciranja, kojim se u procesu izrade plana ispituje konzistentnost ciljeva, a time i sama izvedivost pojedinih planskih proporcija, input-output model omogućuje da se već u procesu izrade plana ispituju složene reperkusije pojedinih varijanti plana na sve elemente privredne strukture. Na taj se način mogu otkriti osnovni strukturni problemi, prije svega u proizvodnoj sferi, koji se u planskom razdoblju mogu očekivati. Tako se pomoću input-output modela mogu identificirati proizvodni sektori koji predstavljaju limitirajuće faktore razvoja i dovode u pitanje ostvarivanje planskih proporcija, ali i uvjete i načine njihova usklađivanja i složene implikacije koje bi takva usklađivanja imala na sve elemente privredne strukture.

FORMULIRANJE INPUT-OUTPUT MODELA ZA PLANIRANJE

Osnovna prednost input-output modela pred drugim modelima jest njegova primjena u analizi strukture proizvodnih međuzavisnosti svih sektora na koje je narodna privreda raščlanjena.[1])

* Fakultet za vanjsku trgovinu, Zagreb.

[1]) O problemima dezagregiranja vidi opširnije u: M. Babić: »Osnove input-output analize«, Narodne novine, Zagreb, 1978. i M. Sekulić: »Primjena strukturnih modela u planiranju privrednog razvoja«, Narodne novine, Zagreb, 1968.

Pokazatelj intenziteta proizvodnih međuzavisnosti dvaju proizvodnih sektora je tehnički koeficijent a_{ij}. Njega definiramo na slijedeći način:

$$a_{ij} = \frac{X_{ij}}{X_j} \tag{1}$$

Tehnički koeficijent a_{ij} pokazuje utrošak proizvoda i-tog sektora potreban za ostvarivanje jedinice proizvodnje sektora j. Na taj način tehničkih koeficijent predstavlja pokazatelj direktne proizvodne međuzavisnosti sektora *i* i sektora *j*.

S obzirom da se u reprodukcionoj potrošnji sektora *j* mogu trošiti proizvodi i-tog sektora domaćeg ili uvoznog podrijetla, možemo i ukupni tehnički koeficijent rastaviti na njegovu domaću i uvoznu komponentu:

$$a_{ij} = a^d_{ij} + a^u_{ij} \tag{2}$$

gdje superskript *d* znači domaći, a superskript *u* uvozni.

Mi ćemo u ovom radu govoriti samo o ukupnom tehničkom koeficijentu, tj. ne ćemo praviti razliku između domaćih i uvoznih proizvoda i-tog sektora koji se troše po jedinici proizvodnje j-tog sektora.[1])

Uz pomoć tehničkog koeficijenta možemo bilančnu relaciju pisati:

$$X_i + U_i = \sum_j a_{ij} X_j + Y_i \quad (i = 1, 2, \ldots, n) \tag{3}$$

Prebacimo li U_i na desnu stranu, imat ćemo:

$$X_i = \sum_j a_{ij} X_j + (Y_i - U_i) \quad (i = 1, 2, \ldots, n) \tag{4}$$

Razliku $Y_i - U_i$ definiramo kao finalnu proizvodnju sektora *i*, tj. proizvodnju sektora *i* domaće privrede koja je namijenjena finalnoj potrošnji. Zbog toga izraz (4) možemo pisati:

$$X_i = \sum_j a_{ij} X_j + F_i \quad (i = 1, 2, \ldots, n) \tag{5}$$

Za sve sektore možemo napisati odgovarajuće jednadžbe namjenske raspodjele. U matričnom obliku te jednadžbe možemo ovako napisati:

$$X = AX + F \tag{6}$$

[1]) O potrebi i analitičkim prednostima razdvajanja tehničkog koeficijenta na njegovu domaću i uvoznu komponentu vidi: M. Babić op. cit.

gdje je:

X — n-komponentni vektor stupac ukupne proizvodnje
A — kvadratna matrica tehničkih koeficijenata n-tog reda
F — n-komponentni vektor stupac finalne proizvodnje
n — broj sektora na koje je narodna privreda u input-output tabeli raščlanjena.

Model (6) možemo prevesti u reducirani oblik. Ako to učinimo, imat ćemo:

$$X = (I - A)^{-1} F = R F \tag{7}$$

U modelu (7) kvadratnu matricu $R = (I - A)^{-1}$ zovemo matrični multiplikator. Njegovi elementi r_{ij} pokazuju veličinu proizvodnje sektora *i* koja je direktno i indirektno uvjetovana jedinicom finalnih isporuka sektora *j*.

Na temelju (7) možemo proizvodnju svakog sektora izraziti kao funkciju veličine finalnih isporuka svih sektora:

$$X_i = \sum_j r_{ij} F_j \quad (i = 1, 2, \ldots, n) \tag{8}$$

Vidimo da je promjena proizvodnje sektora *i* koja je uvjetovana jediničnom promjenom finalnih isporuka sektora *j* izražena sektorskim multiplikatorom r_{ij}, tj.:

$$\frac{\gamma X_i}{\gamma F_j} = r_{ij} \quad \begin{matrix} (i = 1, 2, \ldots, n) \\ (j = 1, 2, \ldots, n) \end{matrix} \tag{9}$$

Promjene finalnih isporuka planiraju se u planu privrednog razvoja. Uz konstantne sektorske multiplikatore r_{ij}, nije poroblem izračunati potrebne promjene proizvodnje sektora *i* ($i = 1, 2, \ldots, n$) koje uvjetuju promjenu finalnih isporuka *j* ($j = 1, 2, \ldots, n$).

Međutim kao što vidimo iz (8), proizvodnja sektora *i* ($i = 1, 2, \ldots, n$) ne ovisi samo o veličini finalnih isporuka sektora *j*, nego i o sektorskim multiplikatorima r_{ij}. Zbog toga se proizvodnja sektora *i* ($i = 1, 2, \ldots, n$), može mijenjati i uz nepromijenjene finalne isporuke *j* ($j = 1, 2, \ldots, n$), ako se mijenjaju sektorski multiplikatori r_{ij}.

Iz izraza (7) vidimo da je $R = (I - A)^{-1}$, tj. da se sektorski multiplikatori mijenjaju kao posljedica promjene tehničkih koeficijenata.

U input-output modelu standardna je pretpostavka o konstantnosti tehničkih koeficijenata. To input-output modelu daje karakter kratkoročnosti. Međutim, u planu privrednog razvoja ta pretpostavka često nije zadovoljena. Naime, u planskom razdoblju može doći, a i dolazi do promjene nekih tehničkih koeficijenata. Razlozi za takvu promjenu mogu biti različiti npr. tehnički progres, supstitucija nekih proizvoda zbog cijena (npr. poskupljenje nafte potiče njezinu supstituciju jeftinijim izvorima energije), ograničenja proizvodnje nekog proizvoda (npr. ograničenje proizvodnje i izvoza nafte od strane OPEC-a) itd.

U svakom slučaju, promjena tehničkih koeficijenata uvjetovat će promjene sektorskih multiplikatora, a promjena sektorskih multiplikatora uvjetovat će promjene proizvodnje. To će sa svoje strane utjecati na narušavanje ravnoteže (izražene u obliku bilanci koje smo naprijed naveli) i do neusklađenosti cjelokupnog plana, čime može biti dovedena u pitanje i njegova izvedivost.

Zbog toga je vrlo važno predvidjeti promjene pojedinih tehničkih koeficijenata u planskom razdoblju. Međutim, predviđanje promjena tehničkih koeficijenata nije lako niti jednostavno. Uz to stoji i činjenica, kao što ćemo u slijedećem odsječku vidjeti, da promjena svakog tehničkog koeficijenta nema istu važnost za formiranje cjelokupnih strukturnih proporcija i za narušavanje makroekonomske ravnoteže. Zbog toga ćemo mi najprije pokušati identificirati tehničke koeficijente koji imaju najveće značenje za formiranje cjelokupnih strukturnih proporcija, čija bi promjena u najvećem stupnju narušila makroekonomsku ravnotežu, kako bi njihovom predviđanju obratili posebnu pozornost.

Promjene koje nastaju u proizvodnoj strukturi narodne privrede vrlo su brojne pa je vrlo teško koncentrirati se na sve njih i adaptirati tehnološku matricu svim tim promjenama. Uostalom, ni jednim ekonomskim modelom ne možemo obuhvatiti sve međuzavisnosti među svim varijablama. Tako je i s I—O modelom.[1]) Međutim sve promjene nemaju isto značenje za formiranje ukupnih međusektorskih tokova. Zbog toga je korisno ocijeniti koji tehnički koeficijenti imaju najveće značenje za formiranje cjelokupnih međusektorskih tokova. Kad se to napravi, onda treba koncentrirati naročitu pozornost na analizu i procjenu promjene tih koeficijenata radi realističnije procjene kretanja ukupnih međusektorskih tokova u planskom periodu.

PROMJENA PROIZVODNIH FUNKCIJA U SEKTORIMA

Kao što smo vidjeli, proizvodnju svakog sektora koja je uvjetovana finalnom potrošnjom izračunat ćemo:

$$X = (I - A)^{-1} Y \tag{10}$$

Pretpostavimo da je došlo do promjene proizvodne funkcije u nekom proizvodnom sektoru j, te da se utrošak proizvoda sektora i u tom sektoru promijenio za b_{ij}, tj:

$$a^{*}_{ij} = a_{ij} + b_{ij} \tag{11}$$

Promjena proizvodne funkcije u sektoru j zbog tehničkog napretka i sl. mijenja j-ti stupac njegove tehnološke matrice. Zbog toga se matri-

[1]) Idealni cilj ekonomske analize jest utvrđivanje svih međuzavisnosti koje postoje među svim varijablama u narodnoj privredi pomoću jednog modela. Međutim, broj međuzavisnosti u svakoj narodnoj privredi je jako velik, pa ih nije moguće sve obuhvatiti jednim modelom. Zbog toga moramo odabirati određeni broj najvažnijih, koje ćemo obuhvatiti modelom. Vidi opširnije u M. Babić: »Makroekonomski modeli«, Narodne novine, Zagreb, 1977, str. 27—29.

ca A mijenja u A* (u kojoj je promijenjen j-ti stupac).

Novu tehnološku matricu možemo sada pisati:

$$A^* = A + B \tag{12}$$

Na temelju toga možemo izračunati ukupnu proizvodnju:

$$X^* = (I - A^*)^{-1}\, Y = (I - A - B)^{-1}\, Y \tag{13}$$

Očigledno postoji razlika između starog i novog matričnog multiplikatora, ako je $B \neq 0$, što smo pretpostavili. Kad bismo za plansko razdoblje mogli predvidjeti promjene u tehnološkoj matrici, mogli bismo pokušati korigirati matrični multiplikator i tako korigiranim množiti planiranu finalnu potrošnju radi izračunavanja ukupne proizvodnje. Označimo li korekcionu matricu s C, novi multiplikator je:

$$(I - A^*)^{-1} = C\,(I - A)^{-1} = (I - A - B)^{-1} \tag{14}$$

Matricu korekcije C možemo izračunati na temelju (14):

$$C\,(I - A)^{-1} = (I - A - B)^{-1}. \tag{15}$$

Množenjem s desna s $(I - A - B)$, slijedi:

$$C\,(I - A)^{-1}(I - A - B) = (I - A - B)^{-1}(I - A - B)$$

odnosno:

$$C\,(I - A)^{-1}(I - A - B) = I \tag{16}$$

Množeći lijevu stranu (16) imamo:

$$C = [I - (I - A)^{-1} B]^{-1} = [I - R\,B]^{-1} \tag{17}$$

Uvrstimo li (17) u (14) imamo novi matrični multiplikator R*:

$$R^* = C\,R = (I - R\,B)^{-1} R \tag{18}$$

Da bismo našli R* treba, dakle, prvo naći umnožak $RB \equiv W$, njega odbiti od jednačine matrice i tu razliku invertirati. Tom inverznom matricom, konačno premultiplicirati stari matrični multiplikator.

Nađimo $W \equiv RB$

$$W = RB = \begin{bmatrix} r_{11}\, r_{12} \ldots r_{1j} \ldots r_{1n} \\ r_{21}\, r_{22} \ldots r_{2j} \ldots r_{2n} \\ - \; - \; - \; - \; - \; - \\ r_{i1}\, r_{i2} \ldots r_{ij} \ldots r_{in} \\ - \; - \; - \; - \; - \; - \\ r_{n1}\, r_{n2} \ldots r_{nj} \ldots r_{nn} \end{bmatrix} \begin{bmatrix} b_{11}\, b_{12} \ldots b_{1j} \ldots b_{1n} \\ b_{21}\, b_{22} \ldots b_{2j} \ldots b_{2n} \\ - \; - \; - \; - \; - \; - \\ b_{i1}\, b_{i2} \ldots b_{ij} \ldots b_{in} \\ - \; - \; - \; - \; - \; - \\ b_{n1}\, b_{n2} \ldots b_{nj} \ldots b_{nn} \end{bmatrix} =$$

$$W = \begin{bmatrix} \sum\limits_k r_{1k}\, b_{k1}\ \sum r_{1k}\, b_{k2} \dots \\ \sum r_{2k}\, b_{k1}\ \sum r_{2k}\, b_{k2} \dots \\ - - - - - \\ \sum r_{ik}\, b_{k1}\ \sum r_{ik}\, b_{k2} \dots \\ - - - - - \\ \sum r_{nk}\, b_{k1}\ \sum r_{nk}\, b_{k2} \dots \end{bmatrix} \begin{bmatrix} \sum r_{1k}\, b_{kj} \dots \sum r_{1k}\, b_{kn} \\ \sum r_{2k}\, n_{kj} \dots \sum r_{2k}\, b_{kn} \\ - - - - - - \\ \sum r_{ik}\, b_{kj} \dots \sum r_{ik}\, b_{kn} \\ - - - - - - \\ \sum r_{nk}\, b_{kj} \dots \sum r_{nk}\, b_{kn} \end{bmatrix} =$$

$$W = \begin{bmatrix} w_{11}\, w_{12} \dots w_{1j} \dots w_{1n} \\ w_{21}\, w_{22} \dots w_{2j} \dots w_{2n} \\ \dots\dots\dots\dots\dots \\ w_{i1}\, w_{i2} \dots w_{ij} \dots w_{in} \\ \dots\dots\dots\dots\dots \\ w_{n1}\, w_{n2} \dots w_{nj} \dots w_{nn} \end{bmatrix}$$

Element matrice W, $w_{ij} = \sum\limits_k r_{ik}\, b_{kj}$ pokazuje promjenu proizvodnje sektora i koja je uvjetovana promjenom tehničkog koeficijenta a_{kj} za b_{kj}. Ta je promjena b_{kj} pokazivala promjenu utroška proizvoda k-tog sektora po jedinici proizvodnje j-tog sektora, a to znači i potrebnu promjenu proizvodnje k-tog sektora koju će on isporučiti j-tom sektoru. Međutim, povećanje proizvodnje k-tog sektora za jednu jedinicu uvjetuje direktno i indirektno povećanje proizvodnje svakog sektora za r_{ik} $(i = 1,2,\dots,n)$. Zbog toga w_{ij} pokazuje promjenu proizvodnje sektora i koja je direktno i indirektno uvjetovana promjenom tehničkog koeficijenta a_{kj} za b_{kj}.

Dakle, element matrice W, $w_{ij} = \sum\limits_k r_{ik}\, b_{kj}$ pokazuje promjenu sektorskog multiplikatora r_{ik} koja je uvjetovana promjenom utroška proizvoda i-tog sektora po jedinici proizvodnje j-tog sektora. Npr. ako se promijeni koeficijent a_{12} za b_{12}, ta će promjena uvjetovati promjenu sektorskog multiplikatora $r_{12} - \sum\limits_k r_{1k}\, n_{k2}$, pa će promjena proizvodnje sektora 1 koja je uvjetovana promjenom tehnologije u sektoru 2, b_{12} utjecati na promjenu ukupne proizvodnje sektora 1 uvjetovanu (direktno i indirektno) promjenom potražnje sektora 2 za proizvodima prvog sektora za b_{12}. Analogno tome, promjena tehničkog koeficijenta b_{k2} $(k = 1,2,\dots,n)$ pokazivala bi promjenu potrošnje proizvoda sektora k u drugom sektoru. Ako to pomnožimo s r_{ik} $(i = 1,2,\dots,n)$ dobit ćemo promjenu proizvodnje, sektora i $(i = 1,2,\dots,n)$ uvjetovanu promjenom tehničkih koeficijenata u drugom sektoru za b_{k2} $(k = 1,2,\dots,n)$.

Nakon što smo našli matricu W, odbijemo ju od jedinične, pa dobijemo matricu $(I - W) \equiv (I - RB)$ koju invertiramo i dobijemo korekcionu matricu $C = (I - RB)^{-1} = (I - W)^{-1}$.

Promjena tehnologije u jednom sektoru

Pretpostavimo da je proizvodna funkcija promijenjena samo u jednom sektoru, recimo u sektoru m. Tada će u matrici B samo elementi m-tog stupca biti različiti od nule:

$$B = \begin{bmatrix} 0\ 0 \dots b_{1m} \dots 0 \\ 0\ 0 \dots b_{2m} \dots 0 \\ - - - - - \\ 0\ 0 \dots b_{km} \dots 0 \\ - - - - - \\ 0\ 0 \dots b_{nm} \dots 0 \end{bmatrix}$$

Sada će matrica W biti:

$$W\ RB = \begin{bmatrix} r_{11}\ r_{12} \dots r_{1j} \dots r_{1n} \\ r_{21}\ r_{22} \dots r_{2j} \dots r_{2n} \\ - - - - - - \\ r_{m1}\ r_{m2} \dots r_{mj} \dots r_{mm} \\ \dots\dots\dots\dots\dots \\ r_{n1}\ r_{n2} \dots r_{nj} \dots r_{nn} \end{bmatrix} \begin{bmatrix} 0\ 0 \dots b_{1m} \dots 0 \\ 0\ 0 \dots b_{2m} \dots 0 \\ - - - - - \\ 0\ 0 \dots b_{km} \dots 0 \\ \dots\dots\dots\dots \\ 0\ 0 \dots b_{nm} \dots 0 \end{bmatrix} =$$

$$W = \begin{bmatrix} 0\ 0 \dots \sum r_{1k}\, b_{km} \dots 0 \\ 0\ 0 \dots \sum r_{2k}\, b_{km} \dots 0 \\ - - - - - - \\ 0\ 0 \dots \sum r_{mk}\, b_{km} \dots 0 \\ - - - - - - \\ 0\ 0 \dots \sum r_{nk}\, b_{km} \dots 0 \end{bmatrix}$$

Vidimo da je:

$$w_{ij} = \sum_k r_{ik}\, b_{kj} = 0 \ \text{za}\ j \neq m$$

Npr. $w_{12} = \sum\limits_k r_{1k}\, b_{km} = 0$ jer je $b_{12} = 0$. Svi su stupci nule kad je $j = m$.

Ako matricu $(I - W)$ invertiramo, dobit ćemo korekcionu matricu C:

$$(I - W)^{-1} = \begin{bmatrix} 1\ 0 \dots \dfrac{\sum r_{1k}\, b_{km}}{1 - \sum r_{mk}\, b_{km}} \dots 0 \\ 0\ 1 \dots \dfrac{\sum r_{2k}\, b_{km}}{1 - \sum r_{mk}\, b_{km}} \dots 0 \\ \dots\dots\dots\dots\dots \\ 0\ 0 \dots \dfrac{1}{1 - \sum r_{mk}\, b_{km}} \dots 0 \\ \dots\dots\dots\dots\dots \\ 0\ 0 \dots \dfrac{r_{nk}\, b_{km}}{1 - \sum r_{mk}\, b_{km}} \dots 1 \end{bmatrix} = C$$

Razlika između novog i starog matričnog multiplikatora je:

$R^* - R = CR - R = (C - I)\,R.$

$$
(C-I)R = \begin{bmatrix}
0 & 0 & \ldots & \dfrac{\Sigma r_{1k}\, b_{km}}{1-\Sigma r_{mk}\, b_{km}} & \ldots & 0 \\
0 & 0 & \ldots & \dfrac{\Sigma r_{2k}\, b_{km}}{1-\Sigma r_{mk}\, b_{km}} & \ldots & 0 \\
- & - & - & - & - & - \\
0 & 0 & \ldots & \dfrac{1}{1-\Sigma r_{mk}\, b_{km}} & \ldots & 0 \\
- & - & - & - & - & - \\
0 & 0 & \ldots & \dfrac{\Sigma r_{nk}\, b_{km}}{1-\Sigma r_{mk}\, b_{km}} & \ldots & 0
\end{bmatrix}
\begin{bmatrix}
r_{11} & r_{12} & \ldots & r_{1m} & \ldots & r_{1n} \\
r_{21} & r_{22} & \ldots & r_{2m} & \ldots & r_{2n} \\
- & - & - & - & - & - \\
r_{m1} & r_{m2} & \ldots & r_{mm} & \ldots & r_{mn} \\
- & - & - & - & - & - \\
r_{n1} & r_{n2} & \ldots & r_{nm} & \ldots & r_{nn}
\end{bmatrix}
$$

$$
(C-I)R = \begin{bmatrix}
\dfrac{\Sigma r_{1k}\, b_{km}}{1-\Sigma r_{mk}\, b_{km}} r_{m1} & \dfrac{\Sigma r_{1k}\, b_{km}}{1-\Sigma r_{mk}\, b_{km}} r_{m2} \ldots & \ldots \dfrac{\Sigma r_{1k}\, b_{km}}{1-\Sigma r_{mk}\, b_{km}} r_{mm} \ldots & \dfrac{\Sigma r_{1k}\, b_{km}}{1-\Sigma r_{mk}\, b_{km}} r_{mn} \\
\dfrac{\Sigma r_{2k}\, b_{km}}{1-\Sigma r_{mk}\, b_{km}} r_{m1} & \dfrac{\Sigma r_{2k}\, b_{km}}{1-\Sigma r_{mk}\, b_{km}} r_{m2} \ldots & \ldots \dfrac{\Sigma r_{2k}\, b_{km}}{1-\Sigma r_{mk}\, b_{km}} r_{mm} \ldots & \dfrac{\Sigma r_{2k}\, b_{km}}{1-\Sigma r_{mk}\, b_{km}} r_{mn} \\
\cdots & \cdots & \cdots & \cdots \\
\dfrac{1}{1-\Sigma r_{mk}\, b_{km}} r_{m1} & \dfrac{1}{1-\Sigma r_{mk}\, b_{km}} r_{m2} \ldots & \ldots \dfrac{1}{1-\Sigma r_{mk}\, b_{km}} r_{mm} \ldots & \dfrac{1}{1-\Sigma r_{mk}\, b_{km}} r_{mn} \\
\dfrac{\Sigma r_{nk}\, b_{km}}{1-\Sigma r_{mk}\, b_{km}} r_{m1} & \dfrac{\Sigma r_{nk}\, b_{km}}{1-\Sigma r_{mk}\, b_{km}} r_{m2} \ldots & \ldots \dfrac{\Sigma r_{nk}\, b_{km}}{1-\Sigma r_{mk}\, b_{km}} r_{mm} \ldots & \dfrac{\Sigma r_{nk}\, b_{km}}{1-\Sigma r_{mk}\, b_{km}} r_{mn}
\end{bmatrix}
$$

Iz ove matrice možemo izračunati razliku između sektorskih multiplikatora prije i poslije promjene tehnologije u sektoru m. Npr.

$$r^*_{11} - r_{11} = \frac{\sum_k r_{1k}\, b_{km}}{1-\sum_k r_{mk}\, b_{km}}\, r_{m1} \qquad r^*_{12} - r_{12} = \frac{\Sigma r_{1k}\, b_{km}}{1-\Sigma r_{mk}\, b_{km}}\, r_{m2} \quad \ldots$$

$$r^*_{13} - r_{13} = \frac{\Sigma r_{1k}\, b_{km}}{1-\Sigma r_{mk}\, b_{km}}\, r_{m3}$$

ili općenito:

$$r^*_{ij} - r_{ij} = \frac{\Sigma r_{ik}\, b_{km}}{1-\Sigma r_{mk}\, b_{km}}\, r_{mj} \tag{19}$$

Ako lijevu i desnu stranu izraza (19) pomnožimo s F_j i zbrojimo imat ćemo:

$$\sum_j r^*_{ij} F_j - \sum_j r_{ij} \cdot F_j = \frac{\Sigma r_{ik}\, b_{km}}{1-\Sigma r_{mk}\, b_{km}}\, \Sigma r_{mj} F_j\,. \tag{20}$$

Budući da je:

$$\sum_j r_{ij} F_j = X_i \quad (i = 1, 2, \ldots, n)$$

izraz (20) možemo pisati:

$$X^*_i - X_i = \frac{\Sigma r_{ik}\, b_{km}}{1-\Sigma r_{mk}\, b_{km}}\, X_m \quad (i = 1, 2, \ldots, n) \tag{21}$$

Na taj način pomoću izraza (21) možemo izračunati promjenu proizvodnje sektora i koja je uvjetovana promjenom proizvodne funkcije u sektoru m.

Ako izraz (21) podijelimo s X_i dobit ćemo relativnu promjenu proizvodnje sektora i koja je posljedica promjene proizvodne funkcije u sektoru m:

$$\frac{X^*_i - X_i}{X_i} = \frac{\Sigma r_{ik}\, b_{km}}{1-\Sigma r_{mk}\, b_{km}}\, \frac{X_m}{X_i} \tag{22}$$

Izraz (22) pokazuje koliko je relativna promjena proizvodnje sektora i uvjetovana promjenom proizvodne funkcije sektora m. Pomnožimo li (22) sa 100, dobit ćemo postotnu promjenu proizvodnje sektora i koja je uvjetovana promjenom proizvodne funkcije u sektoru m.

Mijenjanje pojedinih tehničkih koeficijenata

Najčešće se u proizvodnoj funkciji (stupcu) sektora m mijenja samo jedan koeficijent. Pretpostavimo da se promijenio samo tehnički koeficijent a_{km} za b_{km}, tj:

$$a^{*}_{km} = a_{km} \pm b_{km} \qquad \begin{matrix} (k = 1, 2, \dots, n) \\ (m = 1, 2, \dots, n) \end{matrix}$$

Tada imamo:

$$W = \begin{bmatrix} r_{11} & r_{12} & \dots & r_{1m} & \dots & r_{1n} \\ r_{21} & r_{22} & \dots & r_{2m} & \dots & r_{2n} \\ - & - & - & - & - & - \\ r_{k1} & r_{k2} & \dots & r_{km} & \dots & r_{kn} \\ - & - & - & - & - & - \\ r_{n1} & r_{n2} & \dots & r_{nm} & \dots & r_{nn} \end{bmatrix} \begin{bmatrix} 0 & 0 & \dots & 0 & \dots & 0 \\ 0 & 0 & \dots & 0 & \dots & 0 \\ - & - & - & - & - & - \\ 0 & 0 & \dots & b_{km} & \dots & 0 \\ - & - & - & - & - & - \\ 0 & 0 & \dots & 0 & \dots & 0 \end{bmatrix} =$$

$$= \begin{bmatrix} 0 & 0 & \dots & r_{1k}\, b_{km} & \dots & 0 \\ 0 & 0 & \dots & r_{2k}\, b_{km} & \dots & 0 \\ - & - & - & - & - & - \\ 0 & 0 & \dots & r_{mk}\, b_{km} & \dots & 0 \\ - & - & - & - & - & - \\ 0 & 0 & \dots & r_{nk}\, b_{km} & \dots & 0 \end{bmatrix}$$

Element matrice W, i w_{ij} pokazuje promjenu proizvodnje sektora i koja je uvjetovana promjenom a_{km} za b_{km}. Povećanje potrošnje proizvoda k-tog sektora po jedinici proizvodnje m-tog sektora uvjetovat će i povećanje proizvodnje k-tog sektora. Povećanje proizvodnje k-tog sektora za jedinicu uvjetuje sa svoje strane direktno i indirektno povećanje proizvodnje svakog sektora i $(i = 1, 2, \dots, n)$ za r_{ik}. Zbog toga w_{ij} pokazuje promjenu proizvodnje sektora i koja je direktno i indirektno uvjetovana povećanjem tehničkog koeficijenta a_{km} za b_{km}.

Da bismo našli razliku između starog i novog matričnog multiplikatora: $R^{*} - R = CR - R = (C - I)\, R$, naći ćemo najprije matricu $C - I$, Zatim ćemo matricu $C - I$ pomnožiti sa starim matričnim multiplikatorom R. Kad to i uradimo imamo:

$$(C - I)\, R = \begin{bmatrix} \dfrac{r_{1k}\, b_{km}}{1 - r_{mk}\, b_{km}}\, r_{m1} & \dfrac{r_{1k}\, b_{km}}{1 - r_{mk}\, b_{km}}\, r_{m2} & \dots & \dfrac{r_{1k}\, b_{km}}{1 - r_{mk}\, b_{km}}\, r_{mm} & \dots & \dfrac{r_{1k}\, b_{km}}{1 - r_{mk}\, b_{km}}\, r_{mn} \\ \dfrac{r_{2k}\, b_{km}}{1 - r_{mk}\, b_{km}}\, r_{m1} & \dfrac{r_{2k}\, b_{km}}{1 - r_{mk}\, b_{km}}\, r_{m2} & \dots & \dfrac{r_{2k}\, b_{km}}{1 - r_{mk}\, b_{km}}\, r_{mm} & \dots & \dfrac{r_{2k}\, b_{km}}{1 - r_{mk}\, b_{km}}\, r_{mn} \\ - & - & - & - & - & - \\ \dfrac{r_{mk}\, b_{km}}{1 - r_{mk}\, b_{km}}\, r_{m1} & \dfrac{r_{mk}\, b_{km}}{1 - r_{mk}\, b_{km}}\, r_{m2} & \dots & \dfrac{r_{mk}\, b_{km}}{1 - r_{mk}\, b_{km}}\, r_{mm} & \dots & \dfrac{r_{mk}\, b_{km}}{1 - r_{mk}\, b_{km}}\, r_{mn} \\ - & - & - & - & - & - \\ \dfrac{r_{nk}\, b_{km}}{1 - r_{mk}\, b_{km}}\, r_{m1} & \dfrac{r_{nk}\, b_{km}}{1 - r_{mk}\, b_{km}}\, r_{m2} & \dots & \dfrac{r_{nk}\, b_{km}}{1 - r_{mk}\, b_{km}}\, r_{mm} & \dots & \dfrac{r_{nk}\, b_{km}}{1 - r_{mk}\, b_{km}}\, r_{mn} \end{bmatrix}$$

Na temelju ove matrice možemo naći razliku između novog i starog sektorskog multiplikatora:

$$r^{*}_{ij} - r_{ij} = \frac{r_{ij}\, b_{km}}{1 - r_{km}\, b_{km}}\, r_{mj} \tag{23}$$

Vidimo da je izraz (23) sličan izrazu (19). Razlika je u tome što u izrazu (23) nema $\sum_{k}$ u brojniku i u nazivniku, jer smo pretpostavili da se mijenja samo jedan element a_{km} u proizvodnoj funkciji sektora m.

Zbog toga su svi b_{lm} za $l = k$ jednaki nuli, pa se izraz (19) svodi na izraz (23).

I sada možemo izračunati promjenu proizvodnje sektora i zbog promjene koeficijenta a_{km} za b_{km}. Ta je promjena:

$$\Sigma r^{\star}_{ij} F_j - r_{ij} F_j = \frac{r_{ik}\, b_{km}}{1 - r_{mk}\, b_{km}} r_{mj} F_j$$

odnosno:

$$X^{\star}_i - X_i = \frac{r_{ik}\, b_{km}}{1 - r_{mk}\, b_{km}} X_m \tag{24}$$

Ako opet želimo izračunati relativnu promjenu proizvodnje sektora i, pisat ćemo:

$$\frac{X^{\star}_i - X_i}{X_i} = \frac{\Delta X_i}{X_i} = \frac{r_{ik}\, b_{km}}{1 - r_{mk}\, b_{mk}} \cdot \frac{X_m}{X_i}. \tag{25}$$

Želimo li promjenu proizvodnje sektora i koja je uvjetovana promjenom tehničkog koeficijenta a_{km} za b_{km} izraziti u postotku, pomnožit ćemo (25) sa 100.

Često puta se, međutim, proizvodnja sektora i može mijenjati samo do određene granice. Tako se npr. proizvodnja sektora elektroenergije, nafte itd. može povećati samo do granice njihovih kapaciteta. Isto tako i uvoz proizvoda pojedinih sektora ima gornju granicu određenu platnobilančnim mogućnostima ili nekim drugim okolnostima (ograničenje proizvodnje nafte npr.). Zbog toga ta maksimalno dopustiva promjena proizvodnje sektora i postavlja ograničenje i na dopustivu promjenu pojedinih tehničkih koeficijenata.

Postavimo egzogeno maksimalno dozvoljeno odstupanje proizvodnje sektora i i označimo ga s α. Zatim utvrdimo koliko se svaki tehnički koeficijent može maksimalno promijeniti da se proizvodnja bilo kojeg sektora ne promijeni više od α. Što god se neki koeficijent može više promijeniti, a da time izazvana proizvodnja najosjetljivijeg sektora ne bude veća od α, to je taj koeficijent manje značajan za formiranje strukturnih proporcija. Obrnuto, što su manje promjene nekog tehničkog koeficijenta koje izazivaju promjene proizvodnje najosjetljivijeg sektora jednake α, to je taj koeficijent značajniji za formiranje strukturnih proporcija i na nj treba posebno usredotočiti pozornost u procesu planiranja strukturnih proporcija.

Ispitamo li sve koeficijente, možemo ustanoviti njihovu signifikantnost i izdvojiti sve najznačajnije.

Računski postupak izvodimo ovako:

Postavljamo zahtjev da postotna promjena proizvodnje sektora i ne bude veća od α posto:

$$\frac{\Delta X_i}{X_i} \leq \alpha \tag{26}$$

Zbog toga izraz (25) možemo pisati:

$$\frac{r_{ik}\, b_{km}}{1 - r_{mk}\, b_{km}} \cdot \frac{X_m}{X_i} \leq \alpha \tag{27}$$

Sad se pitamo kolika najveća promjena b_{km} smije biti da promjena proizvodnje sektora i ne bude veća od α. Iz (27) možemo izračunati b_{km} ovako:

$$r_{ik}\, b_{km} \frac{X_m}{X_i} \leq \alpha - r_{mk}\, b_{km} \cdot \alpha$$

$$r_{ik}\, b_{km} \frac{X_m}{X_i} + r_{mk}\, b_{km}\, \alpha \leq \alpha$$

$$b_{km} \left(r_{ik} \frac{X_m}{X_i} + r_{mk}\, \alpha\right) \leq \alpha$$

odnosno:

$$b_{km} \leq \frac{\alpha}{X_m \dfrac{r_{ik}}{X_i} + \alpha \cdot r_{mk}} \tag{28}$$

Uz dani α, sektorske multiplikatore r_{ik} i r_{mk}, te veličine proizvodne X_i i X_m, desna strana izraza (28) ima najmanju vrijednost kad je $\frac{X_m}{X_i}$ najveći uz dani r_{ik}, ili kad je odnos $\frac{r_{ik}}{X_i}$ uz dane odnose proizvodnje maksimalan. Odnos $\frac{r_{ik}}{X_i}$ maksimalan je kad je $i = k$, jer je kao što znamo $r_{ii} > r_{ij}$ za $i \neq j$. Zbog toga se maksimalno odstupanje svakog tehničkog koeficijenta može pisati:

$$b_{km} = \frac{\alpha}{\frac{X_m}{X_i} r_{ik} + \alpha\, r_{mk}} \tag{29}$$

Ako ovu promjenu želimo izraziti u postotku, podijelit ćemo obje strane s a_{km} i množiti sa 100:

$$\frac{b_{km}}{a_{km}} \cdot 100 = \frac{\alpha}{\frac{r_{ik}}{X_i} X_m + \alpha\, r_{mk}} \cdot \frac{100}{a_{km}} \tag{30}$$

Na temelju izraza (30) možemo utvrditi koji su tehnički koeficijenti najznačajniji za formiranje cjelokupnih međusektorskih odnosa i na koje zbog toga u procesu izrade plana treba naročito svratiti pozornost. Isto tako možemo na temelju izraza (30) utvrditi i tehničke koeficijente koji imaju vrlo malo značenje u formiranju cjelokupnih međusektorskih odnosa pa njihova, čak i relativno velika promjena, npr. za 100% ili više, ne bi bitnije utjecala na promjenu proizvodnje bilo kojeg sektora. Na taj način ćemo smanjiti broj tehničkih koeficijenata čije promjene u planskom razdoblju treba posebno brižljivo nastojati predvidjeti i posao oko procjene njihovih promjena svesti u savladive okvire.

Kad jednom utvrdimo koji su koeficijenti najznačajniji za formiranje ukupne strukture međusektorskih odnosa, trebat će uz pomoć granskih eksperata i uz pomoć formaliziranih metoda projekcije tehničkih koeficijenata nastojati što bolje predvidjeti njihove promjene u planskom razdoblju, kako bi primjena input-output modela poslužila svojoj svrsi — usklađivanju proporcija u procesu izrade plana.

EMPIRIJSKA ANALIZA OSJETLJIVOSTI PROMJENE PROIZVODNJE POJEDINIH SEKTORA JUGOSLAVENSKE PRIVREDE NA PROMJENE POJEDINIH TEHNIČKIH KOEFICIJENATA

Pogledamo li izraz (30) uočit ćemo da uz dani r_{ik}, X_m, r_{mk} i X_i, $\frac{b_{km}}{a_{km}}$ je tim veći što je a_{km} manji. To znači da je dopustiva promjena tehničkog koeficijenta a_{km} veća, a da se proizvodnja sektora i ($i = 1, 2, \ldots, n$) ne promijeni više od α posto, što god je manja vrijednost tehničkog koeficijenta a_{km}. Kad je $a_{km} = 0$, on se može promijeniti za α posto, a da se proizvodnja i-tog sektora ne promijeni više od α posto. U tom slučaju je proizvodnja sektora i ($i = 1, 2, \ldots, n$) potpuno neelastična na promjenu koeficijenta a_{km}.

Obrnuto, što je veća vrijednost koeficijenta a_{km}, to je proizvodnja sektora i ($i = 1, 2, \ldots, n$) elastičnija na njegove promjene. Naime, što je veći a_{km}, to će, ceteris paribus, nazivnik u izrazu (30) biti veći, pa će

uz dani α vrijednost $\frac{b_{km}}{a_{km}}$ biti manja, a to znači da će manja promjena koeficijenta a_{km} uvjetovati promjenu proizvodnje sektora i ($i = 1, 2, \ldots, n$) za α posto.

Zbog toga smo mogli odmah iz analize signifikantnosti izostaviti sve tehničke koeficijente čija je vrijednost jednaka nuli, jer je proizvodnja svakog sektora potpuno neelastična na njihove promjene. Time se skraćuje vrijeme i troškovi računanja.

Osim toga, iz analize smo izostavili i tehničke koeficijente koji se odnose na sektore: trgovina i ugostiteljstvo, uslužno zanatstvo, komunalne djelatnosti te stari materijal i otpaci, zbog mjesta koje ti sektori imaju u procesu reprodukcije i njihovog značenja u formiranju cjelokupne reprodukcione potrošnje. Naime, nijedan od tih sektora ne daje značajniju količinu svojih proizvoda u reprodukcionu potrošnju, pa promjena tehničkih koeficijenata koji se odnose na te sektore ne može bitnije utjecati na promjene cjelokupne reprodukcione potrošnje.

Nakon ovih pojednostavljenja izvršili smo proračune signifikantnosti svih 625 tehničkih koeficijenata i svrstali ih u četiri grupe. U prvu grupu spadaju tehnički koeficijenti čija promjena i manja od 10% uvjetuje promjenu proizvodnje sektora i za 1%. Drugu grupu čine sektori čija promjena od 10 do 20 posto uvjetuje promjenu proizvodnje nekog sektora za 1%. Treću grupu čine koeficijenti čije promjene između 20 i 50% uvjetuju promjenu proizvodnje nekog sektora i za 1%. U četvrtu grupu spadaju koeficijenti koji se mogu promijeniti i za više od 50%, a da se proizvodnja najosjetljivijeg sektora ne promijeni za više od 1%. Te ćemo koeficijente smatrati nesignifikantnima.

Rezultati su dani u slijedećoj tabeli:

Tabela 1

Raspodjela tehničkih koeficijenata po grupama signifikantnosti

Grupa	Postotna promj. koeficijenta $\frac{b_{km}}{a_{km}} \cdot 100$	Broj koeficijenata	% od ukup. broja koef.	% od reprod. potrošnje
I	do 10	49	7,8	65,6
II	10—20	41	6,6	8,4
III	20—50	92	14,7	7,7
IV	preko 50	443	70,9	18,3
Ukupno		625	100,0	100,0

Iz tabele 1 vidimo da koeficijenti svrstani u prve tri grupe predstavljaju oko 82% od cjelokupne reprodukcione potrošnje. Tih je koeficijenata 192, što čini 29,1% od ukupnog broja koeficijenata koje smo ispitivali. Preostalih 443 koeficijenta odnosno 70,9% od ispitanih predstavljaju svega 18,3% od cjelokupne reprodukcione potrošnje. Njihova se veličina može promijeniti za više od 50% (neki i znatno više) a da se proizvodnja najosjetljivijeg sektora ne promijeni za 1%. Dakle, proizvodnja jugoslavenskih proizvodnih sektora iz input-output tabele 1974. jako je neelastična na promjene ovih 71% koeficijenata (ponegdje čak i potpuno neelastična!). Zbog toga u daljnjoj analizi ne treba potanje ispitivati osjetljivost proizvodnje pojedinih sektora jugoslavenske privrede na promjene tehničkih koeficijenata iz ove četvrte grupe, koje smo radi toga proglasili nesignifikantnima.

Pogledamo li I. grupu koeficijenata, čija bi promjena i za manje od 10% utjecala na promjenu proizvodnje nekih sektora za 1%. To su koeficijenti na čije je promjene proizvodnja pojedinih sektora jugoslavenske privrede najosjetljivija, pa predviđanju njihovih promjena u slijedećem planskom razdoblju treba posvetiti naročitu pozornost. Tih koeficijenata ima svega 49, što čini tek 7,8% od svih ispitanih koeficijenata. To posao predviđanja ovih koeficijenata svodi u savladive granice. Međutim, tih 7,8% koeficijenata predstavljaju 2/3 ili točnije 65,6% od cjelokupne reprodukcione potrošnje Jugoslavije 1974. godine. Zbog toga bi nepredviđene promjene tih koeficijenata mogle utjecati na bitnije narušavanje strukturnih proporcija u planu privrednog razvoja.

Druga grupa koeficijenata čija promjena od 10 do 20 posto uvjetuje promjenu proizvodnje najosjetljivijeg sektora za 1%, sastoji se od 41 koeficijenta što čini 6,6% od ukupnog broja ispitanih koeficijenata. Tih 6,6% koeficijenata predstavljali su 1974. godine 8,4% cjelokupne reprodukcione potrošnje Jugoslavije.

Prve dvije grupe čine zajedno 14,4% svih ispitanih koeficijenata, ali predstavljaju oko 3/4 ili 74% cjelokupne reprodukcione potrošnje. Zbog toga je važno nastojati predvidjeti eventualne promjene tehničkih koeficijenata tih dviju grupa, jer oni imaju odlučujuću ulogu u formiranju cjelokupnih strukturnih proporcija.

Primljeno: 9. 11. 1979.
Prihvaćeno: 26. 11. 1979.

LITERATURA

Babić, M.: »*Osjetljivost proizvodnje pojedinih sektora jugoslovenske privrede na promjene tehničkih koeficijenata*«, Ekonomski institut, Zagreb, 1979.

Babić, M.: *Osnove input-output analize*, Narodne novine, Zagreb, 1978.

Bachem, A. i Korte, B.: "Estimating Input-Output Matrices" *Seventh International Conference on Input-output Techniques*, Innsbruck, 9—13 April, 1979.

Brody, A. i Carter, A.P.: *Applications of Input-Output Analysis*, North Holland, Amsterdam, 1970.

Dolenc, M. i Pfajfar, L.: »Primerjava nekaterih metod za ocenjevanje tehničkih koeficijentov v medsektorskih tabelah«, *Ekonomska analiza*, 1—2, 1976.

Frisch, R.: *Speed with Safety through National Planning* University of Oslo, Institute of Economics, Oslo, 1974.

Kossov, V. i Uninson, Y.: "Input-Output Models applied in Calculations of Draft Plans of the USSR Economic and Social Development" *Seventh International Conference on Input-Output Techniques*, Innsbruck, 9—13, April, 1979.

Lang, R.: »Institucionalni model i vremenski horizont samoupravnog društvenog planiranja«, *Ekonomski pregled*, 1—3, 1976.

Mesarić, M.: »Funkcije planskog mehanizma u socijalističkoj tržnoj privredi«, *Ekonomski pregled*, 11—12, 1969.

Middlehoeck, A.J.: "Tests of the Marginal Stability of Input-Output Coefficients", u: A.P. Carter i A. Brody (edit.): *Applications of I—O Analysis*, North Holland, Amsterdam, 1970.

Polenske, K.R. i Skolka, J.V. (edit.): *Advances in Input-Output Analysis*, Ballinger Publishing Co., Cambridge, Mass., 1976.

Rayatskas, R.L.: "Integrated Systems of Models for Planning and Forecasting", *Seventh International Conference on Input-Output Techniques*, Innsbruck, 9—13 April, 1979.

Savezni zavod za statistiku: *Međusobni odnosi privrednih delatnosti*, 1974.

Sekulić, M.: *Primjena strukturnih modela u planiranju privrednog razvoja*. Narodne novine, Zagreb, 1968.

Sekulić, M.: »Uloga strukturnih modela u organiziranju sistema samoupravnog društvenog planiranja«, *Ekonomski pregled*, 12, 1974.

Sevaldson, P.: *The Stability of Input-Output Coefficients*, Artikler 32, Statistiks Sentralbyra, Oslo, 1970.

THE IMPACT OF CHANGE IN THE TECHNOLOGICAL MATRIX ON THE PRODUCTION OF INDIVIDUAL SECTORS

Mate BABIĆ

Summary

Relevant to the input-output model, the standard assumption is that of the constancy of technical coefficients. This gives the input-output model a short-term character. However, in economic development plans this assumption frequently goes unsatisfied. More precisely, changes in certain technical coefficients can and do occur in the plan period. The reasons for such change can be varied, for example, technical progress, the substitution of certain products due to cost (to illustrate, the price hike for oil spurs on its substitution by using cheaper sources of energy), limited production of a particular product (for example, limited production and export of oil by OPEC), etc.

It is therefore very important to anticipate changes in particular technical coefficients in the plan period. However, the anticipation of changes in technical coefficients is neither easy nor simple. In addition, there is the fact that changes in each technical coefficient do not hold the same significance for the formation of entire structural proportions and for disturbing macroeconomic equilibrium. For this reason, we have attempted to identify those technical coefficients which have the grea-

test importance for the formation of entire structural proportions, those whose changes would most severely disturb macroeconomic equilibrium, so that particular attention can be given to their anticipation.

This study presents appropriate constructed models which show what impacts are wielded on the production of individual sectors of the national economy by changes in the overall technological matrix, changes in the production of only one sector, or changes in only individual technical coefficients.

On the basis of formula (30):

$$\frac{b_{km}}{a_{km}} \cdot 100 = \frac{\alpha}{\frac{r_{lk}}{X_l} X_m + \alpha\, r_{mk}} \cdot \frac{100}{a_{km}}$$

it is possible to establish which technical coefficients are most important for the formation of overall inter-sectoral relations and, in turn, which should receive particular attention during plan elaboration. On the basis of this formula its also possible to establish those technical coefficients which hold very little significance in the formation of overall inter-sectoral relatiosn, so that even their relatively striking changes, for example, by 100 per cent and more, would not more seriously influence the change in the production of any sector. In this way, it is possible to decrease both the number of coefficients whose changes should be optimally anticipated as well as the work involved in judging their changes — using experts or formalized methods — and thus reduce them to tolerable limits.

In applying formula (30) to the data from the Yugoslav 29-sector input-output table for 1974, we established that the output of the Yugoslav production sectors is highly unelastic to changes in as much as 71 per cent of the technical coefficients which can be altered by more than 100 per cent. For this reason, production in the most sensitive sector does not change by more than 1 per cent. The remaining 29 per cent of technical coefficients were classified into three groups according to the degree of their significance. The results of the calculation are presented in Table 1.

PRIKAZI — BOOK REVIEWS

ILLUSIONS OF POWER AND SOCIALISM

For hundreds of years Austria had been one of the dominant political powers of the European continent. The ruling members of the House of Hapsburg, the archdukes of Austria, were once elected as emperors of the so-called Holy Roman Empire by the German sovereigns. During the Napoleonic wars, this loosely-knotted alliance of principalities was dissolved; and out of the Hapsburg estates the Austrian Empire was formed. In 1914, this empire contained what is today Austria, Czechoslovakia, Hungary, and large parts of Italy, Yugoslavia, and Rumania.

In 1918, with the end of the First World War, this Austrian Empire was completely shattered. Austria shrank to a tiny state not even containing all the German-speaking parts of the old empire. The social and political structure collapsed as well. The ruling members of the Hapsburg family were exiled and a democratic republic was proclaimed; the old social order was totally discredited.

For a short time, a vacuum of power prevailed. With the collapse of the old order the Socialist Party suddenly found the ruling power in its hands. This historical moment, long dreamed of by the opposition against feudalism and capitalism, was there — and it passed, it wasn't used for the profound restructuring of the economic system which Social-Democracy had always argued for. The book by:

Erwin Weissel,
Die Ohnmacht des Sieges. Arbeiterschaft und Sozialisierung nach dem Ersten Weltkrieg in Österreich.
Europaverlag: Wien 1976 (465 pages)
ISBN 3-203-50598-0

tries to explain this interesting phenomenon.[1])

[1]) In contrast to 1918, the situation after World War II *was* used for radical changes in the scope of private property in Austria (but not in West Germany). In 1946/47, two far-reaching nationalization laws were passed by parliament affecting the property structure in industry, banking and the energy sector. However, for the purposes of "socialization", nationalization alone is perhaps a necessary but not a sufficient condition. — For a discussion of these questions, see E. März, F. Weber, Verstaatlichung und Sozialisierung nach dem Ersten und Zweiten Weltkrieg, Eine vergleichende Studie, *Wirtschaft und Gesellschaft* 4 (1978), pp. 115—142; E. März, Gemeinwirtschaft und soziale Veränderung, *Annalen der Gemeinwirtschaft* (1973), pp. 187—202; and Branko Horvat, Vergesellschaftetes Eigentum, *Wirtschaft und Gesellschaft*, 5 (1979), pp. 437—442.