

ГЕНЕРИРАНЕ НА ТОЧНИ ПЛАНОВЕ ЗА МОДЕЛИ ОТ ТРЕТИ РЕД С ПОДОБРЕН ФАКТОР НА МУЛТИКОЛИНЕАРНОСТ

Диана Дечева

Христо Йончев

Минно-геоложки университет
"Св. Иван Рилски"
София 1700, България

Химико-технологичен и металургичен
университет
София 1700, България

РЕЗЮМЕ

Известните планове на експеримента за оценка на модели от трета степен са с изразена мултиколинеарност - линейна зависимост между стълбовете на информационната матрица. Използването им затруднява обработката на експерименталните данни и в много случаи води до намиране на изместени оценки на коефициентите.

За намиране на планове с нисък фактор на мултиколинеарност се предлагат алгоритми и програми, минимизиращи два индиректни критерия: сумата от извъндиагоналните елементи на ковариационната матрица или максималния от тях. С тяхна помощ са генерирани планове на експеримента за кубична регресия при два, три и четири фактора. Във всички случаи намерените експериментални планове са с подобрена стойност на максималния дисперсионен инфлационен фактор от два до три пъти.

Ключови думи: оптимално планиране на експеримента; мултиколинеарност; кубична регресия.

ПРОБЛЕМИ НА ОПТИМАЛНОТО ПЛАНИРАНЕ НА ЕКСПЕРИМЕНТА ПРИ КУБИЧНА РЕГРЕСИЯ

Полиномиалните модели от трети ред при m управляващи фактора включват освен пълен полином от втори ред

$$A = b_0 + \sum_{i=1}^m b_i x_i + \sum_{i=1}^{m-1} \sum_{j=i+1}^m b_{ij} x_i x_j + \sum_{i=1}^m b_{ii} x_i^2 \quad (1)$$

и един или комбинация от няколко члена от вида:

$$B = \sum_{i=1}^{m-2} \sum_{j=i+1}^{m-1} \sum_{l=j+1}^m b_{ijl} x_i x_j x_l \quad (2)$$

$$C = \sum_{i=1}^{m-1} \sum_{j=i+1}^m b_{ijj} x_i x_j^2 + \sum_{i=1}^{m-1} \sum_{j=i+1}^m b_{ijj} x_i^2 x_j \quad (3)$$

$$D = \sum_{i=1}^m b_{iii} x_i^3 \quad (4)$$

Съществуват множество подходи за търсене на оптимални планове за модели от този тип (Вучков, Круг и др., 1971; Вучков, Йончев и др. 1978, Мержанова и Никитин, 1979; Йончев 1991). При тях основно са използвани критерии за D или G оптималност и намерените планове са с много добри стойности за D_{eef} и G_{eef} . Използването им е обаче свързано с проблеми при ста-

тистическата обработка на експерименталните данни. Това се дължи на нарушаване на една от предпоставките за използване на метода на най-малките квадрати за оценка на коефициентите в регресионните модели - изискването за отсъствие на мултиколинеарност (линейна зависимост между колоните на разширената матрица на плана на експеримента F).

За оценка на мултиколинеарността са предложени редица критерии, изчислени от елементите на матрица $G = F^T F$, обзор на които е направен от Митков и Минков (1993). С F е означена стандартизираната матрица на плана на експеримента, чиито елементи са определени по зависимостта:

$$f_{ji-1} = \frac{f_{ji} - \bar{f}_i}{\sqrt{\sum_{j=1}^N (f_{ji} - \bar{f}_i)^2}}, \quad i = 2, k; j = 1, N \quad (5)$$

където k е броя на коефициентите в оценявания регресионен модел, N е броя на опитите в експерименталния план, а \bar{f}_i е средноаритметичната стойност на i -тия стълб на F .

Най-често използваният критерий за мултиколинеарност е дисперсионния инфлационен фактор VIF. Той представлява вектор, съставен от диагоналните елементи на

стандартизираната ковариационна матрица $C = G^{-1}$. Счита се (Belsley, Kuh и др., 1980; Hocking, 1983), че съществува мултиколинеарност, ако максималният елемент на VIF е по-голям от 3÷5.

В Таблица 1 са приведени данни за максималните стойности на VIF за някои известни планове на експеримента при модели от пълна трета степен.

Таблица 1

Тип на плана	Предложен от	m	N	Max VIF
1	2	3	4	5
ПФЕ с 4 нива		2	16	12.69
Ортогонален некомпозиционен	Раздорский, Чальный и др. (1973)	3	40	34.04
	Денисов и Попов (1976)	3	32	67.50
Дискретен квази D-оптимален	Вучков, Круг и др. (1971)	3	40	19.83
Ненаситен последователен D-оптимален	Вучков, Йончев и др. (1978)	3	20	23.48

С изразена мултиколинеарност са и плановете, получени за непълна трета степен (Мержанова и Никитина, 1979; Iontchev H.A., K. Stoianov, 1998).

Прилагането на метода на най-малките квадрати при наличие на мултиколинеарност води до неустойчивост на оценките на коефициентите. В този случай обработката на експерименталните данни се препоръчва да се осъществи с използване на метода на главните компоненти, ридж регресионен анализ, регресионен анализ по характеристични корени, регресионен анализ с обобщено обръщане. Общ недостатък на намерените оценки по тези методи е тяхната изместеност, която е толкова по-значима, колкото по-ярко е изразена взаимната зависимост между стълбовете в матрица F.

Изложените проблеми налагат разработване на алгоритми и програми за генериране на планове на експеримента за кубична регресия, които са с нисък фактор на мултиколинеарност. По този начин ще се създадат предпоставки за намиране на по-точни оценки на коефициентите в търсените уравнения.

ИНДИРЕКТНИ КРИТЕРИИ ЗА МУЛТИКОЛИНЕАРНОСТ

Процедурите за търсене на оптимални експериментални планове най-общо се свеждат до итеративно подобряване на дадена характеристика на начален план чрез последователно отстраняване и добавяне на точки към него.

При поставената задача за търсене на планове с нисък фактор на мултиколинеарност, логично би било критерият за оптималност да бъде свързан с минимизиране на

максималната стойност на VIF. Прякото му използване обаче е ограничено от големия брой необходими изчислителни операции. Всяка промяна в текущия план (добавяне или отстраняване на точка) налага ново стандартизиране на F, формиране и обръщане на матрица G. И ако за първите две операции съществуват рекурентни зависимости, то обръщането на матрицата е свързано с големи изчислителни загуби.

За синтез на алгоритми със задоволително бързодействие е удобно да се използват показатели, свързани с нестандартизираната ковариационна матрица C. Преизчисляването на нейните елементи при промяна на броя на опитите в плана лесно може да се осъществи с използване на зависимостите, предложени от Galil и Kiefer (1980). Замяната на основния критерий с индиректен е възможно само при наличие на корелация между тях. За проверка на тази хипотеза за различни типове експериментални планове при извадка с обем 10 са намерени:

- оценките на коефициента на корелация \hat{r}_1 между max VIF и сумата от абсолютните стойности на извъндиагоналните елементи на C;
- оценките на коефициента на корелация \hat{r}_2 между max VIF и максималния по абсолютна стойност извъндиагонален елемент на C;
- оценките на коефициента на корелация \hat{r}_3 между max VIF и максималния по абсолютна стойност извъндиагонален елемент на C;
- изчислените стойности на t-критерия на Стюдънт $t_i, i = 1, \dots, 3$.

Резултатите за четири от изследваните варианти са представени в таблица 2. При първите три моделът има вида $\hat{y} = A + D$, а при последния $\hat{y} = A + B + D$.

Таблица 2.

Характеристики	Вариант			
	1	2	3	4
1	2	3	4	5
m	2	3	3	4
k	8	13	13	23
N	12	13	19	28
\hat{r}_1	0.896	0.945	0.898	0.786
\hat{r}_2	0.988	0.996	0.991	0.996
\hat{r}_3	0.980	0.996	0.980	0.985
t_1	8.555	8.190	5.769	3.594
t_2	26.799	33.767	20.660	29.694
t_3	21.104	30.318	14.120	16.293

При ниво на значимост 0.05 табличната стойност на t-критерият е 2.306. Във всички изследвани случаи тя е по-малка от изчислената. Това позволява хипотезата за наличие на линейна зависимост между изследваните величини да се приеме и да се изградят алгоритми, използващи индиректни критерии за мултиколинеарност. При това трябва да се има предвид, че намаляването на мултиколинеар-

ността не може да се осъществи “безнаказано” и намерените планове ще бъдат с намалени показатели за D_{eef} .

АЛГОРИТМИ ЗА ГЕНЕРИРАНЕ НА ПЛАНОВЕ С НИСЪК ФАКТОР НА МУЛТИКОЛИНЕАРНОСТ

Използвани са два непреки критерия за търсене на оптимални планове ζ^* с нисък фактор на мулти-колинеарност: минимум на сумата от абсолютните стойности на извъндиагоналните елементи на матрица C и минимум на най-големия по модул извъндиагонален елементи на същата матрица.

$$\sum_{i=1}^{k-1} \sum_{j=1}^{k-1} |c_{ij}(\zeta^*)| = \min_{\zeta} \sum_{i=1}^{k-1} \sum_{j=1}^{k-1} |c_{ij}(\zeta)| \quad (6)$$

$$\max_{i,j} |c_{ij}(\zeta^*)| = \min_{\zeta} \max_{i,j} |c_{ij}(\zeta)| \quad (7)$$

Те са избрани от следните съображения:

- намирането на минимална стойност 0 за първия критерий води до генериране на ортогонален план, което означава некорелираност на оценките на регресионните коефициенти и лесна обработка на експерименталните данни;
- коефициентът на корелация между втория критерий и максималния VIF е с най-голяма стойност.

Алгоритъм MMC1

От случаен начален план с $N+1$ точки се отстранява тази, която минимизира избрания критерий. Към получения план с N точки се добавя една случайна точка от L -те на брой, формиращи кандидат-множеството. Ако при това стойността на критерия намалее, се приема, че е извършена успешна замяна на точка. Процедурата продължава докато последователно не бъдат реализирани L на брой неуспешни смени.

Алгоритъм MMC2

Той използва критерий за оптималност (6) и в обобщен вид реализира следната последователност от операции:

Генерира се начален план с $N+1$ точки, които са избрани по случаен начин от кандидат-множеството.

Чрез последователно отстраняване на по една точка от началния план се получават $N+1$ плана, всеки с N на брой опита.

Изчисляват се сумите от абсолютните стойности на извъндиагоналните елементи $S_i, i=1,2,\dots,N+1$ на ковариационните матрици на всички планове, получени в т.2.

Определя се план k за който $S_k \leq S_i, i=1,2,\dots,N+1$. Той се приема за най-добър до момента и на минималната сума на извъндиагоналните елементи S_{min} се присвоява стойността на S_k .

Извършва се проверка за изчерпване на кандидат-множеството. Ако последователно са направени

неуспешни опити за добавяне на всички кандидат-точки, то най-добрият план, намерен до момента, се приема за търсения план; в противен случай се преминава към т. 6.

Към най-добрия намерен план до момента се добавя случайна точка от кандидат-множеството и се получава план с $N+1$ точки.

Чрез последователно отстраняване на по една точка от плана, формиран в т. 6, се получават $N+1$ плана, всеки с N на брой опита. За всеки от тях се изчислява сумата от абсолютните стойности на извъндиагоналните елементи на ковариационната матрица $S_i, i=1,2,\dots,N+1$.

Определя се план p за който $S_p \leq S_i, i=1,2,\dots,N+1$.

Ако $S_p < S_{min}$, то план p се приема за най-добър за дадения момент на търсенето, на S_{min} се присвоява стойността на S_p и изпълнението на алгоритъма продължава от т. 6. Ако $S_p \geq S_{min}$, се преминава към т.5.

Алгоритъм MMC3 има структура, аналогична на MMC2, но използваният критерий за оптималност е (7).

Представените алгоритми са реализирани програмно на FORTRAN 77. С цел повишаване на бързодействието, при програмните решения е възприето:

- работа само с наддиагоналните елементи на ковариационната матрица поради нейната симетричност;
- рекурентно изчисляване на стойността на критерия за ефективност.

АНАЛИЗ НА РЕЗУЛТАТИТЕ

С представените алгоритми при двата избрани критерия са търсени точни експериментални планове за случаите, представени в таблица 3.

Таблица 3.

№	Вид на модела	m	k	N	L
1	2	3	4	5	6
1	$\hat{y} = A + D$	2	8	12	441
2		3	13	13	9261
3		3	13	19	9261
4		4	19	24	6561
5	$\hat{y} = A + B + D$	3	14	15	9261
6		4	23	28	6561
7	$\hat{y} = A + C$	3	16	21	9261
8	$\hat{y} = A + B + C + D$	3	20	25	9261

Като база за сравнение на получените резултати са използвани характеристиките на планове, генерирани с процедура FDOP, предложена от Йончев (1991).

При алгоритъм MMC1 решението за замяна на точка се взема от стойността на характеристики, изчислени за план с $N+1$ точки. Оказва се, че това се явява съществен проблем при търсенето, тъй като минималната стойност на критерия, определен на база $N+1$ точки не гарантира минимум на критерия, определен от план с N точки. При разглеждания алгоритъм броят на заменените точки е

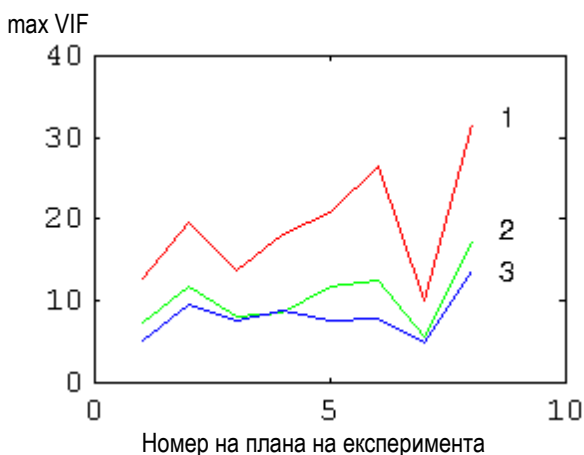
относително малък, забелязва се стремеж за включване на точки, симетрични на съществуващите в текущия план и резултантният план в значителна степен зависи от началния. Поради това, въпреки че алгоритъм MMC1 намира планове с намалена мултиколинеарност, използването му е неефективно.

В Таблица 4 са представени данни за максималния VIF за най-добрите планове, намерени чрез процедури FDOP, MMC2 и MMC3.

Таблица 4

№ на плана	MaxVIF за планове, намерени с		
	FDOP	MMC2	MMC3
1	2	3	4
1	11.1954	5.3504	4.7934
2	15.8430	8.0715	7.2006
3	15.1251	5.8280	6.6307
4	16.5743	7.8128	7.7146
5	22.1535	9.0887	6.1818
6	27.7123	9.9930	5.9266
7	10.0000	4.7857	4.2968
8	28.3218	15.8197	11.6665

На фиг. 1 са представени усреднените показатели за maxVIF. За всеки от осемте търсени плана на експеримента са използвани данни от 10 последователни реализации. С 1, 2 и 3 са означени графиките съответстващи на резултатите получени с процедури FDOP, MMC2 и MMC3.



Фигура 1. Изменение на средната стойност на максималния вариационен инфлационен фактор

Броят на итерациите зависи от началния случаен план. Затова за сравнение на скоростта на сходимост на предлаганите алгоритми може да се използва средния брой итерации. В таблица 5 са представени данни за експериментален план № 1.

Таблица 5

Показатели	Алгоритъм	
	MMC2	MMC3
1	2	3
Среден брой итерации	1520	1560
Максимален брой итерации	2475	2430

Минимален брой итерации	724	805
Среден брой успешни ит.	42	48

Броят итерации, необходими за генериране на останалите планове, също не се различава съществено при използване на алгоритми MMC2 и MMC3. Това позволява да се направи извода, че те са с практически съизмерима скорост на сходимост.

За проверка на свойствата на генерираните експериментални планове, в средата на MATLAB е съставена симулационна програма, която:

1. За всички точки от изследвания план на експеримента многократно определя стойността на изхода на обект, описван с модел от пълна трета степен при наличие на стандартен бял шум. Действителните стойности на коефициентите са дадени в колона 2 на таблица 6. Отношението на стандартните отклонения на шума и полезния сигнал е 7 %.
2. С използване на метода на най-малките квадрати определя оценките на коефициентите на регресионното уравнение.
3. Изчислява дисперсията на регресионните коефициенти.

Резултатите, получени за план № 8 са представени в таблица 6.

Очевидно е, че при плановете, генерирани с използване на MMC2 и MMC3 максималната стойност на дисперсията на коефициентите е намалена повече от два пъти в сравнение със съответния D-оптимален план.

От анализа на получените резултати могат да се направят следните изводи:


- ◆ при използване на процедури MMC2 и MMC3 се получават планове с максимална стойност на вариационния инфлационен фактор 2÷3 пъти по-малка от съответните D-оптимални планове, което води до съществено намаляване на дисперсията на оценките на коефициентите в регресионното уравнение;
- ◆ използването на критерий (7) в общия случай води до намиране на планове с по-малки стойности за maxVIF.

Таблица 6

Условно означение и действителни стойности на коефици.	Дисперсия на коефициентите при използване на			
	FDOP	MMC2	MMC3	
1	2	3	4	5
b0	3.0	0.2868	0.2299	0.1680
b1	-2.0	0.8462	0.4314	1.0682
b2	4.0	3.3604	0.8103	0.5105
b3	6.0	1.2387	0.6983	0.5164
b12	-4.0	0.0809	0.3071	0.1047
b13	2.5	0.1053	0.2905	0.1391
b23	-3.7	0.1293	0.1322	0.1446
b123	9.0	0.1043	0.0619	0.4879
b11	-12.0	0.2012	0.3108	0.2235
b22	-4.0	0.0724	0.2730	0.0892
b33	-3.0	0.1825	0.2694	0.4403

b111	-1.5	0.4016	0.3748	1.0697
b222	2.0	3.3216	1.3945	0.4629
b333	6.0	1.4865	0.3574	0.5643
b112	4.0	0.8494	0.4110	0.9025
b113	-3.0	0.5768	0.5376	0.9957
b221	6.5	0.7121	0.6688	0.3853
b223	4.4	0.2715	0.9387	0.3070
b331	-2.6	0.3759	1.3532	0.9951
b332	3.3	0.2184	1.0997	0.4293

Същевременно не трябва да се забравя, че намаляването на мултиколинеарността води до намаляване и на D-ефективността на плановете. На фиг. 2 са представени усреднените стойности на D_{eef} за осемте плана на експеримента, намерени с MMC2 (графика 1) и MMC3 (графика 2).



Фигура 2. Изменение на средната стойност на D_{eef}

Изследването на алгоритми MMC2 и MMC3 и съответните им програмни реализации показва, че те могат да се използват за генериране на плановете за кубична регресия, като експериментаторът трябва да избере използвания критерий в зависимост от изискванията за близост на намерения план до D-оптималния.

ЛИТЕРАТУРА

- Вучков, И. Н., Х. А. Йончев и др. 1978. Каталог последователно генерирани плановете. Изд. МНП, София.
- Вучков, И. Н., Г. К. Круг и др. 1971. D-оптимални плановете за кубична регресия, *Заводска лаборатория*, № 7.
- Йончев Х. А. 1991. Методи за построяване на оптимални композиционни и многооткликови последователни плановете на експеримента. Дисертация за получаване на научна степен "доктор на техническите науки", СТУ, София.
- Митков, А., Минков Д. 1993. Статистически методи за изследване и оптимизиране на селскостопанската техника. Д.Ф. Земиздат, София.
- Денисов, В. И., А. А. Попов. 1976. A-E-оптимални и ортогонални плановете на регресионни експерименти за полиномиални модели. М., Научный совет по кибернетике.
- Мержанова, Р. Ф., Е. П. Никитина. 1979. Каталог на плановете на трети степен. Изд. МГУ, Москва.
- Раздорский, В.В., В.Д. Чалый и др. 1973. Получение модели на обекта в виде на пълно полиномиално трети степен. Сб. Инженерно-математически методи в физика и кибернетика, вып. 3, М. Атомиздат.
- Belsley, D. A., E. Kuh, R. E. Welsch. 1980. Regression Diagnostics: Identifying Influential Data and Sources of Collinearity. N.Y., John Wiley.
- Galil Z., Kiefer, J. 1980. Time and Space-saving Computer Methods, Related to Mitchell's DETMAX, for Finding D-optimum Designs, *Technometrics*, v 22.
- Iontchev, H. A., K. Stoianov. 1998. Catalogue of response surface designs. University of Chemical Technology and Metallurgy, Sofia.
- Hocking, R. R. 1983. Developments in Linear Regression Methodology, *Technometrics*, v. 25, Nr. 3.

GENERATING ACCURATE PLANS OF THIRD-DEGREE MODELS WITH IMPROVED FACTOR OF MULTICOLINEARITY

Diana Decheva

University of Mining and Geology
 "St Ivan Rilski"
 Sofia 1700 Bulgaria

Hristo Iontchev

University of Chemical Technology and Metallurgy
 Sofia 1700, Bulgaria

ABSTRACT

Known plans of experiment for assessing third-degree models exhibit well expressed multicollinearity, i. e. a linear relationship between the columns of the information matrix. Their implementation impairs the processing of experimental data, and in many cases leads to obtaining biased estimates for the coefficients.

Algorithms and programmes that minimize two indirect criteria, namely the sum of extradiagonal elements of the covariance matrix, or the maximal one of those elements, are proposed for finding plans of a low factor of multicollinearity. Using these algorithms and programmes, plans of experiment for cubic regressions with two, three, or four factors have been generated. In all cases the value of the maximum variance inflation factor of experiment plans obtained has been improved up to two or three times.

Keywords: optimal planning of experiment, multicollinearity, cubic regression.

PROBLEMS OF OPTIMAL EXPERIMENT PLANNING FOR CUBIC REGRESSION

Besides a complete polynomial of second degree the polynomial models of third degree with m controlling factors also involve a term in one of the following forms or a combination of several such terms.

$$A = b_0 + \sum_{i=1}^m b_i x_i + \sum_{i=1}^{m-1} \sum_{j=i+1}^m b_{ij} x_i x_j + \sum_{i=1}^m b_{ii} x_i^2 \quad (1)$$

$$B = \sum_{i=1}^{m-2} \sum_{j=i+1}^{m-1} \sum_{l=j+1}^m b_{ijl} x_i x_j x_l \quad (2)$$

$$C = \sum_{i=1}^{m-1} \sum_{j=i+1}^m b_{ij} x_i x_j^2 + \sum_{i=1}^{m-1} \sum_{j=i+1}^m b_{ij} x_i^2 x_j \quad (3)$$

$$D = \sum_{i=1}^m b_{iii} x_i^3 \quad (4)$$

There exist many approaches to searching optimal plans for models of that type (Vuchkov, Krug et al., 1971; Vuchkov, Iontchev et al., 1978; Merzhanova and Nikitina, 1979; Iontchev, 1991). Criteria for D - or G -optimality are mostly used in those approaches, and the plans obtained have very good values of D_{ef} or G_{ef} . However, their applications are connected with problems emerging in the statistical processing of experimental data. This is due to the violation of one of the pre-requisites of using the method of least squares for assessing the coefficients in regression models, namely the requirement for lack of multicollinearity (i. e. no linear relationship between the columns of extended matrix F of the experiment plan should be present).

Several criteria calculated from the elements of matrix $\overset{\circ}{G} = \overset{\circ}{F}^T \overset{\circ}{F}$ have been proposed for the assessment of multicollinearity. A survey of those criteria has been compiled by Mitkov and Minkov (1993). $\overset{\circ}{F}$ designates the standardized matrix of the experiment plan, the elements of which are determined in accordance with the relationship:

$$f_{ji-1}^o = \frac{f_{ji} - \bar{f}_i}{\sqrt{\sum_{j=1}^N (f_{ji} - \bar{f}_i)^2}}, \quad i = 2, k; j = 1, N \quad (5)$$

where k is the number of coefficients in the regression model being assessed, N the number of trials in the experiment plan, and \bar{f}_i the arithmetic mean of the i^{th} column of F .

The most frequently used criterion for multicollinearity is the variance inflation factor or VIF. It is a vector consisting of the diagonal elements of standardized covariance matrix $\overset{o}{C} = \overset{o}{G}^{-1}$. It is assumed (Belsley, Kuh et al., 1980; Hocking, 1983) that a multicollinearity is present when the maximal element of VIF is greater than 3 to 5.

Table 1 shows data for the maximal VIF values of some known plans of experiment for models of complete third degree.

Table 1

Type of the experiment plan	Proposed by	m	N	Max VIF
1	2	3	4	5
Plan of 4 levels		2	16	12.69
Orthogonal non-compositional	Razdorskiy, Chaliy et al. (1973)	3	40	34.04
	Denisov and Popov (1976)	3	32	67.50
Discrete quasi-D-optimal	Vuchkov, Krug et al. (1971)	3	40	19.83
Non-saturated consecutive D-optimal	Vuchkov, Iontchev et al. (1978)	3	20	23.48

There is also an expressed multicollinearity in plans obtained for a non-complete third degree (Merzhanova and Nikitina, 1979; Iontchev and Stoianov, 1998).

Applying the method of least squares in the presence of multicollinearity leads to instability of coefficient estimates. In such a case it is recommended to process the experimental data by using the method of principal components, ridge regression analysis, regression analysis on characteristic roots, regression analysis with generalized reversal. A common disadvantage of the estimates obtained by these methods is their biasing which is the more considerable the stronger the mutual relationship between columns in matrix F is expressed.

Problems discussed above impose the development of algorithms and programmes for generating plans of experiment for cubic regression that have a low factor of multicollinearity. In such a way the needed pre-conditions will be created for finding more accurate estimates for coefficients in the equations being sought after.

INDIRECT CRITERIA FOR MULTICOLLINEARITY

In the most general case, procedures of searching optimal experiment plans are reduced to improving iteratively a characteristic of an initial plan by consecutively eliminating and adding points to it.

For the assigned task of searching plans of a low multicollinearity factor it would be logical that the criterion of optimality be connected with minimization of the maximal VIF value. However, its direct application is limited by the large number of necessary computational operations. Every modification of the current plan (adding or eliminating a point) requires new standardization of F , forming and reversing matrix G . Although there are recurrent relationships for the first two operations, reversing the matrix implies considerable computational losses.

To synthesize algorithms of satisfactory speed of performance it is convenient to use parameters connected with the non-standardized covariance matrix C . Re-calculating its elements, when there is a change in the number of trials in the plan, can be easily realized by using the relationships proposed by Galil and Kiefer (1980). Substituting an indirect criterion for the basic one will

be possible if only there is a correlation between them. To verify this hypothesis for various types of experiment plans for a sample of volume 10 the following has been found:

1. the estimates for correlation coefficient \hat{r}_1 between maxVIF and the sum of absolute values of the extradiagonal elements in C;
2. the estimates for correlation coefficient \hat{r}_2 between maxVIF and the extradiagonal element of maximal absolute value in C;
3. the estimates for correlation coefficient \hat{r}_3 between maxVIF and the extradiagonal element of maximal absolute value in C;
4. the calculated values of Student's t -criterion $t_i, i = 1, \dots, 3$.

Results for four of the variants examined are shown in Table 2. For the first three of them the model is in the form $\hat{y} = A + D$, and for the last one $\hat{y} = A + B + D$.

Table 2.

Characteristics	Variant			
	1	2	3	4
1	2	3	4	5
m	2	3	3	4
k	8	13	13	23
N	12	13	19	28
\hat{r}_1	0.896	0.945	0.898	0.786
\hat{r}_2	0.988	0.996	0.991	0.996
\hat{r}_3	0.980	0.996	0.980	0.985
t_1	8.555	8.190	5.769	3.594
t_2	26.799	33.767	20.660	29.694
t_3	21.104	30.318	14.120	16.293

At a significance level of 0.05 the tabular value of the t -criterion is 2.306. In all cases examined it is smaller than the calculated one. This allows to assume the hypothesis for the presence of a linear relationship between the investigated variables, and to build up algorithms using indirect criteria for multicollinearity. Here, it should be taken into account that it is not possible to realize "free of charge" decreasing of the multicollinearity, and the plans obtained will have reduced parameter values for D_{ef} .

ALGORITHMS FOR GENERATING PLANS WITH A LOW FACTOR OF MULTICOLLINEARITY

Two indirect criteria for searching optimal plans ζ^* with a low factor of multicollinearity have been used: a minimum of the sum of the absolute values of extradiagonal elements in matrix C, and a minimum of the extradiagonal element of highest module value in the same matrix.

$$\sum_{i=1}^{k-1} \sum_{j=1}^{k-1} |c_{ij}(\zeta^*)| = \min_{\zeta} \sum_{i=1}^{k-1} \sum_{j=1}^{k-1} |c_{ij}(\zeta)| \quad (6)$$

$$\max_{i,j} |c_{ij}(\zeta^*)| = \min_{\zeta} \max_{i,j} |c_{ij}(\zeta)| \quad (7)$$

They have been selected based on the following considerations:

- ◆ finding a minimal value 0 for the first criterion leads to generating an orthogonal plan, which means non-correlation of the estimates for regression coefficients and easy processing of experimental data;
- ◆ the coefficient of correlation between the second criterion and the maximal VIF is of the highest value.

Algorithm MMC1

From a random initial plan of $N-1$ points that point shall be eliminated, which minimizes the criterion selected. A random point from the points of number L forming the set of candidates is added to the N -point plan obtained. If this leads to a decrease in the criterion

value it is assumed that a point has been successfully replaced. This procedure is continued until unsuccessful replacements of number L are carried out.

Algorithm MMC2

It applies a criterion of optimality (6) and in a generalized form realizes the following sequence of operations:

- An initial plan of $N+1$ points is generated, the points being randomly selected from the set of candidates.
- Eliminating consecutively one point at a time from the initial plan leads to obtaining $N+1$ plans, each of them consisting of trials of number N .
- Sums S_i , $i = 1, 2, \dots, N+1$, of the absolute values of extradiagonal elements in the covariance matrices are computed for all plans obtained at step 2.
- A k^{th} plan for which $S_k \leq S_i$, $i = 1, 2, \dots, N+1$ is defined. It is assumed to be the best one for the time being, and the value of S_k is assigned to the minimal sum of extradiagonal elements S_{\min} .
- A check for depleting the set of candidates is performed. If consecutive unsuccessful attempts for adding all candidate points have been made, then the best plan obtained so far is assumed to be the one that has been sought after. Otherwise, the programme goes to step 6.
- A random point from the set of candidates is added to the best plan found so far, and a plan of $N+1$ points is obtained.
- Eliminating consecutively one point at a time from the plan formed at step 6 leads to obtaining $N+1$ plans, each of them consisting of trials of number N . The sum S_i , $i = 1, 2, \dots, N+1$, of the absolute values of extradiagonal elements in the covariance matrix is computed for each of those plans.
- A p^{th} plan, for which $S_p \leq S_i$, $i = 1, 2, \dots, N+1$ is defined.
- If $S_p < S_{\min}$, then the p^{th} plan is assumed to be the best at that moment of the search procedure, the value of S_p is assigned to S_{\min} , and the algorithm continues performing from step 6. If $S_p \geq S_{\min}$, then the programme goes to step 5.

Algorithm MMC3 has a structure analogous to that of MMC2 but the optimality criterion it uses is (7).

The algorithms shown have been realized as programmes in FORTRAN 77. To increase the speed of performance the programming solutions are based on:

- ◆ using only the supradiagonal elements of the covariance matrix for the matrix is a symmetrical one, and
- ◆ applying a recurrent computation of the effectiveness criterion value.

ANALYSIS OF RESULTS

Accurate experiment plans for the cases shown in Table 3 have been searched for by using the algorithms represented for the two selected criteria.

Table 3.

The characteristics of plans generated with procedure FDOP proposed by Iontchev (1991) have been used as a basis for comparing the results obtained.

In algorithm MMC1 the decision for replacing a point is made from the value of characteristics calculated for a plan of N+1 points. It turns out this being an essential problem in searching as the minimal value of the criterion obtained on the basis of N+1 points does not guarantee a minimum for the criterion obtained from a plan of N points. For the algorithm considered the number of replaced points is relatively small, a tendency towards involving points symmetric to those existing in the current plan is observed, and the resulting plan depends to a considerable degree upon the initial one. For these reasons, the use of algorithm MMC1 is inefficient, irrespective of the fact that it finds plans of reduced multicollinearity.

Data for the maximal VIF of the best plans obtained through procedures FDOP, MMC2, and MMC3 are given in Table 4.

Table 4.

№ of plan	MaxVIF for plans obtained through:		
	FDOP	MMC2	MMC3
1	2	3	4
1	11.1954	5.3504	4.7934
2	15.8430	8.0715	7.2006
3	15.1251	5.8280	6.6307
4	16.5743	7.8128	7.7146
5	22.1535	9.0887	6.1818
6	27.7123	9.9930	5.9266
7	10.0000	4.7857	4.2968
8	28.3218	15.8197	11.6665

Fig. 1 shows the averaged parameters for maxVIF. Data from 10 successive realizations have been used for each of the eight required experiment plans. Plots corresponding to results obtained through procedures FDOP, MMC2, and MMC3 are designated by 1, 2, and 3, respectively.

maxVIF




Figure 1. Variation of the mean value of the maximal variance inflation factor.

The number of iterations depends on the initial random plan. That is why the average number of iterations can be used for comparing the speeds of convergence of the algorithms proposed. Data for experiment plan No. 1 are shown in Table 5.

Table 5.

Parameters	Algorithms	
	MMC2	MMC3
1	2	3

Average number of iterations	1520	1560
Maximal number of iterations	2475	2430
Minimal number of iterations	724	805
Average number of successful iterations	42	48

Moreover, there is no much difference between the numbers of iterations needed for generating the rest of the plans when using algorithms MMC2 or MMC3. This allows to conclude that they are characterized by practically comparable speeds of convergence.

A simulation programme has been created in the MATLAB environment for the purpose of checking the properties of experiment plans generated. This programme is characterized by the following:

For all points of the plan examined it determines multiple times the value at the output of a plant described by a model of complete third degree in the presence of a standard white noise. The real values of the coefficients are given in column 2 of Table 6. The ratio between the standard deviations of noise and the useful signal is 7 percent.

Using the method of least squares it determines the estimates of coefficients in the regression equation.

It calculates the variance of regression coefficients.

Results obtained for plan No. 8 are shown in Table 6.

It is obvious that for plans generated by using MMC2 and MMC3 the maximal value of coefficient variance has been reduced more than twice compared to that of the respective D-optimal plan.

The following conclusion can be deduced from the analysis of results obtained:

- using procedures MMC2 and MMC3 leads to obtaining plans of maximum value for the variance inflation factor being 2 to 3 times lower than that of respective D-optimal plans, which determines a considerable decrease in the variance of coefficient estimates for the regression equation;
- using criterion (7) generally leads to finding plans with lower values of maxVIF.

Table 6.

Symbolic designations and real values of coefficients		Coefficient variance when using:		
		FDOP	MMC2	MMC3
1	2	3	4	5
b0	3.0	0.2868	0.2299	0.1680
b1	-2.0	0.8462	0.4314	1.0682
b2	4.0	3.3604	0.8103	0.5105
b3	6.0	1.2387	0.6983	0.5164
b12	-4.0	0.0809	0.3071	0.1047
b13	2.5	0.1053	0.2905	0.1391
b23	-3.7	0.1293	0.1322	0.1446
b123	9.0	0.1043	0.0619	0.4879
b11	-12.0	0.2012	0.3108	0.2235
b22	-4.0	0.0724	0.2730	0.0892
b33	-3.0	0.1825	0.2694	0.4403
b111	-1.5	0.4016	0.3748	1.0697
b222	2.0	3.3216	1.3945	0.4629
b333	6.0	1.4865	0.3574	0.5643
b112	4.0	0.8494	0.4110	0.9025
b113	-3.0	0.5768	0.5376	0.9957
b221	6.5	0.7121	0.6688	0.3853
b223	4.4	0.2715	0.9387	0.3070
b331	-2.6	0.3759	1.3532	0.9951
b332	3.3	0.2184	1.0997	0.4293

At the same time it should be remembered that reducing the multicollinearity leads to lower D-effectiveness of the plans as well. Fig. 2 shows the averaged values of D_{eef} for the eight experiment plans obtained through MMC2 (plot 1) or MMC3 (plot 2).

$$D_{eef}$$

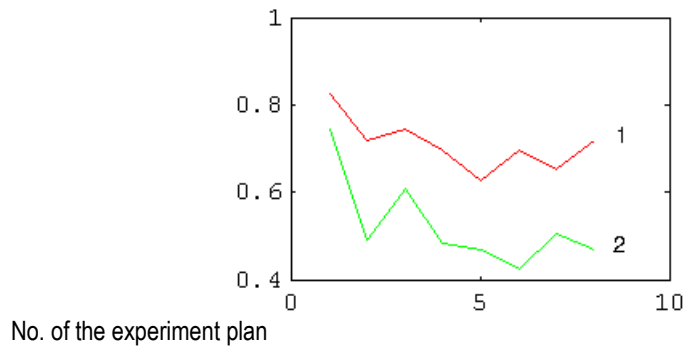


Figure 2. Variation of the mean value of D_{eeff} .

Investigating the algorithms MMC2 and MMC3 and their respective programming implementations has shown that they can be used for generating plans for cubic regression, while the experimenter will have to choose the criterion to be used depending on the requirements for proximity of the plan obtained to the D-optimal one.

REFERENCES

- Vuchkov, I. N., H. A. Iontchev et al. 1978. - *Catalogue of Consecutively Generated Plans*. Ministry of Education Publishing House, Sofia, . (In Bulgarian.)
- Vuchkov, I. N., G. K. Krug et al. 1971. - *D-Optimal Plans for Cubic Regression*. *Zavodskaya Laboratoriya*, No. 7, . (In Russian.)
- Iontchev, H. A. 1991. *Methods for Designing Optimal Compositional and Multi-Response Consecutive Experiment Plans*. Doctor of Technical Sciences Dissertation Thesis. STU, Sofia, . (In Bulgarian.)
- Mitkov, A, D. Minkov. 1993. - *Statistical Methods for Investigating and Optimizing Agricultural Equipment*. Zemizdat State Co., Sofia, . (In Bulgarian.)
- Denisov, V. I., A. A. Popov. 1976. - *A-E-Optimal and Orthogonal Plans of Regression Experiments for Polynomial Models*. Scientific Board in Cybernetics, Moscow, (In Russian.)
- Merzhanova, R. F., E. P. Nikitina. 1979. - *Catalogue of Third-Degree Plans*. Published by Moscow State University, Moscow, . (In Russian.)
- Razdorskiy, V. V., V. D. Chaliy et al. 1973. - *Obtaining Plant Model in the Form of Complete Third-Degree Polynomial*. In *Engineering and Mathematical Methods in Physics and Cybernetics*, Vol. 3, Atomizdat, Moscow, . (In Russian.)
- Belsley, D. A., E. Kuh, R. E. Welsch. 1980. *Regression Diagnostics: Identifying Influential Data and Sources of Collinearity*. N.Y., John Wiley.
- Galil Z., Kiefer, J., 1980. Time and Space-saving Computer Methods, Related to Mitchell's DETMAX, for Finding D-optimum Designs, *Technometrics*, v 22.
- Iontchev, H. A., K. Stoianov. 1998. *Catalogue of response surface designs*. University of Chemical Technology and Metallurgy, Sofia, .
- Hocking, R. R. 1983. Developments in Linear Regression Methodology, *Technometrics*, v. 25, Nr. 3.