

Ein SAS-Makro zur Erzeugung multivariat normalverteilter Zufallsgrößen

Armin Tuchscherer^{1)*}, Paul Eberhard Rudolph¹⁾, Bernd Jäger²⁾,
Margret Tuchscherer¹⁾

- 1) Forschungsinstitut für die Biologie landwirtschaftlicher Nutztiere Dummerstorf-Rostock,
Wilhelm-Stahl-Allee 2, D-18196 Dummerstorf
* *E-mail:* atuchsch@fbn-dummerstorf.de
2) Ernst-Moritz-Arndt - Universität Greifswald, Institut für Biometrie u. Medizinische
Informatik, Sauerbruchstraße, D-17489 Greifswald

1. Einleitung

Eigenschaften insbesondere multivariater statistischer Verfahren sind häufig nicht mehr analytisch, sondern nur mittels Simulationen bestimmbar. Zur Durchführung von Simulationen im Zusammenhang mit multivariaten Verfahren benötigt man geeignete Programme zur Erzeugung multivariat verteilter Zufallsgrößen. Um derartige Simulationen in SAS durchzuführen, ist es naheliegend, die entsprechenden Zufallszahlengeneratoren als SAS-Makros bereitzustellen.

Unter Verwendung von SAS/IML wird ein SAS-Makro vorgestellt, mit dem sich für eine vorgegebene Dimension, einen zugehörigen Mittelwertvektor und eine ebenfalls vorgegebene Kovarianzstruktur multivariat normalverteilte Zufallsgrößen erzeugen lassen. Schätzungen der vorgegeben Parameter aus mit diesem Makro erzeugten Stichproben für verschiedene Stichprobenumfänge und Dimensionen zeigen, wie gut multivariate Normalverteilungen mit diesem Makro nachgebildet werden können, falls die Stichprobenumfänge hinreichend groß sind.

2. Die multivariate Normalverteilung

Zunächst soll die multivariate Normalverteilung kurz beschrieben werden, gefolgt von Bemerkungen zu Eigenschaften, die für die Erzeugung entsprechender Zufallsvariablen benötigt werden. Ein p -dimensionaler Zufallsvektor $\underline{y} = (y_1, \dots, y_p)'$ heißt p -variater normalverteilt mit Erwartungswertvektor

$$E(\underline{y}) = \underline{\mu} = \begin{bmatrix} \mu_1 \\ \vdots \\ \mu_p \end{bmatrix} \quad (1)$$

und Kovarianzmatrix

$$\text{cov}(\underline{y}, \underline{y}') = \underline{\Sigma} = \begin{bmatrix} \sigma_1^2 & \sigma_{12} & \cdots & \sigma_{1p} \\ \sigma_{12} & \sigma_2^2 & & \sigma_{2p} \\ \vdots & \vdots & & \vdots \\ \sigma_{1p} & \sigma_{2p} & \cdots & \sigma_p^2 \end{bmatrix}, \quad (2)$$

wenn die Dichtefunktion $f(\underline{y})$ die Gestalt

$$f(\underline{y}) = ((2\pi)^p |\underline{\Sigma}|)^{-1/2} \cdot e^{-\frac{(\underline{y}-\underline{\mu})' \underline{\Sigma}^{-1} (\underline{y}-\underline{\mu})}{2}} \quad (3)$$

hat. Die Kurzbezeichnung

$$\underline{y} = (y_1, \dots, y_p)' \sim N_p(\underline{\mu}, \underline{\Sigma}) \quad (4)$$

für die p-variate Normalverteilung einer Zufallsvariablen \underline{y} ist allgemein gebräuchlich. Für $p = 2$ kann man die Dichtefunktion (3) z.B. sehr schön mit der SAS-Prozedur g3d grafisch darstellen (Abb. 1).




Abbildung 1: Dichtefunktion $f(y_1, y_2)$ der bivariaten Normalverteilung $N(\underline{\mu}, \underline{\Sigma})$ mit

$$\underline{\mu} = \begin{bmatrix} 10 \\ 1 \end{bmatrix} \text{ und } \underline{\Sigma} = \begin{bmatrix} 9 & 1 \\ 1 & 2 \end{bmatrix}$$

2.1 Lineare Transformation multivariat normalverteilter Zufallsvariablen

Betrachten wir eine m-variate normalverteilte Zufallsvariable $\underline{z} \sim N_m(\underline{\mu}_z, \underline{\Sigma}_z)$ und eine lineare Transformation der Variablen der Form

$$\underline{y} = \underline{L} \cdot \underline{z} + \underline{\mu}, \quad (5)$$

wobei \underline{L} eine $(p \times m)$ -Matrix mit $p \leq m$ ist und $\underline{\mu}$ ein p-dimensional reeller Vektor, dann ist \underline{y} p-variat normalverteilt mit Erwartungswertvektor $E(\underline{y}) = \underline{L} \cdot E(\underline{z}) + \underline{\mu}$ und der Kovarianzmatrix $\text{cov}(\underline{y}, \underline{y}') = \underline{L} \cdot \text{cov}(\underline{z}, \underline{z}') \cdot \underline{L}'$, d.h. $\underline{\Sigma} = \underline{L} \underline{\Sigma}_z \underline{L}'$.

Wählt man $\underline{z} \sim N_m(\underline{0}, \underline{I}_m)$, d.h. die Komponenten von \underline{z} sind unabhängig (0,1)-normalverteilt, so gilt für die lineare Transformation (5):

$$\underline{y} \sim N_p(\underline{\mu}, \underline{L} \underline{L}'),$$

d.h. \underline{y} ist p-variat normalverteilt mit Erwartungswert $E(\underline{y}) = \underline{L} \cdot E(\underline{z}) + \underline{\mu} = \underline{L} \cdot \underline{0} + \underline{\mu} = \underline{\mu}$ und der Kovarianzmatrix $\text{cov}(\underline{y}, \underline{y}') = \underline{L} \cdot \text{cov}(\underline{z}, \underline{z}') \cdot \underline{L}' = \underline{L} \cdot \underline{I}_m \cdot \underline{L}' = \underline{L} \underline{L}'$. Mit $\underline{L} \underline{L}' = \underline{\Sigma}$ läßt sich somit jede p-variat normalverteilte Zufallsvariable $\underline{y} = (y_1, \dots, y_p)' \sim N_p(\underline{\mu}, \underline{\Sigma})$ als lineare Transformation von p unabhängig (0,1)-normalverteilten Zufallsvariablen darstellen. Es ist somit nur noch erforderlich, eine Matrix \underline{L} zu bestimmen, die der Bedingung $\underline{L} \underline{L}' = \underline{\Sigma}$ genügt.

2.2 Zerlegung der Kovarianzmatrix Σ

Die symmetrische und positiv definite Matrix Σ ist in der Form

$$\Sigma = LL' \tag{6}$$


darzustellen. Eine mögliche Wahl der Matrix L ist die $(p \times p)$ -Dreiecksmatrix $L = A$

$$A = \begin{bmatrix} a_{11} & 0 & \cdots & 0 \\ a_{21} & a_{22} & \cdots & 0 \\ \vdots & \vdots & & \vdots \\ a_{p1} & a_{p2} & \cdots & a_{pp} \end{bmatrix}, \tag{7}$$

die man mit Hilfe der folgenden rekursiven Gleichungen (Choleski-Zerlegung; JOHNSON, 1987) bestimmen kann:

$$\left. \begin{aligned} a_{i1} &= \sigma_{i1} / \sigma_1^{1/2} && ; \quad 1 \leq i \leq p \\ a_{ij} &= \left(\sigma_{ij} - \sum_{k=1}^{j-1} a_{ik} a_{jk} \right) / a_{jj} && ; \quad 1 < j < i \leq p \\ a_{ii} &= \left(\sigma_i - \sum_{k=1}^{i-1} a_{ik}^2 \right)^{1/2} && ; \quad 2 \leq j = i \leq p \end{aligned} \right\} \tag{8}$$

Dabei wird folgendes Schema abgearbeitet:



2.3 Algorithmus zur Erzeugung p-variater normalverteilter Zufallsvariablen

- (i) Einlesen des Erwartungswertvektors μ und der Kovarianzmatrix Σ
- (ii) Berechnung von A aus Σ nach (8), so daß $AA' = \Sigma$
- (iii) Erzeugung von $z = (z_1, \dots, z_p)'$ nach $z \sim N_p(0, I)$ unter Verwendung einer Prozedur zur Erzeugung unabhängiger standardnormalverteilter Zufallsvariablen
- (iv) Berechnung von $y = A \cdot z + \mu$

3. Umsetzung des Algorithmus zur Erzeugung p-variater normalverteilter Zufallsvariabler als SAS-Makro

3.1 SAS-Makro zur Erzeugung p-variater normalverteilter Zufallsvariabler

Der oben beschriebene Algorithmus soll durch ein SAS-Makro unter Verwendung der SAS-Prozedur `iml` umgesetzt werden, wobei vorausgesetzt wird, daß der Mittelwertvektor und die Kovarianzmatrix jeweils als (permanente bzw. temporäre) SAS-Datei vorliegen.

Ein Beispiel für den Fall temporärer SAS-Dateien und $p = 4$ enthält die folgende Tabelle.

Temporäre SAS-Datei für Mittelwertvektor	temporäre SAS-Datei für Kovarianzmatrix
<pre>Data WORK.MITTEL; input mue; cards; 10 1 5 8 run;</pre>	<pre>data WORK.KOVAR; input co1-co4; cards; 9 1 0.5 -1 1 2 0.5 2 0.5 0.5 3 1 -1 2 1 7 run;</pre>

Die im folgenden Schema jeweils grau hinterlegten Programmzeilen des Makros repräsentieren die Schritte des oben beschriebenen Algorithmus (Nummer in der linken Spalte von Tab. 1).

Tabelle 1: SAS-Makro zur Erzeugung p-variater normalverteilter Zufallsvariabler mit Kommentaren (rechte Spalte)

SAS-Makro: %MACRO PNORMAL(M, MEANS, COVAR, DATA, NAMES)		
	<pre>%MACRO PNORMAL(M, MEANS, COVAR, DATA, NAMES); proc iml; use &MEANS; read all into MUE; use &COVAR; read all into COV; p=ncol(COV); de=det(COV); ERROR='Die Kovarianzmatrix ist nicht positiv semidefinit! Determinante: '; if de<0 then print ERROR de; A=j(p,p,0); do i=1 to p; do j=1 to i; if j=1 then do; A[i,1]=cov[i,1]/sqrt(cov[1,1]); end; if j<i then do; sum=0; do k=1 to j-1; sum=sum+A[i,k]*A[j,k]; end; A[i,j]=(COV[i,j]-sum)/A[j,j] ; end; if i=j then do; sm=0; do kk=1 to i-1; </pre>	1
(i)	<pre>use &MEANS; read all into MUE; use &COVAR; read all into COV;</pre>	
(ii)	<pre>A=j(p,p,0); do i=1 to p; do j=1 to i; if j=1 then do; A[i,1]=cov[i,1]/sqrt(cov[1,1]); end; if j<i then do; sum=0; do k=1 to j-1; sum=sum+A[i,k]*A[j,k]; end; A[i,j]=(COV[i,j]-sum)/A[j,j] ; end; if i=j then do; sm=0; do kk=1 to i-1;</pre>	

SAS-Makro: %MACRO PNORMAL(M, MEANS, COVAR, DATA, NAMES)		
	<pre> sm=sm+A[i,kk]*A[i,kk]; end; A[i,i]=sqrt(COV[i,i]-sm) ; end; end; end; </pre>	
	<pre> Test=A*A`; print 'Testdruck für die Zerlegung der Kovarianzmatrix: TEST=A*A`' ; print A; print COV ' ' TEST; DAT=j(&m,p,0); MUE_EST=j(p,1,0); COV_EST=J(p,p,0); do i=1 to &M; </pre>	②
(iii)	<pre> Z=j(p,1,0); Z=NORMAL(Z); </pre>	③
(iv)	<pre> Y=A*Z+mue; MUE_EST=MUE_EST+Y; do j=1 to p; DAT[i,j]=Y[j]; end; end; MUE_EST=MUE_EST/&m; print ' '; print 'Vergleich Parameter - Schätzung bei Stichprobenumfang:' &M; Mattrib MUE_EST format=10.2; print 'Parameter' ' Schätzung' ; print '-----'; print MUE ' ' MUE_EST ; do i=1 to &M; do k=1 to p; do j=1 to p; COV_EST[k,j]=COV_EST[k,j]+(DAT[i,k]-MUE_EST[k])*(DAT[i,j]- MUE_EST[j]); end; end; end; COV_EST=COV_EST/(&m-1); Mattrib COV_EST format=10.2; print ' ' COV ' ' COV_EST ; c=&NAMES ; create &Data from DAT [colname=c]; append from DAT; quit; %mend MNORMAL; </pre>	④
		⑤

❶ Parameter des Makros PNORMAL(M, MEANS, COVAR, DATA, NAMES)

INPUT:

M	Anzahl der zu erzeugenden Datensätze, z.B.:	10
MEANS	SAS-Datei die den Mittelwertvektor enthält, z.B.:	WORK.Mittel oder SASUSER.Mittel
COVAR	SAS-Datei die die Kovarianzmatrix enthält, z.B.:	WORK.KOVAR oder SASUSER.KOVAR

OUTPUT:

DATA	SAS-Datei in die die erzeugten Datensätze geschrieben werden, z.B.:	WORK.Daten oder SASUSER.Daten
NAMES	Variablenamen in WORK.Daten bzw. SASUSER.Daten, z.B.:	{ 'Y1' 'Y2' 'Y3' 'Y4' } oder 'Y1' : 'Y4'

Das Makro könnte zum Beispiel wie folgt aufgerufen werden:

```
%PNORMAL(10, Mittel, KOVAR, Daten, {'Y1' 'Y2' 'Y3' 'Y4'});
```

 (9)

Mit diesem Aufruf werden M=10 Datensätze mit 4-dimensional normalverteilten Variablen Y1,...,Y4 auf der Basis der temporären SAS-Dateien 'Mittel' (Mittelwertvektor) und 'KOVAR' (Kovarianzmatrix) erzeugt, die in der temporären SAS-Datei 'Daten' abgelegt werden (siehe ❸).

❷ Kontrollausdruck für die Zerlegung der Kovarianzmatrix Σ (im Beispiel: COV) in AA' mit der Dreiecksmatrix (7). COV und TEST müssen identisch sein. Mit dem Makroaufruf (9) erhält man folgenden Testdruck:

Testdruck für die Zerlegung der Kovarianzmatrix: TEST=A*A'							
				A			
				3	0	0	0
				0.3333333	1.3743685	0	0
				0.1666667	0.3233808	1.6934128	0
				-0.3333333	1.536059	0.3299984	2.1025016
		COV				TEST	
9	1	0.5	-1	9	1	0.5	-1
1	2	0.5	2	1	2	0.5	2
0.5	0.5	3	1	0.5	0.5	3	1
-1	2	1	7	-1	2	1	7

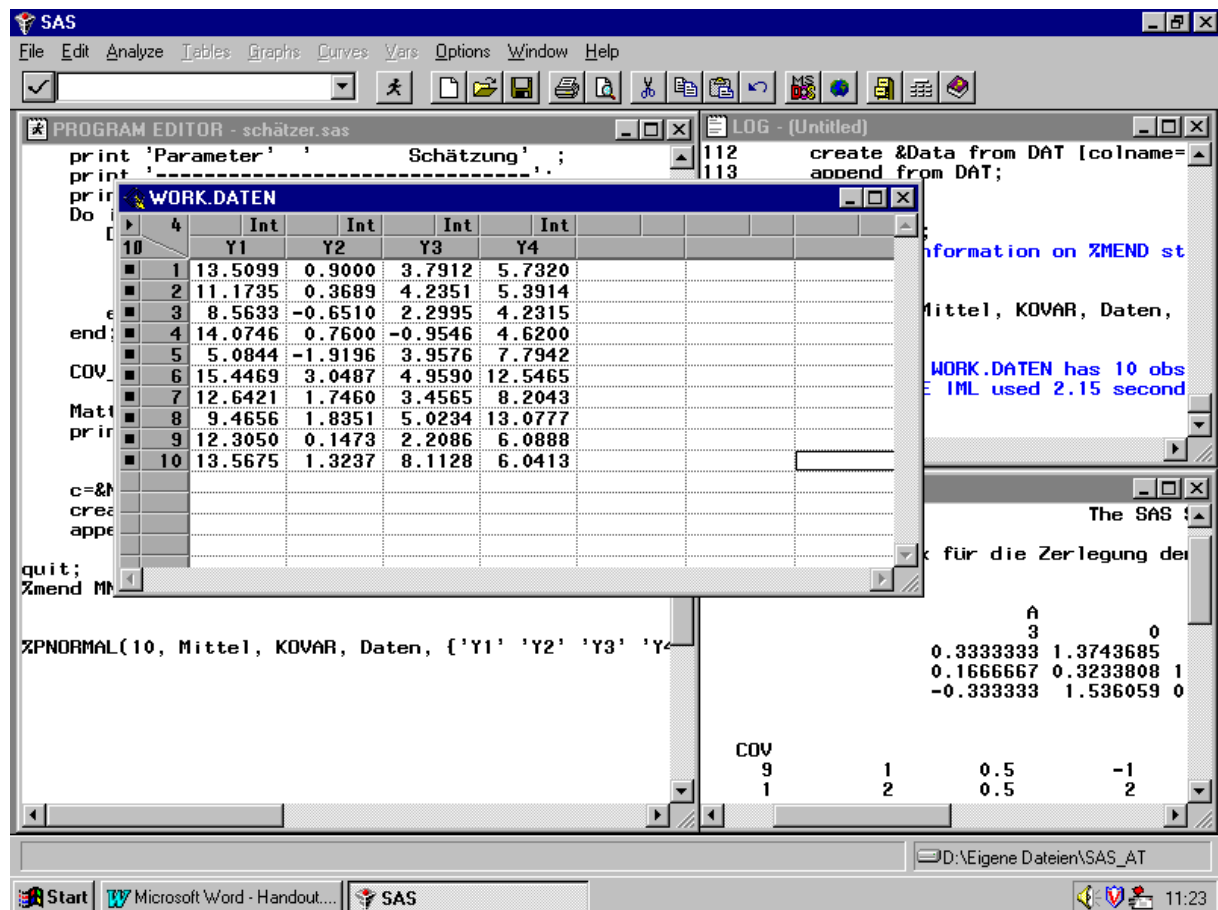
❸ Durch Nullsetzung des p-dimensionalen Vektors \mathbf{z} wird mit dem Aufruf NORMAL(\mathbf{z}) die IML-Funktion NORMAL(.) mit zufälligen SEED-Werten (Systemzeit) gestartet und ein p-dimensionaler Vektor mit unabhängig (0,1)-normalverteilten Komponenten erzeugt.

❹ Druck der Parameter (Mittelwertvektor 'MUE', und Kovarianzmatrix 'COV') und ihrer Schätzungen 'MUE_EST' bzw. 'COV_EST' aus den M erzeugten Datensätzen (hier z.B. M = 10).

Vergleich Parameter - Schätzung bei Stichprobenumfang: 10

Parameter				Schätzung			
-----				-----			
		MUE		MUE_EST			
		10		11.58			
		1		0.76			
		5		3.71			
		8		7.37			
COV				COV_EST			
9	1	0.5	-1	9.60	3.38	0.04	0.31
1	2	0.5	2	3.38	1.93	0.95	2.52
0.5	0.5	3	1	0.04	0.95	5.45	2.89
-1	2	1	7	0.31	2.52	2.89	9.74

Die erzeugten Datensätze werden von der Matrix DAT in die SAS-Datei WORK.DATEN geschrieben, die z.B. bei Makroaufruf (9) folgende Gestalt haben könnte.



Das Laufzeitverhalten des Makros `PNORMAL(M, MEANS, COVAR, DATA, NAMES)` wurde für unterschiedliche Dimensionen und Anzahlen der zu erzeugenden multivariat normalverteilten Zufallsvektoren geprüft. Die Ergebnisse sind in Tabelle 2 zusammengefaßt.

Tabelle 2: Mittlere Rechenzeit des Makros PNORMAL (M, MEANS, COVAR, DATA, NAMES)

Dimension der Zufallsvektoren P	Anzahl der Datensätze M	Rechenzeit [sec]	
		PC 128 MHz 46 MB RAM	PC 300 MHz 64 MB RAM
4	1	0.21	0.14
	10	0.23	0.15
	100	0.26	0.19
	1000	0.42	0.25
	10000	2.21	1.09
2	1	0.20	0.14
	10	0.23	0.14
	100	0.25	0.15
	1000	0.38	0.21
	10000	1.50	0.78

Die Tabelle 2 verdeutlicht, daß selbst Simulationsumfänge von 10.000 Datensätzen im Sekundenbereich mit Standard-PC zu bewältigen sind. Bei kleinen Umfängen kann man erkennen, daß ein wesentlicher Teil der Rechenzeit für das Einlesen und Ausgeben der Daten benötigt wird. Für intensive Simulationsuntersuchungen ist daher zu empfehlen, möglichst viele Operation in IML auszuführen, um die Anzahl der zeitaufwendigen Einlese-, Ausgabeoperationen und Datasteps so gering wie möglich zu halten.

Mit Hilfe des folgenden Beispiels soll nun der Einfluß des Simulationsumfanges auf die Genauigkeit der Schätzung des Mittelwertvektors und der Kovarianzmatrix demonstriert werden, ohne auf Genauigkeitsabschätzung oder eventuelle Versuchsplanung einzugehen.

Zu diesem Zweck wählen wir Umfänge von 10, 100, 1000, 10000 und rufen das Makro mit den entsprechenden Parametern auf:

```
%PNORMAL( 10, Mittel, KOVAR, Daten1, {'Y1' 'Y2' 'Y3' 'Y4'});
%PNORMAL( 100, Mittel, KOVAR, Daten2, {'Y1' 'Y2' 'Y3' 'Y4'});
%PNORMAL( 1000, Mittel, KOVAR, Daten3, {'Y1' 'Y2' 'Y3' 'Y4'});
%PNORMAL(10000, Mittel, KOVAR, Daten3, {'Y1' 'Y2' 'Y3' 'Y4'});
```

Bei kleinen Umfängen muß man mit recht ungenauen Schätzungen für den Mittelwertvektor MUE und besonders für die Kovarianzmatrix COV rechnen, wie im folgenden SAS-OUTPUT zu sehen ist. Wie erwartet, erhält man für hinreichend große Stichprobenumfänge auch sehr gut geschätzte Mittelwerte und Kovarianzmatrizen.

SAS-OUTPUT (Parameter und Schätzungen bei unterschiedlichen Umfängen):

Vergleich Parameter - Schätzung bei Stichprobenumfang:				10				
Parameter				Schätzung				
-----				-----				
MUE				MUE_EST				
10				10.44				
1				1.21				
5				4.88				
8				8.48				
COV				COV_EST				
9	1	0.5	-1	4.97	-1.00	0.22	-4.12	
1	2	0.5	2	-1.00	1.33	0.02	2.37	
0.5	0.5	3	1	0.22	0.02	0.73	-0.48	
-1	2	1	7	-4.12	2.37	-0.48	8.16	
Vergleich Parameter - Schätzung bei Stichprobenumfang:				100				
Parameter				Schätzung				
-----				-----				
MUE				MUE_EST				
10				9.76				
1				1.23				
5				5.01				
8				8.21				
COV				COV_EST				
9	1	0.5	-1	7.65	0.55	-0.82	-1.46	
1	2	0.5	2	0.55	1.84	0.41	2.03	
0.5	0.5	3	1	-0.82	0.41	2.91	1.35	
-1	2	1	7	-1.46	2.03	1.35	6.31	
Vergleich Parameter - Schätzung bei Stichprobenumfang:				1000				
Parameter				Schätzung				
-----				-----				
MUE				MUE_EST				
10				9.82				
1				1.10				
5				5.06				
8				8.15				
COV				COV_EST				
9	1	0.5	-1	9.52	1.11	0.41	-1.04	
1	2	0.5	2	1.11	1.86	0.50	1.84	
0.5	0.5	3	1	0.41	0.50	2.88	0.97	
-1	2	1	7	-1.04	1.84	0.97	6.66	
Vergleich Parameter - Schätzung bei Stichprobenumfang:				10000				
Parameter				Schätzung				
-----				-----				
MUE				MUE_EST				
10				9.94				
1				0.99				
5				5.02				
8				8.00				
COV				COV_EST				
9	1	0.5	-1	8.95	0.98	0.44	-0.94	
1	2	0.5	2	0.98	1.96	0.51	2.01	
0.5	0.5	3	1	0.44	0.51	3.00	1.02	
-1	2	1	7	-0.94	2.01	1.02	6.98	

3.2 SAS-Makro zur Erzeugung multivariat normalverteilter Zufallsgrößen in Klassen

Wie bereits im vorherigen Abschnitt beschrieben, ist es ratsam, bei umfangreichen Simulationen so viele Operationen wie möglich in IML auszuführen, um die Zahl der zeitaufwendigen Einlese-, Ausgabeoperationen und Datasteps auf ein Minimum zu reduzieren.

Zur Beurteilung multivariater Verfahren wie z.B. der Diskriminanzanalyse werden multivariat normalverteilte Zufallsvariable in Klassen benötigt, die möglicherweise durch unterschiedliche Mittelwertvektoren und eventuell auch durch unterschiedliche Kovarianzmatrizen charakterisiert sind.

Aus diesem Grund wurde das Makro

$$\text{PNORMAL}(M, \text{MEANS}, \text{COVAR}, \text{DATA}, \text{NAMES}) \quad (10)$$

derart modifiziert, daß mit dem resultierenden Makro

$$\text{PNORMALK}(M, \text{MEANS}, \text{COVAR}, \text{DATA}, \text{NAMES}) \quad (11)$$

p-variater normalverteilter Zufallsvariablen in Klassen erzeugt werden können.

Da (11) für die Zufallsvariablenenerzeugung zur Beurteilung von Diskriminanzanalyseverfahren gedacht ist, wurde hier auf die Schätzung der Mittelwertvektoren und der Kovarianzmatrizen in den Klassen innerhalb des Makros verzichtet, da diese mit Hilfe der SAS-Prozedur DISCRIM ohnehin optional bestimmt werden können.

Ein weiterer Unterschied von (11) im Vergleich zu (10) besteht in der Struktur der Eingabegrößen MEANS und COVAR.

In der SAS-Datei MEANS werden bei (11) die Mittelwertvektoren der Klassen als Zeilenvektoren erwartet, wobei das erste Element einer Zeile immer der Umfang der entsprechenden Klasse ist. Durch die Anzahl der Zeilen von MEANS wird automatisch die Dimension p bestimmt. In der SAS-Datei COVAR stehen die Kovarianzmatrizen der einzelnen Klassen untereinander.

Die SAS-Datei DATA, als Ergebnis des Makros (11), enthält als erste Variable die Nummer der Simulationswiederholung ($1, \dots, M$), gefolgt von der Klassennummer als zweite Variable und den p Komponenten der erzeugten Zufallsvektoren als dritte bis $(p+2)$ -te Variable.

Das vollständige Makro mit Kommentaren, Aufruf-, Testbeispiel und Ergebnisdatei ist als Anlage angefügt.

Literatur

Geißler, H.; Ortseifen, C.: SAS-Makroprogrammierung: Eine Einführung. Universitätsrechenzentrum Heidelberg 1995, 54 S.

Johnson, M. E.: Multivariate Statistical Simulation. J. Wiley, New York 1987.

Johnson, N. L.; Kotz, S.: Distributions in Statistics: Continuous Multivariate Distributions. J. Wiley, New York 1972.

Kleijnen; J.; van Groenendaal, W.: Simulation: A Statistical Perspective. J. Wiley, Chichester 1992, 241 pp.

SAS Institute Inc., SAS/IML Software: Usage and Reference, Version 6, First Edition Cary, NC: SAS Institute Inc., 1989, 501 pp.

SAS Institute Inc., SAS Language: Reference, Version 6, First Edition Cary, NC: SAS Institute Inc., 1990, 1042 pp.

Anlage**A1 SAS-Makro zur Erzeugung multivariat normalverteilter Zufallsgrößen in Klassen**

```

/*-----*
| %PNORMALK(M, MEANS, COVAR, Data, names)
| =====
|
| erzeugt p-dimensional normalverteilte Merkmalsvektoren Y=(y1,...,yp)
| in NK Klassen vom Umfang k(i) mit
|
| Erwartungswertvektor mue_i=(mue_1(1), ..., mue_1(p))' und
|
| Kovarianzmatrix COV_i=
|
|           /           \
|           | COV_i(1,1) ... COV_i(1,p) |
|           | ... |
|           | COV_i(p,1) ... COV_i(p,p) |
|           \           /
|
| in der Klasse i , (i=1,...,NK).
|-----*
| INPUT:
| =====
|
| M          Anzahl der Simulationswiederholungen in jeder Klasse i
|           (i=1,...,NK)
|
| MEANS      SAS-Datei der Form
|
|           k(1)  mue_1(1)  ... mue_1(p)
|           .      .          .
|           .      .          .
|           k(NK) mue_NK(1) ... mue_NK(p)
|
| COVAR      SAS-Datei in der Form
|
|           COV_1(1,1) ... COV_1(1,p)
|           .          .
|           .          .
|           COV_1(p,1) ... COV_1(p,p)
|           .
|           .
|           COV_NK(1,1) ... COV_NK(1,p)
|           .          .
|           .          .
|           COV_NK(p,1) ... COV_NK(p,p)
|
| OUTPUT:
| =====
|
| DATA      SAS-Datei, mit der Datensatzstruktur:
|           Simulations-Nr. Klassen-Nr. y1 y2 ... yp
|
| NAMES      Namen der Variablen der Datei 'DATA'
|           z.B. bei p=4 in der Form:
|           {'Nsim' 'CLASS_NR' 'Y1' 'Y2' 'Y3' 'Y4'}
|-----*

```

```

%macro PNORMALK(M, MEANS, COVAR, DATA, NAMES);

proc iml;
  use &MEANS; read all into MEANS;
  use &COVAR;  read all into COVAR;
  p=ncol(means)-1;
  nk=nrow(means);

  mue=j(p,1,0);
  cov=j(p,p,0);

  NKi=0;
  do i=1 to NK;
    NKi=NKi+means[i,1];
  end;

  DAT=j(&m*NKi, p+2,0);

  L=0;

  do KNR=1 to nk;

    do i=1 to p;
      mue[i]=means[KNR,i+1];
      kk=(KNR-1)*p+i;
      do j=1 to p;
        cov[i,j]=COVAR[kk,j];
      end;
    end;

    de=det(COV);
    ERROR='Die Kovarianzmatrix ist nicht positiv semidefinit in Klasse: ';
    if de<0 then print ERROR KNR;

    A=j(p,p,0);
    do i=1 to p;
      do j=1 to i;
        if j=1 then do; A[i,1]=cov[i,1]/sqrt(cov[1,1]); end;
        if j<i then do;
          sum=0;
          do k=1 to j-1;
            sum=sum+A[i,k]*A[j,k];
          end;
          A[i,j]=(COV[i,j]-sum)/A[j,j] ;
        end;
        if i=j then do;
          sm=0;
          do kk=1 to i-1;
            sm=sm+A[i,kk]*A[i,kk];
          end;
          A[i,i]=sqrt(COV[i,i]-sm) ;
        end;
      end;
    end;
  end;
end;

```

```

do k=1 to &M;
  do i=1 to means[KNR,1] ;
    Z=j(p,1,0);
    Z=NORMAL(Z);
    Y=A*Z+mue;
    L=L+1;
    DAT[L,2]=KNR;
    DAT[L,1]=k;
    do j=1 to p;
      DAT[L,j+2]=Y[j];
    end;
  end;
end;

end;

c=&names;
create &Data from DAT [colname=c];
append from DAT;

quit;

%mend PNORMALK;

```

A2 Testbeispiel

```

/*=====
| Testbeispiel: |
| ===== |
| 1. Erzeugen der temporären SAS-Dateien 'Mittel' und 'KOVAR' (Voraussetzung) |
| 2. Aufruf des Makros 'PNORMALK': |
| %PNORMALK(10, Mittel, KOVAR, Daten, {'Nsim' 'Klasse' 'X1' 'X2' 'X3' 'X4'}); |
| 3. Ergebnis: temporäre SAS-Datei 'Daten' mit den Variablen: |
| | Nsim Klasse X1 X2 X3 X4 |
*=====*/

```

```

/*-----*
| Erzeugen der Datei 'Mittel' (Klassenumfänge, Mittelwertvektoren) |
*-----*/

```

```

data Mittel;
input Ki MUE1-MUE4;
cards;
  5 1 3 6 0.5
  4 3 3 5 1
  3 2 4 2 6
run;

```

```

/*-----*
| Erzeugen der Datei 'KOVAR' (Kovarianzmatrizen) |
*-----*/

```

```

data KOVAR;
input co1-co4;

```

```

cards;
  9  1  0.5 -1
  1  2  0.5  2
  0.5 0.5 3  1
 -1  2  1  7
  8  1  0.5 -1
  1  4  0.5  2
  0.5 0.5 6  1
 -1  2  1  5
  4  1  0.5 -1
  1  9  0.5  2
  0.5 0.5 8  1
 -1  2  1  9

run;

/*-----*
| Aufruf des Makros PNORMALK |
*-----*/
%PNORMALK(10, Mittel, KOVAR, Daten, {'Nsim' 'Klasse' 'X1' 'X2' 'X3' 'X4'});A3
Ergebnis
    
```

A3 Ergebnis

The screenshot shows the SAS interface with the following components:

- PROGRAM EDITOR - testclass.sas:** Contains the macro call `%PNORMALK(10, Mittel, KOVAR, Daten, {'Nsim' 'Klasse' 'X1' 'X2' 'X3' 'X4'});` and a comment: `erzeugt p-dimensional normalverteilte Merkmalsvektoren in NK Klassen vom Umfang k(i) mit Erwartungswertvektor mue_i=(mue_1(1), ...)`.
- LOG - (Untitled):** Shows the execution of the macro call and the message: `IML Ready...`.
- WORK.DATEN:** A data table window displaying the following data:

Obs	NSIM	KLASSE	X1	X2	X3	X4
1	1	1	1.7358	4.5504	5.3255	4.9648
2	1	1	5.3521	3.2871	6.3902	0.7274
3	1	1	3.6063	4.0461	7.6753	-0.4296
4	1	1	-0.4551	5.8412	8.3176	2.4971
5	1	1	-1.3575	3.8912	6.2080	3.7942
6	2	1	1.9230	3.4113	5.9884	2.1780
7	2	1	2.9796	4.3913	6.1642	4.7769
8	2	1	4.0302	4.3368	5.4279	0.7633
9	2	1	-0.6640	3.9019	3.8520	1.2414
10	2	1	1.4044	4.1225	5.5586	-1.3446
11	3	1	1.5425	5.3412	7.0048	2.7819
12	3	1	6.2031	2.7762	6.3927	-1.5686
13	3	1	2.0288	2.0370	5.8275	-1.4107
14	3	1	-2.1130	2.2547	8.8305	4.9138
15	2	1	6.9189	2.1269	5.9886	6.5924

Additional information from the log window: `DATEN has 120 observations used 0.17 second`