

MATHEMATISCH CENTRUM

2e BOERHAAVESTRAAT 49

AMSTERDAM

STATISTISCHE AFDELING

Leiding: Prof. Dr D. van Dantzig

Chef van de Statistische Consultatie: Prof. Dr J. Hemelrijk

Rapport S 210

Enige statistische aspecten van de factoranalyse

door

G. de Leve

September 1956

1. Inleiding

In dit korte overzicht zullen wij enkele statistische aspecten van de factor analyse bespreken. Alvorens wij deze technieken afzonderlijk behandelen, willen wij eerst enige aandacht besteden aan een probleem, waarbij de factor analyse veelvuldig wordt toegepast. De toepasbaarheid van de factoranalyse blijft echter geenszins tot dit voorbeeld of zelfs tot het gebied, waaraan dit ontleend is, beperkt.

Stel dat wij gelijktijdig aan N personen een serie van n verschillende psychologische tests afnemen. Met behulp van deze testresultaten kunnen de correlaties tussen de verschillende tests berekend worden. Wanneer nu blijkt, dat deze testvariabelen hoog gecorreleerd zijn, dan rijst direct de vraag of er misschien factoren zijn (b.v. karaktereigenschappen), die meer dan één test beïnvloeden. Men zou dan de reactie van de persoon op een test kunnen beschouwen als een functie van een aantal wellicht psychologisch interpreteerbare factoren, waarvan er één of meer bij meer dan één test een rol spelen. In formule:

$$z_j = z_j(x_1, \dots, x_p) \quad (j = 1, \dots, n) \quad (1)$$

waarbij p het aantal factoren aangeeft,

z_j de functie is behorende bij de j^{de} test en
 x_i de i^{de} factorvariabele voorstelt.

Als vervolgens z_{jk} de score is, welke de k^{de} persoon in de j^{de} test behaalt en x_{ik} de waarde van de i^{de} factor bij de k^{de} persoon, dan geldt voor de scores z_{jk} :

$$z_{jk} = z_j(x_{1k}, \dots, x_{pk}) \quad (j = 1, \dots, n; k = 1, \dots, N). \quad (2)$$

De vragen, waarop men een antwoord tracht te vinden, kunnen als volgt worden samengevat:

1e. Hoeveel factoren x_i spelen bij meer dan één test een rol,

2e. hoe is de gedaante van de functie

$$z_j = z_j(x_1, \dots, x_p) \quad (j = 1, \dots, n),$$

3e. Welke waarden nemen de variabelen x_i aan voor de k^{de} persoon ($i = 1, \dots, m; k = 1, \dots, N$).

De technieken, die wij later zullen bespreken, gaan uit van de veronderstelling, dat de functies z_j lineair zijn, m.a.w. dat voor (1) geschreven kan worden:

$$Z_j = a_{j1} X_1 + \dots + a_{jp} X_p \quad (j=1, \dots, n), \quad (3)$$

waarbij er onder de constanten a_{ji} ook mogen voorkomen, die gelijk zijn aan nul.

De betrekking (2) gaat dan over in:

$$Z_{jk} = a_{j1} X_{1k} + \dots + a_{jp} X_{pk} \quad (j=1, \dots, n; k=1, \dots, N). \quad (4)$$

De factoren, die bij meer dan één test een rol spelen, zullen wij in het vervolg aangeven met de letter F en gemeenschappelijke factoren noemen. Voor het geval er m gemeenschappelijke factoren zijn, gaat de betrekking (4) over in:

$$Z_{jk} = a_{j1} F_{1k} + a_{j2} F_{2k} + \dots + a_{jm} F_{mk} + a_j S_{jk} \quad (5)$$

waarbij $a_j S_{jk}$ dat deel van de score aangeeft, dat niet "verklaard" kan worden door de bijdragen van de gemeenschappelijke factoren. De variabelen S_j worden in het vervolg specifieke factoren genoemd.

Indien er geen specifieke factoren worden ondersteld, gaat (5) over in:

$$Z_{jk} = a_{j1} F_{1k} + a_{j2} F_{2k} + \dots + a_{jm} F_{mk} \quad \left(\begin{matrix} j=1, \dots, n \\ k=1, \dots, N \end{matrix} \right). \quad (6)$$

Het getal Z_{jk} in betrekking (5) en (6) stelt eigenlijk niet de gevonden testscore van de j^{de} test bij de k^{de} persoon voor, maar de mathematische verwachting daarvan. De gevonden testscore zal hier ongetwijfeld van verschillen, daar er altijd bijkomstige omstandigheden zijn, die het resultaat van de test beïnvloeden.

Aangezien het model aangegeven in (5) en (6) berust op de veronderstelling, dat de waarden F_{ik} en S_{jk} constant zijn, zal men bij verwerking van de gevonden testcores in het model extra termen moeten toevoegen om de stochastische afwijkingen van de verwachting te kunnen verklaren.

Voor de gevonden testcores gelden dan in plaats van (5) en (6) de volgende betrekkingen:

$$Z_{jk} = a_{j1} F_{1k} + a_{j2} F_{2k} + \dots + a_{jm} F_{mk} + a_j S_{jk} + e_{jk} \quad (7)$$

$$(j=1, \dots, n; k=1, \dots, N)$$

en

$$Z_{jk} = a_{j1} F_{1k} + \dots + a_{jm} F_{mk} + e_{jk} \quad (8)$$

$(j = 1, \dots, n; k = 1, \dots, N).$

Daar het echter bij de te bespreken technieken, waarbij de aanwezigheid van specifieke factoren wordt verondersteld, niet mogelijk is een onderscheid te maken tussen deze factoren en de storingstermen, zal men toch uitgaan van het model aangegeven in (5), waarbij dan de waarden S_{jk} niet meer constant behoeven te zijn.

De technieken, die worden toegepast op het model aangegeven in (8) vormen de Componenten Analyse.

De technieken, die uitgaan van het model aangegeven in (5) behoren tot de Zuivere Factor Analyse.

De componenten analyse en de zuivere factor analyse vormen tezamen de factor analyse. De verschillende interpretatie van de laatste termen (resp. e_{jk} en $a_j S_{jk}$) als stochastische afwijkingen specifieke factoren (de laatste desgewenst als som van specifieke factoren en stochastische afwijkingen) leidt tot verschil in de mogelijkheden van analyse. In het eerste geval kan men trachten door het verrichten van duplo-bepalingen (indien deze mogelijk zijn) iets over de verdeling der stochastische afwijkingen te weten te komen en op grond hiervan het aantal factoren m te toetsen. In het laatste geval hebben duplo-bepalingen weinig zin, daar de specifieke factoren bij beide bepalingen dezelfde waarden aannemen en de variantie der duplo-bepalingen slechts op de, feitelijk in de specifieke factoren opgenomen, stochastische afwijkingen betrekking heeft. Voor de bepaling van het aantal gemeenschappelijke factoren moet men dan andere criteria gebruiken. Men kan het verschil ook als volgt karakteriseren. Afgezien van de stochastische afwijkingen e_{jk} zijn de Z_{jk} van (8) algebraïsch lineair afhankelijk (de lineaire betrekkingen worden verkregen door eliminatie van de factoren F_i en zij gelden dan voor iedere k), terwijl dit voor (5) niet geldt.

Aan de variabelen F_i en S_j in (5) en (8) worden de volgende beperkingen, - die de algemeenheid niet schaden - opgelegd:

$$\begin{aligned} \sum_{k=1}^N F_{ik} &= 0, & \sum_{k=1}^N S_{jk} &= 0, \\ \frac{1}{N} \sum_{k=1}^N F_{ik}^2 &= 1, & \frac{1}{N} \sum_{k=1}^N S_{jk}^2 &= 1. \end{aligned} \quad (9)$$

Men kan gemakkelijk inzien, dat de gegevens verschaft door de testcores onvoldoende zijn om de waarden a_{ji} , a_j , F_{ik} en S_{jk} ondubbelzinnig vast te leggen. Deze grootheden zijn binnen het model zoals het nu is niet identificeerbaar. Immers ook de waarden, welke de factorvariabelen F_i en S_j aannemen voor de verschillende personen zijn onbekend. Men zal nu aan de variabelen F_i en S_j extra eigenschappen moeten toekennen om identificeerbaarheid te verkrijgen en deze eigenschappen zijn in de te bespreken technieken statistisch van karakter.

Deze weg wordt gevolgd, omdat directe meting der factoren niet mogelijk is. Was dit wel zo, dan zou men de zoveel eenvoudigere regressie-analyse kunnen toepassen.

Het identificeerbaar maken, dat nu dus wel door het opleggen van extra eigenschappen moet geschieden, geeft geen enkele garantie omtrent praktische interpreteerbaarheid der uiteindelijk verkregen ondubbelzinnige oplossing. Het is uiteraard zeer wel mogelijk, dat één of meer der factoren of lineaire combinaties daarvan, gerepresenteerd door de gevonden getalwaarden (schattingen), een praktische interpretatie bezitten, doch het is al te optimistisch hierop zonder meer te rekenen. Alleen indien een factor, waarvoor men een praktische interpretatie meent te hebben gevonden, achteraf toch direct meetbaar blijkt te zijn, kan men tot verificatie van het resultaat overgaan. Dit is echter een uitzonderlijke situatie.

In verschillende handboeken over factor analyse worden niettemin aanvullende methoden beschreven met behulp waarvan men, uitgaande van de op bovenstaande wijze verkregen oplossing, toch het gestelde doel - het schrijven van de testvariabelen als lineaire combinaties van variabelen, behorende bij factoren met psychologisch interpreteerbare betekenis - meent te kunnen bereiken.

Wanneer men in een $m+n$ dimensionale ruimte op de assen van een orthogonaal coördinatensysteem de variabelen F_i en S_j uitzet (één punt voor iedere k), dan leiden deze aanvullende methoden tot een coördinatentransformatie in de door de m gemeenschappelijke factoren voortgebrachte deelruimte. Op grond van bepaalde a priori opvattingen over het verband tussen de variabelen z_j en de factorvariabelen komt men dan tot een nieuwe ondubbelzinnige schrijfwijze, waaraan men dan een psychologische interpretatie geeft. Tot een directe verificatie van deze interpretatie leiden deze methoden echter niet.

Wij zullen ze hier, in verband met hun zeer specialistische karakter, niet bespreken.

Wij kunnen dus onze $n \times N$ waarnemingen plaatsen in één van de volgende modellen:

$$Z_{jk} = \sum_{i=1}^m a_{ji} F_{ik} + e_{jk} \quad (\text{Componenten Analyse}) \quad (8)$$

$$Z_{jk} = \sum_{i=1}^m a_{ji} F_{ik} + a_j S_{jk} \quad (\text{Zuivere Factor Analyse}) \quad (5)$$

De statistische doelstellingen van de factor analyse kunnen nu als volgt worden geformuleerd:

- 1e. Het opstellen van een hypothese omtrent het minimale aantal gemeenschappelijke factoren en het toetsen van deze hypothese.
- 2e. Het schatten van, en het geven van betrouwbaarheidsintervallen voor, de constanten a_{ji} en a_j .
- 3e. Het schatten van, en het geven van betrouwbaarheidsintervallen voor, de factorwaarden F_{ik} .

De technieken, die gebruikt worden zowel in de Componenten Analyse als in de Zuivere Factor Analyse, verschillen van elkaar doordat de extra eigenschappen, welke men aan de variabelen F_i en S_j heeft opgelegd, voor iedere techniek niet dezelfde zijn.

2. Componenten Analyse

Zoals wij reeds eerder hebben vastgesteld, dienen aan de variabelen F_i extra eigenschappen te worden toegevoegd om tot een ondubbelzinnige uitkomst te komen.

Het opleggen van de extra eigenschappen geschiedt op de meest natuurlijke wijze in de populatie, waaruit de proefpersonen een steekproef vormen. Om tot eenvoudige schattingsmethoden te komen worden deze eigenschappen veelal onveranderd opgelegd binnen de steekproef. Het onderscheid hiertussen wordt in vele boeken en artikelen over factoranalyse verwaarloosd.

De technieken behorende tot de Componenten Analyse gaan dus uit van het volgende model:

$$Z_{jk} = \sum_{i=1}^m a_{ji} F_{ik} + e_{jk} \quad (8)$$

De oudste methode, welke wij zullen bespreken is afkomstig van H. HOTELLING.¹⁾²⁾ In het begin van zijn beschouwing neemt hij aan, dat er eventueel gemeenschappelijke factoren zijn als variabelen z_j en negeert hij het bestaan van meetfouten.

Zijn model ziet er dan als volgt uit:

$$z_{jk} = \sum_{i=1}^n a_{ji} F_{ik} \quad (j=1, \dots, n; k=1, \dots, N). \quad (9)$$

Alvorens aan te geven welke extra eigenschappen Hotelling oplegt aan de variabelen F_i , zullen wij zijn methode eerst meetkundig toelichten.

Om te beginnen worden de z_{jk} gestandaardiseerd over k , d.w.z. verminderd met $z_{j\cdot} = \frac{1}{N} \sum_{k=1}^N z_{jk}$ en gedeeld door de spreiding $\sqrt{\frac{1}{N} \sum_{k=1}^N (z_{jk} - z_{j\cdot})^2}$.

Daartoe voeren wij een orthogonaal assenstelsel in met op de assen de variabelen z_j uitgezet. Met de k^{de} persoon correspondeert dan een punt in deze door n assen voortgebrachte ruimte en wel met de coördinaten z_{jk} ($j=1, \dots, n$). De testresultaten kunnen dan worden aangegeven met een puntenwolk van N punten. Door de standaardisering voor iedere waarde van j ligt het zwaartepunt van deze puntenwolk in de oorsprong. Wij voeren nu een nieuw assenstelsel in, waarvan de assen, met het zwaartepunt van de puntenwolk als nieuwe oorsprong, als volgt worden vastgelegd. De eerste as wordt zo gekozen, dat zij ligt in de richting van de grootste spreiding. Vervolgens projecteren wij de puntenwolk op een hypervlak loodrecht op de eerste as. De in dit hypervlak overblijvende spreiding is dan zo klein mogelijk. Vervolgens kiezen wij de tweede as in de richting van de grootste spreiding van deze geprojecteerde puntenwolk. Wanneer wij steeds na het vaststellen van een richting van het nieuwe assenstelsel de puntenwolk projecteren op een hypervlak, dat loodrecht staat op de reeds verkregen assen, dan vinden wij op deze wijze de richtingen van de n assen van ons nieuwe coördinatenstelsel. Op de assen van het nieuwe coördinatenstelsel worden nu de variabelen F_i uitgezet. Dit betekent, dat de eerste m gemeenschappelijke factoren gezamenlijk de grootste bijdrage leveren, die een m -tal gemeenschappelijke factoren geven kan. Dit is nu de eigenschap, toegekend aan de factoren $F_1, F_2, \dots$ in volgorde, waardoor ondubbelzinnige schattingen verkregen worden.

1) H. HOTELLING, Analysis of a complex of statistical variables into principal components, Journal of Educational Psychology 1933, blz. 417 e.v.

2) Zie ook voor korte samenvatting: M.G. KENDALL, Factor Analysis, Journal of Royal Statistical Society B, 12 (1950), blz. 60 e.v.

Ook heeft Hotelling een toets ontwikkeld om na te gaan of de bijdragen van de laatste factoren te onderscheiden zijn van meetfouten. Hiervoor is het noodzakelijk, dat de waarnemingen in duplo of in multiplo worden verricht.

De Principal component analysis van Hotelling beantwoordt dus in sterke mate aan onze statistische doelstellingen.

P. WHITTLE ³⁾ heeft, voortbouwende op denkbeelden van G. YOUNG een andere techniek voorgesteld, welke het best gezien kan worden als een reactie op die technieken, waarin verondersteld wordt, dat de factorvariabelen normaal verdeeld zijn (een onderstelling, die voor de methode van Hotelling ook niet noodzakelijk is). Whittle is van mening dat in de praktijk aan deze veronderstelling niet altijd voldaan is en bovendien is zij vaak overbodig.

Hij ziet dan ook F_{ik} niet als een waarde, welke de variabele F_i aanneemt, maar als een parameter van de persoon, terwijl a_{ji} een parameter is van de test. De beide parameters komen in het model gelijkwaardig voor en waarom zouden zij dan ook niet gelijkwaardig worden behandeld?

Ter onderscheiding van de andere technieken zullen wij het model van Whittle als volgt aangeven:

$$z_{jk} = \sum_{i=1}^m a_{ji} b_{ik} + e_{jk} \quad (10)$$

Zijn techniek komt dan neer op de minimalisering van de volgende vorm:

$$U = \sum_{j=1}^N \sum_{k=1}^N \frac{(z_{jk} - \sum_{i=1}^m a_{ji} b_{ik})^2}{S_{e_j}^2} \quad (11)$$

Met betrekking tot de parameterwaarden a_{ji} en b_{ik} , waarbij $S_{e_j}^2$ een schatting is van de variantie van de meetfoutvariabele e_j . Hiertoe moeten de waarnemingen b.v. in duplo worden verricht, hetgeen echter niet altijd mogelijk is (zo kan men b.v. een psychologische test niet "onafhankelijk" herhalen met dezelfde proefpersoon).

Hierdoor verkrijgt men een aantal betrekkingen waaraan de op een voorgeschreven wijze genormaliseerde constanten a_{ji} en b_{ik} moeten voldoen.

3) P. WHITTLE, On principal components and least square methods of Factor Analysis, Skandinavisk Aktuarie tidskrift, 35 (1953) blz. 223-229.

Verder zijn Whittle en Young in staat de hypothese omtrent het minimum aantal gemeenschappelijke factoren te toetsen. Ook kunnen zij betrouwbaarheidsintervallen geven voor de parameterwaarden.

De techniek van Whittle en Young past men dus direct toe op het waarnemingsmateriaal, terwijl door Hotelling eerst de variabelen worden gestandaardiseerd. Daardoor worden volgens Whittle de meetfouten niet gelijkwaardig behandeld. De door Whittle uitgevoerde standaardisering van de parameters heeft dit bezwaar niet.

Ook D.N. LAWLEY⁴⁾ heeft een techniek ontwikkeld, welke men zou kunnen rangschikken onder de Componenten Analyse. Aangezien deze methode veel overeenkomst vertoont met een andere techniek van Lawley, welke wij bij de zuivere Factor Analyse zullen bespreken, wordt slechts met de vermelding volstaan.

3. Zuivere Factor Analyse

De eerste methode, welke wij zullen bespreken is afkomstig van D.N. LAWLEY⁵⁾. Zoals boven is vermeld, ziet het model in de zuivere Factor Analyse er als volgt uit:

$$z_{jk} = \sum_{i=1}^m a_{ji} F_{ik} + a_j S_{jk}. \quad (5)$$

Lawley gaat er bij zijn methode vanuit, dat de variabelen F_i en S_j alle normaal en onafhankelijk verdeeld zijn op de populatie der proefpersonen. Verder neemt hij aan, dat deze verdelingen alle $\sigma=1$ hebben (hetgeen mogelijk is, daar de spreidingen in de coëfficiënten a_{ji} en a_j opgenomen kunnen worden. De verdeling van de steekproefcovarianties van de z_j 's worden dan gegeven door de Wishartverdeling. De kansdichtheid van deze verdeling kan zo geschreven worden, dat hierin de constanten a_{ji} en a_j als onbekende parameters voorkomen. Deze constanten worden nu zo gekozen, dat de kansdichtheid voor de gevonden waarden van de steekproefcovarianties maximaal wordt (methode der grootste aannemelijkheid). Wederom vinden wij dan een aantal betrekkingen, waaraan de constanten a_{ji} en a_j dienen te voldoen.

4) D.N. LAWLEY, Further investigations in Factor Analysis, Proceedings of the Royal Society of Edinburgh, A 61, blz. 176 e.v.

5) D.N. LAWLEY, the estimation of Factor Loadings by the method of maximum Likelihood, Proceedings Royal Society of Edingburgh A 61 (1940), blz. 64-83.

Deze vergelijkingen geven echter geen unieke oplossing. Lawley vervangt deze betrekkingen dan ook door een ander stelsel vergelijkingen, waarvan niet duidelijk is, welke extra voorwaarden het vertegenwoordigt, doch dat een ondubbelzinnige oplossing bezit, die ook voldoet aan het eerste stelsel vergelijkingen. Later zullen wij bij de bespreking van RAO's canonical factor analysis nog een tweede oplossing ontmoeten van het eerste stelsel vergelijkingen. Vervolgens heeft Lawley in de loop der jaren verschillende bijzondere gevallen van zijn methoden bekeken.

Lawley berekent geen factorwaarden, maar behandelt wel een toets voor de hypothese omtrent het minimum aantal gemeenschappelijke factoren. Bovendien geeft hij betrouwbaarheidsintervallen voor de constanten a_{ji} en a_j .

Tenslotte zullen wij enige aandacht besteden aan een methode, welke door C.R. RAO is voorgesteld en door hem Canonical Factor Analysis wordt genoemd.⁶⁾

Om aan te geven welke extra voorwaarden Rao aan de variabelen F_i oplegt, denken wij eerst de variabelen z_j geschreven als lineaire combinaties van de variabelen x_j en S_j en wel als volgt:

$$z_j = x_j + a_j S_j \quad (j = 1, \dots, n). \quad (12)$$

Vervolgens voeren wij twee variabelen U en V in, waarvoor geldt:

$$U = \sum_{j=1}^n \ell_j z_j \quad (13)$$

$$V = \sum_{j=1}^n q_j x_j \quad (14)$$

en waarbij zowel ℓ_j als q_j constanten zijn.

Het principe van de methode is nu, dat de correlatie tussen U en V zo groot mogelijk gemaakt wordt. Deze correlatiecoëfficiënt is een functie van de ℓ_j en q_j en bezit m maxima. Bij ieder van deze maxima behoort een stelsel waarden van ℓ_j en q_j , dus ook een variabele V . Deze m variabelen neemt Rao nu als de gemeenschappelijke factoren F_i . De berekeningen verlopen volgens een ingewikkelde iteratiemethode, met behulp waarvan de coëfficiënten a_{ji} en a_j geschat worden. Vervolgens kunnen dan ook schattingen van de waarden der factoren verkregen worden.

6) C.R. RAO, Estimation and tests of Significance in Factor Analysis, Psychometrika, vol. 20, no. 2, blz. 93-111.

Men kan bewijzen, dat de constanten a_{ji} en a_j ook moeten voldoen aan de eerste betrekkingen, die Lawley heeft gevonden, zodat de oplossing van Rao ook meest aannemelijke schattingen geeft, hetgeen deze techniek bijzonder aantrekkelijk maakt.

Ook geeft Rao een toets voor de hypothese omtrent het minimum aantal gemeenschappelijke factoren.