2.1 Ein erstes Treffen

Im Café Villars in Fribourg sitzen drei befreundete Psychologiestudierende an einem Tisch zusammen.


**Stefanie:** Hi Stoffel, mach’ dir mal keine Sorgen, wir werden das mit deiner Bachelorarbeit gemeinsam gut hinbekommen.

**Stevie:** Hallo, ihr beiden Psycho-Freaks! Ich hätte da eine Idee. Wie wäre es, wenn wir zusammen eine Anleitung für Bachelorarbeiten erstellen, die jeder gut verstehen kann und in der nur die wichtigsten Dinge, die man von der Fragestellung über die Datenerhebung bis zur Auswertung wirklich braucht, enthalten sind? Ich stelle mir das wie eine Art Kochbuch für Studierende der Sozialwissenschaften vor.

**Stefanie:** Okay, dann wären die Merkmale der Menschen bzw. die Variablen mit ihren Messwerten die Zutaten für die Rezepte, der Computer mit dem Statistikprogramm SPSS wäre der Backofen und die Bachelorarbeit mit den Tabellen und Grafiken wäre das fertige Gericht.

**Stoffel:** Ja, und ich bin dann seine Exzellenz Monsieur Stoffel Bocuse (Abb. 2.1).

**Stefanie:** Lieber Stoffel, als Chefkoch solltest du aber die Haare so wie früher wieder kürzer tragen. Das steht dir auch viel besser, finde ich.

**Stoffel:** Ja, ja. Am besten fangen wir mit den Kochzutaten, also mit den Variablen, an. Was für Merkmale können bei der Beschreibung von Menschen sinnvoll verwendet werden und nach welchen Kriterien können die Variablen eingeteilt werden?

2.2 Typische Variablen zur Beschreibung von Personen

**Stevie:** Machen wir es doch möglichst anschaulich und handlungsorientiert. Stoffel, erstelle bitte mal für jeden von uns eine Art Steckbrief, damit unsere Zuschauer uns besser kennenlernen und damit wir außerdem die wichtigsten grundlegenden Variablen näher betrachten und ordnen können.

Es dauert eine ganze Weile. Dann präsentiert Stoffel stolz drei Beschreibungsprofile, die dank der Hinweise und Korrekturen von Stefanie sehr umfangreich und einheitlich gestaltet und in denen die Variablen alphabetisch geordnet sind (Tab. 2.1).
Stevie: Sehr gut gemacht! Damit das Ganze aber als Tabelle von Messwerten auch mit dem SPSS so richtig schön bearbeitet werden kann, müssen wir noch ein paar kleine Veränderungen vornehmen, lieber Stoffel:

1. Die Spalten und Zeilen der Tabelle müssen vertauscht werden. Jede Zeile steht dann für eine Person und jede Spalte für eine Variable.
2. Für die Variablen Augenfarbe, Beruf, Geschlecht, Haarfarbe, Hobby, Nationalität, Prüfungsnote, Religionszugehörigkeit und Zivilstand sollten auch Zahlenwerte verwendet werden. Ich schlage Folgendes vor:
   - Augenfarbe: blau = 1, braun = 2, grün = 3, Restkategorie (andere Farbe) = 4
   - Beruf: Student = 1, Nicht-Student = 2
   - Geschlecht: weiblich = 1, männlich = 2
   - Haarfarbe: blond = 1, braun = 2, rot = 3, Restkategorie (andere Farbe) = 4
   - Hobby: Lesen = 1, Sport = 2, Kino = 3, Restkategorie (andere Aktivität) = 4
   - Nationalität: Schweiz = 1, Nicht-Schweiz = 2
Prüfungsnote: sehr gut = 1, gut = 2, befriedigend = 3, ausreichend = 4, mangelhaft = 5, ungenügend = 6
Religionszugehörigkeit: katholisch = 1, nicht-katholisch = 2
Zivilstand: ledig = 1, nicht-ledig = 2

Stoffel macht sich an die Arbeit, kommt aber einige Stunden später mit hängendem Kopf zurück.

**Stoffel:** Das klappt so nicht. Wenn ich die Zeilen und Spalten vertausche, kann ich die Tabelle nicht mehr vollständig auf einer normalen DIN A4-Seite (im Hochformat) darstellen, auch wenn ich sehr klein schreibe. Die Variablen Intelligenzquotient, Körpergewicht usw. haben keinen Platz mehr. Schaut selbst (Tab. 2.2).

**Stefanie:** Da gibt es doch den einfachen Trick, die Bezeichnungen der Variablen durch Buchstabenzahlenkennzeichnungen zu ersetzen. Zum Beispiel: Alter = x₁, Anzahl der Geschwister = x₂, ..., Zivilstand = x₁₅. Außerdem können die Namen der untersuchten Personen einfach durchnumeriert werden: Stefanie = 1, Stevie = 2 und Stoffel = 3.

**Stoffel:** Alles klar, aber das hättest du mir auch vorher sagen können.

<table>
<thead>
<tr>
<th>Tab. 2.1 Datentabelle für drei fiktive Personen</th>
</tr>
</thead>
<tbody>
<tr>
<td>Merkmal bzw. Variable</td>
</tr>
<tr>
<td>------------------------</td>
</tr>
<tr>
<td>Alter (in Jahren)</td>
</tr>
<tr>
<td>Anzahl der Geschwister</td>
</tr>
<tr>
<td>Anzahl der Kinder</td>
</tr>
<tr>
<td>Augenfarbe</td>
</tr>
<tr>
<td>Beruf</td>
</tr>
<tr>
<td>Geschlecht</td>
</tr>
<tr>
<td>Haarfarbe</td>
</tr>
<tr>
<td>Hobby</td>
</tr>
<tr>
<td>Intelligenzquotient</td>
</tr>
<tr>
<td>Körpergewicht (in kg)</td>
</tr>
<tr>
<td>Körpergröße (in cm)</td>
</tr>
<tr>
<td>Nationalität</td>
</tr>
<tr>
<td>Prüfungsnote in Statistik</td>
</tr>
<tr>
<td>Religionszugehörigkeit</td>
</tr>
<tr>
<td>Zivilstand</td>
</tr>
</tbody>
</table>
**2.2 · Typische Variablen zur Beschreibung von Personen**

<table>
<thead>
<tr>
<th>Person</th>
<th>Alter (in Jahren)</th>
<th>Anzahl der Geschwister</th>
<th>Anzahl der Kinder</th>
<th>Augenfarbe</th>
<th>Beruf</th>
<th>Geschlecht</th>
<th>Haarfarbe</th>
<th>Hobby</th>
</tr>
</thead>
<tbody>
<tr>
<td>Stefanie</td>
<td>21</td>
<td>0</td>
<td>0</td>
<td>3</td>
<td>1</td>
<td>1</td>
<td>1</td>
<td>1</td>
</tr>
</tbody>
</table>

**Tab. 2.3 · SPSS-Datentabelle für Stefanie, Stevie und Stoffel**

<table>
<thead>
<tr>
<th>x1</th>
<th>x2</th>
<th>x3</th>
<th>x4</th>
<th>x5</th>
<th>x6</th>
<th>x7</th>
<th>x8</th>
<th>x9</th>
<th>x10</th>
<th>x11</th>
<th>x12</th>
<th>x13</th>
<th>x14</th>
<th>x15</th>
</tr>
</thead>
<tbody>
<tr>
<td>1</td>
<td>21</td>
<td>0</td>
<td>0</td>
<td>3</td>
<td>1</td>
<td>1</td>
<td>1</td>
<td>1</td>
<td>130</td>
<td>65</td>
<td>172</td>
<td>1</td>
<td>2</td>
<td>1</td>
</tr>
<tr>
<td>2</td>
<td>26</td>
<td>1</td>
<td>0</td>
<td>2</td>
<td>1</td>
<td>2</td>
<td>2</td>
<td>2</td>
<td>120</td>
<td>81</td>
<td>181</td>
<td>2</td>
<td>1</td>
<td>2</td>
</tr>
<tr>
<td>3</td>
<td>20</td>
<td>3</td>
<td>0</td>
<td>1</td>
<td>1</td>
<td>2</td>
<td>3</td>
<td>3</td>
<td>110</td>
<td>76</td>
<td>185</td>
<td>2</td>
<td>3</td>
<td>2</td>
</tr>
</tbody>
</table>

Kurze Zeit später kommt Stoffel erhobenen Hauptes mit seiner neuen Tabelle daher stolz (Tab. 2.3).


**Stoffel**: Alles easy, mach’ mal halblang. Ich bin fertig für heute, gehen wir ein Bierchen trinken?

Am nächsten Tag in der Mensa.


**Stevie**: Das denke ich auch. Man könnte natürlich auch darauf achten, ob es sich eher um äußere körperliche Merkmale (wie das Geschlecht, die Haarfarbe usw.) oder um psychologische Merkmale (wie die Intelligenz) handelt. Ich kann mir hier eine enorme Menge an weiteren Einteilungsmöglichkeiten vorstellen. Für die gesamte weitere Verwendung der Variablen werden aber vor allem Dingen die folgenden beiden mathematisch-methodischen Einteilungsaspekte wichtig sein:

a. Ist die Variable stetig oder diskret?
b. Auf welchem Skalenniveau wird die Variable gemessen?

**Stoffel**: Stetig oder diskret? Ich weiß es, ich weiß es! Lasst es mich erklären!
2.3 Stetige und diskrete Variablen

**Stoffel:** Stetige Variablen sind wie wenn man schön gleichmäßig (kontinuierlich) mit dem Fahrrad fährt, und diskrete Variablen sind wie wenn man zu Fuß einen Fluss überquert und dabei von Stein zu Stein springt.

**Stefanie:** Stetige Variablen (Alter, Intelligenzquotient, Körpergewicht, Körpergröße) können rein theoretisch unendlich viele Werte (Ausprägungen) zwischen zwei beliebigen Werten annehmen. Bei diskreten Variablen (Anzahl der Geschwister, Augenfarbe, Prüfungsnote usw.) dagegen gibt es grundsätzlich nur endlich viele mögliche Werte zwischen zwei beliebigen Werten.

Auch wenn man in der Realität die Körpergröße normalerweise in Zentimetern misst und damit praktisch nur zu endlich vielen Messwerten zwischen zwei beliebigen Messwerten kommen kann, ist es eben theoretisch vorstellbar, die Messgenauigkeit beliebig fein einzustellen (Millimeter, Nanometer usw.) und somit theoretisch zu unendlich vielen Messwerten zwischen zwei beliebigen Messwerten (z.B. zwischen 180 cm und 181 cm) zu gelangen. Die Anzahl der Geschwister (0, 1, 2, 3 usw.) dagegen kann grundsätzlich nur eine endliche Anzahl von Werten zwischen zwei beliebigen Werten (z.B. zwischen 2 Geschwistern und 10 Geschwistern) annehmen.

2.4 Angenähert normalverteilte vs. nicht normalverteilte Variablen

2.4.1 Normalverteilung

**Stevie:** Die Normalverteilung ist eine mathematisch theoretische Verteilung, der ein stetiges Merkmal zugrunde liegt und die über die folgenden Eigenschaften verfügt:

Die Verteilung hat einen glockenförmigen Verlauf, sie ist eingipflig, symmetrisch und nähert sich asymptotisch an die Abszisse (x-Achse). Sie ist durch die beiden Parameter Mittelwert und Standardabweichung eindeutig charakterisiert.

Jede Normalverteilung kann durch die z-Transformation in die Standardnormalverteilung mit einem Mittelwert von 0 und einer Standardabweichung von 1 überführt werden.

Etwa 68% der Merkmalswerte liegen im Bereich des Mittelwerts plus/minus einer Standardabweichung. Die Wahrscheinlichkeitsabnahme hinsichtlich der Entfernung der Variablenwerte vom Mittelwert erfolgt beschleunigt: Je größer die Entfernung vom Mittelwert wird, desto schneller nimmt die Wahrscheinlichkeit ab. Extreme Merkmalswerte haben daher bald eine sehr kleine Wahrscheinlichkeit p (z.B. drei Standardabweichungen oberhalb vom Mittelwert: $p = 0,0013$) und sollten praktisch sehr selten auftreten.


Die Grundbedingung dabei ist, dass es eine Vielzahl von zufällig und unabhängig voneinander wirkenden Einflussfaktoren auf die Merkmalsausprägung gibt.

Menschliche Merkmale wie z.B. die Körpergröße und die gemessene Intelligenz gelten relativ unbestritten als zumindest sehr gut angenähert normalverteilt.

Da bei den meisten parametrischen Signifikanztests eine der zentralen Voraussetzungen die Normalverteilung des untersuchten Merkmals in der Population ist, wird in der sozialwissenschaftlichen Forschung (nicht unbestritten) überwiegend davon ausgegangen, dass für die
meisten untersuchten physischen, psychischen und sozialen menschlichen Merkmalen (Angstlichkeit, Konzentrationsfähigkeit, Kreativität usw.) oder Verhaltensweisen (Reaktionszeiten, motorische Fähigkeiten usw.) die Normalverteilungseigenschaft angenähert vorliegt oder die Abweichungen moderat sind und bei geeigneter Anwendung (gleich große Stichprobengruppen usw.) keine wesentlichen Effekte auf die Ergebnisse der Signifikanztests haben.

**2.4.2 Nicht normalverteilte Variablen**

Es gibt Variablen wie z.B. das *finanzielle Vermögen* von Menschen, von denen wir eindeutig wissen, dass sie, über das gesamte Merkmalspektrum betrachtet, nicht normalverteilt sind. Sehr, sehr, sehr extreme Abweichungen vom Mittelwert (z.B. Anfang 2015 geschätzte ca. 88 Milliarden Dollar von Bill Gates) hätten bei einer Normalverteilung des Vermögens eine so geringe Wahrscheinlichkeit, dass sie in der gesamten Menschheitsgeschichte praktisch nie auftreten könnten und würden.


Für die Bereiche der Wirtschaftswissenschaften und der Meteorologie werden daraus resultierende, möglicherweise katastrophale Auswirkungen wie z.B. unerwartet starke, existenzvernichtende Börsencrashes oder unerwartet starke, alle Däme und Deiche zerstörende Sturmfluten beschrieben.

Mit der von dem französischen Mathematiker Paul Lévy (1886-1971) entwickelten Lévy-Verteilung, die im Vergleich zur Normalverteilung stark *heavy-tailed* (hohe Wahrscheinlichkeiten an den Rändern der Verteilung) ist und über keinen endlichen Erwartungswert und keine endlich Varianz verfügt, können solche extremen Ereignisse (im Gegensatz zur Normalverteilung, die das nicht erklären kann) modelliert werden.

In seinem Artikel *Nonrobustness in one-sample Z and t tests: A large-scale sampling study* beschreibt Bradley (1980) eine psychomotorische Aufgabe (unter bestimmten Bedingungen muss ein von der Handposition leicht entfernter mehr oder weniger kleiner Knopf gedrückt werden). Die Zeitmesswerte der 2520 Versuche der gleichen Versuchsperson waren L-förmig (extrem linkssteil und mit einem sehr langen rechten dünnen Verteilungsschwanz) und somit eindeutig nicht normalverteilt.

**Stefanie:** Ich kann erahnen, dass bei den oben genannten Variablen die Grundbedingung der Normalverteilung, dass sich die vielen Einflussfaktoren *unabhängig* voneinander auswirken, nicht erfüllt ist: Beim Entstehen oder Zusammenbrechen riesiger Vermögenswerte oder bei den sogenannten Monsterwellen kommt es vermutlich zu Prozessen, bei denen sich einige Einflussfaktoren in *gegenseitiger Abhängigkeit* sehr stark hochschaukeln können und sich deswegen nicht wie bei der Normalverteilung gegenseitig ausgleichen werden.

Bei der psychomotorischen Aufgabe könnte ich mir vorstellen, dass sich die Versuchsperson während der großen Anzahl der 2520 Wiederholungen im Wesentlichen in zwei unterschiedlichen Konzentrationszuständen befinden wird. Stark vereinfacht: Während etwa 90% der Versuche ist sie gut konzentriert und erzeugt überwiegend sehr ähnliche Zeitmesswerte. Während der anderen 10% der Versuche ist sie irgendwie abgelenkt und die Zeitmesswerte
werden in diesem Zustand sehr stark anwachsen. Diese beiden Konzentrationszustände könnten sich dabei in für mich nicht abschätzbaren Reihenfolge beliebig abwechseln.

**Stoffel:** Na gut, aber wie kann ich damit umgehen, wenn ich in meiner Bachelorarbeit offensichtlich nicht normalverteilte Variablen untersuchen möchte oder soll?

**Stevie:** Ohne die Thematik hier zu sehr vertiefen zu wollen, schlage ich die folgenden drei Möglichkeiten vor:

1. Nur reine deskriptive Statistiken anwenden.
2. Die Messwertskalen inhaltlich und theoretisch gut begründet so einschränken, dass die Messwerte im verbleibenden Bereich vermutlich annähernd normalverteilt sind.

Bei der Vermögensvariablen könnte man z.B. nur Personen berücksichtigen, deren Vermögenswerte zwischen 1000 und 500.000 Euro liegen (in Europa).

Bei der Zeitmessung der psychomotorischen Aufgabe könnte man vor der Datenerhebung einen maximalen Zeitraum festlegen, der die Zustandsbereiche gut konzentriert vs. abgelenkt voneinander abgrenzen sollte. Es werden dann nur die Messwerte unterhalb dieses maximalen Messwertes verwendet.

Generell sollte auf Folgendes geachtet werden:

a. Die zu bearbeitenden Aufgaben in einem Experiment oder die Variablen in einem Fragebogen sollten weder zu leicht noch zu schwer sein (Vermeidung von Boden- oder Deckeneffekten).


Bei einem solchen Vorgehen sind allerdings ein guter Kenntnisstand in dem Forschungsgebiet und ein exzellentes Fingerspitzengefühl erforderlich.


**Stoffel:** Auf die mögliche alternative Verwendung nicht-parametrischer Verfahren wollen wir hier nicht weiter eingehen, zumal mir zu Ohren gekommen ist, dass damit auch nicht automatisch alle Verteilungsprobleme gelöst werden.

**Stevie:** Das wäre geklärt.

**Stefanie:** In der Arbeit von Micceri (1989) werden auch noch andere Verteilungen, die auf realen Datensätzen beruhen und die nicht-normalverteilt sind, vorgestellt.

**Stevie:** Aber auch darauf werden wir nicht weiter eingehen.

---

**Stefanie:** Liebster und bester Stoffel, kannst du uns nun bitte noch die verschiedenen Skalen niveaus der Variablen erklären?

**Stoffel:** Oh, verdammt. Mein Handy hat gerade geklingelt. Ich muss mal eben schnell telefonieren gehen.