

Eine elementarmathematische Begründung des Benford-Gesetzes¹

Hans HUMENBERGER, Wien

Zusammenfassung

Das Anliegen dieses Aufsatzes ist zu zeigen, wie eine elementarmathematische Begründung des in letzter Zeit sehr populären BENFORD-Gesetzes auch auf Schulniveau möglich ist.

Eine „außermathematische Anwendung“ des *prima vista* vielleicht höchst theoretisch scheinenden Gesetzes wurde durch Mark NIGRINI realisiert (NIGRINI 2000), der mittels dieses Gesetzes Steueründern auf die Spur gekommen ist. Internationale Konzerne und Finanzbehörden interessieren sich mittlerweile für die Software von M. NIGRINI.

1 Einleitung

1881 entdeckte der Astronom und Mathematiker Simon NEWCOMB bei der Arbeit mit Logarithmenbüchern, dass diese auf den Anfangsseiten viel abgegriffener und abgenutzter waren als auf den hinteren. Dies wäre bei anderen Büchern als Logarithmentafeln in Bibliotheken durchaus erklärbar, denn viele Leute beginnen ein Buch zu lesen (Roman, Gedichte, Theaterstück, Kurzgeschichten, Sachbücher, Fachbücher etc.), hören aber vorzeitig damit wieder auf, weil sie keine Zeit mehr haben, weil es ihnen zu langweilig wird, weil es ihnen zu kompliziert wird (Fachbücher) u. ä. Wenn viele die Lektüre unfertig unterbrechen, ist es klar, dass der Anfang von Büchern abgenutzt ist als der Schluss. Aber warum soll dies bei Logarithmentafeln der Fall sein – diese werden ja nach anderen Gesichtspunkten benutzt. Die einzige Erklärung, die es dafür gibt, ist, dass der Logarithmus von Zahlen mit niedrigen Anfangsziffern (1, 2, ...) häufiger gesucht wurde als von Zahlen mit hohen Anfangsziffern (9, 8, ...). Aber warum? Kommen Zahlen mit niedrigen Anfangsziffern „in der Welt“ häufiger vor? Warum sollte die Natur eine Präferenz für die 1 als Anfangsziffer haben?

NEWCOMB gab auch schon eine mathematische Formel an, die seine Beobachtungen gut beschreiben konnte: Die relative Häufigkeit, mit der die Ziffer d als Anfangsziffer einer Zahl auftritt, ist ca. $\log_{10} \left(\frac{d+1}{d} \right)$. Er gab aber keine Erklärungen dafür, sondern empfand diese Tatsache einfach als interessante Kuriosität, die bald danach auch wieder vergessen wurde.

Es dauerte über 50 Jahre, bis der Physiker Frank BENFORD (1938) dieselbe Entdeckung an Logarithmenbüchern machte. Er war von diesem Phänomen viel mehr fasziniert und sammelte mit Akribie eine Unmenge von Daten aus den verschiedensten Bereichen, um immer wieder festzustellen, dass 1 als führende Ziffer mit einer relativen Häufigkeit von ca. 30% auftrat, 2 mit ca. 18% usw. bis 9 mit ca. 5%. Wenn die Anfangsziffern von Werten

¹Dies ist eine überarbeitete Fassung des Aufsatzes in: Der Mathematikunterricht, **54**, 1, S. 24–34.

tatsächlich eine Wahrscheinlichkeitsverteilung haben, die ca. diesen relativen Häufigkeiten entsprechen, ist es einleuchtend, dass bei einer Logarithmentafel die Seiten mit führender Ziffer 1 (das sind eben die vorderen) abgenützter sind als die mit führender Ziffer 9 (ca. sechsmal so stark!).

Intuitiv würden die meisten sicher Gleichverteilung erwarten: Warum soll eine bestimmte Ziffer als führende Ziffer bevorzugt sein? Dann müsste die Wahrscheinlichkeit für alle möglichen Anfangsziffern (1,2,...,8,9) bei ca. $\frac{1}{9} \approx 0,1111$ liegen².

BENFORD hat z. B. untersucht: Oberflächen von Seen, Halbwertszeiten radioaktiver Substanzen, Energieverbrauchsdaten von Haushalten, Entfernungen zwischen Orten, Baseball-Statistiken etc. Aber auch er hat keine Erklärung dafür angegeben, die erste mathematische Erklärung stammt von Roger S. PINKHAM (1961).

Man kann sich heutzutage z. B. mit Google sehr schnell selbst einen Überblick über große Datenmengen verschaffen: Man wählt z. B. eine beliebige 3-stellige Zahl (473) und gibt in Google diese Zahl der Reihe nach mit einer führenden 1, . . . , 9 als Suchbegriff ein: 1473, . . . , 9473. Z. B. bei 1473 erhält man ca. 30,5 Mio „Treffer“, für 9473 nur mehr ca. 3,5 Mio Treffer. In relativen Häufigkeiten ergibt sich das Bild von Fig. 1, wobei auch die theoretisch nach dem BENFORD-Gesetz zu erwartenden Werte zum Vergleich eingezeichnet sind.

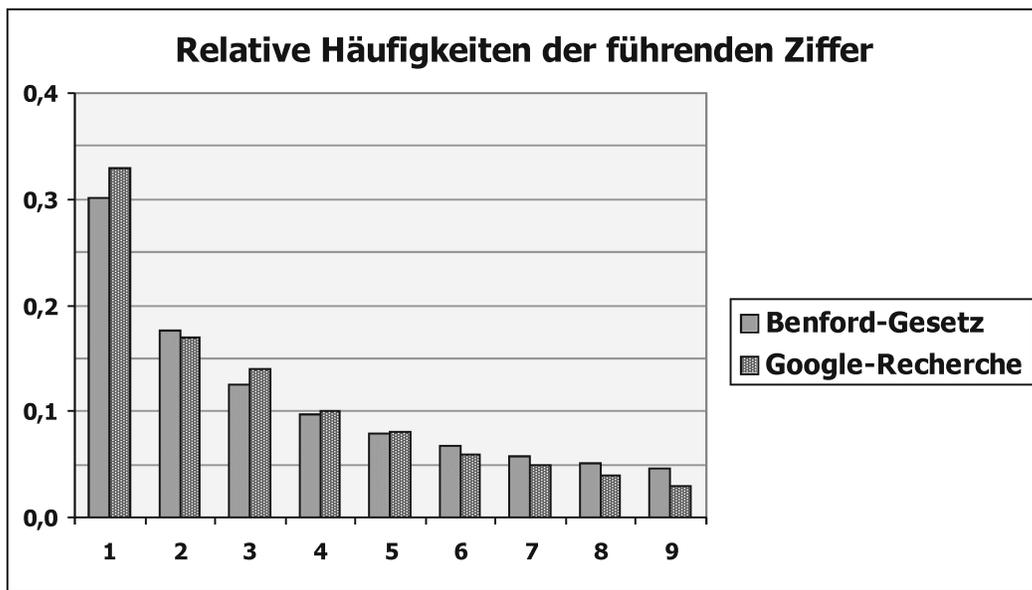


Fig. 1: Ein Versuch mit Google

Es hat natürlich keinen Sinn, Daten zu betrachten, die von vornherein auf einen Bereich eingeschränkt sind, der die Möglichkeiten für die erste Ziffer ziemlich einengt — z. B. Lottozahlen, die Laufzeiten in Sekunden bei 1000m-Laufbewerben, die Anzahl der Buchstaben in den Familiennamen der Bewohner eines Landes, die Gebäudehöhen in einer Stadt, das Alter von Studierenden an einer Universität (das Alter generell!), die Anzahl der Schulbildungsjahre, die Anzahl der Sitze in Fahrzeugen, die Wurzeln der ersten 1000

²Mit *Anfangsziffer* sei im Folgenden stets *die erste Ziffer ungleich 0* bzw. *erste „signifikante“ Ziffer* gemeint; also z. B. 3 in 0,0367.

natürlichen Zahlen usw. Eine statistische Analyse von vielfältigen Daten zeigt, dass die Verteilung der führenden Ziffer gut mit dem BENFORD-Gesetz übereinstimmt, wenn sich die Daten wenigstens über einige Zehnerpotenzen verteilen.

Wir nehmen \mathbb{R}^+ als das potentielle Universum der physikalischen Maßzahlen, aus denen die Daten stammen sollen³ und wollen im Folgenden dem „BENFORD-Gesetz“ auf die Spur kommen⁴:

$$P(Z \in Z_d) := P(\text{1. Ziffer von } Z = d) = \lg(d + 1) - \lg d \quad d = 1, \dots, 9 .$$

Dabei bezeichnet Z_d die Menge aller positiven reellen Zahlen, die in der Dezimaldarstellung mit Ziffer d beginnen. Ziel der Überlegungen ist es, ein stochastisches Modell für das Auftreten der 1. Ziffer herzuleiten. Dabei muss man natürlich die Zahl Z – im konkreten Fall ein *Datum* – als *Zufallsvariable* auffassen. Konsequenterweise bezeichnen wir die Zahl Z mit einem Großbuchstaben.

Nach diesem Gesetz hätten die einzelnen Ziffern die in Tab. 1 angegebenen Wahrscheinlichkeiten, die mit den in vielen Datensätzen beobachteten relativen Häufigkeiten gut übereinstimmen, so auch bei unserem obigen Versuch mit Google (diese Zahlen sind die numerischen Werte der Graphik in Fig. 1 in der Rubrik „BENFORD-Gesetz“).

1. Ziffer	1	2	3	4	5	6	7	8	9
Wahrscheinlichkeit	0,301	0,176	0,125	0,097	0,079	0,067	0,058	0,051	0,046

Tab. 1: Wahrscheinlichkeiten für die einzelnen Ziffern nach BENFORD

An anderen Stellen (vgl. HUMENBERGER 1996, 1997, 2000) haben wir deutlich gemacht, dass und wie dieses Phänomen im Schulunterricht anschaulich thematisiert werden könnte durch *Einschränkung auf natürliche Zahlen*: $P_n(1)$ bzw. $P_n(9)$ seien die *relativen Anteile* der natürlichen Zahlen $\leq n$, die mit 1 bzw. 9 beginnen. Anschauliche und einfache Überlegungen liefern schnell: Nur wenn n von der Form $9 \dots 9$ ist, sind diese beiden relativen Anteile gleich, bei allen anderen n ist immer $P_n(1) > P_n(9)$. Dies liefert schon die erste Einsicht in die Tatsache, dass die 1 bei der 1. Ziffer von Zahlen gegenüber der 9 doch bevorzugt ist. Es finden sich dort (1996, 2000) auch schon Überlegungen für den Fall *positiver reeller Messwerte*, aber diese enthalten einiges an *Maßtheorie*, was wir hier aus Gründen der Elementarität vermeiden wollen, damit man die grundsätzlichen Gedanken rund um eine Begründung des BENFORD-Gesetzes auch im Schulunterricht umsetzen kann.

³*Messwerte* sind zwar naturgemäß rational, aber mit reellen Zahlen rechnet es sich leichter. Alles Folgende würde auch mit \mathbb{Q}^+ statt \mathbb{R}^+ funktionieren. Wenn physikalische Werte in Wirklichkeit negativ wären, kann man z. B. deren Betrag nehmen.

⁴In weiterer Folge schreiben wir $\lg := \log_{10}$ („Logarithmus generalis“). Diese Formel gilt auch für $d = 9$.

2 Wahrscheinlichkeiten bei unbeschränkten Mengen und eine zunächst vordergründige Argumentation

Beispiel

Die Lüftung eines Tunnels wird automatisch in Betrieb gesetzt und wieder ausgeschaltet; und zwar ist sie von jeder vollen Stunde an 20 Minuten lang in Betrieb (d. h. sie wird z. B. um 10.00 Uhr eingeschaltet und um 10.20 Uhr wieder ausgeschaltet). Wie groß ist die Wahrscheinlichkeit, dass ein zu einem *zufälligen* Zeitpunkt⁵ in den Tunnel einfahrendes Auto die Lüftung in Betrieb vorfindet?

Die „Lösung“ scheint hier ziemlich klar zu sein: Innerhalb jeder vollen Stunde spielt sich dasselbe Szenario ab (20 von 60 Minuten Betrieb); wegen dieser offensichtlichen Periodizität wird man auch intuitiv den möglichen großen Stichprobenraum \mathbb{R} einschränken auf $[0; 1)$ (in Stunden) und dort die Wahrscheinlichkeit mit $\frac{20}{60} = \frac{1}{3}$ ausrechnen. Dabei ist ebenfalls intuitiv klar, dass es keine Rolle spielt, ob die Lüftung jeweils zu den vollen Stunden oder jeweils zu irgendeinem anderen fixen Zeitpunkt 20 Minuten lang pro Stunde eingeschaltet wird (z. B. jeweils um *.10 Uhr).

Dies ist ein Beispiel, bei dem einer Teilmenge (Vereinigung unendlich vieler Intervalle) einer *unbeschränkten* Menge (nämlich \mathbb{R}^+) ein Maß („Wahrscheinlichkeit“) zugeordnet wurde.

Welchen relativen Anteil $P(A)$ hat eine gewisse Teilmenge A an einer Gesamtmenge Ω ? Bei beschränkten Mengen ist die Antwort darauf kein Problem, z. B. macht das Intervall $A = [1; 2)$ den Bruchteil $1/9$ von $\Omega = [1; 10)$ aus.

Bei unbeschränktem Ω ist dies aber i. A. gar nicht mehr so leicht, es bedarf oft langwieriger Überlegungen aus der so genannten *Maßtheorie*. Wie groß sind „relative Anteile“ bei unbeschränkten Mengen? Klar ist aber auch hier, dass das Wahrscheinlichkeitsmaß jeder *beschränkten* Menge den Wert 0 zuordnen muss, denn „ $\frac{\text{endlich}}{\infty} = 0$ “.

Im Folgenden wird zunächst obiges Tunnel-Beispiel verallgemeinert und formal aufgeschrieben: Die unbeschränkte Teilmenge von \mathbb{R}

$$K_{a,b} := \bigcup_{n=-\infty}^{\infty} [n+a, n+b) \quad \text{mit} \quad 0 \leq a \leq b \leq 1$$

ist eine Vereinigung unendlich vieler halboffener Intervalle und ist in Fig. 2 dargestellt.

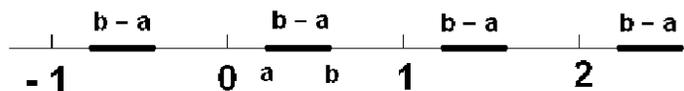


Fig. 2: Die Menge $K_{a,b}$ mit $P(K_{a,b}) = b - a$

⁵„Zufällig“ soll hier heißen, dass die Ankunftszeiten der Autos *gleichverteilt* angenommen werden: kein Intervall und kein Zeitpunkt soll bevorzugt werden.

Kein Intervall $[n; n + 1)$ sei bevorzugt, innerhalb dieser Intervalle sind die Ankunftszeiten gleichverteilt, d. h. das gesuchte Maß entspricht dem relativen Anteil von $K_{a,b}$ an \mathbb{R} . Hier ist auch intuitiv klar (vgl. obiges Beispiel): Dieser relative Anteil ist $b - a$ (in jedem Teilintervall mit $(b - a) : 1$ abzulesen). Die Wahrscheinlichkeit, dass eine „zufällig“ gewählte Ankunftszeit (bzw. reelle Zahl) Z in $K_{a,b}$ liegt⁶, ist daher mit $b - a$ zu quantifizieren:

$$P(Z \in K_{a,b}) = b - a .$$

Wir erinnern uns nun an die Mengen Z_d : die Menge aller *positiven* reellen Zahlen, die Anfangsziffer d haben:

$$Z_d = \bigcup_{n=-\infty}^{\infty} [d 10^n, (d + 1) 10^n) \quad d = 1, \dots, 9 .$$

Unser Ziel ist $P(Z \in Z_d) = \lg(d + 1) - \lg d$ plausibel zu machen („BENFORD-Gesetz“).

Für $Z \in \mathbb{R}^+$ ist $\lg Z \in \mathbb{R}$ und für $\lg Z_d$ (d. h. die Menge aller $\lg Z$ mit $Z \in Z_d$) erhalten wir eine Menge, deren Elemente sich über ganz \mathbb{R} erstrecken⁷:

$$\lg Z_d = \bigcup_{n=-\infty}^{\infty} [n + \lg d, n + \lg(d + 1)) .$$

D. h. die Menge $\lg Z_d$ ist nichts anderes als $K_{\lg d, \lg(d+1)}$ in obiger Notation ($a = \lg d$, $b = \lg(d + 1)$). Wie können wir dieser Menge ein Maß bzw. eine Wahrscheinlichkeit zuordnen? Bei dem obigen einfachen Argument für $P(Z \in K_{a,b}) = b - a$ war ja Gleichverteilung von Z die Voraussetzung („relativer Anteil von Mengen“). Verwenden wir dieses Argument hier analog, so müssen wir voraussetzen, dass $\lg Z$ gleichverteilt ist. Damit erhalten wir: $P(\lg Z_d) = \lg(d + 1) - \lg d$.

Man könnte nun etwas vordergründig bzw. voreilig argumentieren:
Wegen $\lg Z \in \lg Z_d \Leftrightarrow Z \in Z_d$ erhalten wir „klarer Weise“

$$P(Z \in Z_d) = P(\lg Z \in \lg Z_d) = \lg(d + 1) - \lg d$$

und dadurch das gewünschte Resultat

$$\boxed{P(Z \in Z_d) = \lg(d + 1) - \lg d} .$$

Diese Folgerung gilt aber nur unter der Voraussetzung, dass $\lg Z$ (und nicht Z) gleichverteilt ist. Die Frage muss also lauten:

Warum ist $\lg Z$ gleichverteilt?

Um die Klärung genau dieser Frage soll es im Folgenden noch gehen – siehe insbesondere den nächsten Abschnitt.

⁶Gleichverteilung von Z vorausgesetzt!

⁷Weil \lg stetig und streng monoton wachsend ist, werden Intervalle dabei wieder auf Intervalle abgebildet (linke/rechte Randpunkte auf linke/rechte Randpunkte), und wir erhalten wieder eine Vereinigung von Intervallen.

Man darf ja nicht automatisch davon ausgehen, dass Zufallsgrößen gleichverteilt sind. Insbesondere das Anwenden einer Funktion f auf eine Größe Z verändert i. A. das zugehörige Verteilungsgesetz.

Dazu ein einfaches Beispiel mit der Quadratfunktion: Es soll eine Zahl Z zufällig (im Sinne der „geometrischen Wahrscheinlichkeit“: kein Bereich bevorzugt) aus $[0, 1)$ gezogen werden. Das interessierende Intervall sei dabei $I := [0, \frac{1}{2})$. Mit günstigen und möglichen Intervalllängen argumentiert ergibt sich $P(Z \in I) = \frac{1}{2}$. Nun betrachten wir die Quadratfunktion $f : Z \mapsto Z^2$. Wegen $f([0, 1)) = [0, 1)$ und $f(I) = [0, \frac{1}{4})$ ergibt sich „analog“ $P(f(Z) \in f(I)) = \frac{1}{4} \neq \frac{1}{2}$. Wenn man also in beiden Fällen – vor und nach dem Quadrieren – ohne weiter darüber nachzudenken Gleichverteilung voraussetzt, so kommt man dabei in Schwierigkeiten, denn wegen $Z \in I \Leftrightarrow f(Z) \in f(I)$ muss natürlich $P(Z \in I) = P(f(Z) \in f(I))$ sein.

Oft werden LAPLACE- oder „geometrische“ Wahrscheinlichkeiten in sehr naiver Weise benutzt $P = |\text{günstig}| / |\text{möglich}|$, wobei $|\cdot|$ für eine *Anzahl* im diskreten Fall bzw. für *Längen, Flächen, Volumina* im „geometrischen“ Fall steht. „Sehr naiv“ soll dabei bedeuten, dass man sich zu wenig Gedanken macht, ob wirklich kein Ausgang des Zufallsexperiments bevorzugt ist, d. h. ob wirklich Gleichverteilung vorliegt (widrigenfalls wäre ja $P = |\text{günstig}| / |\text{möglich}|$ falsch).

Das Anwenden einer Funktion f (oben: Quadratfunktion) ist eine Transformation einer Zufallsvariable, und diese Transformationen ändern i. A. das zugehörige Verteilungsgesetz⁸.

Wir brauchen uns zwar über das Verteilungsgesetz von Z (d. h. vor dem Logarithmieren) gar keine Gedanken zu machen, aber wir müssen die Frage beantworten: *Warum* ist $\lg Z$ *gleichverteilt*? Denn das obige einfache Argument des relativen Anteils von Mengen setzte ja *Gleichverteilung* voraus.

3 Skaleninvarianz und die Gleichverteilung der logarithmierten Werte

Wenn es überhaupt ein Verteilungsgesetz für die erste Ziffer von Zahlen gibt⁹, so muss dieses doch ein *universelles* sein, d. h. es kann doch nichts ausmachen, in welchen Einheiten man die entsprechenden Größen angibt, da Einheiten ja nicht vom Universum oder einer höheren Macht vorgegeben, sondern willkürliches Menschenwerk sind. Es wäre ja wirklich höchst merkwürdig, wenn das Verteilungsgesetz von den gewählten Maßeinheiten abhinge, durch Wechsel vom anglo-amerikanischen ins metrische System würde sich dieses Gesetz ändern.

⁸Wenn man eine Zufallsvariable einer Transformation f unterzieht, so muss man immer überlegen, wie sich das auf das zugehörige Verteilungsgesetz (Dichte- bzw. Verteilungsfunktion) auswirkt, um danach wieder Überlegungen zu Wahrscheinlichkeiten anstellen zu können. Es geht uns hier nur um den zu Grunde liegende Sachverhalt, und nicht darum, wie man die jeweils neue Dichtefunktion bei der Transformation f bestimmt; deswegen ist dies hier auch nicht näher für die log- bzw. für die Quadratfunktion ausgeführt.

⁹Empirische Beobachtungen unterstützen die These, dass ein solches gibt.

Die Einheiten für eine feste physikalische Größe unterscheiden sich i. A. nur um einen konstanten Faktor $s \in \mathbb{R}^+$, z. B. unterscheiden sich km und Meilen ungefähr um den Faktor $s = 1,609344$. Wenn Entfernungen in km statt Meilen angegeben werden, so muss man die entsprechenden Werte mit $s = 1,609344$ multiplizieren, wenn Preise von Dollar in € umgerechnet werden, so muss man die Zahlen durch ca. 1,33 dividieren¹⁰.

D. h. ein Verteilungsgesetz für die erste Ziffer von Zahlen soll sich nicht ändern, wenn jede Zahl mit einem konstanten Faktor multipliziert wird. Mit anderen Worten: Wenn es ein „vernünftiges“ Verteilungsgesetz für die erste Ziffer von Zahlen gibt, so muss dieses **skaleninvariant** sein, d. h. es darf sich nicht ändern, wenn alle Werte mit einer positiven Konstante multipliziert werden.

Welche Verteilungsgesetze für die erste Ziffer kommen dafür in Frage?

Zunächst ein Test, ob Gleichverteilung der 1. Ziffer die Bedingung der Skaleninvarianz erfüllt:

Dazu nehmen wir mal an, dass alle Ziffern 1, . . . , 9 gleichwahrscheinlich als führende Ziffer wären¹¹, und betrachten als Beispiel eine Vielzahl von Geldwerten in Euro. Bei einer Währungsänderung, z. B. wenn man statt der €-Werte in Deutschland in die alte DM-Welt zurückfallen möchte, muss jeder Geldwert mit (dem gerundeten Wert) 2 multipliziert werden. Bleibt dabei die ursprünglich in der €-Welt angenommene Gleichverteilung erhalten?

Nein, denn: Alle €-Werte mit führender Ziffer 5, 6, 7, 8, 9 haben als DM-Wert die führende Ziffer 1, d. h. nach der Multiplikation mit 2 wäre $P(1) = \frac{5}{9}$.

Alleine damit ist schon klar, dass hier 1, . . . , 9 als führende Ziffern nicht mehr gleich wahrscheinlich sein können, die Anfangsziffer 1 ist deutlich bevorzugt! D. h. die **Gleichverteilung** als Verteilungsgesetz zwischen der Ziffern 1, . . . , 9 ist **nicht skaleninvariant!**

Begründung, warum die Skaleninvarianz der Messwerte zu gleichverteilten Logarithmen führt

Wir interessieren uns für die erste Ziffer von positiven reellen Messwerten Z (wobei wir führende Nullen nicht zählen). Es bietet sich also die so genannte „wissenschaftliche“ Schreibweise von Zahlen an („Gleitkommazahl“): $Z = M \cdot 10^n$, wobei $1 \leq M < 10$ ist¹² („Mantisse“). So kann man alle positiven Zahlen darstellen. Diese Schreibweise hat den Vorteil, dass die interessierende Ziffer einfach die 1. Ziffer von M ist, denn M hat keine führenden Nullen. Indem wir statt Z nur mehr die zugehörige Mantisse M betrachten, befreien wir uns sozusagen von den – hier nur lästigen – Zehnerpotenzen, die für das Problem der Anfangsziffer ja irrelevant sind.

Multiplikationen mit $s \in \mathbb{R}^+$ bewirken in der Welt der Zahlen $Z \in \mathbb{R}^+$ (bis auf 10er-Potenzen) genau dasselbe wie in der Welt der Mantissen $M \in [1, 10)$. Damit ist sehr

¹⁰Dieser Wert variiert natürlich von Tag zu Tag.

¹¹So würde es die ursprüngliche Intuition eigentlich nahe legen: $P(1) = \dots = P(9) = \frac{1}{9}$

¹²So wie Z kann auch M als Zufallsvariable aufgefasst werden, deswegen wieder ein Großbuchstabe.

einleuchtend¹³: Wenn die Verteilungsgesetze von Z und $Z \cdot s$ gleich sind („Skaleninvarianz“), dann sind es auch jene von M und $M \cdot s$ ¹⁴.

Wenn das Verteilungsgesetz für M skaleninvariant ist (d. h. die Verteilungsgesetze für M und $M \cdot s$ sind gleich), dann müssen auch die Verteilungsgesetze von $\lg M$ und $\lg(M \cdot s)$ gleich sein. Wegen $\lg(M \cdot s) = \underbrace{\lg M}_{=:Y} + \underbrace{\lg s}_{=:c}$ bedeutet dies, dass das Verteilungsgesetz unverändert bleiben muss, wenn man eine beliebige Konstante c addiert: die Größen Y und $Y + c$ haben für alle $c \in \mathbb{R}$ dasselbe Verteilungsgesetz¹⁵.

Es ist aber bedeutend leichter die Frage zu beantworten, welche Verteilungsgesetze durch beliebige *Additionen* unverändert bleiben, als die ursprüngliche Frage, welche Verteilungsgesetze durch beliebige *Multiplikationen* unverändert bleiben.

Verteilungsgesetze können durch Dichtefunktionen¹⁶ beschrieben werden, wobei sich zugehörige Wahrscheinlichkeiten als Flächeninhalte unter diesen Dichtefunktionen berechnen lassen.

Nun ist sehr *plausibel*, dass nur die konstante Funktion als Dichtefunktion so eines Verteilungsgesetzes in Frage kommt, das durch beliebige Additionen (d. h. horizontale Verschiebungen) nicht verändert wird – siehe Fig. 3a. Wie sonst sollte man jemals erreichen, dass sich die Dichtefunktion des zugrunde liegenden Verteilungsgesetzes durch beliebiges horizontales Verschieben nicht ändert¹⁷? Der konstante Funktionswert der Dichte muss 1 sein, da der mögliche Bereich für $Y = \lg M$ die Länge 1 hat und der Gesamtflächeninhalt unter der Dichtefunktion den Wert 1 haben muss (= „gesamte Wahrscheinlichkeitsmasse“).

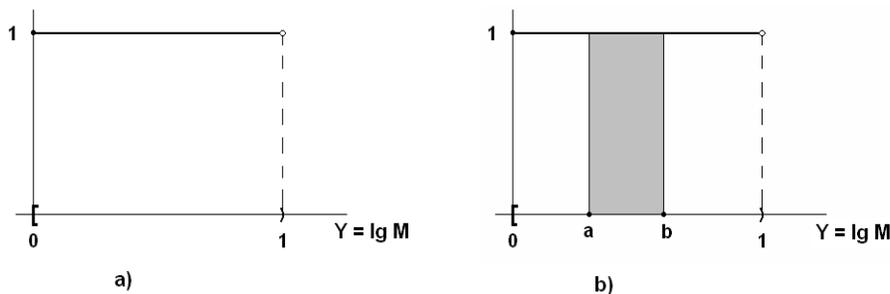


Fig. 3: Dichte der Gleichverteilung auf von $Y = \lg M$ auf $[0; 1)$

Die Sache ist jetzt schon deutlich einfacher, denn mit dieser konstanten Dichte („Gleichverteilung“) lassen sich Wahrscheinlichkeiten der Art $P(a \leq Y < b)$ besonders leicht

¹³Für genauere Ausführungen dazu bräuchte man Maßtheorie, die hier aber vermieden werden soll.

¹⁴Wenn der Wert von $M \cdot s$ dabei nicht in $[1, 10)$ liegen sollte, so muss man dabei erneut die *Mantisse* bilden, z. B. hat man also für $M = 9$ und $s = 2$ bei $M \cdot s$ an 1,8 zu denken!

¹⁵Bei $Y + c$ muss man dabei eigentlich „modulo 1“ denken, damit $Y + c$ wieder dieselbe Wertemenge $[0; 1)$ wie Y hat.

¹⁶Diskrete Verteilungen kommen für $Z \in \mathbb{R}^+$ nicht in Frage, jedes Intervall soll ja positive Wahrscheinlichkeit haben.

¹⁷Natürlich wieder modulo 1 gedacht, d. h. jener Teil des Graphen der Dichtefunktion, der beim Verschieben den Bereich $[0; 1)$ auf *einer* Seite verlässt, wandert auf der *anderen* Seite wieder herein – siehe Fig. 3. Man könnte auch einen *formalen Beweis* für diese Tatsache führen, dass hier nur die konstante Funktion in Frage kommt.

ausrechnen (Flächeninhalt unter der Dichtefunktion zwischen a und b – siehe Fig. 3b):
 $P(a \leq Y < b) = (b - a) \cdot 1 = b - a$.

Damit können wir die gewünschten Wahrscheinlichkeiten bestimmen, für alle Ziffern $d = 1, \dots, 9$ ergibt sich unmittelbar:

$$P(\text{1. Ziffer von } Z = d) = P(\text{1. Ziffer von } M = d) = P(d \leq M < d + 1) =$$

$$P(\underbrace{\lg d \leq \lg M < \lg(d + 1)}_Y) = \boxed{\lg(d + 1) - \lg d} \quad - \quad \text{das BENFORD-Gesetz!}$$

Die Gleichverteilung der logarithmierten Werte ist hiermit also aus der Annahme der Skaleninvarianz der Messwerte abgeleitet. Die Lücke in der obigen, anschaulichen, zunächst nur vordergründigen Argumentation ist also geschlossen! Das oben noch ausstehende „Warum sind die logarithmierten Werte gleichverteilt?“ kann also beantwortet werden mit: Wegen der Skaleninvarianz der Messwerte! Diese Forderung erscheint vernünftig und kann nicht weiter bewiesen werden.

In Fig. 4 wird beides gleichzeitig dargestellt: die Gleichverteilung von $Y := \lg M$ auf $[0; 1)$ und die daraus (von unten nach oben!) resultierende „logarithmische“ Verteilung von M auf $[1; 10)$. Darin sind auch schön die immer kleiner werdenden relativen Anteile der Ziffern $d = 1, \dots, 9$ zu sehen: $P(\text{1. Ziffer von } Z = d) = \lg(d + 1) - \lg d$.

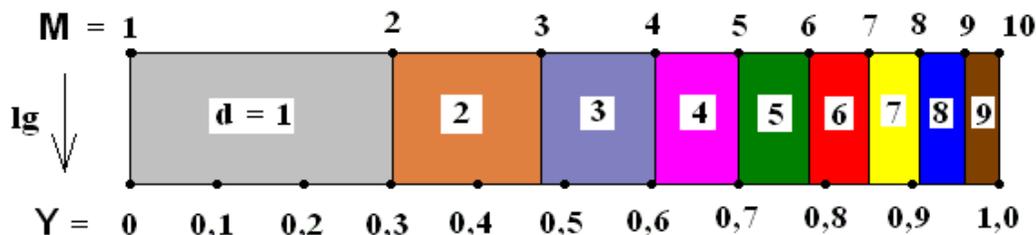


Fig. 4: Gleichverteilung von $Y := \lg M$ auf $[0; 1)$ bzw. die Verteilung von M auf $[1; 10)$ – „logarithmisch“

Arithmetisches versus geometrisches Zählen

Wir Menschen zählen bekanntlich in arithmetischer Folge

$$0 \xrightarrow{+1} 1 \xrightarrow{+1} 2 \xrightarrow{+1} 3 \dots$$

mit konstanten Differenzen (konstantes absolutes Wachstum, additives Zählprinzip). Wir drücken Verschiedenheiten aber oft auch durch Quotienten (Verhältnisse) aus, wobei hier nicht das additive (arithmetische), sondern das „multiplikative (geometrische) Zählprinzip“ im Vordergrund steht.

Es gibt viele Phänomene (insbesondere Wachstumsphänomene, auch beim Tasten, Hören und Sehen, d. h. generell beim Empfinden¹⁸), bei denen auch die Natur quasi geometrisch

¹⁸Vgl. die Lautstärkeeinheiten „Bel“ bzw. „Dezibel“, bei denen in Logarithmen gedacht werden muss. Auch bei der Tonhöhe werden Unterschiede als gleich wahrgenommen, wenn die Töne dasselbe Frequenzverhältnis haben. Dies alles wird subsumiert unter „Weber-Fechner’sches Grundgesetz“.

zählt, d. h. von Schritt zu Schritt immer mit einer Konstanten multipliziert:

$$\underbrace{a \cdot q^0}_a \xrightarrow{\cdot q} a \cdot q^1 \xrightarrow{\cdot q} a \cdot q^2 \xrightarrow{\cdot q} a \cdot q^3 \dots$$

Dies entspricht einem konstanten relativen Wachstum. Solche Werte haben dann die Eigenschaft, dass sich die logarithmierten Werte um eine additive Konstante unterscheiden:

$$\log a \xrightarrow{+\log q} \log a + \log q \xrightarrow{+\log q} \log a + 2 \log q \xrightarrow{+\log q} \log a + 3 \log q \dots$$

Wenn diese Werte (nach dem Logarithmieren) gleichverteilt sind, was man aus der Forderung nach Skaleninvarianz bei den ursprünglichen Werten folgern kann, schlägt in diesen Situationen „naturgemäß“ das BENFORD-Gesetz voll zu – siehe oben.

STEWART (1994, S.20) schreibt dazu: „Wir Menschen zählen in arithmetischer Folge 1, 2, 3, ... und wundern uns, ungleiche Wahrscheinlichkeiten für die Anfangsziffern zu finden. Aber das lässt sich dadurch erklären, dass die Natur mit gleichen Wahrscheinlichkeiten unter den Termen einer geometrischen Folge wählt x, x^2, x^3, \dots “. Diese Aussage erklärt aber noch nicht, warum daraus das BENFORD-Gesetz folgt. Die vernünftig scheinende *Forderung nach Skaleninvarianz* ist eine mögliche Erklärung dafür.

So wie oben die Werte erst nach dem Logarithmieren *gleichverteilt* waren (man könnte von einer „Log-Gleichverteilung“ sprechen), so trifft man statt der gewöhnlichen Normalverteilung oft auch auf die so genannte Log-Normalverteilung (d. h. die entsprechenden Werte sind erst nach Logarithmieren *normalverteilt*): z. B. Durchmesser von Bäumen, Durchmesser von Bakterien, Partikelgrößen in Eis oder Wasserwolken, etc.

4 Anwendungen

Das BENFORD-Gesetz über die Häufigkeit der 1. Ziffer von Zahlen ist ein interessantes und überraschendes Resultat. Aber hat es auch reale Anwendungen? Kann man dieses Wissen irgendwo mit Nutzen einsetzen? Wenn jemand allzustark an das BENFORD-Gesetz glaubt, könnte er ja meinen, dass auch beim Lottospielen Zahlen mit Anfangsziffer 1 bevorzugt seien. Aber das ist nicht der Fall: Jede Zahl aus $\{1, \dots, 45\}$ hat bei den Ziehungen dieselbe Chance, es „herrscht“ einfach jedes Mal aufs Neue der „neutrale Zufall“. Das BENFORD-Gesetz hilft nicht, um bessere Tipps beim Lotto zu erhalten, leider!

Der amerikanische Mathematiker Mark NIGRINI hat dieses Gesetz erst Anfang der 90-er Jahre der Öffentlichkeit bekannt gemacht, indem er Anwendungen dieses Gesetzes in die Tat umgesetzt hat. Wenn z. B. Steuerpflichtige (große Betriebe mit wirklich vielen Daten) ihre Steuererklärung beim Finanzamt einreichen, so sind die Daten in manchen Fällen ja etwas manipuliert: Gewisse Daten wurden vielleicht verändert, einige wurden erfunden, andere gestrichen etc. In vielen Fällen tendieren Manipulateure dazu, bei ihren erfundenen Zahlen die Anfangsziffern 1, ..., 9 relativ gleichmäßig zu benutzen, nicht zu kleine aber auch nicht zu große Anfangsziffern zu wählen, also z. B. sehr viele mit 4, 5, 6 beginnen zu lassen. Dies führt dazu, dass die 1 (oder auch die 2) als Anfangsziffer im Vergleich zum BENFORD-Gesetz zu selten auftritt.

Mark NIGRINI hat eine Software entwickelt, die überprüft, ob irgendwelche übermittelten Daten dem BENFORD-Gesetz „gehören“. Diese Software wird schon vielfach eingesetzt in Amerika, Deutschland und in der Schweiz. Wenn ein Datensatz das BENFORD-Gesetz zu schlecht erfüllt, so ist dies natürlich kein Beweis, dass die Daten gefälscht sind, aber es können die Alarmglocken läuten, und eine genauere Untersuchung (Steuerprüfung) kann veranlasst werden. Auch die Steuererklärungen von Bill Clinton und Bill Gates wurden angeblich mit Nigrinis Programm überprüft, es ergaben sich dabei aber keine Anzeichen von Steuerbetrug (siehe WALTHOE).

Bei der Entdeckung so mancher berühmter gefälschter Bilanzen, z. B. bei den Riesenskandalen (2002) um die Bilanzfälschungen von *Enron* und *Worldcom*, bei denen unzählige Anleger um ihr Kapital betrogen wurden, war angeblich eine BENFORD-Überprüfung (Wikipedia-Artikel zum BENFORD-Gesetz) mit im Spiel.

Es ist gar nicht so leicht, Daten „passend“ zu manipulieren, denn es gibt nicht nur ein Verteilungsgesetz für die 1. Ziffer von Zahlen, sondern auch welche für die nachfolgenden Ziffern, aber da sind die Unterschiede zwischen den einzelnen Ziffern 1, . . . , 9 nicht mehr ganz so groß wie bei der 1. Ziffer. Die Ziffern folgen umso besser einer Gleichverteilung, je kleiner ihr Stellenwert ist. Wir geben in Tab 2 nur die Werte ohne Begründung an (die zugehörige Formel zur Berechnung ist z. B. im Wikipedia-Artikel über das BENFORD-Gesetz zu lesen).

Ziffer	0	1	2	3	4	5	6	7	8	9
1. Ziffer		0,301	0,176	0,125	0,097	0,079	0,067	0,058	0,051	0,046
2. Ziffer	0,120	0,114	0,109	0,104	0,100	0,097	0,093	0,090	0,088	0,085
3. Ziffer	0,1018	0,1014	0,1010	0,1006	0,1002	0,0998	0,0994	0,0990	0,0986	0,0983

Tab. 2: Wahrscheinlichkeiten für die Ziffern

Außerdem muss ein professioneller Fälscher noch einer Reihe anderer stochastischer Gesetzmäßigkeiten Rechnung tragen (z. B. Häufigkeit von Ziffernpaaren). Trimmt der Datenfälscher die Daten allzu genau auf die theoretische Erwartung aus dem BENFORD-Gesetz hin, besteht Gefahr, dass die Manipulationen eben daran erkannt werden!

Manche Daten passen aber auch ungefälscht nicht zum BENFORD-Gesetz, eine Verletzung des BENFORD-Gesetzes ist eben nie ein Beweis, sondern nur ein Hinweis darauf, dass die Daten gefälscht sein könnten. Man denke z. B. auch an Preise (von denen ja auch viele in Bilanzen und Steuererklärungen vorkommen); hier sind oft aus psychologischen Gründen Werte knapp unterhalb von Zehnerpotenzen deutlich häufiger anzutreffen (9,90 oder 99,90 etc.), so dass die 9 als führende Ziffer auch in ungefälschten Verkaufsbilanzen häufiger vorkommen wird als ihr laut BENFORD-Gesetz zusteht.

Es gibt noch so manche andere Anwendung des BENFORD-Gesetzes. In der Wissenschaft kann das BENFORD-Gesetz helfen zu erkennen, ob ein „übereifriger“ Wissenschaftler (z. B. aus dem Drang heraus, durch ein *signifikantes* Ergebnis mehr Aufmerksamkeit zu erregen) seinen Daten zur Signifikanz etwas nachgeholfen hat. In Belgien arbeitet man daran, Ungereimtheiten bei Krankenhausabrechnungen auf die Spur zu kommen, in Freiburg wird angeblich (vgl. WALTHOE u. a.) auch daran gearbeitet, die Verwaltung von Speicherplatz auf Festplatten mit Hilfe des BENFORD-Gesetzes zu optimieren¹⁹. Die Anwendungen des BENFORD-Gesetzes scheinen also immer weitere Kreise zu ziehen.

¹⁹Ich weiß nicht genau, wie.

5 Zusammenfassung und Ausblick

Empirische Daten legen es nahe, dass es ein stabiles Verteilungsgesetz für die Häufigkeit des Auftretens der 1. Ziffer von Zahlen gibt, und diese Daten sprechen auch dafür, dass diese Verteilung sich in der Nähe des BENFORD-Gesetzes befindet. Wenn es ein stochastisches Gesetz gibt, dann muss es wohl unabhängig von den zugrunde gelegten Skalen sein. Es würde doch sehr befremdlich anmuten zu sagen: „Dass die Daten so gut der BENFORD-Verteilung folgen, liegt nur an der (zufällig genau passenden??) Wahl der Einheiten, bei anderen Einheiten gäbe es das BENFORD-Gesetz gar nicht.“ Durch Umwandlung der Datenmengen in andere Einheiten könnte man dies auch widerlegen und bestätigen, dass das BENFORD-Gesetz auch dann weiterhin Gültigkeit hat.

Wenn nur das Verteilungsgesetz der Zahl Z selbst und damit der Mantisse M (in wissenschaftlicher Schreibweise) skaleninvariant ist (und das ist eine sehr vernünftige bzw. plausible Annahme), dann sind die logarithmierten (Mantissen-) Werte gleichverteilt, woraus das BENFORD-Gesetz unmittelbar folgt.

Es gibt also keine Alternative zum BENFORD-Gesetz, außer *kein* Gesetz (dagegen sprechen aber empirische Daten).

Am Ergebnis und an der prinzipiellen Vorgangsweise ändert sich nichts, wenn man realitätschererweise nicht \mathbb{R}^+ , sondern \mathbb{Q}^+ (oder gar nur die *endlichen* Dezimalzahlen) als das mögliche Universum aller physikalischen Konstanten ansieht (bei allen in Dezimalschreibweise angegebenen Werten aller möglichen Tabellen können ja nur endlich viele Stellen berücksichtigt werden).

Das BENFORD-Gesetz hat mit der Darstellung im *Dezimalsystem* **nichts** zu tun. Auch bei Darstellungen mit jeder anderen natürlichen Zahl $a > 2$ als Basis ergäbe sich ein analoges Gesetz für die Wahrscheinlichkeit, dass eine Zahl mit einer Ziffer d beginnt: $P(Z \in Z_d) = \log_a(d+1) - \log_a(d)$ für $d = 1, 2, 3, \dots, a-1$.

Zum unterrichtlichen Einsatz

In einem Wahlpflichtfach kann ein interessantes und überraschendes Phänomen (kaum jemand wird dies intuitiv vermuten) mit relativ wenig Formalaufwand (keine Maßtheorie) begründet und plausibel gemacht werden, so dass zugehöriges wirkliches Verständnis ermöglicht wird. Das Thema eignet sich auch für eine Fachbereichsarbeit.

Im Unterricht ist die hier angedeutete „elementarmathematische Begründung“ (und auch die anderen möglichen!) *nicht* in erster Linie für eine *selbständige* Auseinandersetzung der Schülerinnen und Schüler gedacht, hier wird viel Lenkung durch die Lehrkraft notwendig sein. Aber auch solche Phasen im Unterricht muss es geben (neben jenen, in denen die Lernenden selbständig arbeiten).

Sehr wohl können sich aber Lernende selbständig einbringen, indem sie Informationen über das Gesetz und seine Anwendungen sammeln (z. B. Internet, Literatur) und darüber ein kurzes Referat halten. Auch eine Google-Recherche lädt zum selbständigen Experimentieren ein.

Literatur:

- ALBRECHT, J. (2000): Die Eins von Planet Zob. Die Zeit (40, 28. 09. 2000), 35.
- BENFORD, F. (1938): The law of anomalous numbers. In: Proceedings of the American Philosophical Society **78**, 551–572.
- DWORSCHAK, M. (1998): Weiter Weg zur Zwei – ein kurioses Gesetz der Wahrscheinlichkeitstheorie kann Finanzbeamten helfen, Steuersünder aufzuspüren. In: Der Spiegel 47/1998, 228–229.
- HUMENBERGER, H. (1996): Das BENFORD-Gesetz über die Verteilung der ersten Ziffer von Zahlen. In: Stochastik in der Schule **16**, 3, 2–17. Kurzfassung: Beiträge zum Mathematikunterricht 1997, 251–254.
- HUMENBERGER, H. (1997): Eine Ergänzung zum BENFORD-Gesetz — weitere mögliche schulrelevante Aspekte. In: Stochastik in der Schule **17**, 3, 42–48.
- HUMENBERGER, H. (2000): Das „BENFORD-Gesetz“ — warum ist die Eins als führende Ziffer von Zahlen bevorzugt? (Überarbeitete und kombinierte Version von HUMENBERGER 1996 und 1997.) In: HENN, H.W., F. FÖRSTER u. J. MEYER (Hrsg., 2000): Materialien für einen realitätsbezogenen Mathematikunterricht, Band 6, 138–150. Schriftenreihe der ISTRON-Gruppe, Franzbecker, Hildesheim.
- MATTHEWS R. (1999): The power of one. In: New Scientist 2194 (July 10), 27–30.
- NIGRINI, M. (2000): Digital Analysis Using Benford’s Law: Tests & Statistics for Auditors. Global Audit Publications, Vancouver.
- PINKHAM, R.S. (1961): On the distribution of first significant digits. In: Annals of Mathematical Statistics **32**, 1223–1230.
- STEWART (1994): Mathematische Unterhaltungen. In: Spektrum der Wissenschaft (April 1994), 16–20.
- WALTHOE, J., R. HUNT u. M. PEARSON: Looking out for number one. Internet: <http://plus.maths.org/issue9/features/benford/>

Anschrift des Verfassers:

Hans HUMENBERGER, Fakultät für Mathematik, Universität Wien, Nordbergstraße 15 (UZA 4), A – 1090 Wien

Mail: Hans.Humenberger@univie.ac.at