

Tagebuch 26.2.

Heute Kapitel 6: "Umgang mit Datensätzen" begonnen.
 Besprochen wurde Kap. 6.1 und Kap. 6.2 sowie die erste Computersimulation

Verstanden zu **merkende Formeln:**

Mittelwert, Streuung der Daten um das Datenmittel
 Schätzung der Datenstreuung um den wahren Wert
 Schätzung der Streuung der Mittelwerte um den wahren Wert!

Nachfolgend ein eigener Datensatz zur Pendelschwingungsdauer. In der ersten Spalte die wie angegeben vermessene Pendellänge (in cm) und rechts die Dauer von 20 Schwingungen (in s).

	10	14.5
	020.5	20.25
	34	24.5
	47	28.75
$D =$	62.5	32.5
	69	34.25
	73	35.75
	85	38.75
	113	43
	155.5	50

In diesem Datensatz wurden die letzten drei Längen etwas ungenau und unachtsam vermessen.


Von Ihrer Seite wurde - vollkommen zu recht - vorgeschlagen, nach der Pendellänge aufzulösen und diese soden über T und $g=9.81\text{cm/s}^2$ effektiv zu bestimmen. Das gibt mit $L = \left(\frac{T}{2\pi \cdot 20}\right)^2 981$ folgende Liste effektiver Längen, von der wir sogleich die gemessenen Längen subtrahieren:

13.061	10	3.061
25.474	020.5	4.974
37.289	34	3.289
51.349	47	4.349
65.617	62.5	3.117
72.873	69	3.873
79.396	73	6.396
93.281	85	8.281
114.86	113	1.86
155.31	155.5	-0.19


Und das heißt, die vermessenen Längen sind alle etwa 3-4cm zu kurz. Das zugehörige mathematische Pendel hat eine etwa größere Längen. Mittelwert 3.9

Verschiedene graphische Auftraggungen


Die daten einfach aufgetragen mit der Funktion $T=T(L)$




Und jetzt mit mit $T=20 \cdot 2\pi \sqrt{\frac{L-4}{g}}$. Man sieht die verbesserte Übereinstimmung



Zwei Datensätze wurden mir von Ihrer Seite abgeliefert. diese sind in der nachfolgenden Figur mit eingetragen:



Man sieht auch hier: Die Werte sind systematisch zu hoch. Oder auch: Das mathematische Ersatzpendel muss eine etwa 3-4cm größere Länge haben. Und das ist deutlich größer als der Abstand des Aufhängepunktes zum Schwerpunkt, der etwa 2cm beträgt.



27.2.

Verstanden zu **merkende Formeln aus Kap. 6:**

Mittelwert, Streuung der Daten um das Datenmittel


Schätzung der Datenstreuung um den wahren Wert

Schätzung der Streuung der Mittelwerte um den wahren Wert!

Es werden zwei gleichverteilte Zufallszahlen zwischen 0 und 1 gezogen und deren Summe gebildet. Dieser Vorgang wird N-mal wiederholt. Das ergibt einen Datensatz vom Auszählungstyp.

- a) Welche Werte sind möglich? (Alle zwischen 0 und 1)
- b) Was für eine Verteilung der Werte ist zu erwarten? ("Dreiecksverteilung")
 - b1) Bei einer mittigen Einteilung des Wertebereiches in 2 Teile
 - b2) In sehr viele Teile
- b3) Wie sollte die Verteilung der relativen Häufigkeiten für sehr große N ($N \rightarrow \infty$) aussehen?
- c) Was ändert sich, wenn man die Summe von drei derartigen Zufallszahlen bildet?

▼ Hierzu zwei Bilder, einmal für die Summe aus zwei, einmal aus drei Zufallszahlen:



In beiden Fällen erfolgt eine Auszählung in 200 Häuser. Schwarz noch die relativen Häufigkeiten, die sich mit wachsendem N nur wenig ändern.

Wir gehen aus von der Linsenformel und nehmen an, dass die Brennweite f der Linse nur ungenau bekannt sei: $f_0 \pm \Delta f$. Dagegen sei g genau bekannt. Welche Ungenauigkeit bewirkt das für die Bildweite? Wie kann man diese Ungenauigkeit näherungsweise bestimmen?

f ist veränderlich, also unabh. Variable. Abhängig ist b . Also die Linsenformel *nach* b umstellen zu $b = b_g(f)$. Die von der Ungenauigkeit von f bewirkte ungenausigkeit in b ist gegeben durch

$$b_g(f_0 \pm \Delta f) - b_g(f_0) \approx \pm \frac{db_g}{df}(f_0) \Delta f.$$

wobei wir näherungsweise die mittlere Änderungsrate durch die momentane ersetzen können. Rechnerisch ist


$$b = b(f) = \frac{gf}{g-f} \quad \frac{db}{df}(f) = \frac{g(g-f) - gf(-1)}{(g-f)^2} = \frac{g^2}{(g-f)^2}.$$

Wir gehen aus von der Formel für die Schwingungsdauer des Pendels. Bilden Sie von beiden Seiten der Gleichung den Logarithmus.

$$T = 2\pi g^{-\frac{1}{2}} L^{\frac{1}{2}} \quad \underbrace{\log(T)}_y = \log(2\pi g^{-\frac{1}{2}}) + \frac{1}{2} \underbrace{\log(L)}_x$$

Was erwarten Sie daher, wenn man einen Datensatz (Pendellänge, zugeh. Schwingungsdauer) doppelt logarithmisch aufträgt? Was für ein Graph entsteht? Der einer Gerade mit Steigung $\frac{1}{2}$

Die folgende figur zeigt das Resultat für den am Vortag gegebenen Datensatz. Mit eingetragen ist die vorhergesagte Gerade $\log T = b + \frac{1}{2} \log L$ mit $b = \log \frac{20 \cdot 2\pi}{\sqrt{981}}$. (Die Daten sind in cm und Sekunden angegeben.)



Eine Aufgabe. zum relativem Fehler.

□ Wir ersetzen $\sin(x)$ durch x .

a) Was für ein absoluter Fehler wird bei dieser Ersetzung gemacht ($AF = \sin(x) - x$...)

b) Bestimmen Sie die beiden relativen Fehler dieser Ersetzung: ($RF_W = \frac{\sin(x) - x}{\sin(x)}$..., $RF_S = \frac{\sin(x) - x}{x}$)

Bemerkung: Gemeint ist in der Regel die erste Größe. Meist hat man aber Werte zur Bestimmung der zweiten. Dann nimmt man diese als Schätzung für die erste. Der Unterschied ist meist nicht groß und für die üblichen Fragestellungen unwichtig. Index W für "wahr" und S für "Schätzung".

c) Welcher Fehler wird gemacht, wenn man RF_W durch RF_S ersetzt?

$$AFF = \frac{\sin(x) - x}{\sin(x)} - \frac{\sin(x) - x}{x} = -\frac{-2(\sin x)x + x^2 + \sin^2 x}{(\sin x)x}$$

d) Einsetzen einiger Zahlwerte. Wähle $x=0.3$ und $x=0.8$

$$\begin{array}{ccc} \frac{\sin(.3) - .3}{\sin(.3)} & \frac{\sin(.8) - .8}{\sin(.8)} & -4.4798 \times 10^{-3} \quad -8.2644 \times 10^{-2} \\ \frac{\sin(.3) - .3}{\sin(.3)} & \frac{\sin(.8) - .8}{\sin(.8)} & = -1.5159 \times 10^{-2} \quad -0.11521 \\ \frac{\sin(.3) - .3}{\sin(.3)} - \frac{\sin(.3) - .3}{.3} & \frac{\sin(.8) - .8}{\sin(.8)} - \frac{\sin(.8) - .8}{.8} & = -1.4933 \times 10^{-2} \quad -0.1033 \\ \frac{\sin(.3) - .3}{\sin(.3)} - \frac{\sin(.3) - .3}{.3} & \frac{\sin(.8) - .8}{\sin(.8)} - \frac{\sin(.8) - .8}{.8} & = -2.2636 \times 10^{-4} \quad -1.1901 \times 10^{-2} \end{array}$$

Die logarithmische Auftragung des Einzelfehlers (als Funktion der Schrittweite Δx wurde diskutiert und in einer animation gezeigt!

$$\text{Einzelfehler } \boxed{EF=c\Delta x^2}$$

$$\boxed{\log(EF)} = \log(c) + 2 \boxed{\log(\Delta x)}$$

In der ersten Aufgabe von Freitag lag ein Schreibfehler vor, den man auf zwei Weisen interpretieren konnte. Ein Klammerzeichen fehlte. Wir bestimmen die Ableitung für beide Interpretationen.

Die erste richtige Interpretation:

$$\vec{r}_2(t) = \begin{pmatrix} \cos(\varphi(t)) \cdot \sin(\theta(t)) \\ \sin(\varphi(t)) \cdot \sin(\theta(t)) \\ \cos(\theta(t)) \end{pmatrix}$$

Rechnung, ohne Zwischenrechnung. Zuvor Strategietüberlegung über die Form des Ergebnisses und den Weg dahin: :

$$\vec{v}_2(t) = \dot{\theta}(t) \begin{pmatrix} \cos \theta(t) \cos \varphi(t) \\ \cos \theta(t) \sin \varphi(t) \\ -\sin \theta(t) \end{pmatrix} + \dot{\varphi}(t) \sin \theta(t) \begin{pmatrix} -\sin \varphi(t) \\ \cos \varphi(t) \\ 0 \end{pmatrix}$$

Und jetzt die andere nicht gemeinte Interpretation:

$$\vec{r}_2(t) = \begin{pmatrix} \sin(\theta(t)) \cdot \cos \varphi(t) \\ \sin(\theta(t)) \cdot \sin \varphi(t) \\ \cos \theta(t) \end{pmatrix}$$

Strategietüberlegung: Erst innere Ableitung \times dann äußere:

$$\vec{v}(t) = \begin{pmatrix} \cos(\theta(t)) \cdot \cos \varphi(t) \cdot [\dot{\theta}(t) \cos \varphi(t) + (-\dot{\varphi}(t)) \sin \varphi(t)] \\ \cos(\theta(t)) \cdot \sin \varphi(t) \cdot [\dot{\theta}(t) \sin \varphi(t) + (\dot{\varphi}(t)) \cos \varphi(t)] \\ -\dot{\theta}(t) \sin \theta(t) \end{pmatrix}$$

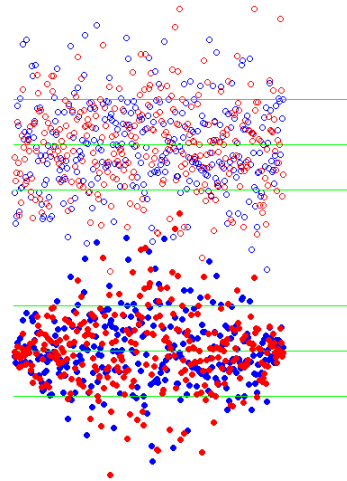

Stoff:

Das wichtige Kapitel 6.6 durchgesprochen! Wie genau schätzt eine absolute Häufigkeit einen wahren Wert?

Sei N_i der ausgezählte Wert und $p_i N$ der wahre oder der vorhergesagte Wert. Bilde dazu die Koordinatengröße $\frac{N_i - p_i N}{\sqrt{N_i}}$ bzw. deren Quadrat. Bedeutung dieser Größe?

Dazu eine Computeranimation gezeigt:

Die oberen Punkte der Animation bestimmten diese Werte. Sie liegen immer im und in der Nähe des Intervalles $-2 < w < 2$. Die Animation zeigt, dass das für ganz unterschiedliche Werte von N und N_i der Fall ist. In der unteren Verteilung ist $N=20000$ und in der oberen ist $N=2000000$. Unten rechts sind die absoluten Fehler aufgetragen, wobei die zur oberen Verteilung gehörigen um einen Faktor $10 = \sqrt{100}$ herabskaliert sind. Oben sind die Koordinatengrößen $\frac{N_i - p_i N}{\sqrt{N_i}}$ für beide Fälle im Bereich $-1 < w < 1$ aufgetragen (grüne Linien!)



28.2.

Zunächst: Einige Warmdenkübungen gerechnet. Erneut das Problem: Die zusammengefassten Ergebnisse des Vortages sollten verfügbar sein. Klappte nicht. Probleme bei der vierten aufgaben


Dann das Thema lineare Regression nach Skript. Wie macht man sich einen solchen Text zugänglich, insbesondere die Resultate. Geübt: Formel oder Rechnung anschauen, abdecken und selbst rekonstruieren.

Nach der Pause: Nochmals die einleitende Zusammenfassung des Kurses durchgegangen, was ist zu merken, wie geht man an die Probleme heran. Sah etwas besser aus, aber nach einiger Zeit machten sich Ermüdungsercheinungen bemerkbar!

□ 1) Gegeben ein Datensatz a von Zahlpaaren:

1	2	3	4
(0.5, 1.6)	(2, 3.2)	(3, 4.0)	(5, 6.3)

- Skizzieren Sie den Datensatz als "Punkteschwarm" in der Ebene,
- Zeichnen Sie "per Augenmaß" eine passende Gerade hinein und schätzen Sie die Werte für m und b . (Lineal, kariertes Papier, Schnell! 2-3 Minuten)



c) Bestimmen Sie rechnerisch die Lage des Schwerpunktes und zeichnen Sie ihn mit ein.

□ 2) Sie messen die jeweilige Länge von $N=475$ Werkstücken aus. Sie finden, dass davon $n=25$ einen zu großen Wert haben. Erlaubt ist eine relative Häufigkeit $h_A = 0.08$...Ist der von Ihnen gefundene Wert akzeptabel oder nicht? **Erst** allgemeine Formel, dann die speziellen Zahlenwerte!

▼ Man benötigt an bestehenden Formeln bzw. Ausdrücken: $N \pm \sqrt{N}$ und $\Delta N = h_A \cdot N$.▲

□ 3) Sie messen die jeweilige Länge von $N=475$ Werkstücken aus. Sie finden, dass davon $n=25$ einen zu großen Wert haben. Was erwarten Sie nach der Fluktuationsregel, für eine Messung weiterer 475 Werkstücke? Was für eine Messung von 1000 Werkstücken?

□ 4) Sie haben eine vierfache Messung einer gesuchten Größe x_W . Die Resultate sind

1	2	3	4
5.31	5.27	5.33	5.25

Was können Sie über den Wert x_w aussagen, wenn Sie annehmen, dass kein systematischer Fehler vorliegt?

▼ Mittelwert / Für die Ungenauigkeit: $\sigma_{MW}^S = \frac{\sigma_{\text{Daten,wahr}}^S}{\sqrt{N}}$ Antwort: 5.29 ± 0.018 ▲

Herleitung der Formeln für die lineare Regression: Strategie und Notizen:

$$\frac{\partial A}{\partial m}(m, b) = -2 \sum_{i=1}^N x_i (y_i - mx_i - b) \stackrel{!}{=} 0$$

$$\frac{\partial A}{\partial b}(m, b) = -2 \sum_{i=1}^N (y_i - mx_i - b) \stackrel{!}{=} 0$$

$$\sum x_i = N\bar{x} \quad \sum x_i y_i = N(\bar{x}\bar{y}) \quad \sum x_i^2 = N\bar{x}^2$$

$$\sum x_i y_i = m \sum x_i^2 + b \sum x_i$$

$$\sum y_i = m \sum x_i + bN$$

$$(\bar{x}\bar{y}) = m\bar{x}^2 + b\bar{x} \quad (1)$$

$$\bar{y} = m\bar{x} + b \quad (-\bar{x})$$

$$m = \frac{(\bar{x}\bar{y}) - \bar{x}\bar{y}}{\bar{x}^2 - \bar{x}^2}$$

□ Wie groß ist der relative Fehler, den man macht, wenn man anstatt der Schätzung der Streuung um den wahren Wert die übliche Datensatzstreuung nimmt?

▼ Es muss $N > 1$ gelten!

$$\begin{aligned} RF &= \frac{\sigma_{\text{Daten,wahr}}^S - \sigma}{\sigma_{\text{Daten,wahr}}^S} = \frac{\sqrt{\frac{1}{N-1} \sum (a_i - \bar{a})^2} - \sqrt{\frac{1}{N} \sum (a_i - \bar{a})^2}}{\sqrt{\frac{1}{N-1} \sum (a_i - \bar{a})^2}} \\ &= \frac{\sqrt{\frac{1}{N-1}} - \sqrt{\frac{1}{N}}}{\sqrt{\frac{1}{N-1}}} = \frac{\sqrt{N} - \sqrt{N-1}}{\sqrt{N}} = 1 - \sqrt{\frac{N-1}{N}} \\ &= 1 - \sqrt{1 - \frac{1}{N}} \end{aligned}$$

1.3.2007

Die letzten heute besprochenen Aufgaben:

Und wieder zeigt sich, dass viele die vorangegangenen Ergebnisse vergessen hatten. Was ist eine relative Größe? Was eine Auszählung. Wie erhält man numerisch die Lösung einer Differentialgleichung? Welcher Unterschied besteht zwischen Datenstreuung und Streuung der Mittelwerte. usw.

Die heute besprochenen Aufgaben in nicht ausgearbeiteter Form!

Konzept - Endformulierung


Nachfolgend eine Auszählung eines Datensatzes der ersten Ziffer der Einwohnerzahl von Ländern der Welt.

1	2	3	4	5	6	7	8	9
53	27	24	18	18	6	14	13	7
0.29	0.15							
7.3								

- Bestimmen sie die zugehörigen relativen Häufigkeiten $N=180$
- Zeichnen Sie ein Histogramm der Verteilung der absoluten Zahlen
- Bestimmen Sie die Größe der zugehörigen $1-\sigma$ -Fluktuationen und zeichnen Sie diese in die Skizze ein

Die nachfolgende Skizze erfasst einen Sachverhalt aus der Optik.

- Was wird dargestellt?
- Welches zu lösende mathematische Problem entsteht, wenn der Ort des Punktes P, das davon ausgehende schmale Lichtbündel ebenso wie die Form der reflektierenden Kurve vorgegeben ist?
- Formulieren Sie eine Strategie, wie dieses Problem mit Hilfe uns bekannter mathematischer Methoden zu lösen ist.
- (Angenommen die Kurve ist ein Kreis mit Radius R und das Bündel liegt auf der opt. Achse). Dann kennen Sie das Resultat. Nämlich?)



□ Flugparabel: Ein Massenpunkt bewegt sich auf einer Flugparabel. Es gilt $\vec{r}^K(-3) = \begin{pmatrix} 0 \\ 0 \\ h \end{pmatrix}$ und

$$\vec{v}^K(-3) = \begin{pmatrix} 0 \\ 2 \\ 3 \end{pmatrix} \text{ und } \vec{g}^K = \begin{pmatrix} 0 \\ 0 \\ -g \end{pmatrix}.$$

Bestimmen Sie den Ort des Scheitelpunktes (in Form einer Formel).

Zunächst a) Wie sieht die Vorgehensstrategie aus?

$$\vec{r}^K(t) = \vec{r}_1 + \vec{v}_1 T + \frac{1}{2} \vec{g} T^2 \quad T=t-t_1 \quad \text{hier } \boxed{T=t+3}$$

$$\vec{r}^K(t) = \begin{pmatrix} 0 \\ 0 \\ h \end{pmatrix} + \begin{pmatrix} 0 \\ 2 \\ 3 \end{pmatrix} T + \frac{1}{2} \begin{pmatrix} 0 \\ 0 \\ -g \end{pmatrix} T^2 = \begin{pmatrix} 0 \\ 2T(t) \\ h + 3T(t) - \frac{1}{2}gT^2(t) \end{pmatrix}$$

$$\vec{v}^K(t) = \begin{pmatrix} 0 \\ 2 \\ \boxed{3-gT} \end{pmatrix}$$

$$\text{Scheitel: } T_S = \frac{3}{g} \quad t_s = \frac{3}{g} - 3$$

$$\vec{r}^K\left(\frac{3}{g} - 3\right) = \begin{pmatrix} 0 \\ \frac{6}{g} \\ h + \frac{9}{2g} \end{pmatrix} \quad -\frac{1}{2}g\frac{9}{g^2}$$

□ Numerisches Lösen der Differentialgleichungen

Gegeben die Differentialgleichung $\boxed{y'(x) = y^2(x) + x^2}$ mit dem Anfangswert $y(1)=1$.

Bestimmen Sie den Einzelschrittfehler, den Sie im ersten Schritt für $\Delta x = 0.2, 0.1, 0.05$ und 0.025 machen und kommentieren Sie das Resultat. Wieso sollte man wohl $\log(\text{Einzelfehler})$ gegen $\log(\Delta x)$ auftragen.

- Wieso ist diese Aufgabe so nicht lösbar???
- Formulieren Sie das Argument, das zeigte, dass der Gesamtfehler proportional zu Δx ist.
- Wie sieht die Grundformel für die numerische 'Methode aus und das daraus folgende REchenschema? Formel $y(x+\Delta x) = \dots$ Und das Schema für einen Schritt:

$$\begin{array}{lll} x & 1 & 1 + \Delta x \\ y & 1 & 1.4 \\ \frac{dy}{dx}(x_0) & 2 & \\ \frac{dy}{dx}(x_0)\Delta x & 0.4 & \end{array}$$

$$\begin{array}{lll} x & 1 & 1 + \Delta x \\ y & 1 & 1.2 \\ \frac{dy}{dx}(x_0) & 2 & \\ \frac{dy}{dx}(x_0)\Delta x & 0.2 & \end{array}$$

Rechenbeispiel zur Bestimmung einer Regressionsgeraden.

Der Datensatz: Die Formeln für m und b werden aus dem Skriptum genommen. Dann sind eine Reihe von Hilfsgrößen zu berechnen:

$$\bar{x} = \frac{1}{4}(.5 + 1 + 2 + 3) = 1.625$$

$$\bar{y} = \frac{1}{4}(1.1 + 1.9 + 4.3 + 5.5) = 3.2$$

$$\bar{x}^2 = \frac{1}{4}\left(\frac{1}{4} + 1 + 4 + 9\right) = 3.5625$$

$$\bar{y}^2 = \frac{1}{4}(1.1^2 + 1.9^2 + 4.3^2 + 5.5^2) = 13.39$$

$$\bar{x}\bar{y} = \frac{1}{4}(.5 \cdot 1.1 + 1 \cdot 1.9 + 2 \cdot 4.3 + 3 \cdot 5.5) = 6.8875$$

$$: x^2 =$$

$$\frac{1}{4}(1.1^2 + 1.9^2 + 4.3^2 + 5.5^2) = 13.39$$

$$\frac{1}{4}(.5 \cdot 1.1 + 1 \cdot 1.9 + 2 \cdot 4.3 + 3 \cdot 5.5) =$$

$$m = \frac{6.8875 - 3.2 \cdot 1.625}{3.5625 - 1.625^2} = 1.8305$$
