

# Grundlagen der Diagnostik

## Sitzung 9

### **Einzelfalldiagnostik II**



We are happy to share our materials openly:

The content of these Open Educational Resources by Lehrstuhl für Psychologische Methodenlehre und Diagnostik, Ludwig-Maximilians-Universität München is licensed under CC BY-SA 4.0. The CC Attribution-ShareAlike 4.0 International license means that you can reuse or transform the content of our materials for any purpose as long as you cite our original materials and share your derivatives under the same license.

Sitzung	Datum	Thema	Themenblock
1	16.04.26	Einführung I	Definitionen; diagnostischer Prozess; gesetzlicher Rahmen; diagnostische Entscheidungen; Gütekriterien
2	23.04.26	Einführung II	
3	30.04.26	Einführung II fertig	
4	07.05.26	Verhaltensbeobachtung	Verhaltensbeobachtung als diagnostisches Verfahren
/	14.05.26	entfällt wegen Feiertag	
5	21.05.26	Beobachterübereinstimmung I	Maße zur Bestimmung der Übereinstimmung zwischen verschiedenen Beobachtern/Ratern
6	28.05.26	Beobachterübereinstimmung II	
/	04.06.26	<i>entfällt wegen Feiertag</i>	
7	11.06.26	Interviews	Interviews als diagnostisches Verfahren
8	18.06.26	Urteile und Fehler	Diagnostische Urteilsbildung und Güte von Urteilen
9	25.06.26	Einzelfalldiagnostik I	Methoden der Einzelfalldiagnostik aus der frequentistischen und bayesianischen Statistik
10	02.07.26	Einzelfalldiagnostik II	

→ In der heutigen Vorlesung schauen wir uns an, wie wir Vorannahmen in der Einzelfalldiagnostik berücksichtigen können.

# 8. Berücksichtigung von Vorwissen mittels Bayesianischer Statistik

Bei der **Bayesianischen Statistik** handelt es sich um einen alternativen statistischen Ansatz zur frequentistischen Statistik:

- Frequentistisches 95% KI: Wenn man unendliche viele Zufallsstichproben ziehen würde (bzw. in der Einzelfalldiagnostik eine Person unendlich oft testen würde, ohne dass diese sich an die vorherigen Testungen erinnert), enthalten 95% aller gebildeten KIs den wahren Wert.
- Bayesianisches 95% KI: Gegeben meiner Vorannahme (Prior), befindet sich der wahre Wert mit 95% Wahrscheinlichkeit zwischen den errechneten Intervallgrenzen.
  - Ermöglicht den Einbezug von **Vorwissen**, was in der Einzelfalldiagnostik sehr praktisch sein kann!

## Grundprinzipien der Bayesianischen Statistik

„Im Satz von Bayes wird eine bestehende Erkenntnis über den zu untersuchenden Parameter (die *A-priori*-Verteilung, kurz **Prior**) mit den neuen Erkenntnissen aus den Daten kombiniert (**Likelihood**), woraus eine neue, verbesserte Erkenntnis (*A-posteriori*-Verteilung, kurz **Posterior**) resultiert.“ (nach [Wikipedia](#))

$$\text{Posterior} \propto \text{Likelihood} \times \text{Prior}$$

Lies: „Die **Posterior** ist proportional ( $\propto$ ) zum Produkt aus **Likelihood** und **Prior**“

## Grundprinzipien der Bayesianischen Statistik

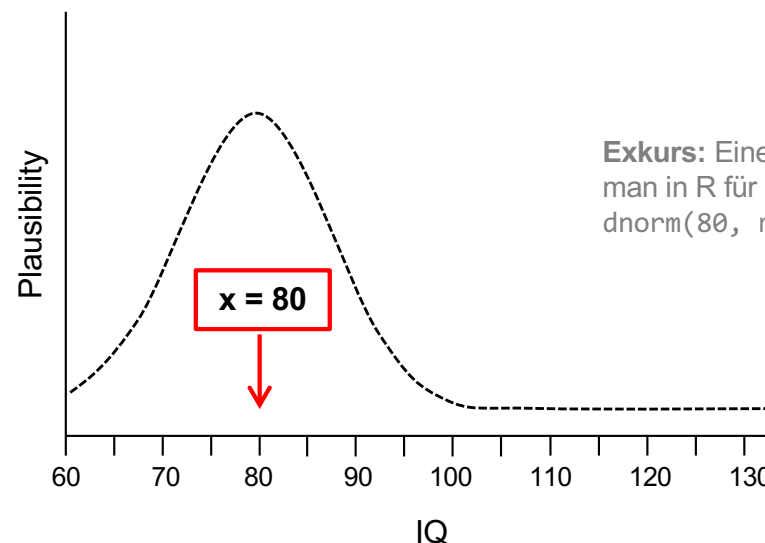
Beispiel:

- Bob hat einen Testwert von 80 IQ-Punkten im Intelligenztest ( $x = 80$ )
- Testwertverteilung:  $X \sim N(\text{IQ}, \sigma_x^2 \cdot (1 - \text{Rel}))$
- Wobei in der Formel...
  - „IQ“ für die **wahre Intelligenz** von Bob steht, die uns eigentlich interessiert
  - „ $\sigma_x^2$ “ für die Varianz des Testwerts steht, in diesem Beispiel 225 wegen IQ-Normwerten
  - „Rel“ für die Reliabilität des Testwerts steht, die als bekannt vorausgesetzt wird
- Die Testwertverteilung entspricht wieder dem vereinfachten Testmodell, welches wir auch zur Berechnung der approximativen frequentistischen Konfidenzintervalle herangezogen haben (siehe LE9).

## Grundprinzipien der Bayesianischen Statistik

### Likelihood

- Verteilungsfunktion, die einer beobachteten Variable zugeordnet ist  
→ „Wie plausibel ist es die tatsächlich vorliegenden Daten zu beobachten gegeben bestimmter Werte für die Modellparameter?“
- Plausibilität einen Testwert von  $x = 80$  zu beobachten in Abhängigkeit von verschiedenen wahren IQ-Werten

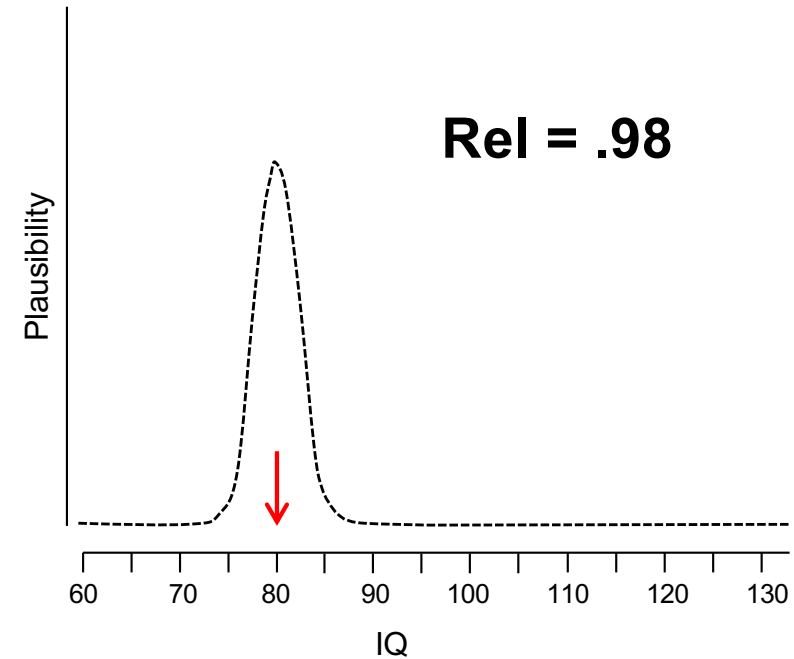
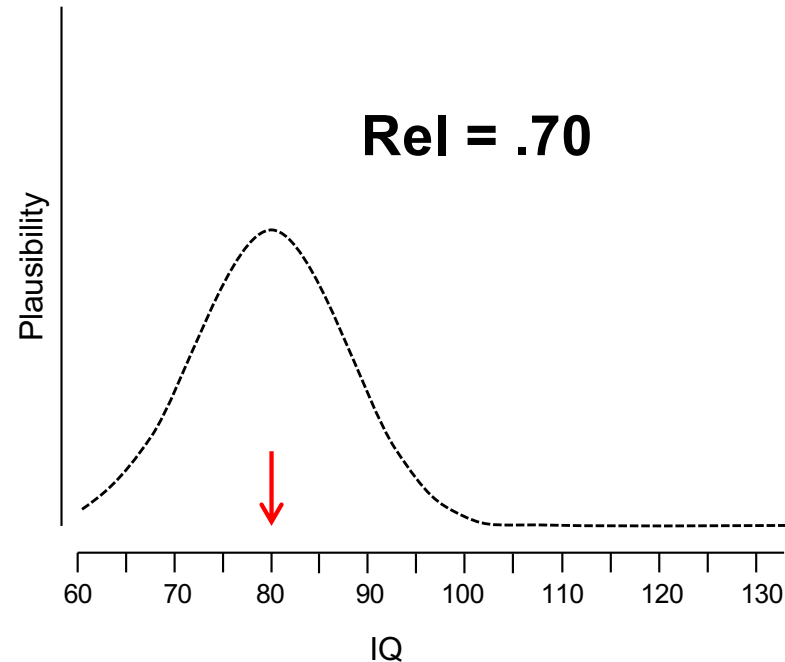


**Exkurs:** Einen einzelnen Wert auf der Likelihood-Kurve könnte man in R für das vorliegende Beispiel wie folgt berechnen:  
`dnorm(80, mean = IQ, sd = sqrt(225*(1-0.7)))`

## Grundprinzipien der Bayesianischen Statistik

### Likelihood




- Formalisiert das Wissen, das wir durch die Daten erlangen
- Hängt von der Reliabilität ab: Je unreliabler der Test, desto breiter ist die Likelihood (d.h. desto plausibler sind wahre Werte weit weg vom Testwert)



## Grundprinzipien der Bayesianischen Statistik

### Prior

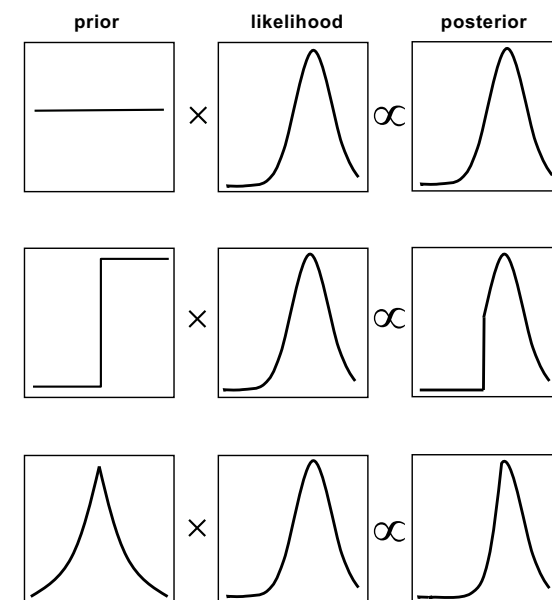
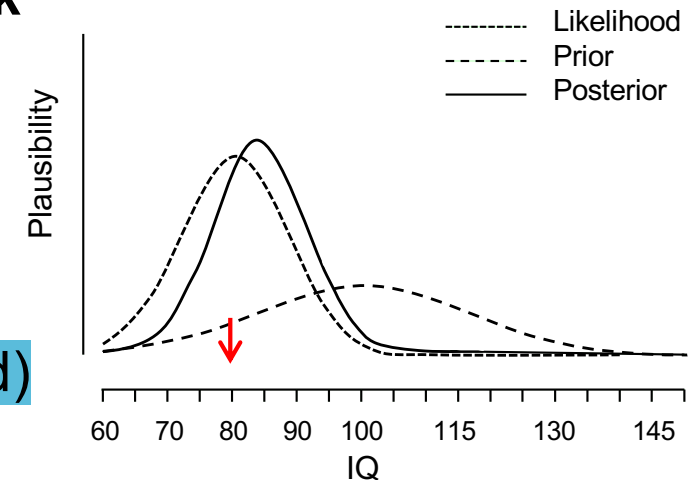
- Die Prior-Verteilung ist eine Vorannahme, die definiert, wie plausibel mögliche wahre Werte in der Population a priori sind (d.h., bevor man die Daten beobachtet hat)
- Diese Vorannahmen können sehr vage sein („uninformativ“), oder substantielles Vorwissen enthalten („informativ“)
- Je sicherer man sich vorher schon ist, desto schmalgipfliger ist die Prior um den erwarteten Wert herum (→ geringere Varianz der Verteilung)



## Grundprinzipien der Bayesianischen Statistik

### Posterior

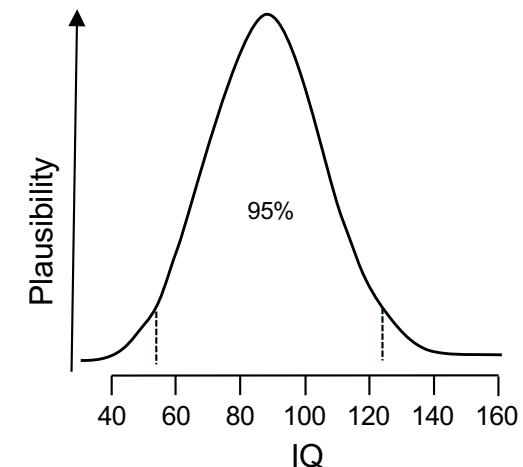
- „Updating process“:
  - Wir aktualisieren unser **Vorwissen (Prior)** mit Hilfe der **erhobenen Daten (Likelihood)**
  - daraus resultiert eine (verbesserte) Wahrscheinlichkeitsverteilung
- Die **Posterior-Verteilung** quantifiziert die Plausibilität möglicher wahrer Werte *nachdem* man die **Testwerte** beobachtet hat



## Grundprinzipien der Bayesianischen Statistik

### Highest Density Interval (HDI)

- Ein bestimmtes Intervall definierter Masse der Posterior stellt das **bayesianische KI-Äquivalent** dar
  - z.B. 95% der Fläche → 95% HDI
- Unter Annahme der Prior kann man mit diesen bayesianischen KIs dann Interpretationen über den wahren Wert vornehmen
  - z.B. „Der wahre Wert liegt mit 95% Wahrscheinlichkeit zwischen...“

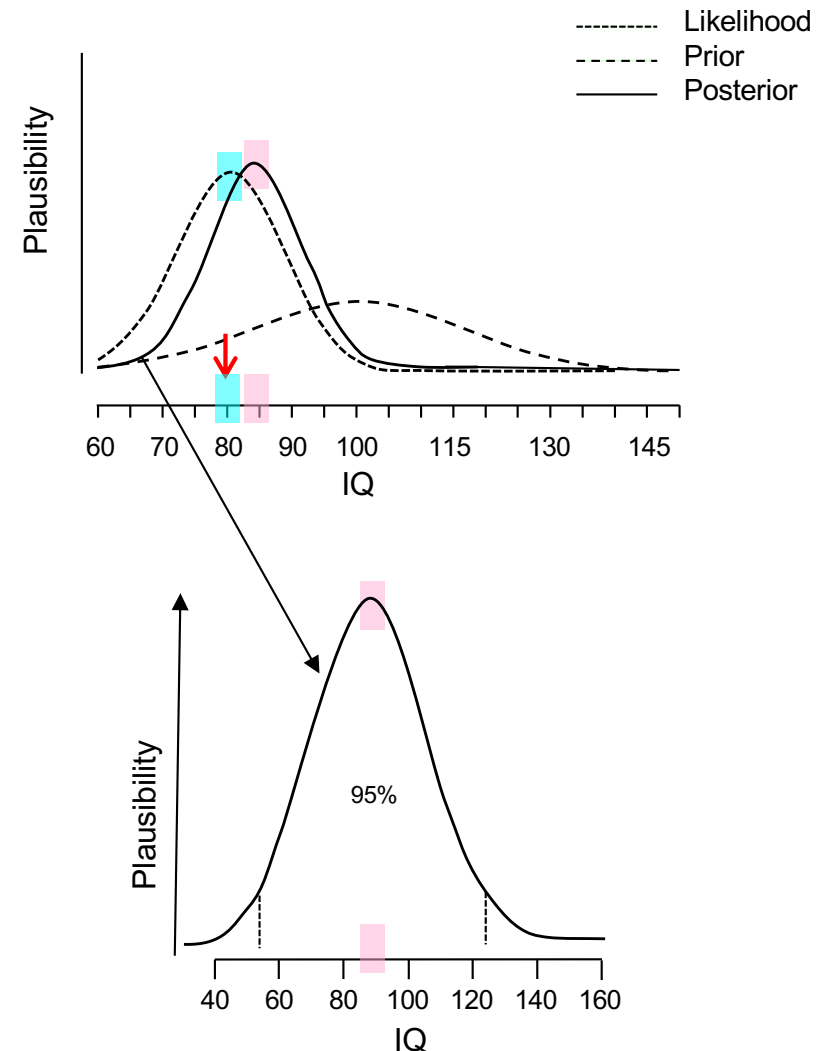


## Grundprinzipien der Bayesianischen Statistik

### Bester Punktschätzer

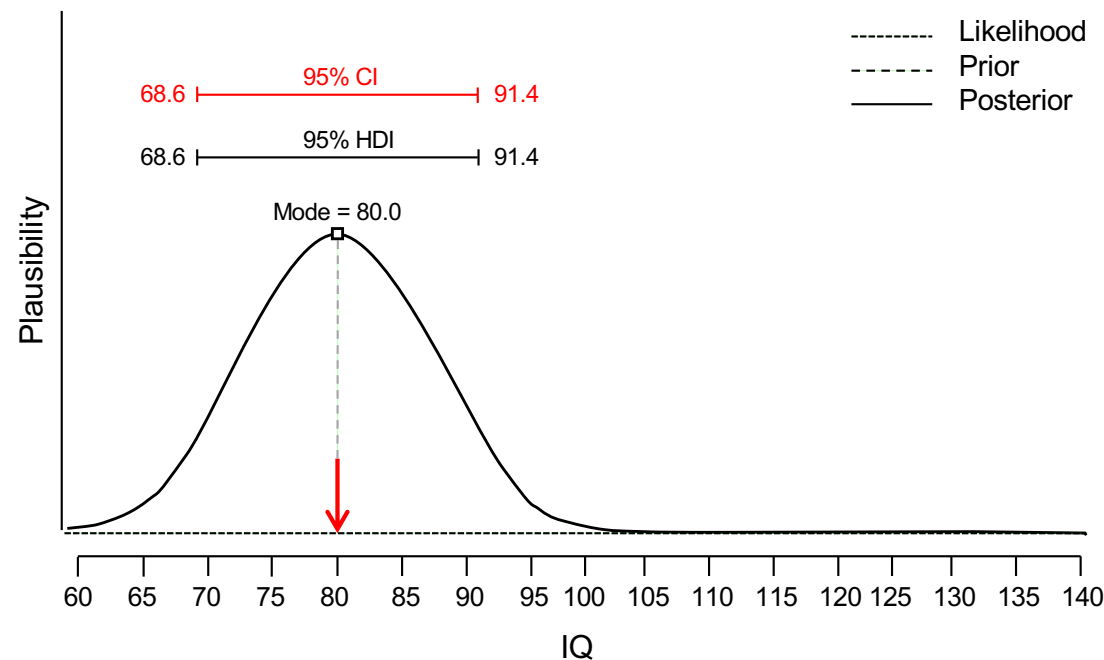
- Frequentismus: **beobachteter Wert** ist die beste Punkt-Schätzung für den wahren Wert
- Bayes: **Modus der Posterior** (d.h., der Gipfel der Verteilung) ist die beste Punkt-Schätzung für den wahren Wert

*Hinweis:* Alternativ zum Modus wird häufig auch der Erwartungswert oder der Median der Posterior als bayesianischer Punkt-Schätzer verwendet.



### Beispiel 1: kein Vorwissen


- Testwert = 80 IQ-Punkte, Reliabilität = .85
- flache („uninformative“) Prior → Jeder IQ-Wert von  $-\infty$  bis  $+\infty$  ist a priori gleich wahrscheinlich



→ Frequentistisches KI und Bayesianisches HDI (und die dazugehörigen Punktschätzer) fallen zusammen!

### Beispiel 2: Vorwissen vorhanden


- Testwert = 80 IQ-Punkte, Reliabilität = .85
- **Prior:  $IQ \sim N(100, 15^2)$**  → die Prior ist normalverteilt mit einem Mittelwert von 100 und einer Varianz von  $15^2$  bzw. SD von 15



→ Frequentistisches KI und Bayesianisches HDI fallen unterschiedlich aus und der wahrscheinlichste Bayes-Punktschätzer ist *nicht* der Testwert von 80, sondern liegt bei 82.6!

### Beispiel 3: Spezifisches Vorwissen vorhanden I

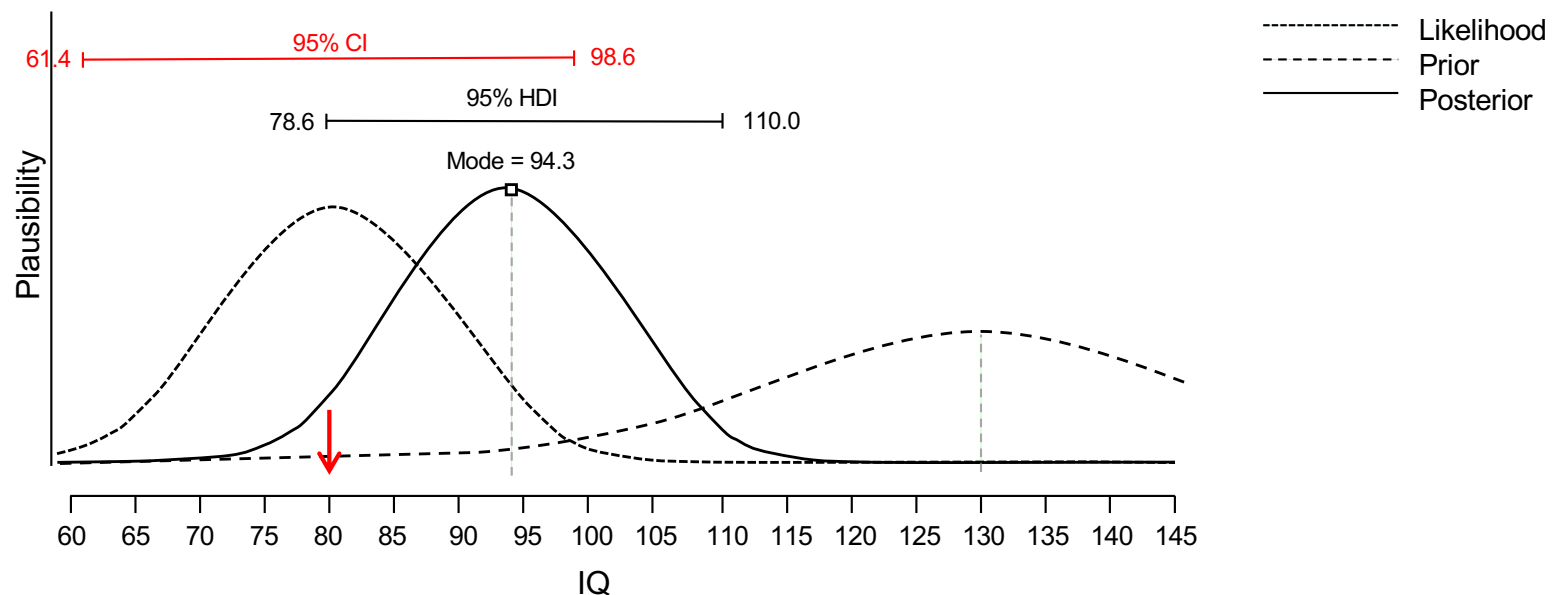
- Testwert = 80 IQ-Punkte, Reliabilität = .85
- **Prior:  $IQ \sim N(130, 15^2)$**  → die Prior ist normalverteilt mit einem Mittelwert von 130 und einer Varianz von  $15^2$  bzw. SD von 15 (Annahme, weil wir wissen, dass die begutachtete Person aus der Population Psychologiestudierender kommt)



→ Der wahrscheinlichste Bayes-Punktschätzer liegt in diesem Fall bei 86.5

### Beispiel 3: Spezifisches Vorwissen vorhanden II

- Testwert = 80 IQ-Punkte, **Reliabilität = .60**
- **Prior:  $IQ \sim N(130, 15^2)$**  → die Prior ist normalverteilt mit einem Mittelwert von 130 und einer Varianz von  $15^2$  bzw. SD von 15 (wie auf der vorigen Folie)



→ Je unreliabler das Messinstrument, desto **breiter** das frequentistische KI und das bayesianische HDI und desto **stärker der Einfluss der Prior** auf die Posterior!

## Fazit zum Einsatz von Bayes in der Einzelfalldiagnostik:

- Das Bayes-Theorem stellt eine „Berechnungsvorschrift“ dar, wie man Vorwissen mit neuen Daten verrechnen kann. Das bisher Bekannte (die Prior) wird mit den neuen Daten aktualisiert, um so den aktualisierten Wissensstand zu erhalten (die Posterior).
- Damit kann ein Prozess formalisiert werden, was in der Praxis ohnehin implizit abläuft: Urteile mithilfe externer Informationen anzupassen, abhängig davon, wie stark mein Vertrauen in meine diagnostische Messung ist.
  - Wenn man ein reliables Messinstrument hat, kann man dem Messwert relativ stark vertrauen, und das Vorwissen ist relativ irrelevant
  - Wenn das Messinstrument schlecht ist, kann es ratsam sein, vorhandenes Wissen einzubeziehen
  - Extremfall: Das Messinstrument liefert im Grunde nur Rauschen. Dann sollte man rationaler Weise nur das Vorwissen nutzen (unter der Voraussetzung, dass das Vorwissen mehr als nur Rauschen kodiert)
- Sensitivitätsanalysen überprüfen die Ergebnisse bei Heranziehen verschiedener (plausibler) Priors

## Fazit zum Einsatz von Bayes in der Einzelfalldiagnostik:

- Ob die Berücksichtigung von **spezifischem** Vorwissen für meinen diagnostischen Einzelfall sinnvoll ist, hängt vom Kontext ab
- Dabei stellen sich ähnliche Fragen, wie bei der Auswahl der „interessierenden“ Normstichprobe (siehe Sitzung 08)

Es gibt Situationen, da möchte ich...

- **...spezifisches Vorwissen über die von mir getestete Person berücksichtigen, um die individuelle diagnostische Entscheidung zu verbessern**, z.B. wenn ich in einem neuropsychologischen Setting herausfinden will, ob eine Person kognitive Defizite durch eine degenerative Erkrankung aufweist und Vorwissen über ihre frühere Leistungsfähigkeit oder aktuelle Beeinträchtigungen im Alltag vorliegt
- **...für alle getesteten Personen das gleiche Vorwissen verwenden, um alle Personen gleich (“fair“) zu behandeln**, z.B. wenn ich in einem personalpsychologischen Setting Bewerberinnen basierend auf einem standardisierten Leistungstest auswählen will und es nicht vertretbar ist, dass Personen mit dem gleichen Testwert unterschiedliche Beurteilungen bekommen


# Praxis-Tipp: Shiny-App zur Berechnung von HDIs

[http://shinyapps.org/apps/Bobs\\_IQ/](http://shinyapps.org/apps/Bobs_IQ/)

## Bayesian Credible Interval for an IQ Test Score

### Properties of the test instrument

#### Test reliability:




#### Between-person standard deviation of the test scores (e.g. 15 for IQ scores, or 1 for z scores)

15

### Obtained test score

#### Observed test score



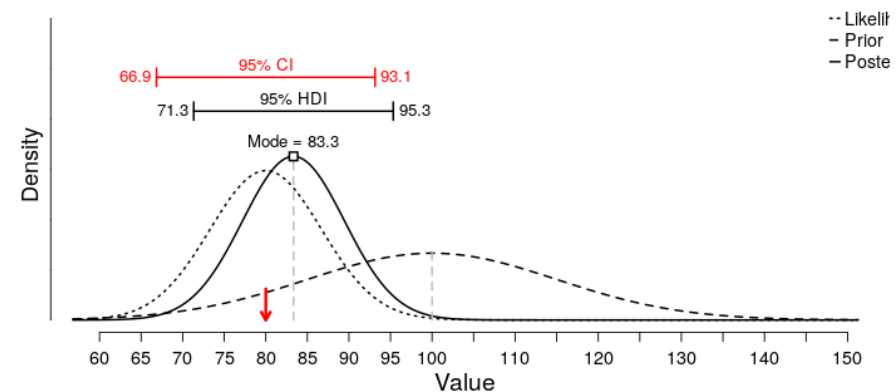
### Prior

#### Mean of prior

100

#### SD of prior (enter large value, such as 999, for flat prior)

15



This app extends [code](#) from Quentin Gronau and Richard Morey.

"Bob's IQ" is an example from the paper: [Wagenmakers, E.-J., Morey, R. D., & Lee, M. D. \(2016\). Bayesian benefits for the pragmatic researcher. Current Directions in Psychological Science, 25, 169-176. doi:10.1177/0963721416643289.](#)

Technical details: The app assumes a known (fixed) variance for the single data point, which is derived from the reliability of the measurement instrument.

## Das war's schon fast für heute ...

- *Ausblick:* In der nächsten Vorlesung beschäftigen wir uns mit dem Einsatz digitaler Daten und maschineller Lernverfahren in der psychologischen Diagnostik.
- Aber zuerst: Gibt es offene Fragen zur heutigen Vorlesung?

## Quellen zu Bayes

- Hoekstra, R., Morey, R. D., Rouder, J. N., & Wagenmakers, E. J. (2014). Robust misinterpretation of confidence intervals. *Psychonomic Bulletin & Review*, 21(5), 1157–1164. <http://doi.org/10.3758/s13423-013-0572-3>
- McElreath, R. (2020). *Statistical rethinking: A Bayesian course with examples in R and Stan*. Chapman and Hall/CRC.  
[https://github.com/rmcelreath/stat\\_rethinking\\_2024](https://github.com/rmcelreath/stat_rethinking_2024)
- Morey, R. D., Hoekstra, R., Rouder, J. N., Lee, M. D., & Wagenmakers, E.-J. (2015). The fallacy of placing confidence in confidence intervals. *Psychonomic Bulletin & Review*, 23, 103–123. <http://doi.org/10.3758/s13423-015-0947-8>
- Wagenmakers, E. J., Morey, R. D., & Lee, M. D. (2016). Bayesian Benefits for the Pragmatic Researcher. *Current Directions in Psychological Science*, 25(3), 169–176. <http://doi.org/10.1177/0963721416643289>