Memory Retention

1. Zentrale Fragestellung

Gedächtnisleistung nimmt mit zunehmender Verzögerung ab. Entscheidend ist jedoch nicht nur, dass Leistung abnimmt, sondern welche mathematische Funktion den Verlauf am besten beschreibt und ob dieselbe Funktion für alle Personen gilt.

2. Rubin, Hinton & Wenzel (1999)

Ziel:

- Präzise Retentionsdaten erheben, mit denen verschiedene mathematische Vergessensfunktionen unterschieden werden können.
- Nicht nur einen hohen Fit erreichen, sondern systematische Abweichungen zwischen Modell und Daten sichtbar machen.
- Treffer, Fehlerarten und Reaktionszeiten gemeinsam betrachten, um die Modellkomponenten psychologisch einzuordnen.

Studienlogik

Der Lag wird systematisch variiert. An jedem Lag werden viele Beobachtungen gesammelt. Anschließend wird geprüft, welche mathematische Funktion die Daten beschreibt, ohne regelmäßige Fehler zu hinterlassen.

- Unabhängige Variable: Retentionsintervall bzw. Lag.
- Abhängige Hauptvariable: Wahrscheinlichkeit korrekten Erinnerns oder Erkennens.
- Ergänzend: Fehlerarten und Reaktionszeiten.

Versuchsaufbau

Bereich	Umsetzung
Aufgaben	3 Cued-Recall- und 2 Recognition-Bedingungen
Stichprobe	100 ausgewertete Personen pro Bedingung, insgesamt 500
Retentionsintervalle	0, 1, 2, 4, 7, 12, 21, 35, 59 und 99 intervenierende Items
Messung	Erinnerungs- bzw. Erkennungswahrscheinlichkeit sowie Reaktionszeiten

Durchführung

- Beim Cued Recall wird zunächst ein Wortpaar gelernt. Beim späteren Test erscheint nur das erste Wort als Hinweisreiz.
- Beim Recognition-Test wird entschieden, ob ein Item bereits gezeigt wurde. In einer Variante wird zusätzlich zwischen „remember“ und „know“ unterschieden.
- Alle Personen bearbeiten mehrere Retentionsintervalle. Dadurch entstehen Retentionskurven innerhalb derselben Versuchspersonen.

3. Ergebnisse von Rubin et al.

Was wird modelliert?

Modelliert wird der funktionale Zusammenhang zwischen dem Lag t und der mittleren Erinnerungswahrscheinlichkeit y(t). Gesucht ist eine Kurve, die sowohl den schnellen frühen als auch den langsameren späteren Leistungsabfall beschreibt. Erst danach werden die mathematischen Komponenten psychologisch interpretiert.

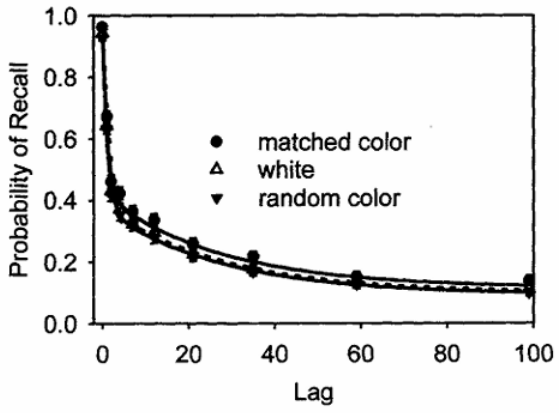

Figure 2. Probability of correctly recalling a word as a function of the number of items intervening since its presentation for conditions in which the color of the cue and to-be-remembered item were matched, randomly mixed, or all white. Error bars for standard error are included but are not always visible because they are often hidden by the plot points.

Abbildung 1: Recall-Leistung in drei Farbbedingungen in Abhängigkeit vom Lag. Quelle: Rubin et al. (1999), Figure 2.

Warum einfache Fits nicht genügen

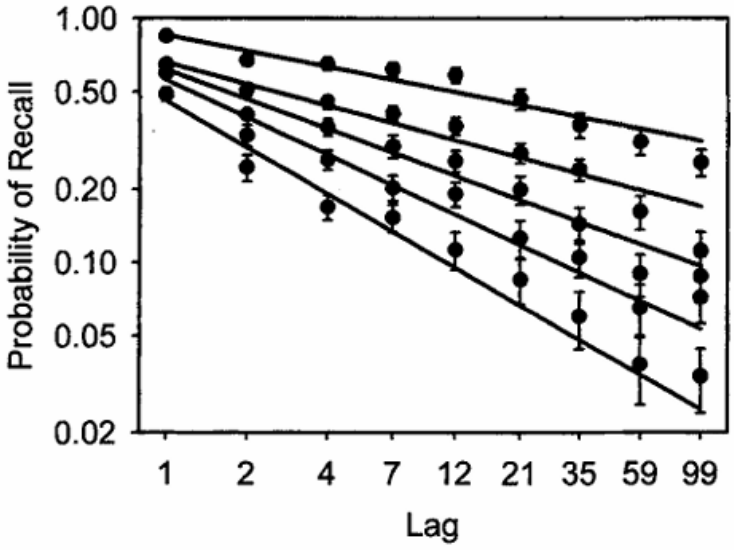

Figure 4. The same data as Figure 3 plotted on logarithmic scales and fit to power functions. Note the systematic deviations in that at Lag 2 all five points are below the lines fit; at Lags 7, 12, and 21, 14 of the 15 points are above the lines fit; and at Lags 35, 59, and 99 the points tend to converge to a middle value. For this figure, the error bars are $p < .05$ confidence intervals.

Abbildung 2: Power-Function-Fits auf logarithmischen Skalen. Die Abweichungen verlaufen systematisch. Quelle: Rubin et al. (1999), Figure 4.

Vorgeschlagene Retentionsfunktion

$$y(t) = a_1 \cdot \exp(-t/T_1) + a_2 \cdot \exp(-t/T_2) + a_3$$

Bestandteil	Mögliche Interpretation
Schneller Term, $T_1 \approx 1{,}15$	kurzfristige bzw. Working-Memory-Komponente
Langsamer Term, $T_2 \approx 27{,}55$	längerfristiger Gedächtnisprozess
Konstante a_3	Asymptote bzw. sehr langsamer Rest im untersuchten Bereich

Wichtig: Die Funktion wurde zunächst aufgrund ihrer guten empirischen Beschreibung vorgeschlagen. Die psychologische Interpretation der einzelnen Terme ist nicht eindeutig bewiesen.

4. Shiffrin et al. (2008): Modellaufbau

Shiffrin et al. verwenden ein bewusst vereinfachtes Retentionsmodell, um Modellbewertung und hierarchische Struktur zu demonstrieren. Die Daten sind fiktiv, aber realistisch: vier Personen, 18 Items pro Zeitpunkt und zehn Zeitpunkte. Für Person 4 liegen absichtlich keine Daten vor; bei 200 Sekunden fehlen Daten für alle Personen. Damit werden Generalisierung auf eine neue Person geprüft.

$$\theta_{ij} = \exp(-\alpha_i \cdot t_j) + \beta_i \quad \text{und} \quad k_{ij} \sim \text{Binomial}(n_{ij}, \theta_{ij})$$

Drei Modellstufen

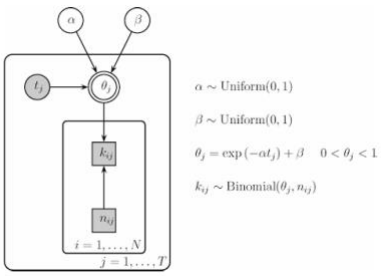

1. Gemeinsame Parameter

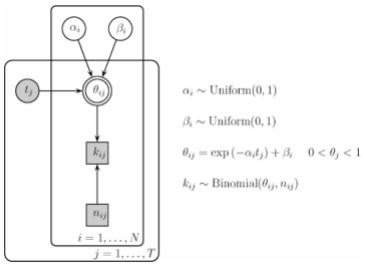

2. Getrennte Personenparameter

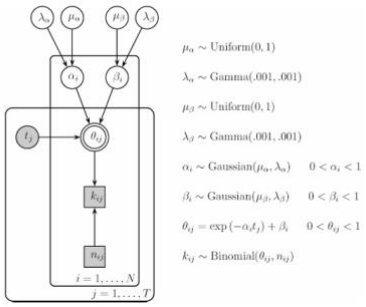

3. Hierarchische Parameter

Die drei grafischen Modelle aus Shiffrin et al. zeigen den schrittweisen Übergang von vollständigem Pooling zu einem hierarchischen Modell. Quellen: Shiffrin et al. (2008).

Stufe	Annahme	Konsequenz
1. Keine Unterschiede	Alle teilen α und β.	Zu grob: Eine Kurve beschreibt die verschiedenen Personen schlecht.
2. Volle Unterschiede	Jede Person hat α_i und β_i; Parameter sind unabhängig.	Guter Fit für bekannte Personen, aber kaum Generalisierung auf Person 4.
3. Hierarchisch	Individuelle Parameter stammen aus Gruppenverteilungen.	Partial Pooling: individuelle Unterschiede plus gemeinsame Gruppeninformation.

Hierarchischer Zusammenbau in Beispiel 1

- 1. Beobachtungsmodell: k_{ij} ist die Zahl korrekter Antworten aus 18 Items und wird binomial modelliert.
- 2. Retentionskurve: θ_{ij} wird aus Zeitpunkt t_j, Zerfallsrate α_i und Grundniveau β_i berechnet.
- 3. Personenebene: Jede Person behält eigene α_i- und β_i-Werte.
- 4. Gruppenebene: Die individuellen Parameter stammen aus gemeinsamen Gruppenverteilungen.
- 5. Informationsaustausch: Die beobachteten Personen lernen die Gruppenverteilung; die Gruppenverteilung ermöglicht eine Vorhersage für Person 4.

Hierarchischer Kern

$$\alpha_i \sim \text{Normal}(\mu_a, 1/\lambda_a) \qquad \beta_i \sim \text{Normal}(\mu\beta, 1/\lambda\beta)$$

- Die Daten der beobachteten Personen informieren die Gruppenverteilungen.

- Die Gruppenverteilungen informieren wiederum individuelle Parameter, besonders bei wenigen oder fehlenden Daten.
- Dieses „Partial Pooling“ verhindert sowohl eine einzige starre Gruppenkurve als auch vollständig unverbundene Einzelfits.

5. Was verändert die Hierarchie praktisch?

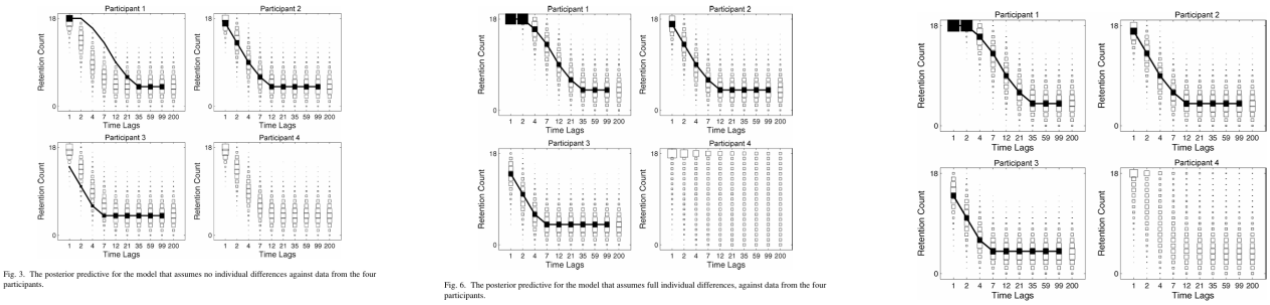

Fig. 3. The posterior predictive for the model that assumes no individual differences against data from the four participants.

Fig. 6. The posterior predictive for the model that assumes full individual differences, against data from the four participants.

Keine Individualunterschiede | **Volle Individualunterschiede** | **Hierarchisches Modell**

Posterior-Predictive-Darstellungen für die drei Modellstufen. Das hierarchische Modell verbindet individuelle Fits mit einer Vorhersage für Person 4. Quelle: Shiffrin et al. (2008).

Vergleich

- Das gemeinsame Modell verfehlt systematische Unterschiede zwischen den Personen.
- Das Modell mit vollständig unabhängigen Personenparametern passt die beobachteten Personen, kann bei einer neuen Person jedoch kaum aus den übrigen Daten lernen.
- Das hierarchische Modell nutzt die Population, ohne individuelle Verläufe gleichzusetzen. Für Person 4 entsteht dadurch eine unsichere, aber informative Vorhersage.

Person 4 ist der entscheidende Testfall: Complete Pooling ignoriert Personenunterschiede; No Pooling hat ohne persönliche Daten kaum Information; Partial Pooling verwendet die aus Personen 1–3 gelernte Populationsverteilung.

6. Zentrale Takeaways

- Rubin et al.: Präzise Daten und Residuenanalysen sind notwendig, um ähnlich gut passende Funktionen zu unterscheiden.
- Shiffrin et al. zeigen: Modellbewertung umfasst nicht nur Fit, sondern auch Interpretation, Vorhersage und Generalisierung.
- Hierarchische Modelle behandeln individuelle Unterschiede als strukturierte Information und nicht nur als Störfaktor.
- Der Kern von Beispiel 1 ist der Übergang von Complete Pooling über No Pooling zu Partial Pooling.

Literatur

Rubin, D. C., Hinton, S., & Wenzel, A. (1999). The Precise Time Course of Retention. Journal of Experimental Psychology: Learning, Memory, and Cognition, 25(5), 1161–1176.

Shiffrin, R. M., Lee, M. D., Kim, W., & Wagenmakers, E.-J. (2008). A Survey of Model Evaluation Approaches With a Tutorial on Hierarchical Bayesian Methods. Cognitive Science, 32, 1248–1284.