



## Statistik II

# Logistische Regression

Divergent (2014). Concorde Filmverleih.


# Überblick

- Einleitung
- Drei Darstellungsformen
- Multiple logistische Regression
- Parameterschätzung
- Hypothesenprüfung
- Zerlegung der Likelihood-Ratio-Teststatistik
- Klassifikation
- Voraussetzungen der Maximum-Likelihood-Schätzung und Hypothesentestung

# Einleitung (Eid, Gollwitzer & Schmitt, 2017)

- **Logistische Regression:** Regression, bei dem die Prädiktorvariablen zumindest teilweise metrisch und die Kriteriumsvariable kategorial ist
- **Einfache logistische Regressionsanalyse:** Logistische Regression mit einer einzelnen Prädiktorvariable

# Kurzes Erklärvideo zur logistischen Regressionsanalyse



# Drei Darstellungsformen der logistischen Regressionsanalyse (Eid, Gollwitzer & Schmitt, 2017)

- **In Form bedingter Wahrscheinlichkeiten:** Wahrscheinlichkeit einer Kategorie der Kriteriumsvariablen als Funktion der Prädiktorvariablen
- **In Form bedingter Wettquotienten:** Modellierung des Wettquotienten als Funktion der Prädiktorvariablen
- **In Form bedingter Logits:** Zerlegung des Logits in Linearkombination der Prädiktorvariablen

# Darstellung in Form bedingter Wahrscheinlichkeiten (Eid, Gollwitzer & Schmitt, 2017)

- Exponentialfunktion mit zwei Parametern
  - $\beta_0$ : Angabe, dass generell die Wahrscheinlichkeit, eine bestimmte Kategorie zu wählen, bei  $X = 0$  auf einem höheren oder geringeren Niveau liegen kann
  - $\beta_1$ : Angabe, wie stark die Wahrscheinlichkeit, die Kategorie zu wählen, mit Zunahme der Werte auf der Prädiktorvariable ansteigt
- Formel der Exponentialfunktion: 
$$P(Y = 1|X) = \frac{e^{\beta_0 + \beta_1 \cdot X}}{1 + e^{\beta_0 + \beta_1 \cdot X}}$$
- Vergleich mit der linearen Regression: 
$$\hat{y} = b_0 + b_1 \cdot x$$

# Darstellung in Form bedingter Wahrscheinlichkeiten (Eid, Gollwitzer & Schmitt, 2017)

- Auswirkungen verschiedener Parameter / Regressionsgewichte




Abbildung 22.2 Abhängigkeit der bedingten Wahrscheinlichkeit von einer metrischen unabhängigen Variablen im logistischen Regressionsmodell: Auswirkungen verschiedener Regressionskonstanten  $\beta_0$




Abbildung 22.3 Abhängigkeit der bedingten Wahrscheinlichkeit von einer metrischen unabhängigen Variablen im logistischen Regressionsmodell: Auswirkungen verschiedener Regressionsgewichte  $\beta_1$

Quellen: Eid, Gollwitzer und Schmitt (2017)

# Darstellung in Form bedingter Wettquotienten (Eid, Gollwitzer & Schmitt, 2017)

- **Wettquotienten (Odds):** Verhältnis aus der Wahrscheinlichkeit eines Ereignisses und seiner Gegenwahrscheinlichkeit
- **Bedingter Wettquotient im logistischen Regressionsmodell:** Verhältnis aus der bedingten Wahrscheinlichkeit  $P(Y = 1 | X = x)$  und der Gegenwahrscheinlichkeit  $[1 - P(Y = 1 | X = x)]$
- **Formel:** 
$$\frac{P(Y=1|X)}{1-P(Y=1|X)} = e^{\beta_0 + \beta_1 \cdot X} = e^{\beta_0} \cdot e^{\beta_1 \cdot X} = e^{\beta_0} \cdot (e^{\beta_1})^X$$
- **Bedeutung der Parameter:**
  - $e^{\beta_0}$ : Entspricht dem Wettquotienten an der Stelle  $X = 0$ ; Wenn  $\beta_0 = 0 \rightarrow e^{\beta_0} = 1$  und Wettquotient = 1; Wenn  $\beta_0 > 0 \rightarrow e^{\beta_0} > 1$ ; Wenn  $\beta_0 < 0 \rightarrow e^{\beta_0} < 1$
  - $e^{\beta_1}$ : Odds-Ratio; gibt die Veränderung des Wettquotienten an, wenn die Prädiktorvariable um eine Einheit erhöht wird

# Darstellung in Form des Logits

(Eid, Gollwitzer & Schmitt, 2017)

- **Logit:** Logarithmierte Wettquotient
- **Formel:** 
$$\ln \left( \frac{P(Y=1|X)}{1-P(Y=1|X)} \right) = \beta_0 + \beta_1 \cdot X$$
- **Rechte Seite der Gleichung:** Entspricht exakt der einfachen linearen Regression
- Logit strebt gegen  $+\infty$ , wenn der Wettquotient gegen  $\infty$  strebt
- **Bedeutung der Parameter:**
  - $\beta_0$ : Konstante entspricht dem Wert des Logits an der Stelle  $X = 0 \rightarrow$  Achsenabschnitt in der einfachen linearen Regression
  - $\beta_1$ : Regressionsgewicht zeigt an, um welchen Wert der Logit sich ändert, wenn der Wert der Variablen  $X$  um eine Einheit erhöht wird;  $\beta_1 = 0 \rightarrow$  Kein Zusammenhang zwischen beiden Variablen

# Multiple logistische Regression (Eid, Gollwitzer & Schmitt, 2017)

- **Multiple logistische Regression:** Logistische Regression mit mehreren Prädiktorvariablen
- **Indizierung der Prädiktorvariablen:**  $j = 1, \dots, k$
- **Nachfolgend die Formeln zu den drei Darstellungsformen:**
- **Exponentialfunktion:**  $P(Y = 1|X_1, \dots, X_k) = \frac{e^{\beta_0 + \beta_1 \cdot X_1 + \beta_2 \cdot X_2 + \dots + \beta_k \cdot X_k}}{1 + e^{\beta_0 + \beta_1 \cdot X_1 + \beta_2 \cdot X_2 + \dots + \beta_k \cdot X_k}}$
- **Bedingter Wettquotient:**  $\frac{P(Y=1|X_1, \dots, X_k)}{1-P(Y=1|X_1, \dots, X_k)} = e^{\beta_0 + \beta_1 \cdot X_1 + \beta_2 \cdot X_2 + \dots + \beta_k \cdot X_k}$
- **Logit:**  $\ln \left( \frac{P(Y=1|X_1, \dots, X_k)}{1-P(Y=1|X_1, \dots, X_k)} \right) = \beta_0 + \beta_1 \cdot X_1 + \beta_2 \cdot X_2 + \dots + \beta_k \cdot X_k$


# Multiple logistische Regression (Eid, Gollwitzer & Schmitt, 2017)

- **Skalenniveau:** Prädiktorvariablen können metrischer als auch qualitativer Natur sein
- **Wechselwirkungen:** Interaktionseffekte zwischen den Prädiktorvariablen ebenfalls modellierbar
- **Indikatorcodierung (Dummy-Codierung):** Berücksichtigung nominalskalierter und ordinalskalierter Prädiktorvariablen mittels Indikatorcodierung
- **Nonlineare Abhängigkeiten:** Mittels Quadrierung oder Potenzen höherer Ordnung der Prädiktorvariablen ebenfalls modellierbar

# Parameterschätzung (Eid, Gollwitzer & Schmitt, 2017)

- **Parameterschätzung:** Mittels Maximum-Likelihood-Verfahren
- **Likelihood-Funktion:** beschreibt die Wahrscheinlichkeit der Daten, die man in einer Untersuchung erhalten hat, als Funktion der Modellparameter unter der Voraussetzung, dass das Modell gilt
- **Bedingte Wahrscheinlichkeiten:** Ausschließlich abhängig von den Regressionsparametern
- **Maximierung der Likelihood-Funktion  $L$ :** Ziel bei der Schätzung der Regressionsparameter
- **Schätzung der Regressionsparameter:** Mittels iterativer statistischer Verfahren

# Kurzes Erklärvideo zur Parameterschätzung in der logistischen Regressionsanalyse



# Hypothesenprüfung (Eid, Gollwitzer & Schmitt, 2017)

- Hypothesenprüfung analog zur multiplen Regressionsanalyse
  1.  $H_0$ : Einzelter Parameter ( $\beta_0$  oder  $\beta_j$ ) = 0
  2.  $H_0$ : Alle Parameter  $\beta_1 = \dots = \beta_j = \dots = \beta_k = 0$
  3.  $H_0$ : Satz von UVs keinen Einfluss über andere UVs hinaus
- Zu 1.  $H_0$ : Einzelter Parameter ( $\beta_0$  oder  $\beta_j$ ) = 0
- Drei Testverfahren
  - z-Test
  - Wald-Test
  - Likelihood-Ratio-Test (Likelihood-Quotienten-Test)
- Verfahren werden nachfolgend kurz skizziert

# Hypothesenprüfung (Eid, Gollwitzer & Schmitt, 2017)

- **z-Test:** Geschätzter Parameter wird durch seinen geschätzten Standardfehler geteilt
- **Formeln:**  $z = \frac{b_0}{\hat{\sigma}_{B_0}}$  bzw.  $z = \frac{b_j}{\hat{\sigma}_{B_j}}$
- **Prüfgröße:** Asymptotisch standardnormalverteilt
- **Bestimmung des kritischen Wertes:** Für ein a priori festgelegtes  $\alpha$ -Niveau bzw. die  $p$ -Werte anhand der Quantile der Standardnormalverteilung
- **Signifikanzprüfung:** Vergleich des empirischen  $z$ -Wertes mit dem kritischen  $z$ -Wert

# Hypothesenprüfung (Eid, Gollwitzer & Schmitt, 2017)

- **Wald-Test:** Basiert auf dem quadrierten z-Wert
- **Formeln:**  $z^2 = \frac{b_0^2}{\hat{\sigma}_{B_0}^2}$  bzw.  $z^2 = \frac{b_j^2}{\hat{\sigma}_{B_j}^2}$
- **Prüfgröße:** Wald-Statistik genannt; asymptotisch  $\chi^2$ -verteilt
- **Bestimmung des kritischen Wertes:** Für ein a priori festgelegtes  $\alpha$ -Niveau bzw. die  $p$ -Werte anhand der Quantile der  $\chi^2$ -Verteilung
- **Signifikanzprüfung:** Vergleich des empirischen  $z^2$ -Wertes mit dem kritischen  $\chi^2$ -Wert

# Hypothesenprüfung (Eid, Gollwitzer & Schmitt, 2017)

- **Likelihood-Ratio-Test:** Vergleich der Likelihoods zweier logistischer Regressionsmodelle
- **Modellvergleich:** Vergleich eines uneingeschränkten Modells, in dem alle Modellparameter frei geschätzt werden können mit einem eingeschränkten Modell, in dem ein Parameter ( $\beta_j$ ) nicht mehr frei geschätzt, sondern auf 0 fixiert wird
- **Prüfung durch Likelihood-Ratio-Test:** Sinkt die Likelihood durch die Fixierung auf 0 signifikant?
- **Formel:**  $LR = -2 \cdot \ln \left( \frac{L_e}{L_u} \right) = -2 \cdot [\ln(L_e) - \ln(L_u)]$ 

$L_e$  = Likelihood des eingeschränkten Modells  
 $L_u$  = Likelihood des uneingeschränkten Modells
- **Signifikanzprüfung:** Vergleich des LR-Wertes mit einem kritischen  $\chi^2$ -Wert

# Hypothesenprüfung (Eid, Gollwitzer & Schmitt, 2017)

- Vergleich der drei Tests (z-Test, Wald-Test, Likelihood-Ratio-Test)
- Selbes Ergebnis: z-Test und Wald-Test
- Teststärke: Geringere Teststärke des Wald-Tests im Vergleich zum LR-Test, wenn die Regressionsgewichte einen großen (positiven oder negativen) Wert annehmen oder bei kleineren Stichproben
- Fazit aufgrund der Teststärke: Likelihood-Ratio-Test ist dem Wald-Test und dem z-Test vorzuziehen

# Zerlegung der Likelihood-Ratio-Teststatistik (Eid, Gollwitzer & Schmitt, 2017)

- **Additive Zerlegung** von Likelihood-Ratio-Teststatistiken in Teilmodelle mit unterschiedlich vielen UVs
- **Beispiel:** Teilmodelle mit vier UVs

$$M_u: \ln \left( \frac{P(Y=1 | X_1, X_2, X_3, X_4)}{1 - P(Y=1 | X_1, X_2, X_3, X_4)} \right) \\ = \beta_0 + \beta_1 \cdot X_1 + \beta_2 \cdot X_2 + \beta_3 \cdot X_3 + \beta_4 \cdot X_4$$

$$M_{e1}: \ln \left( \frac{P(Y=1 | X_1, X_2, X_3)}{1 - P(Y=1 | X_1, X_2, X_3)} \right) \\ = \beta_0 + \beta_1 \cdot X_1 + \beta_2 \cdot X_2 + \beta_3 \cdot X_3$$

$$M_{e2}: \ln \left( \frac{P(Y=1 | X_1, X_2)}{1 - P(Y=1 | X_1, X_2)} \right) \\ = \beta_0 + \beta_1 \cdot X_1 + \beta_2 \cdot X_2$$

$$M_{e3}: \ln \left( \frac{P(Y=1 | X_1)}{1 - P(Y=1 | X_1)} \right) = \beta_0 + \beta_1 \cdot X_1$$

$$M_{e4}: \ln \left( \frac{P(Y=1)}{1 - P(Y=1)} \right) = \beta_0$$

# Zerlegung der Likelihood-Ratio-Teststatistik (Eid, Gollwitzer & Schmitt, 2017)

- **Zwei generelle Strategien** zur Auswahl unabhängiger Variablen (= Prädiktorvariablen) analog zum Vorgehen in der multiplen, linearen Regressionsanalyse
  - Auswahl aufgrund theoretischer Überlegungen
  - Datengesteuerte Auswahl
- **Strategien bei der datengesteuerten Auswahl**
  - Vorwärtsselektion
  - Rückwärtselimination

# Effektgrößen (Eid, Gollwitzer & Schmitt, 2017)

- **Determinationskoeffizient:** Allgemein akzeptierte Effektgröße in der multiplen Regressionsanalyse; gibt den Varianzanteil der AV an, der durch die UVs aufgeklärt wird
- **Weitere Effektgrößen:** Siehe Sitzung zur Stichprobenumfangsplanung
- **Effektgrößen in der logistischen Regression:** Kein generell anerkanntes Maß, sondern nur verschiedene Vorschläge
- **Vorschläge:** Nachfolgend drei Indizes, die typischerweise in Statistikprogrammen berichtet werden: Koeffizienten nach...
  - McFadden (1974)
  - Cox und Snell (1989)
  - Nagelkerke (1991)

# Effektgrößen (Eid, Gollwitzer & Schmitt, 2017)

- **McFadden-Index:** Index ( $MF$ ) von McFadden (1974), der auf einem Vergleich von folgenden logarithmierten Likelihoods beruht
  - $L_M$ : Likelihood des Modells mit allen UVs
  - $L_0$ : Likelihood des Modells ohne UVs (nur mit Regressionskonstante)
  - **Differenz  $\ln(L_M) - \ln(L_0)$ :** Gibt den (nicht normierten) Erklärungsgewinn an, der aus der Hinzunahme der UVs in das Modell resultiert
  - $L_S$ : Likelihood des saturierten Modells, welches keine Restriktionen enthält und die Daten somit perfekt reproduziert ( $L_S = 1$ )
- **Formel:**  $MF = \frac{\ln(L_M) - \ln(L_0)}{\ln(L_S) - \ln(L_0)} = \frac{\ln(L_0) - \ln(L_M)}{\ln(L_0)}$
- **Wertebereich:** Zwischen 0 (keine Erklärung durch die UVs) und 1 (perfektes Modell)

# Effektgrößen (Eid, Gollwitzer & Schmitt, 2017)

- **Cox-Snell-Index:** Index (CS) nach Cox und Snell (1989) vergleicht die Likelihood des Modells, das nur den Parameter  $\beta_0$ , aber keine UVs enthält ( $L_0$ ), mit dem Modell, das die  $k$  UVs enthält ( $L_M$ )
- **Formel:**  $CS = 1 - \left( \frac{L_0}{L_M} \right)^{\frac{2}{n}}$
- **Funktionsweise:** Je größer  $L_M$  im Vergleich zu  $L_0$  wird, d. h., je erklärungsstärker die UVs sind, umso kleiner wird der Wert  $L_0/L_M$  und umso größer wird der Index CS
- **Cox-Snell-Index = Determinationskoeffizient** (bei Anwendung auf eine multiple Regressionsanalyse)
- **Wertebereich:** Zwischen 0 (keine Erklärung durch die UVs) und...(siehe nächste Folie)

# Effektgrößen (Eid, Gollwitzer & Schmitt, 2017)

- Wertebereich des Cox-Snell-Index: Nagelkerke (1991) hat gezeigt, dass der maximal mögliche Wert des CS-Index ist:
- $CS_{max} = 1 - (L_0)^{\frac{2}{n}}$
- Nagelkerke-Index: Standardisierung des CS-Index an  $CS_{max}$ :
- Formel:  $NK = \frac{CS}{CS_{max}}$
- Wertebereich: Zwischen 0 und 1

# Klassifikation (Eid, Gollwitzer & Schmitt, 2017)

- **Klassifikation von Personen:** Zuordnung von Personen zu einer Klasse von Personen (Kategorie der AV) anhand der Regressionsgleichung mittels logistischer Regressionsanalyse
- **Wahrscheinlichkeiten:** Zuordnung der Person mittels der (anhand der Regressionsgleichung) geschätzten Wahrscheinlichkeiten für die Kategorien der AV
- **Beispiel:** Prognose für spätere Alzheimer-Erkrankung

# Voraussetzungen der Maximum-Likelihood-Schätzung & Hypothesentestung (Eid, Gollwitzer & Schmitt, 2017)

- **Korrekte Modellspezifikation:** Annahme erfüllt, wenn das Modell die relevanten UVs enthält und die bedingte Wahrscheinlichkeitsfunktion der postulierten Funktion entspricht
- **Bedingte Binomialverteilung:** Annahme impliziert, dass die bedingte Varianz der Varianz der Binomialverteilung folgt
- **Unabhängigkeit der Beobachtungen:** Annahme, dass Beobachtungen unabhängig voneinander sind (z. B. bei einer echten Zufallsstichprobe gegeben)

# Zusammenfassung I

- **Logistische Regression:** Regression, bei dem die Prädiktorvariablen zumindest teilweise metrisch und die Kriteriumsvariable kategorial ist
- **Darstellungsformen der logistischen Regressionsanalyse:** In Form bedingter Wahrscheinlichkeiten, bedingter Wettquotienten oder bedingter Logits
- **Multiple logistische Regression:** Logistische Regression mit mehreren Prädiktorvariablen
- **Parameterschätzung:** Mittels Maximum-Likelihood-Verfahren
- **Hypothesenprüfung:** Mittels der Testverfahren z-Test, Wald-Test oder Likelihood-Ratio-Test
- **Zerlegung der Likelihood-Ratio-Teststatistik** analog zur multiplen Regressionsanalyse

# Zusammenfassung II

- **Klassifikation** Zuordnung von Personen zu einer Klasse von Personen (Kategorie der AV) anhand der Regressionsgleichung
- **Voraussetzungen der Maximum-Likelihood-Schätzung und Hypothesentestung:** Korrekte Modellspezifikation, bedingte Binomialverteilung und Unabhängigkeit der Beobachtungen

# Prüfungsliteratur

- Eid, M., Gollwitzer, M., & Schmitt, M. (2017). *Statistik und Forschungsmethoden* (5. Aufl.). Weinheim: Beltz.
  - Logistische Regression (S. 799–839)

# Weiterführende Literatur

- Backhaus, K., Erichson, B., Gensler, S., Weiber, R., & Weiber, T. (2025). *Multivariate Analysemethoden. Eine anwendungsorientierte Einführung* (18. Auflage). Wiesbaden: Springer Gabler.
  - Kapitel 5: Logistische Regression (S. 293–387)
- Kalisch, M., & Meier, L. (2021). *Logistische Regression: eine anwendungsorientierte Einführung mit R*. Springer Nature.