

Empirische Wirtschaftsforschung

Der Maximum Likelihood Schätzer

Ulrich Fritsche

Universität Hamburg

Email: Ulrich.Fritsche@wiso.uni-hamburg.de

Die Idee des ML-Schätzers

Vergleich von OLS und ML:

- ▶ OLS-Schätzer: Welcher Schätzer minimiert die quadrierten Abweichungen der Schätzgeraden von den tatsächlichen Beobachtungen?
- ▶ ML-Schätzer: Welcher Schätzer erhöht die Wahrscheinlichkeit, dass die Verteilung der Schätzwerte möglichst nahe an der Verteilung der tatsächlichen Werten liegt?
- ▶ Vorteil der ML-Methode: Schätzung nichtlinearer Modelle
- ▶ Grundvoraussetzung für ML: Verteilung der Daten ist bekannt, Annahme der Normalverteilung

Schätzung einer Cobb-Douglas-Produktionsfunktion

$$Y_t = a \cdot K_t^\alpha \cdot L_t^\beta \quad (1)$$

Diese kann mit OLS nur nach Loglinearisierung geschätzt werden:

$$\log Y_t = a + \alpha \log K_t + \beta \log L_t \quad (2)$$

Eine Schätzung von Gleichung (1) mit Maximum Likelihood und (2) mit OLS ergibt¹

	a	α	β	MSE
OLS	1.239	0.267	0.691	171.954
ML	-0.177	0.233	0.807	105.818

Einsetzen der geschätzten Koeffizienten in die jeweilige Gleichung ergibt die geschätzte Reihe für Y_t . Die Berechnung des **mittleren quadratischen Fehlers (MSE, mean squared error)** spricht für die Schätzung des nichtlinearen Modells.

¹Daten aus Cobb/Douglas (1928): A Theory of Production, in: American Economic Review.

Beispiel 1

Gegeben ist eine Zufallsvariable X mit zwei Beobachtungen $X_1 = 4$ und $X_2 = 6$. X ist normalverteilt mit Standardabweichung $\sigma = 1$. Was ist der Erwartungswert von X , d.h. $E(X) = \mu$?

Die Normalverteilung ist gegeben als:

$$f(X) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left\{ -\frac{1}{2} \frac{(X - E(X))^2}{\sigma^2} \right\} \quad (3)$$

Da wir $E(X)$ nicht kennen, nehmen wir einen Startwert an, z.B. $E(X) = 3.5$. Damit erhalten wir die Wahrscheinlichkeiten für $p(4) = 0.3521$ und $p(6) = 0.0175$.

Die Wahrscheinlichkeit für das gemeinsame Eintreten von 4 und 6 ergibt sich als $L = p(4) \cdot p(6)$, mit L als **Likelihoodfunction**.

Beispiel 1, cont'd





Abbildung: Einzelne und gemeinsame Wahrscheinlichkeitsfunktionen

μ	$p(4)$	$p(6)$	L
3.5	0.3521	0.0175	0.0062

Abbildung: Werte

Beispiel 1, cont'd





Abbildung: Einzelne und gemeinsame Wahrscheinlichkeitsfunktionen

μ	$p(4)$	$p(6)$	L
3.5	0.3521	0.0175	0.0062
4.0	0.3989	0.0540	0.0215
4.5	0.3521	0.1295	0.0456
5.0	0.2420	0.2420	0.0585
5.5	0.1295	0.3521	0.0456

Abbildung: Werte

Beispiel 2

Bernoulli-Verteilung: Eine diskrete Zufallsvariable X aus einer Grundgesamtheit T :

$$X = \begin{cases} 1 & : \text{bestimmter Zustand tritt ein} \\ 0 & : \text{bestimmter Zustand tritt nicht ein} \end{cases}$$

Wahrscheinlichkeit für $X = 1$: $P(X = 1) = p \rightarrow$ unbekannt

Wahrscheinlichkeit für $X = 0$: $P(X = 0) = 1 - p = q$

Mit $T_1 = \sum_{i=1}^T y_i$ als Anzahl der Beobachtungen für $X = 1$ erhält man die gemeinsame Wahrscheinlichkeitsverteilung (Likelihood-Funktion) f

$$f(p; T_1) = p^{T_1} (1 - p)^{(T - T_1)} \quad (4)$$

Beispiel 2 cont'd

Logarithmieren von Gleichung (4) ergibt die **Loglikelihood-Funktion**

$$\log L(p; T_1) = T_1 \log p + (T - T_1) \log(1 - p) \quad (5)$$

Maximiere die Wahrscheinlichkeit p für den Eintritt von $X = 1$:

$$\frac{\partial \log L}{\partial p} = T_1 \frac{1}{\hat{p}} - (T - T_1) \frac{1}{1 - \hat{p}} \quad (6)$$

Auflösen nach \hat{p} ergibt den Maximum-Likelihood-Schätzer:

$$\hat{p} = \frac{T_1}{T} \quad (7)$$

Idee des ML-Schätzers

1. Gegeben sind Daten T_1 als Stichprobe aus einer Grundgesamtheit T
2. Annahme: Wahrscheinlichkeitsverteilung der Daten ist bekannt, und abhängig vom unbekanntem p
3. Frage: Wie hoch ist die unbekannte Wahrscheinlichkeit p , dass die angenommene Verteilung mit der tatsächlichen Verteilung übereinstimmt, dass also die Stichprobe möglichst exakt der wahren Verteilung entspricht?
4. Antwort: Wähle p so, dass die Wahrscheinlichkeit der Übereinstimmung maximal wird

Anwendung auf das lineare Regressionsmodell

Das tatsächliche lineare Schätzmodell aus dem 1. Teil der Vorlesung:

$$\mathbf{y} = \mathbf{X}\beta + \mathbf{u} \quad (8)$$

Unter der Annahme normalverteilter Störterme

$$\mathbf{u} \sim N(\mathbf{0}, \sigma_u^2 \mathbf{I})$$

kann man die Wahrscheinlichkeitsfunktion der Normalverteilung nutzen: Für eine Zufallsvariable X mit $X \sim N(E(X), \sigma^2)$ gilt

$$f(X) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left\{ -\frac{1}{2} \frac{(X - E(X))^2}{\sigma^2} \right\} \quad (3)$$

Mit $E(\mathbf{u}) = \mathbf{0}$ gilt $E(\mathbf{y}) = \mathbf{X}\beta$, und man kann für die Likelihood-Funktion schreiben

$$f(\beta; \sigma^2) = \frac{1}{(\sqrt{2\pi\sigma^2})^T} \exp \left\{ -\frac{1}{2} \frac{(\mathbf{y} - \mathbf{X}\beta)'(\mathbf{y} - \mathbf{X}\beta)}{\sigma^2} \right\} \quad (9)$$

Durch Logarithmieren erhält man:

$$\log L(\beta; \sigma^2) = -\frac{T}{2} [\log \sigma^2 + \log(2\pi)] - \frac{1}{2\sigma^2} ((\mathbf{y} - \mathbf{X}\beta)'(\mathbf{y} - \mathbf{X}\beta)) \quad (10)$$

Den ML-Schätzer erhält man durch Ableitung von (10) nach β .

$$\frac{\partial \log L}{\partial \beta} = -2\mathbf{X}'\mathbf{y} + 2\mathbf{X}'\mathbf{X}\hat{\beta} = 0 \quad (11)$$

D.h., der ML-Schätzer für β entspricht genau dem OLS-Schätzer:

$$\hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y} \quad (12)$$

Ableitung von (10) nach σ^2 ergibt den Schätzer für die Varianz:

$$\frac{\partial \log L}{\partial \sigma^2} = -\frac{T}{2} \frac{1}{\sigma^2} + \frac{1}{2\sigma^4} (\mathbf{y} - \mathbf{X}\beta)'(\mathbf{y} - \mathbf{X}\beta) = 0 \quad (13)$$

Auflösen führt zu

$$\hat{\sigma}_{ML}^2 = \frac{\mathbf{u}'\mathbf{u}}{T} \quad (14)$$

Dies bedeutet, dass der ML-Schätzer der Varianz im Vergleich zu dem OLS-Schätzer einen Bias aufweist:

Aus dem 1. Teil der Vorlesung:

$$\hat{\sigma}_{OLS}^2 = \frac{1}{T - m} \mathbf{u}' \mathbf{u} \quad (15)$$

Allerdings ist der ML-Schätzer **asymptotisch** erwartungstreu:

Für $T \rightarrow \infty$, geht die Differenz der Schätzer, $\frac{m}{(T-m)T}$ gegen Null.

Testprinzipien auf Basis des ML-Schätzers

Auf Basis des ML-Prinzips lassen sich eine Reihe von Testverfahren berechnen:
Schätze

$$\max_{\beta} \log L(\beta) \quad (16)$$

mit der Nullhypothese

$$H_0 : \mathbf{R}(\beta) = \mathbf{q} \quad (17)$$

mit \mathbf{R} als $J \times m$ Matrix, \mathbf{q} als Vektor der Restriktionen, m als Anzahl der Parameter und J als Anzahl der Restriktionen.

Beispiel

Test auf Nullrestriktion bei zwei Parametern, d.h. $m = J = 2$:

$$\begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$

Das heißt, wir testen auf:

$$\beta_1 = 0$$

$$\beta_2 = 0$$

All drei Testverfahren

- ▶ Likelihood-Ratio (LR) - Test
- ▶ Lagrange-Multiplier (LM) - Test
- ▶ Wald-Test

beruhen auf einem Vergleich des restringierten mit dem unrestringierten Modell. Asymptotisch sind all drei Tests Chi-Quadrat verteilt.

Der LR-Test

- ▶ Idee: Ist die *Differenz* der geschätzten Loglikelihood-Funktionen des restringierten und des unrestringierten Modells signifikant von Null verschieden?

$$\lambda = \frac{L(\tilde{\beta})}{L(\hat{\beta})} \quad (18)$$

- ▶ Dass heißt, man erhält die Teststatistik als

$$LR = -2\log\lambda = 2[\log L(\hat{\beta}) - \log L(\tilde{\beta})] \stackrel{a}{\sim} \chi^2(J) \quad (19)$$

- ▶ Wenn Differenz statistisch signifikant von Null verschieden, Ablehnung der Restriktion
- ▶ Lehne H_0 ab, wenn Differenz groß ist.

Der LM-Test

- ▶ Schätzung des Modells mit Restriktionen
- ▶ Test, ob *1. Ableitungen der Loglikelihood-Funktion signifikant von Null verschieden* sind, d.h., ob sich die Steigungen der Loglikelihood-Funktion signifikant unterscheiden
- ▶ Die Teststatistik ergibt sich somit als:

$$LM = \frac{\partial \log L'}{\partial \tilde{\beta}} [\mathbf{J}(\tilde{\beta})^{-1}] \frac{\partial \log L}{\partial \tilde{\beta}} \stackrel{a}{\sim} \chi^2(J) \quad (20)$$

mit \mathbf{J}^{-1} als *Informationsmatrix*, d.h. der Inversen der geschätzten Varianz-Kovarianz-Matrix des restringierten Modells.

- ▶ Lehne H_0 ab, wenn die Ableitung ungleich Null ist.
- ▶ LM-Test-Statistik als Basis für eine Reihe von Tests:
 - ▶ Test auf ausgelassene Variablen
 - ▶ Test auf Heteroskedastie (Breusch-Pagan-Test)
 - ▶ Test auf Autokorrelation (Breusch-Godfrey-Test)

Der Wald-Test

- ▶ Der Wald-Test vergleicht die Schätzer des restringierten mit dem unrestringierten Modell. Da der ML-Schätzer erwartungstreu ist, sollte die Differenz Null betragen, wenn die Restriktion gültig ist.

$$\hat{\beta} - \tilde{\beta} = 0$$

- ▶ Diese Differenz wird mit den *2. Ableitungen der Loglikelihood-Funktion* gewichtet, also der Krümmung. Man erhält die Teststatistik als:

$$W = (\mathbf{R}\tilde{\beta})[\mathbf{R}'\mathbf{J}(\hat{\beta})]^{-1}\mathbf{R}(\mathbf{R}\tilde{\beta}) \stackrel{a}{\sim} \chi^2(J) \quad (21)$$

- ▶ Vorteil: Restringierte Schätzung muss nicht durchgeführt werden (da $H_0 : \tilde{\beta} = 0$)
- ▶ Nachteil: Testergebnisse abhängig von mathematischer Formulierung der Restriktion
- ▶ F-Statistik als Spezialfall des Wald-Tests
- ▶ Lehne H_0 ab, wenn $h(\hat{\beta})$ ungleich Null ist.

Beispiel 2 cont'd

Im Bernoulli-Beispiel war der ML-Schätzer über die 1.Ableitung berechnet als:

$$\frac{\partial \log L}{\partial p} = T_1 \frac{1}{\hat{p}} - (T - T_1) \frac{1}{1 - \hat{p}} \quad (6)$$

Die 2.Ableitung führt auf die Varianz-Kovarianz-Matrix (2. Moment der Verteilung):

$$\frac{\partial^2 \log L}{\partial^2 p} = T_1 \frac{1}{\hat{p}^2} - (T - T_1) \frac{1}{1 - \hat{p}^2} \quad (6a)$$

Dies kann man auflösen nach der Varianz-Kovarianz-Matrix V :

$$J = \frac{1}{p(1-p)} = V^{-1} \quad (6b)$$

Beispiel 2 cont'd: Teststatistiken

Der Wald-Test

$$\xi_W = T(\hat{p} - \tilde{p})[\hat{p}(1 - \hat{p})]^{-1}(\hat{p} - \tilde{p}) \quad (22)$$

Der Likelihood Ratio Test

$$\xi_{LR} = 2(\log L(\hat{p}) - \log L(\tilde{p})) \quad (23)$$

Der Lagrange Multiplier Test

$$\begin{aligned} \xi_{LM} &= T^{-1} \left(\frac{T_1}{\hat{p}} - \frac{T - T_1}{1 - \hat{p}} \right) [\tilde{p}(1 - \tilde{p})] \left(\frac{T_1}{\hat{p}} - \frac{T - T_1}{1 - \hat{p}} \right) \quad (24) \\ &= T^{-1}(T_1 - T\tilde{p})[\tilde{p}(1 - \tilde{p})]^{-1}(T_1 - T\tilde{p}) \end{aligned}$$

und, da $\hat{p} = T_1/T$:

$$\xi_{LM} = T(\hat{p} - \tilde{p})[\tilde{p}(1 - \tilde{p})]^{-1}(\hat{p} - \tilde{p}) \quad (24)$$

Beispiel 3: Sensitivität des Wald-Tests

Schätze

$$\log(C_t) = \beta_1 + \beta_2 \log(Yver_t) + \beta_3 \log(Yver_{t-4}) + \beta_4 \log(C_{t-4}) + u_t \quad (25)$$

mit C = reale Konsumausgaben und $Yver$ = reales verfügbares Einkommen.

Teste, ob die langfristige Einkommenselastizität des Konsums gleich 1 beträgt:²

Langfristig gilt: $C_t = C_{t-4} = C$ und $Yver_t = Yver_{t-4} = Yver$

Auflösen von Gleichung (25) führt zu

$$H_0 : \frac{\beta_2 + \beta_3}{1 - \beta_4} = 1$$

oder

$$H_0 : \beta_2 + \beta_3 + \beta_4 - 1 = 0$$

²Kointegration zwischen Konsum und Einkommen

Sensitivität des Wald-Tests

Eine Schätzung mit Daten für Großbritannien von 1955:1 bis 1998:4 ergibt:

Tabelle: Wald-Test

Hypothese	F-Statistik	p-Wert
$\frac{\beta_2 + \beta_3}{1 - \beta_4} = 1$	34.23852	0.0000
$\beta_2 + \beta_3 + \beta_4 - 1 = 0$	5.592360	0.0192

Gute Nachricht: GRETl erlaubt nur das Testen von linearen Restriktionen und formuliert nichtlineare automatisch um.

Erweiterungen

- ▶ Quasi-ML als allgemeinere Methode, Aufgabe der Annahme normalverteilter Störterme
- ▶ Problem: Schätzer ist nur asymptotisch effizient.
- ▶ Lösung: großer Beobachtungsumfang oder Bayesianische Priors

Zusammenfassung

- ▶ ML-Schätzer als allgemeines Schätzprinzip
- ▶ Schätzer für σ^2 nicht erwartungstreu bei kleinem Beobachtungsumfang, dafür Möglichkeit der Schätzung nichtlinearer Modelle
- ▶ Berechnungsgrundlage für eine Reihe von Testprinzipien
- ▶ **Literatur:**
Verbeek (2008): Kapitel 6.1 - 6.3
Dougherty (2002): Kapitel 11.6