

3. Geld

„Die Phönizier haben das Geld erfunden - aber warum so wenig?“

Johann Nepomuk Nestroy

„Money makes the world go around“ hätte als fremdsprachiges geflügeltes Wort am Eingang zu diesem Kapitel auch gut gedient. Die Rolle des Geldes als zentrales Element einer Volkswirtschaft haben wir ja schon in Kapitel 1 an Hand einer Extremsituation beleuchtet. Selbstverständlich ist es mindestens ebenso interessant zu analysieren, welchen Gesetzmäßigkeiten die monetären Aspekte einer Ökonomie unter normalen Umständen unterliegen. Von nahezu historischem Interesse – in an der Entwicklung der Ökonometrie gemessenen Zeitbegriffen – sind dabei die Mechanismen der Generierung von Nachfrage nach Geld.

Die Geldnachfragefunktion ist ein Eckpfeiler des IS-LM Modells. Die Reaktion des ganzen Modells auf wirtschaftspolitische Eingriffe hängt unter anderem von den Parametern der Geldnachfragefunktion ab. Mittlerweile ist es ein Gemeinplatz, dass die Geldnachfrage im Wesentlichen von zwei Faktoren bestimmt wird: einem Indikator für das Transaktionsvolumen in der Wirtschaft und einem Indikator für die Kosten der Geldhaltung. Je mehr Transaktionen in einer Wirtschaft abgewickelt werden, desto höher ist der Bedarf privater Haushalte und Unternehmen nach dem allgemeinen akzeptierten Transaktionsmittel Geld. Je höher die Kosten der Geldhaltung sind, desto geringer wird die Geldnachfrage sein, weil man durch Geldhaltung z. B. auf Zinserträge verzichtet.

Nach der Veröffentlichung der General Theory von John M. Keynes (1936) entbrannte um diese Fragestellung eine heftige theoretische und empirische Auseinandersetzung, die sich vor allem darum drehte, ob die Geldnachfrage vom Zinssatz abhängt oder nicht, bzw. ob die Zinselastizität der Geldnachfrage hoch oder niedrig ist. Wenn die Zinselastizität der Geldnachfrage besonders hoch ist, ist die Geldpolitik tendenziell unwirksam. Wenn die Zinselastizität niedrig ist, ist sie tendenziell sehr wirksam (vgl. Blanchard, 2000, Kap. 5).

Unser Beispiel für dieses Kapitel ist ein Modell für die Geldnachfragefunktion des Vereinigten Königreiches von Milton Friedman und Anna Schwartz (1982), das wegen der aufwendigen Dokumentation der Daten besonders aufschlussreich ist. Es ist die Fortsetzung einer Arbeit von Milton Friedman (1959) in der er folgerte, dass die Geldnachfrage nicht zinsabhängig ist.

Welche Formen von Geld werden in der Geldnachfragefunktion eigentlich berücksichtigt?

Unter Geldnachfrage versteht man im Allgemeinen nicht nur die Nachfrage nach Münzen und Banknoten, sondern auch die auf Girokonten gehaltenen Beträge. Die Summe aus diesen drei Kategorien von Geld bezeichnet man als M1.

In englischsprachigen Texten wird dies oft auch als high powered money bezeichnet.

Wenn man alle Sparguthaben – also alle Einlagen auf Sparbüchern – hinzurechnet, gelangt man zum Geldmengenaggregat M2. Das am häufigsten verwendete Geldmengenaggregat ist M3. Es beinhaltet alle Komponenten von M2 und zusätzlich die Termineinlagen. Das sind zeitlich befristet Bankeinlagen, üblicherweise mit höherer Verzinsung. Die Europäische Zentralbank rechnet in die Geldmenge M3 auch die in Geldmarktfonds veranlagten Mittel, weil sie gleichzeitig verzinst sind und ein hohes Ausmaß an Liquidität aufweisen. Die Wachstumsrate von M3 ist eine Zielgröße der Europäischen Zentralbank. In der geldpolitischen Strategie ist dieser Referenzwert in die 2. Säule der europäischen Geldpolitik integriert (European Central Bank, 2004).

Warum gibt es eigentlich so viele unterschiedliche Geldmengenkonzepte?

Im Prinzip wegen der möglichen Substitutionsbeziehung zwischen den einzelnen Komponenten der Geldmenge: Je größer die Substitutionsbeziehung zwischen den Einzelkomponenten der Geldmenge ist, desto umfassender muss die Definition der Geldmenge erfolgen. Diese Substitutionsbeziehung ändert sich auch über die Zeit: teilweise wegen technischer Neuerungen und teilweise als Reaktion auf geldpolitische Maßnahmen. Die Entwicklung und Nutzung von Geldmarktfonds ist ein Beispiel für eine technische Neuerung. In Kombination mit elektronischen Bankkonten (Online Banking) wird der Transfer zwischen unterschiedlichen Veranlagungsformen immer leichter und schneller. Damit ist ein rascher und kostengünstiger Umstieg von Geld zu einer verzinsten Veranlagung, bei gleichzeitig hoher Liquidität, möglich.

Neue Technologien erzeugen also neue Substitutionsmöglichkeiten und erschweren einer Zentralbank mit einem Geldmengenziel die Definition der für die Preisentwicklung relevanten Geldmenge?

Stimmt, und das bringt mich auf die zweite Erklärung für die Vielfalt an Geldmengendefinitionen. In den Jahren 1974-1979 verfolgte die Labour-Regierung im Vereinigten Königreich ein Geldmengenziel. Charles Goodhart (1984) formulierte aus dieser Erfahrung das nach ihm benannte Goodhart's Law. Es besagt, dass wann immer eine Regierung oder eine Nationalbank eine statistische Regelmäßigkeit für Kontrollzwecke benützen möchte und zur Erreichung des wirtschaftspolitischen Zieles Druck ausübt, diese Regelmäßigkeit zusammenbricht. Maßnahmen zur Erreichung des Geldmengenzieles, veranlassen die davon betroffenen Wirtschaftssubjekte zur Suche nach Umgehungsmöglichkeiten.

In diesem Sinn ist Goodhart's Law eine Version der Lucas Kritik und zeigt, dass zur Schätzung einer Geldnachfragefunktion sowohl das Angebot als auch die Nachfrage am Geldmarkt berücksichtigt werden müssen. Die simultane Beziehung zwischen Geldmenge und Bruttoinlandsprodukt kann Identifikationsprobleme bereiten. Zusätzlich können geänderte institutionelle Rahmenbedingungen – wie etwa die Liberalisierung des Kapitalverkehrs oder

eine Änderung des Wechselkursregimes – die Geldnachfrage beeinflussen. Laidler (1985) gibt einen sehr guten Überblick der praktischen Probleme in der Schätzung von Geldnachfragefunktionen.

Wenn schon der Indikator für die Geldnachfrage umstritten ist, gibt es wenigstens Einigkeit über die Indikatoren für das Transaktionsvolumen oder die Opportunitätskosten?

Üblicherweise nimmt man das reale Bruttoinlandsprodukt als Indikator für das Transaktionsvolumen. Das entspricht zwar nicht dem tatsächlichen Transaktionsbedarf – das wären die schwer messbaren nominellen Umsätze der Unternehmen bzw. der privaten und öffentlichen Haushalte – aber die Umsätze sollten in der Regel proportional zum Bruttoinlandsprodukt sein. Dass dieses Verhältnis nicht immer konstant ist, zeigt das hohe Wachstum der Geldmenge in der Europäischen Währungsunion und den USA während des Rückgangs der Börsenkurse zwischen 2000 und Mitte 2003. Private Haushalte und Investmentfonds bauten in dieser Periode ihre Geldhaltung aus, um das hohe Risiko von Kursverlusten auf den Aktienmärkten zu vermeiden. In diesem Fall kann der Bestand an Finanzvermögen ein besserer Indikator für den Transaktionsbedarf sein.

Was den Zinssatz betrifft, muss man zwischen direkten und indirekten Kosten der Geldhaltung unterscheiden. Die direkten Kosten bestehen aus der Möglichkeit eines Verlustes und z. B. Buchungsgebühren bei Abhebungen. Vereinfachend werden sie meistens vernachlässigt und Null gesetzt. Die indirekten Kosten beziehen sich auf Opportunitätskosten der Geldhaltung in Form entgangener Zinsen. Da jede Komponente der Geldmenge andere Opportunitätskosten hat (Zinsen auf Girokonten, Sparbücher usw.), kann diese Frage eigentlich nur gemeinsam für alle Komponenten gelöst werden. Im IS-LM-Modell wird vereinfachend angenommen, dass es nur zwei mögliche Veranlagungsformen gibt. Entweder halten die Wirtschaftssubjekte Geld und verzichten damit auf eine Verzinsung oder sie veranlagen ihr Vermögen in einer Einheitsanleihe zu einem einheitlichen Zinssatz. In der Realität gibt es allerdings viele sich mehr oder weniger stark hinsichtlich Liquidität und Verzinsung unterscheidende Veranlagungsformen. Friedman und Schwartz haben immer ein sehr weit gefasstes Verständnis alternativer Veranlagungsformen; es reicht von Bargeld bis zur Veranlagung in physische Vermögenswerte. Eigentlich sollten in der Geldnachfragefunktion die erwarteten ex ante Zinssätze einbezogen sein. Weil die aber schwer zu berechnen sind, werden oft die ex post beobachteten Zinssätze und Inflationsraten eingesetzt.

In unserem Beispiel untersuchen Milton Friedman und Anna Schwartz (1982) den Zusammenhang zwischen Geldnachfrage, Einkommen, Preisen und Zinssätzen für das Vereinigte Königreich. Mit Jahreswerten von 1868 bis 1975 erreichen sie eine in der Ökonometrie unübliche Stichprobengröße von mehr als einem Jahrhundert. Ihr theoretischer Ausgangspunkt ist die folgende individuelle Nachfragefunktion nach Geld

$$M/P = f(Y, w; E(r_M), E(r_B), E(r_E), \pi^e; u).$$

Die reale Geldnachfrage M/P eines Wirtschaftssubjektes hängt vom realen Einkommen Y , dem Anteil w dieses Einkommens, das aus Vermögenserträgen entsteht, und dem erwarteten nominellen Zinssatz auf geldnahe Anlagen r_M , sowie den nominellen Renditen auf festverzinsliche Anleihen r_B und Aktien r_E , wobei die Ertragsraten auf Anleihen und Aktien die erwarteten Preis- bzw. Kursänderungen beider Anlageformen beinhalten. Die erwartete Inflationsrate π^e dient zur Ermittlung von ex ante Realzinssätzen. Das letzte Element in der Geldnachfragefunktion u beschreibt alle Variablen, die den Nutzen von Geld beeinflussen können, z. B. die Dichte von automatischen Geldausgabeautomaten.

Die abhängige Variable ist in diesem Modell die reale Geldmenge. Dadurch wird implizit angenommen, dass Preisänderungen nur eine Veränderung der Zählereinheit darstellen. Die nominelle Geldnachfrage sollte also auf eine Preissteigerung von 10% mit einem Anstieg von 10% reagieren. Damit bleibt die reale Geldnachfrage von Preisänderungen unabhängig. Technisch wird damit die direkte Preiselastizität der Geldnachfrage auf Eins gesetzt, bzw. die Geldnachfrage ist homogen vom Grad Eins in Bezug auf das Preisniveau. Eine für Monetaristen typische Annahme, die eigentlich nur langfristig gilt, aber von Friedman und Schwartz getestet und nicht abgelehnt wird.

Friedman und Schwartz schätzen eine aggregierte Geldnachfrage für die Gesamtwirtschaft. Wie kommen sie von der individuellen Geldnachfragefunktion zur gesamtwirtschaftlichen?

Sie verwenden anstelle individueller Werte die reale Geldmenge und das Bruttoinlandsprodukt und normieren diese Größen auf die Bevölkerung. Dadurch erreichen sie eine Funktion für die Realkasse und das Realeinkommen in Pro-Kopf-Werten, die sie in einer herkömmlichen Regression verwenden. Diese Vereinfachung unterstellt, dass Geld und Einkommen gleichmäßig über die Bevölkerung verteilt sind, bzw. dass man Verteilungseffekte vernachlässigen kann.

Friedman und Schwartz (1982) wollen die langfristige Beziehung zwischen Geld, Einkommen und Zinssätzen untersuchen und bereinigen die Daten daher von zyklischen Schwankungen. Die kurzfristigen Schwankungen innerhalb eines Konjunkturzyklus können in einem langfristigen Vergleich der Daten starke Verzerrungen bewirken, wenn die erste und die letzte Beobachtung der Stichprobe aus einer anderen Phase des Konjunkturzyklus stammen. Friedman und Schwartz folgen in der Bereinigung einer damals im National Bureau of Economic Research (NBER) beliebten Methode. Sie nehmen die Beginn- und Endpunkte aller Konjunkturzyklen zwischen 1868 und 1975 und bilden aus den Beobachtungen jeder Aufschwung- bzw. jeder Abschwungphase jeweils einen Durchschnittswert. Dadurch verkleinert sich die Anzahl der Beobachtungen von 108 Jahreswerten auf 38 und letztendlich 36 brauchbare Phasenwerte.

Die Daten stehen aus diesem Grund auch nur als „irreguläre“ Zeitreihen in EViews zur Verfügung, die entsprechenden Phasenmittelpunkte sind in der Variable t dokumentiert.

Obwohl die Datendokumentation schon in Friedman und Schwartz ausgezeichnet ist - sämtliche, auch transformierte Reihen sind abgedruckt - verwenden wir in diesem Kapitel den von Ericsson et al. (1998) aus den Originaljahresdaten rekonstruierten und von David Hendry freundlicherweise zur Verfügung gestellten Datensatz. Die von Friedman und Schwartz (1982) erzielten Ergebnisse lassen sich damit qualitativ richtig wiedergeben, kleinere Abweichungen sind laut Ericsson et al. (1998) vor allem auf Rundungsfehler zurückzuführen.

Weil Ericsson et al. die Zeitreihen noch bis ins Jahr 1993 (Beobachtungszahl 44) verlängert haben, muss zu Beginn der Analyse der Zeitbereich (sample) auf 1 - 36 gesetzt werden.

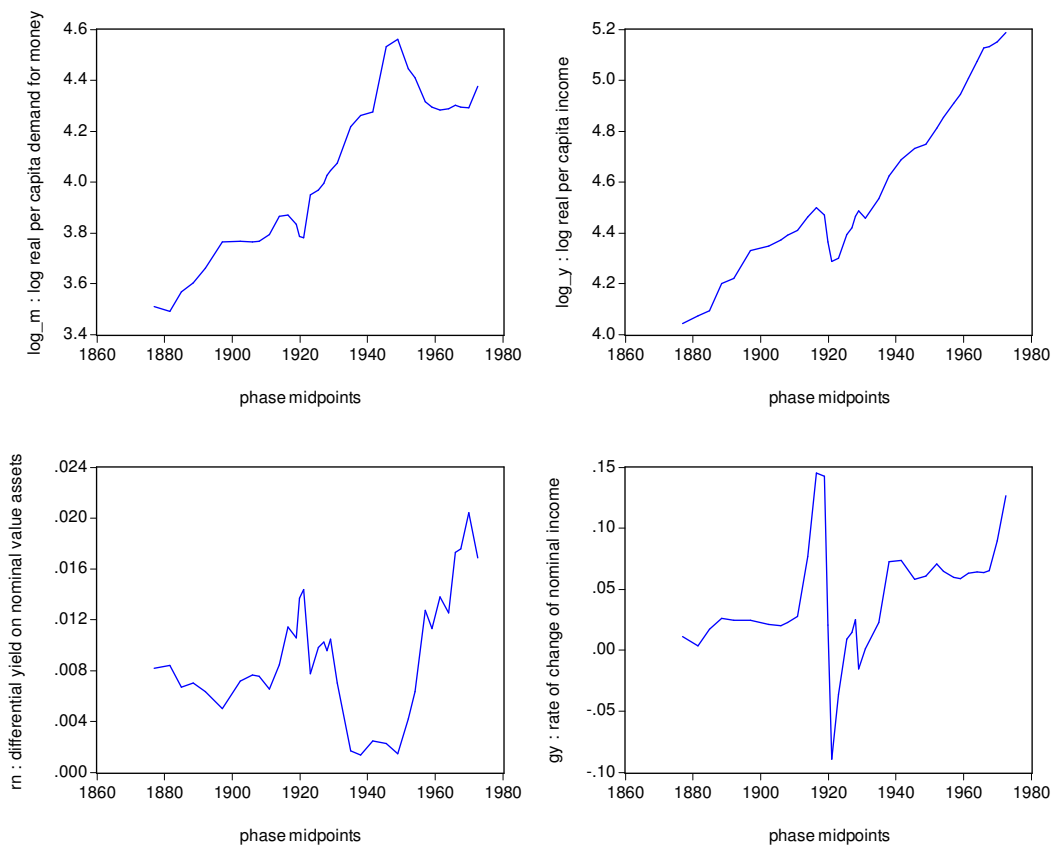
Im Einklang mit ihrer theoretischen Geldnachfragefunktion verwenden Friedman und Schwartz den Logarithmus der realen pro Kopf Geldmenge als abhängige Variable. Als Indikator für das Transaktionsvolumen verwenden sie das reale pro Kopf Einkommen Y_c , ebenfalls in Logarithmen. Die Kosten der Geldhaltung messen sie als Unterschied zwischen hypothetischen direkten Kosten der Geldhaltung und den Opportunitätskosten in Form des kurzfristigen Zinssatzes. Dieser Unterschied misst die Grenzkosten für das Halten einer zusätzlichen Geldeinheit und wird mit R_N bezeichnet. Da sie keinen großen Einfluss des Anleihezinssatzes auf die Geldnachfrage feststellen konnten, verzichten sie auf diesen Indikator.

Die Breite der Substitutionsmöglichkeiten im monetaristischen Verständnis zeigt sich in der Berücksichtigung von Aktienerträgen in der Geldnachfragefunktion. Sie sollen alternative Veranlagungsformen in Form von Investitionen in physische Anlagen oder langfristige Konsumgüter in die Analyse integrieren. Weil die Ertragskennziffern börsennotierter Unternehmen einen viel zu engen Kreis von Anlagemöglichkeiten beschreiben, verwenden sie die Wachstumsrate g_Y des nominellen Einkommens. Sie soll den nominellen Ertrag auf physische Vermögensanlagen für die Gesamtwirtschaft abbilden.

3.1 Multiple Regression

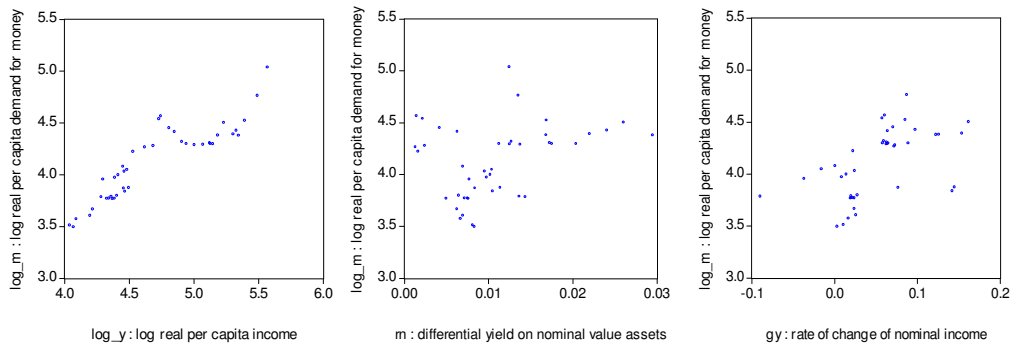
Sehen wir uns doch zunächst die Zeitreihenplots dieser vier Kenngrößen an.

Hierbei darf in EViews nicht einfach die Line_Plot Option gewählt werden, da ja die Zeitabstände zwischen den Beobachtungen unregelmäßig sind. Abhilfe schafft die Definition einer Gruppe mit t (den Phasenmitteln) als erster Variable und danach ein Plot mittels View - Multiple_Graphs - XY_line.



Es ist naturgemäß schwierig daraus bereits Zusammenhänge zu erkennen, vor allem auch deshalb weil die Reihen trendbehaftet erscheinen. Einen besseren Überblick sollte uns eine Reihe von Streudiagrammen liefern. Am Interessantesten sind für uns sicher jene zwischen dem Regressanden und den einzelnen Regressoren.

In EViews gibt es zwar die Möglichkeit aus einer vorher definierten Gruppe mittels View_Multiple-Graphs-Scatter-First_series_against_all eine einzelne Zeitreihe in einer Reihe von Streudiagrammen gegen mehrere andere zu plotten, dabei wird aber die betreffende Zeitreihe auf der horizontalen Achse aufgetragen. Da es sich in unserem Fall ja um den Regressanden handelt, entspräche dies nicht der Konvention und vertrauten Sichtweise. Es bleibt uns also nichts anderes übrig, als die Streudiagramme einzeln zu erzeugen und dann wie folgt nebeneinander zu stellen.



In dieser Sichtweise erwecken alle drei Regressoren den Eindruck sie wären mit dem Regressanden mehr oder weniger stark verbunden (am wenigsten sicherlich RN, am stärksten wohl LOG_Y). Wir wissen nun schon, dass wir die Einzelzusammenhänge mittels einfacher Regressionen analysieren können. Es ergeben sich die Outputs:

Dependent Variable: LOG_M
 Method: Least Squares
 Sample: 1 36
 Included observations: 36

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.362372	0.371001	0.976743	0.3356
LOG_Y	0.801767	0.080932	9.906715	0.0000
R-squared	0.742703	Mean dependent var		4.028569
Adjusted R-squared	0.735135	S.D. dependent var		0.305842
S.E. of regression	0.157402	Akaike info criterion		-0.806079
Sum squared resid	0.842360	Schwarz criterion		-0.718106
Log likelihood	16.50942	F-statistic		98.14301
Durbin-Watson stat	0.205516	Prob(F-statistic)		0.000000

Dependent Variable: LOG_M
 Method: Least Squares
 Sample: 1 36
 Included observations: 36

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	4.002880	0.112355	35.62709	0.0000
RN	2.834092	11.00699	0.257481	0.7984
R-squared	0.001946	Mean dependent var		4.028569
Adjusted R-squared	-0.027408	S.D. dependent var		0.305842
S.E. of regression	0.310005	Akaike info criterion		0.549497
Sum squared resid	3.267510	Schwarz criterion		0.637471
Log likelihood	-7.890954	F-statistic		0.066297
Durbin-Watson stat	0.063624	Prob(F-statistic)		0.798359

Dependent Variable: LOG_M
 Method: Least Squares
 Sample: 1 36
 Included observations: 36

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	3.909157	0.063412	61.64683	0.0000
GY	2.853887	1.025829	2.782031	0.0088
R-squared	0.185428	Mean dependent var		4.028569
Adjusted R-squared	0.161470	S.D. dependent var		0.305842
S.E. of regression	0.280064	Akaike info criterion		0.346353
Sum squared resid	2.666813	Schwarz criterion		0.434327
Log likelihood	-4.234359	F-statistic		7.739699
Durbin-Watson stat	0.156595	Prob(F-statistic)		0.008750

Diese Regressionen bestätigen die theoretisch erwarteten Beziehungen nur teilweise. Die Schätzgleichung mit Y_c als erklärender Variable hat das höchste Bestimmtheitsmaß und der entsprechende Koeffizient ist statistisch signifikant. Letzteres trifft auch für die Gleichung mit g_Y zu, nicht aber für jene mit R_N . Direkte Kosten der Geldhaltung und kurzfristige Opportunitätskosten haben keinen signifikanten Einfluss auf die reale Geldnachfrage.

Dieses Ergebnis verleitet zur Vermutung, dass eine Spezifikation mit Transaktionsvolumen und Ertragsraten auf Veranlagungen in physische Vermögensgegenstände das bestmögliche Modell ist, also

$$\log(M/P_c) = \beta_0 + \beta_1 \log(Y_c) + \beta_2 g_Y + \varepsilon,$$

womit im Raum steht, dass nur die Substitutionsbeziehung zwischen Geldmenge und physischen Veranlagungen praktisch relevant sind; eine doch etwas unerwartete Schlussfolgerung.

Ja, diese Schlussfolgerung ist unplausibel, dies kann jedoch in Modellen mit mehr als einem Regressor, so genannten multiplen Regressionsmodellen, durchaus auftreten. Um zu verstehen, warum dies so ist, müssen wir zuerst überlegen, wie wir im obigen Fall zu vernünftigen Schätzern kommen.

Nun, das sollte kein Problem sein, da wir ja die Kleinst-Quadrate Lösung ohnehin schon in einer allgemeinen Matrixform dargestellt haben.

Ganz genau, wir setzen also im allgemeinen Regressionsmodell $\beta = \{\beta_0, \beta_1, \beta_2\}'$ und $X = \{1, \log(Y_c), g_Y\}$, sowie $y = \log(M/P_c)$ ein und erhalten den gewünschten Schätzer wieder mit $\hat{\beta} = (X'X)^{-1}X'y$. Dabei haben wir nun geometrisch statt einer Geraden an eine zweidimensionale Punktwolke eine Ebene an eine dreidimensionale Punktwolke angepasst. Die Parameterschätzer $\hat{\beta}_1$ und $\hat{\beta}_2$ sind deshalb auch nicht als (marginale) Steigung der individuellen Geraden zu interpretieren sondern als (bedingte) Steigung für den Fall, dass die jeweils andere Einflussgröße einen konstanten Wert annimmt. Genau darum aber sind

diese Schätzer im Allgemeinen von einander abhängig und es ist nicht klar, dass die Kombinationen von individuell „guten“ oder „schlechten“ Regressoren auch insgesamt „gute“ oder „schlechte“ Modelle ergeben.

Im vorliegenden Fall ergibt sich für die multiple Regression mit LOG_Y und GY als Regressoren der Output:

Dependent Variable: LOG_M
 Method: Least Squares
 Sample: 1 36
 Included observations: 36


Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.161671	0.437417	0.369604	0.7140
LOG_Y	0.851301	0.099034	8.596079	0.0000
GY	-0.616611	0.705491	-0.874017	0.3884
R-squared	0.748524	Mean dependent var		4.028569
Adjusted R-squared	0.733283	S.D. dependent var		0.305842
S.E. of regression	0.157951	Akaike info criterion		-0.773408
Sum squared resid	0.823301	Schwarz criterion		-0.641448
Log likelihood	16.92135	F-statistic		49.11271
Durbin-Watson stat	0.224265	Prob(F-statistic)		0.000000

Die den Koeffizienten zugeordneten Kenngrößen sind genau wie im Fall der Einfachregression interpretierbar, das heißt in dieser Spezifikation hat die Wachstumsrate g_Y keinen statistisch signifikanten Einfluss (zusätzlich zu dem vom Einkommen $\log(Y_c)$ generierten). Der in der Einzelgleichung festgestellte Effekt von g_Y wurde also von $\log(Y_c)$ sozusagen überlagert.

Algebraisch lässt sich diese Möglichkeit im Zwei-Regressoren-Modell leicht zeigen. Es folgt zum Beispiel aus $\hat{y} = X_{0,1}\hat{\beta}_{0,1} + x_2\hat{\beta}_2$ sofort $X_{0,1}'\hat{y} = X_{0,1}'X_{0,1}\hat{\beta}_{0,1} + X_{0,1}'x_2\hat{\beta}_2$ und daraus $\hat{\beta}_{0,1} = \hat{\beta}_{0,1} - (X_{0,1}'X_{0,1})^{-1}X_{0,1}'x_2\hat{\beta}_2$. Hierbei steht $\hat{\beta}_{0,1}$ für den Schätzer aus der Einfachregression und die Abweichung verschwindet (bei geeigneter Skalierung) entweder, wenn die Regressoren unkorreliert sind ($x_1'x_2 = 0$) oder wenn der zweite Regressor keinen Einfluss hat ($\hat{\beta}_2=0$).

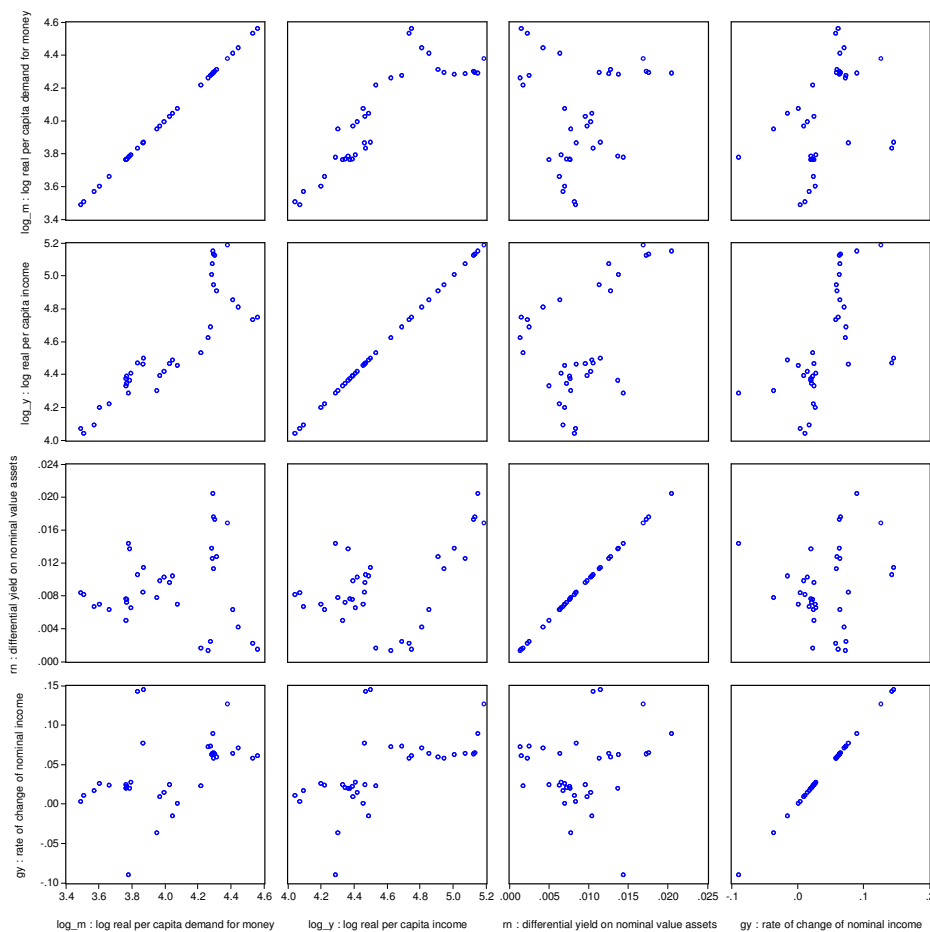
Das bedeutet also, dass auch die Beziehungen der Regressoren untereinander die Schätzergebnisse wesentlich beeinflussen.

Deshalb macht es auch Sinn, die Scatterplots der Regressoren untereinander in die explorative Analyse einzubeziehen. In unserer Anwendung ergeben sich die Plots



aus denen ganz klar positive Beziehungen zwischen den Regressoren zu erkennen sind.

Am besten ist es wohl, gleich zu Beginn, sämtliche in die Analyse ein zu beziehende Variablen paarweise gegeneinander zu plotten. Dies lässt sich übersichtlich in einer Matrixform zusammenstellen und wird in EVIEWS überdies nach dem Definieren einer Gruppe automatisch durch den Befehl View – Multiple Graphs – Scatter – Matrix of all pairs (SCATMAT) erzeugt.



Für die Analyse hilft uns dies nun aber nur beschränkt weiter, wir wollen ja herausfinden, welche von den Regressoren wir zur Erklärung von $\log(M/P_c)$ heranziehen sollen und auf welche wir verzichten können. Bis jetzt wissen wir nur, dass wir aufgrund der Beziehungen der Regressoren untereinander bei der Bewertung ihrer Relevanz vorsichtig sein müssen. Gibt es auch grafische Verfahren, die es uns ermöglichen darüber hinaus noch Rückschlüsse zu ziehen und ein „gutes“ Modell zu finden?

3.2 Added Variable Plots

Zu diesem Zweck gibt es mehrere Verfahren, von denen die von Cook & Weisberg (1982) eingeführten, so genannten Added Variable Plots (A-V-P's) am meisten verbreitet sind. Sie geben den partiellen Einfluss eines einzelnen Regressors auf den Regressanden wieder und lassen sich in einfacher Weise motivieren. Dazu ist es wieder nützlich, den Regressor „unter Beobachtung“ herauszuheben und das lineare Modell in der Form $y = X_{0,1}\beta_{0,1} + x_2\beta_2 + \varepsilon$ darzustellen. Der Schätzer für den „interessanten“ Parameter lässt sich nun als


$$\hat{\beta}_2 = [x_2'(I-H_{0,1})x_2]^{-1}x_2'(I-H_{0,1})\hat{\varepsilon}_{0,1}$$

schreiben, also als Koeffizienten der Regression (ohne Interzept) der Residuen $\hat{\varepsilon}_{0,1}=(I-H_{0,1})y$ aus der Regression von y auf $X_{0,1}$ auf die Residuen $(I-H_{0,1})x_2$ der Regression von x_2 auf $X_{0,1}$ ($H_{0,1}$ bezeichnet hier die dem Modell mit Interzept und Regressor x_1 zugeordnete „Hat“-matrix).

Diese Darstellung ergibt sich aus $y = X_{0,1}\hat{\beta}_{0,1} + x_2\hat{\beta}_2 + \hat{\varepsilon}$ durch Vormultiplizieren mit $x_2'(I-H_{0,1})$ wegen der Orthogonalität von Regressoren und Residuen (also sowohl $x_2'\hat{\varepsilon}$ als auch $X_{0,1}'\hat{\varepsilon} = 0$); also vorerst $x_2'(I-H_{0,1})y = x_2'(I-H_{0,1})x_2\hat{\beta}_2$ und wegen der Idempotenz von $(I-H_{0,1})$ auch wie oben. Man bemerke, dass man hier nicht auf das Zwei-Variablen Modell beschränkt ist, da sich $X_{0,1}$ durch jede beliebige mehrspaltige Matrix ersetzen lässt. Die obige Form bietet somit also die in Kapitel 1 erwähnte Verallgemeinerung des auf den Fall $x_2=t$ bezogenen Resultats von Frisch und Waugh (1933).

Als Kandidat für einen partiellen Residualplot ergibt sich also ein Streudiagramm der Residuen $(I-H_{0,1})y$, also des um den Erklärungsanteil von $X_{0,1}$ bereinigten Regressanden, gegen die Residuen $(I-H_{0,1})x_2$, also des „Erklärungsrestes“ im hinzugefügten (added) Regressor x_2 . Aus diesem Grund werden diese Streudiagramme eben A-V-P's genannt.

In den meisten Softwarepaketen (so auch in EViews) müssen die Regressionen leider einzeln durchgeführt und danach die entsprechenden Residuen gegeneinander geplottet werden. Im konkreten Fall regressiert man zur Eliminierung des Einflusses von $\log(Y_c)$ dies gegen $\log(M/P_c)$ und gegen g_Y . Die resultierenden Residuen wurden mit RESIDM_Y und RESIDGY_Y bezeichnet. Analoges kann man für g_Y machen.



Aus den Resultaten ist nun, wie zuvor schon festgestellt wurde, deutlich ersichtlich, dass der partielle Einfluss von g_Y auf $\log(M/P_c)$ kaum vorhanden ist, während umgekehrt jener von $\log(Y_c)$ auf $\log(M/P_c)$ besonders stark ausgeprägt ist.

Das ist aus der diffusen Punktwolke im linken Bild und der fast diagonalen Anordnung im rechten Bild erkennbar. Könnte es also sein, dass wegen der Beziehungen zwischen den Regressoren die bereits als nichtsignifikant ausgeschiedene Variable R_N doch ins Modell aufgenommen werden müsste?

Dies lässt sich durch Hinzunahme von R_N zur multiplen Regression leicht überprüfen. Dort ergibt sich nämlich:

Dependent Variable: LOG_M
 Method: Least Squares
 Sample: 1 36
 Included observations: 36

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.625109	0.281156	-2.223351	0.0334
GY	-1.137629	0.428107	-2.657347	0.0122
LOG_Y	1.086674	0.066687	16.29503	0.0000
RN	-29.53291	3.816182	-7.738863	0.0000
R-squared	0.912425	Mean dependent var		4.028569
Adjusted R-squared	0.904215	S.D. dependent var		0.305842
S.E. of regression	0.094655	Akaike info criterion		-1.772709
Sum squared resid	0.286709	Schwarz criterion		-1.596762
Log likelihood	35.90876	F-statistic		111.1344
Durbin-Watson stat	0.488062	Prob(F-statistic)		0.000000

also der gegenteilige Effekt zu g_Y , der partielle Einfluss von R_N ist sehr wohl signifikant. Eine schöne Übersicht würde hier selbstverständlich wieder eine Aufstellung der A-V-P's bieten.

3.3 Der F -Test

Es könnte doch nun allerdings – eben wegen der Korreliertheit der Regressoren – auch vorkommen, dass t -Tests für individuelle Koeffizienten (Variable) aus einer Gruppe signifikante bzw. nicht signifikante Resultate liefern, während man, wenn man den Einfluss der Kombination aller Koeffizienten berücksichtigt, zum gegenteiligen Ergebnis kommt.

In seltenen Fällen kann dies geschehen. Deshalb benötigen wir Testverfahren zum Überprüfen von Hypothesen der Form $\beta_1 = \dots = \beta_g = 0$, also unter gleichzeitiger Auslassung mehrerer potenzieller Einflussfaktoren. Dies leisten so genannte F -Statistiken, die in ihrer allgemeinsten Form

$$F = (SSR_R - SSR) / SSR \cdot (T - k - 1) / g$$

geschrieben werden können. Die Abkürzung SSR steht hier für die Residuenquadratsumme (sum of squared residuals) unter dem allgemeineren Modell, SSR_R für jene unter dem eingeschränkten (restricted) Modell, bei dem die betreffenden Regressoren weggelassen wurden. Der Wert k bezeichnet die Gesamtzahl der Regressoren (ohne Interzept), der Wert g die Zahl der (Null-)Restriktionen (weggelassenen Regressoren). Unter der Normalverteilungsannahme und der Nullhypothese folgen diese Zufallsgrößen einer F -verteilung, die durch die Parameter g und $T - k - 1$, die so genannten Freiheitsgrade, bestimmt ist, aus der sich durch Transformation wieder die bereits bekannten p -Werte bestimmen lassen.

Übrigens ist die obige F -Statistik bereits so allgemein formuliert, dass sie auch für andere (lineare) Restriktionen als nur einfache Nullrestriktionen anwendbar ist.

Wenn wir also in unserem konkreten Beispiel überprüfen wollen ob g_Y und R_N gemeinsam einen in Bezug auf Y_c zusätzlichen signifikanten Erläuterungsbeitrag für M/P_c liefern, müssen die Residuenquadratsumme unserer ersten Schätzung 0.842 mit der unserer letzten Schätzung 0.287 verglichen werden.

Wir erhalten einen F -Wert von $(0.842 - 0.287) / 0.287 \cdot 32 / 2 \approx 30$, welcher einem p -Wert nahe bei 0 entspricht; die Hypothese, dass beide Regressoren nicht signifikant sind, muss also abgelehnt werden.

In EViews lässt sich dieser p -Wert direkt durch Eingabe von

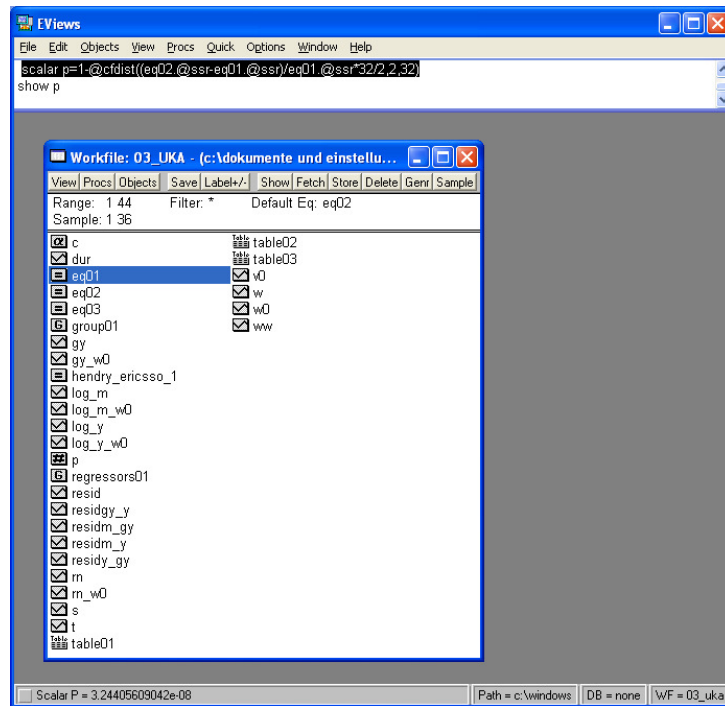
```
scalar p=1-@cfdist( (eq02.@ssr - eq01.@ssr) /eq01.@ssr*32/2,2,32)
```

in der Kommandozeile generieren, nachdem zunächst die beiden Modellgleichungen unter eq01 und eq02 gespeichert wurden. Generell lassen sich in EViews mittels der Funktionen @c?(Wert, Freiheitsgrade) die Verteilungsfunktionen verschiedener Verteilungen bestimmen.

Der Befehl

show p

(oder Anklicken des Objekts) führt dann zur Anzeige des Wertes links unten.



Diese Testtechnik müsste aber auch anwendbar sein, um zu überprüfen, ob alle Regressoren in einem Modell nicht signifikant sind, oder?

Dies ist ein wichtiger Spezialfall, bei dem SSR_R durch eine Residuenquadratsumme aus einem Nur-Interzept Modell gegeben ist. Dies wird üblicherweise als totale Residuenquadratsumme SST (sum of squares total) bezeichnet, und kann mit $\text{Var}(y) \cdot T$ bestimmt werden.

Wir verwenden zur Berechnung von SST die Funktionen $@\text{var}(\cdot)$ und $@\text{obs}(\cdot)$ und erhalten hier also $\text{scalar sst}=@\text{var}(\log_m)*@\text{obs}(\log_m)$.

Dieser Test wird oft als Overall-Test bezeichnet und die zugehörige Testgröße findet man in den Standardoutputs unter F-statistic mit dem zugehörigen p -Wert unter $\text{Prob}(F\text{-statistic})$.

Diese F-Werte stehen in enger Beziehung zu den Bestimmtheitsmaßen. Es gilt ja die Quadratsummenzerlegung $SST = SSR + SSE$ (sum of squares explained). Aus der Definition von $R^2 = SSE/SST = SSE/(SSE+SSR)$ ergibt sich $1-R^2 = (SSE+SSR)/(SSE+SSR) - SSE/(SSE+SSR) = SSR/(SSE+SSR)$, also $R^2/(1-R^2) = SSE/SSR$. Wegen $F = SSE/SSR \cdot (T-k-1)/k$ gilt deshalb auch $F = R^2/(1-R^2) \cdot (T-k-1)/k$.

3.4 Gewichtete (verallgemeinerte) Kleinst-Quadrate-Schätzung

Lass uns zu unseren Added-Variable-Plots zurückkommen. Wir haben schon angesprochen, dass die verwendeten Daten keinen einheitlichen Erhebungszeiträumen entsprechen, sondern Durchschnittswerten über einzelne

Konjunkturzyklen entsprechen. Sollten wird diese Tatsache bei der Interpretation unserer Plots nicht auch in Betracht ziehen?

Das ist ein ganz wichtiger Punkt, denn die Herkunft und das Konstruktionsprinzip der Daten hat nicht nur für die explorative, grafische Analyse Bedeutung, sondern wirkt sich auch bezüglich der verwendeten schließenden Verfahren, also der Schätz- und Testmethoden entscheidend aus.

Wie wir aus der elementaren Statistik wissen (vgl. Hackl und Katzenbeisser, 1994) ist unter der Annahme statistisch unabhängiger Messungen x_i mit gleicher Varianz, die Varianz eines Durchschnitts stets umgekehrt proportional zur Anzahl der Jahre n , über die dieser Durchschnitt gebildet wird, also $\text{Var}(\sum_n x_i/n) = n\text{Var}(x_i)/n^2$.

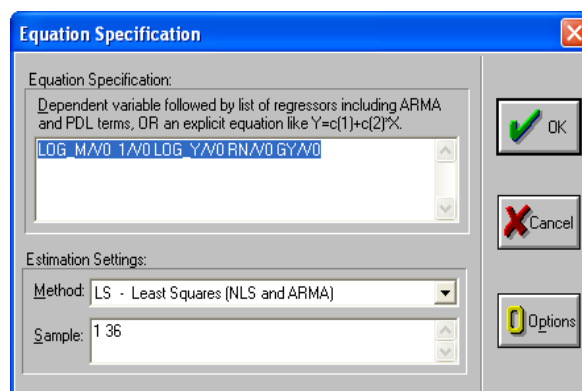
Für unsere Zyklusphasen bedeutet dies also, dass – für Ursprungsmessungen von ähnlicher „Genauigkeit“ – die verwendeten Durchschnittsdaten sozusagen unterschiedliche Genauigkeiten (weniger oder mehr Variabilität) aufweisen. Diese Genauigkeit verhält sich in etwa proportional zur Dauer eines Konjunkturzyklus.

Man nennt diese Eigenschaft der Daten ganz generell Heteroskedastizität. Sie lässt sich an Hand der von Friedman und Schwartz zur Verfügung gestellten Information noch expliziter machen. Es wird dort nämlich ausgeführt, dass bei der Erstellung der Phasennittel, die erste und letzte Beobachtung jeder Phase nur mit halbem Gewicht berücksichtigt wurde, weshalb sich für die entsprechende Varianz ein Proportionalitätsfaktor von $(2n_i-1)/2n_i^2$ ergibt.

Aus der Definition $\bar{x}_i = (x_{i,1}/2 + \sum_{j=2,ni} x_{i,j} + x_{i,ni+1}/2)/n_i$ ergibt sich für die Varianz: $\text{Var}(\bar{x}_i) = (\text{Var}(x_i)/4 + \sum_{j=2,ni} \text{Var}(x_i) + \text{Var}(x_i)/4)/n_i^2 = (n_i-1/2) \text{Var}(x_i)/n_i^2 = (2n_i-1)/2n_i^2 \text{Var}(x_i)$.

Wenn man also die Phasendurchschnitte standardisiert, kann man mit der Analyse wie bisher fortfahren. Dazu muss man nur alle Beobachtungen durch die Standardabweichung dividieren, das heißt durch die Wurzel des Proportionalitätsfaktors $(2n_i-1)/2n_i^2$.

Zu diesem Zweck konstruiert man sich in unserem Workfile am besten diesen Standardisierungsfaktor als neue Reihe mit dem Befehl `series V0=@sqrt((2*dur-1)/(2*dur^2))`, wobei die Variable `dur` die Phasendauern n_i beinhaltet. Danach müssen alle Variablen, sowohl Regressand als auch Regressoren – inklusive der Konstante – standardisiert werden. Man kann dies direkt bei der Spezifikation der Gleichung durchführen.



Als Resultat der Schätzung erhält man nun den korrigierten Output:

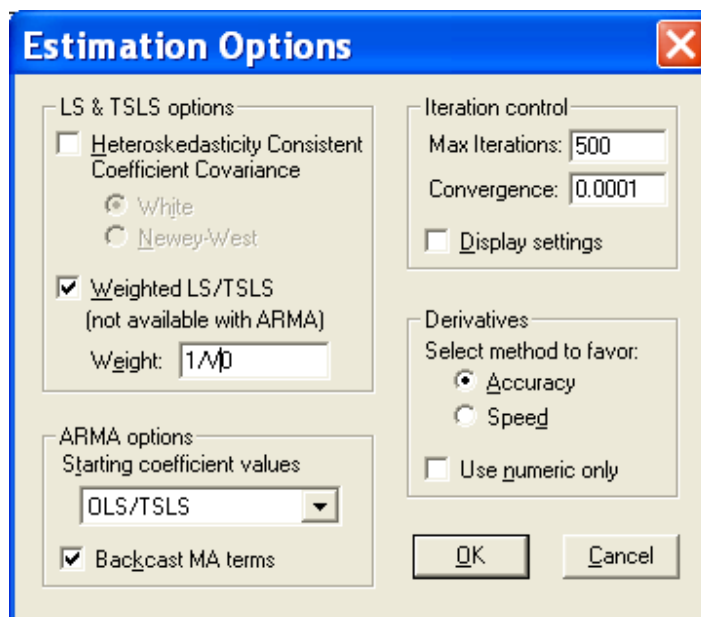
Dependent Variable: LOG_M/V0
 Method: Least Squares
 Sample: 1 36
 Included observations: 36

Variable	Coefficient	Std. Error	t-Statistic	Prob.
1/V0	-0.763842	0.281027	-2.718039	0.0105
LOG_Y/V0	1.114142	0.066509	16.75166	0.0000
RN/V0	-30.05410	3.790253	-7.929312	0.0000
GY/V0	-0.996446	0.470155	-2.119399	0.0419
R-squared	0.987624	Mean dependent var		7.333740
Adjusted R-squared	0.986464	S.D. dependent var		1.530226
S.E. of regression	0.178032	Akaike info criterion		-0.509268
Sum squared resid	1.014252	Schwarz criterion		-0.333322
Log likelihood	13.16683	F-statistic		851.2442
Durbin-Watson stat	0.673531	Prob(F-statistic)		0.000000

Diese Vorgangsweise ist völlig äquivalent zur so genannten gewichteten Kleinst-Quadrate Schätzung mit Gewichten v_t , in der die Zielgröße $\sum_t v_t (y_t - \hat{y}_t)^2$ minimiert wird (der Sonderfall $v_1 = \dots = v_T$ führt uns zurück zur gewöhnlichen Kleinst-Quadrateschätzung).

Um dies deutlich zu machen schreiben wir in einem linearen Regressionsmodell die Varianz-(Kovarianz)matrix $\text{Var}(y|X) = \text{Var}(\varepsilon) = \sigma^2 V$, wobei V hier eine Diagonalmatrix mit den (positiven) Einträgen v_1, \dots, v_T bezeichnet. Wir suchen nun eine Matrixzerlegung der Form $L'L = V^{-1}$ damit $LVL' = I_T$ und aus dem transformierten Modell $Ly = LX\beta + L\varepsilon$ der Kleinst-Quadrate Schätzer $\hat{\beta}_{GLS} = (X'L' LX)^{-1} X'L' Ly$ gebildet wird, was dem besten linearen unverzerrten Schätzer aus dem gewichteten Kleinst-Quadrate Problem (siehe Greene, 2000) entspricht. Für eine Diagonalmatrix V enthält die Zerlegung L gerade die Kehrwerte der Quadratwurzeln also $1/\sqrt{v_1}, \dots, 1/\sqrt{v_T}$ in der Diagonale, was der Division aller Variablen durch diese Kehrwerte entspricht. Bemerke, dass der Schätzer $\hat{\beta}_{GLS} = (X' V^{-1} X)^{-1} X' V^{-1} y$ für jedes – auch nicht diagonale – positiv definite V definiert ist. Man spricht in diesem Fall von verallgemeinerter Kleinst Quadrate Schätzung (generalized least squares – GLS).

Der gewichtete Kleinst-Quadrate Schätzer ist in EViews auch einfacher zu erhalten. Bei der Spezifikation der zu schätzenden Gleichung muss zunächst die Schaltfläche Options angeklickt werden, anschließend wird in neben stehendem Panel die Option Weighted LS/TSLS markiert und im darunter liegenden Feld der Name oder die Funktion der Gewichtungvariable, hier also 1/V0 angegeben.



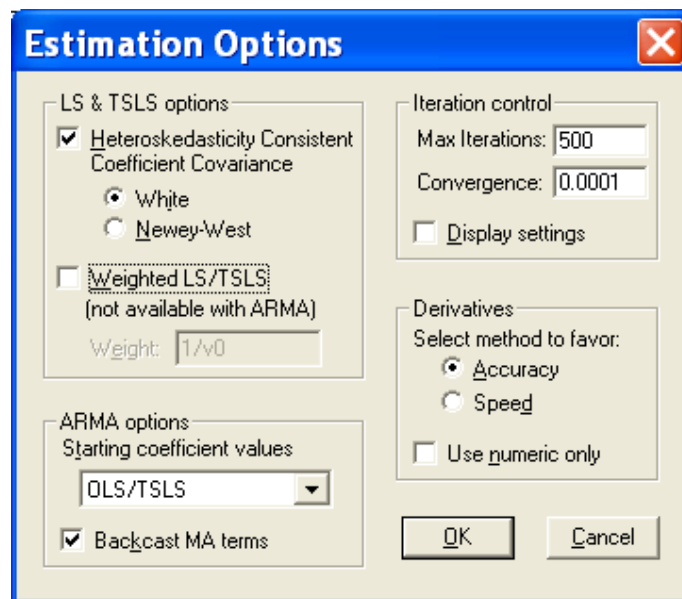
Der resultierende Output gibt neben den Kenngrößen aus der transformierten Regression zum Vergleich auch die der untransformierten Regression an:

Dependent Variable: LOG_M
 Method: Least Squares
 Sample: 1 36
 Included observations: 36
 Weighting 1/V0

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.763842	0.281027	-2.718039	0.0105
LOG_Y	1.114142	0.066509	16.75166	0.0000
RN	-30.05410	3.790253	-7.929312	0.0000
GY	-0.996446	0.470155	-2.119399	0.0419
Weighted Statistics				
R-squared	0.987624	Mean dependent var		4.017565
Adjusted R-squared	0.986464	S.D. dependent var		0.838288
S.E. of regression	0.097529	Akaike info criterion		-1.712888
Sum squared resid	0.304383	Schwarz criterion		-1.536941
Log likelihood	34.83198	F-statistic		851.2442
Durbin-Watson stat	0.673531	Prob(F-statistic)		0.000000
Unweighted Statistics				
R-squared	0.909011	Mean dependent var		4.028569
Adjusted R-squared	0.900481	S.D. dependent var		0.305842
S.E. of regression	0.096483	Sum squared resid		0.297886
Durbin-Watson stat	0.470633			

Man sollte hier beachten, dass EViews leider die der ungewichteten Schätzung entsprechenden Residuen in das Objekt RESID speichert!

Für den Fall, dass nichts über die Struktur der Heteroskedastie bekannt ist, kann nach wie vor der auch hier noch erwartungstreue OLS Schätzer verwendet werden. Allerdings liefert er verzerrte Standardfehler (in der Regel nach oben), da ja nun $\text{Var}(\hat{\beta}_{OLS}|X) = \sigma^2 (X'X)^{-1}X' V X(X'X)^{-1} \neq \sigma^2 (X'X)^{-1}$ ist. Abhilfe schafft hier die Heteroskedastiekorrektur von White (1980), der einfach die Diagonale von V durch die Quadrate der standardisierten OLS-Residuen, also $\hat{V}_{it} = T\hat{\xi}^2/\sum \hat{\xi}^2$, abschätzt. Die entstandenen Standardfehler werden oft als robust bezeichnet.



In EViews lässt sich dies wieder über das Menü Estimation Options regeln. Hierzu muss Heteroskedasticity und dann White markiert werden.

Die zugehörige Schätzung liefert aber im vorliegenden Fall nur geringfügige Korrekturen:

Dependent Variable: LOG_M

Method: Least Squares

Sample: 1 36

Included observations: 36

White Heteroskedasticity-Consistent Standard Errors & Covariance

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.625109	0.264925	-2.359572	0.0246
LOG_Y	1.086674	0.064017	16.97467	0.0000
RN	-29.53291	3.589260	-8.228133	0.0000
GY	-1.137629	0.396766	-2.867253	0.0073
R-squared	0.912425	Mean dependent var		4.028569
Adjusted R-squared	0.904215	S.D. dependent var		0.305842
S.E. of regression	0.094655	Akaike info criterion		-1.772709
Sum squared resid	0.286709	Schwarz criterion		-1.596762
Log likelihood	35.90876	F-statistic		111.1344
Durbin-Watson stat	0.488062	Prob(F-statistic)		0.000000

Falls gar nicht bekannt ist, ob in einem spezifischen Fall Heteroskedastizität vorliegt, lässt sich dies mit einem auch von White (1980) vorgeschlagenen Test überprüfen. Auch der beruht auf der Idee, dass die quadrierten OLS Residuen die Heteroskedastie reflektieren und diese sich recht unspezifisch als Polynom (zweiten Grades) in den Regressoren manifestieren. Man führt also die zusätzliche Regression

$$\hat{\varepsilon}_t^2 = \alpha_0 + \alpha_1 x_{1t} + \dots + \alpha_m x_{mt} + \alpha_{m+1} x_{1t}^2 + \dots + \alpha_{2m} x_{mt}^2 + \alpha_{2m+1} x_{1t} x_{1t} + \dots + \omega_t$$

durch und überprüft die Hypothese anschließend mittels Overall F -Test.

Eviews bietet uns hier direkt zwei Möglichkeiten, nämlich einmal mit, das andere mal ohne Einbeziehung von Wechselwirkungen. Man wählt dazu nach erfolgter Schätzung einfach aus dem Menu View-Residual Tests zum Beispiel White Heteroskedasticity (no cross terms) und erhält dann sofort nachstehenden Output.

White Heteroskedasticity Test:

F-statistic	0.847128	Probability	0.544445
Obs*R-squared	5.368684	Probability	0.497468

Test Equation:

Dependent Variable: RESID^2

Method: Least Squares

Sample: 1 36

Included observations: 36

White Heteroskedasticity-Consistent Standard Errors & Covariance

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.455250	0.275624	-1.651708	0.1094
LOG_Y	0.200017	0.125852	1.589304	0.1228
LOG_Y^2	-0.021608	0.014289	-1.512241	0.1413
RN	0.836425	1.389004	0.602176	0.5517
RN^2	-39.31663	73.61233	-0.534104	0.5973
GY	0.012665	0.027326	0.463475	0.6465
GY^2	-0.350086	0.193145	-1.812558	0.0803
R-squared	0.149130	Mean dependent var		0.007964
Adjusted R-squared	-0.026912	S.D. dependent var		0.007417
S.E. of regression	0.007516	Akaike info criterion		-6.770767
Sum squared resid	0.001638	Schwarz criterion		-6.462860
Log likelihood	128.8738	F-statistic		0.847128
Durbin-Watson stat	1.696422	Prob(F-statistic)		0.544445

In vorliegendem Fall ergibt sich (trotz gegenteiligen Wissens) kein Hinweis auf Heteroskedastie, was nicht weiter verwunderlich ist, da die entscheidende Größe – die Dauer der Zyklusphasen – in der Regression nicht aufscheint.

3.5 Dummy Variable

Friedman und Schwartz untersuchen die Beziehung zwischen realer Pro-Kopf Geldmenge und dem realen Pro-Kopf Einkommen sehr eingehend und bemerken drei Phasen mit ungewöhnlichen Abweichungen von der ansonsten konstanten Einkommenselastizität der Geldnachfrage. Im Vereinigten Königreich fallen ihnen die 1920er Jahre und die Zeit jeweils nach den beiden Weltkriegen durch außergewöhnlich hohe Geldnachfrage auf.

Sie schreiben die Abweichung in den 1920er Jahren den Auswirkungen der Weltwirtschaftskrise zu. Im Vereinigten Königreich begann die Wirtschaftskrise bereits zu Beginn der 1920er Jahre und endete 1932 etwas früher als in den USA und im restlichen Europa. In dieser Periode kam es zu

Deflation, d. h. zu einem fallenden Preisniveau, sodass selbst Bargeldhaltung einen positiven Ertrag hatte. Bei fallenden Preisen entsteht dieser Ertrag durch Aufschieben der Konsumententscheidung in die Zukunft.

Kennen wir dieses Phänomen nicht auch heute noch? Elektronische Geräte, wie z. B. PCs, machen nach der Neueinführung doch regelmäßig eine Phase mit starkem Preisrückgang durch.

Ja, die Ertragsrate aus der Verschiebung des Kaufes in die Zukunft entspricht genau dem prozentuellen Preisrückgang. Zusätzlich zum positiven Ertrag der Geldhaltung erwähnen Friedman und Schwartz die hohe Unsicherheit durch Arbeitslosigkeit und Bankenzusammenbrüche, die ebenfalls zu gesteigerter Bargeldnachfrage führte.

Die Periode während und nach den beiden Weltkriegen fällt auch durch höhere Geldnachfrage auf. Erhöhte Unsicherheit in Kriegszeiten und das kleinere Angebot an Waren während des Krieges und danach belebten die Geldnachfrage. Jeweils die ersten drei Konjunkturphasen nach dem I. und II. Weltkrieg unterscheiden sich von den anderen Phasen.

Als nahe liegendste Lösung fällt mir ein, das Modell über diese Perioden separat zu schätzen, was allerdings zu erheblichen Verlusten in den Freiheitsgraden führt. Es gibt allerdings ein Instrument mit dem wir zeitlich begrenzte Abweichungen vom Normalzustand in einer Regressionsgleichung berücksichtigen können ohne die Schätzer in den unterschiedlichen Perioden vollständig von einander zu trennen: die so genannte Dummy Variable. Als solches werden in der Mathematik ja üblicherweise Größen genannt, die nur während eines Kalkulationsvorgangs vorübergehend verwendet werden und im Ergebnis nicht mehr aufscheinen, daher der ursprünglich von „dumb“ abgeleitete Name. Die Bedeutung in der Ökonometrie ist etwas anders. Hier bezeichnet Dummy eine einfach strukturierte, üblicherweise binäre, Variable zur Unterscheidung beziehungsweise Modellierung von Unterscheidungen.

Im einfachsten Fall – zur Differenzierung zweier unterschiedlicher Perioden, so genannter Regime – weist die Dummy Variable die Werte 0 (für die Referenzperiode) und 1 (sonst) auf. Im Fall von Friedman und Schwartz wird also eine Größe S_t mit den Eigenschaften $S_1 = \dots = S_{15} = 0$, $S_{16} = \dots = S_{28} = 1$, $S_{29} = \dots = S_{36} = 0$ eingeführt, wobei die mit dem Wert 1 ausgeflaggten Daten den Perioden 1923-1954 entsprechen. Wenn nun eine einfache Verschiebung der Geldnachfrage in dieser Periode modelliert werden soll, muss die Schätzgleichung einfach um die Variable S ergänzt werden (vorerst mal ungewichtet):

Dependent Variable: LOG_M

Method: Least Squares

Sample: 1 36

Included observations: 36

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.121560	0.188028	-0.646497	0.5227
LOG_Y	0.924542	0.047119	19.62137	0.0000
RN	-14.74058	3.134206	-4.703130	0.0001
GY	-0.371056	0.286295	-1.296060	0.2045
S	0.198453	0.027521	7.210842	0.0000
R-squared	0.967290	Mean dependent var		4.028569
Adjusted R-squared	0.963069	S.D. dependent var		0.305842
S.E. of regression	0.058775	Akaike info criterion		-2.701961
Sum squared resid	0.107089	Schwarz criterion		-2.482028
Log likelihood	53.63531	F-statistic		229.1804
Durbin-Watson stat	1.249423	Prob(F-statistic)		0.000000

Der der Dummy zugeordnete Koeffizient bezeichnet nun den Unterschied im Interzept zwischen der Referenz- und der Restperiode, es gab also laut obiger Gleichung zwischen 1923 und 1954 eine deutlich erhöhte Geldnachfrage, was sich – wegen der logarithmischen Natur des Modells – siehe Kennedy, 1981 in einer durchschnittlichen Steigerung um etwa $100 \times [\exp(\hat{\beta}_4) - 1] \approx 22\%$ niederschlägt.

Obiges ergibt sich wenn der relative Effekt der Dummy über $[y(S_t=1)-y(S_t=0)]/y(S_t=0)$ bestimmt wird. Kennedy, 1981 weist allerdings darauf hin, dass eine bessere Abschätzung des Effekts durch $100 \times [\exp(\hat{\beta}_4 - \hat{\alpha}\hat{\beta}_4/2) - 1]$ erzielt wird, was hier allerdings keinen wesentlichen Unterschied macht.

Letztendlich verwenden Friedman und Schwartz noch eine zweite Dummy Variable W, nämlich zur Modellierung zweier Anpassungsperioden in den Nachkriegsjahren. Es ergibt sich damit – nach korrekter Gewichtung - auch das von Ericsson et al. in deren Gleichung (6) replizierte Modell:

Dependent Variable: LOG_M

Method: Least Squares

Sample: 1 36

Included observations: 36

Weighting series: 1/V0

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.021083	0.193736	0.108825	0.9141
LOG_Y	0.882881	0.048982	18.02473	0.0000
RN	-11.21374	3.285429	-3.413172	0.0019
W	0.013782	0.005821	2.367800	0.0245
S	0.205901	0.027388	7.517951	0.0000
GY	-0.212149	0.291022	-0.728979	0.4717

Weighted Statistics

R-squared	0.996072	Mean dependent var	4.017565
Adjusted R-squared	0.995417	S.D. dependent var	0.838288
S.E. of regression	0.056751	Akaike info criterion	-2.749292
Sum squared resid	0.096619	Schwarz criterion	-2.485372
Log likelihood	55.48726	F-statistic	1521.371
Durbin-Watson stat	1.503403	Prob(F-statistic)	0.000000

Unweighted Statistics

R-squared	0.966056	Mean dependent var	4.028569
Adjusted R-squared	0.960399	S.D. dependent var	0.305842
S.E. of regression	0.060863	Sum squared resid	0.111128
Durbin-Watson stat	1.325585		

Jetzt wo wir die Phasenlänge und abweichende Teilperioden in die Gleichung eingearbeitet haben, können wir einen näheren Blick auf die Ergebnisse werfen und zu einer Interpretation schreiten. Erstens, wir konnten eine Geldnachfragefunktion mit hohem Erklärungswert identifizieren. Zweitens alle Koeffizienten haben das erwartete Vorzeichen. Die Einkommenselastizität der Geldnachfrage ist positiv, während die Opportunitätskosten der Geldhaltung die Geldnachfrage senken.

Mit 0,88 ist der Koeffizient des logarithmierten Pro-Kopf-Einkommens etwas kleiner als Eins. Weil beide Größen logarithmiert sind, ist dieser Wert als eine Elastizität zu interpretieren. Sie zeigt an, dass eine Steigerung des Realeinkommens um 1% mit einer Erhöhung der realen Geldnachfrage um etwa 0,9% einhergeht. Ein Wert in der Nähe von 1% erscheint plausibel, wenn man davon ausgeht, dass ein höheres Einkommensniveau mit mehr Transaktionen verbunden ist. Ein Wert kleiner als 1% kann durch eine mit der Einkommenssteigerung verbundene Weiterentwicklung von Finanzdienstleistungen erklärt werden. In diesem Fall wirkt das Realeinkommen als ein dynamischer Indikator für den technischen Fortschritt in den Finanzdienstleistungen einer Wirtschaft.

Die Maßeinheiten für die Opportunitätskosten sind Prozentpunkte. Daher ist der betreffende Koeffizient ein semilogarithmischer Parameter mit etwas anderer Interpretation. Diese Wahl der Maßeinheit garantiert, dass eine Zinsänderung von einem halben Prozentpunkt dieselbe prozentuelle Wirkung auf die reale Geldnachfrage erzeugt, unabhängig davon, ob der Zinssatz ursprünglich 5% oder 10% beträgt. Es wird also unterstellt, dass die absolute Veränderung des Zinssatzes die relevante ökonomische Größe ist und nicht die relative Veränderung.

Ein halber Prozentpunkt entspricht 10% des ursprünglichen Zinsniveaus, wenn im Ausgangszeitpunkt der Zinssatz 5% beträgt, aber nur 5% des ursprünglichen Zinsniveaus, wenn er im Ausgangszeitpunkt 10% beträgt. Zinssätze werden üblicherweise in Prozentpunkten (z. B. 5.0) oder in mathematischen Prozent (z. B. 0.05) ausgedrückt.

Die Reaktion der Geldmenge auf Zinsänderungen wird damit allerdings von der Einheit abhängig, in der der Zinssatz gemessen wird. Das sieht man ganz deutlich am Unterschied zwischen den Koeffizienten für die kurzfristigen Opportunitätskosten R_N und dem Ertrag auf physische Veranlagungen g_Y . Obwohl der Koeffizient für g_Y um einen Faktor 100 kleiner ist als der für R_N , wirkt eine Änderung des Alternativertrags um einen halben Prozentpunkt doppelt so stark auf die reale Geldnachfrage wie eine gleich große Änderung der kurzfristigen Opportunitätskosten. Der einfache Grund ist der unterschiedliche Maßstab. Im Unterschied zu den Originalergebnissen von Friedman und Schwartz (1982) ist der Koeffizient für physische Veranlagungen mit den rekonstruierten Daten von Ericsson et al. (1998) nicht mehr signifikant.

Die Ergebnisse und Schlussfolgerungen von Friedman und Schwartz haben David Hendry und Neil Ericsson (1991) dazu veranlasst, die alten Berechnungen nachzuvollziehen. Sie zeigen einige Mängel dieser Schätzgleichung auf, die an dieser Stelle nicht aufgegriffen werden. Hier erscheint jedoch wichtig, dass sie eine der zentralen Schlussfolgerungen von Friedman und Schwartz widerlegen: sie können keine über die Zeit stabile Geldnachfragefunktion identifizieren. Wie schon erwähnt ist eine stabile Geldnachfragefunktion Grundlage für jede Geldpolitik, die ein Geldmengenziel verfolgt. Weiters finden Hendry und Ericsson Hinweise auf Geldillusion im Vereinigten Königreich. Die Preiselastizität der Geldnachfrage kann also nicht per Annahme auf 1 gesetzt werden, sondern sollte durch eine eigene Preisvariable als Regressor berücksichtigt werden. Friedman und Schwartz (1991) geben eine interessante Replik auf diese Vorwürfe.

Übungsaufgaben

- Erstellen Sie A-V-P's für alle relevanten Regressorvarianten im korrekt gewichteten Modell und interpretieren Sie sie.
- Ericsson et al. (1998) haben die Schätzungen auf einer erweiterten Datenbasis bis 1993 erneut durchgeführt. Replizieren Sie deren Ergebnisse (phase-average daten) und diskutieren Sie die Unterschiede zur vorherigen Schätzung.
- Führen Sie dafür einen Goldfeld-Quandt Test auf Heteroskedastie durch.
- Welche Schwierigkeiten geben sich beim Vergleich gewichteter Kleinst-Quadrate Regressionen?

Literaturhinweise

Cook, R. D., and Weisberg S. (1982), *Residuals and Influence in Regression*, London : Chapman and Hall.

Ericsson, N.R., Hendry, D.F., Prestwich, K.M., “Friedman and Schwartz (1982) revisited: Assessing annual and phase-average models of money demand in the United Kingdom”, *Empirical Economics*, 23, 401-415, 1998.

Friedman, M., „The Demand for Money – Some Theoretical and Empirical Results“, *Journal of Political Economy*, 67, 327-351, 1959.

Friedman, M., Schwartz, A.J., „Monetary Trends in the United States and the United Kingdom“, University of Chicago Press, Chicago, 1982.

Friedman, M., Schwartz, A., „An Alternative Approach to Analyzing Economic Data“, *American Economic Review*, 81, 39-49, 1991.

Frisch, R. und Waugh, F. „Partial time regressions as compared with individual trends“, *Econometrica*, 45, 939-953, 1933.

Goldfeld, S.M. und Quandt, R.E., „Some Tests for Homoskedasticity“. *Journal of the American Statistical Association*, 60, 539-547, 1965.

Goodhart, C., „Monetary Theory and Practice“, Macmillan, Basingstoke, 1984.

Hendry, D.F., Ericsson, N.R., “An econometric analysis of U.K. money demand in ‘Monetary Trends in the United States and the United Kingdom’ by Milton Friedman and Anna J. Schwartz”, *American Economic Review*, 81, 8-38, 1991.

Kennedy, P., "Estimation with Correctly Interpreted Dummy Variables in Semilogarithmic Equations", *American Economic Review*, Vol. 71, 1981, p. 801.

Keynes, J.M., „The General Theory of Employment Interest and Money“, 1936, reprinted MacMillan, London, 1973.

Laidler, D., „The Demand for Money“, Harper & Row, New York, 1985.

White, H. (1980), A Heteroscedasticity-Consistent Covariance Matrix Estimator and a Direct Test for Heteroscedasticity. *Econometrica* 48, 817-838.