

Univ.-Prof. Dr. Rainer Baule

# **Modul 32861**

## **Finanzmanagement mit Excel**

### **Leseprobe**

Fakultät für  
**Wirtschafts-**  
**wissenschaft**

Das Werk ist urheberrechtlich geschützt. Die dadurch begründeten Rechte, insbesondere das Recht der Vervielfältigung und Verbreitung sowie der Übersetzung und des Nachdrucks, bleiben, auch bei nur auszugsweiser Verwertung, vorbehalten. Kein Teil des Werkes darf in irgendeiner Form (Druck, Fotokopie, Mikrofilm oder ein anderes Verfahren) ohne schriftliche Genehmigung der FernUniversität reproduziert oder unter Verwendung elektronischer Systeme verarbeitet, vervielfältigt oder verbreitet werden.

Der Inhalt dieses Studienbriefs wird gedruckt auf Recyclingpapier (80 g/m<sup>2</sup>, weiß), hergestellt aus 100 % Altpapier.

## 6.1 Einfaktormodelle

### 6.1.1 Allgemeine Konzeption

Ziel: Empirische Beziehungen zwischen Renditen

Indexmodelle, allgemeiner Faktormodelle, stellen Zusammenhänge zwischen den Renditen einzelner Wertpapiere eines Marktes oder Teilmarktes auf. Die einfachste Variante ist ein Einfaktor-Indexmodell. In einem solchen Modell wird die Rendite einer Aktie  $r_i$  erklärt durch die Rendite eines Index  $r_I$ :

$$r_i = \alpha_i + \beta_i r_I + \epsilon_i, \quad (6.1)$$

wobei wir hier aus Gründen der Übersichtlichkeit zunächst auf den Zeitindex verzichten.

Das Indexmodell (6.1) stellt einen Zusammenhang zwischen den Renditen einer Aktie und den Renditen eines Index auf. Der Hintergrund ist dabei, dass sich Aktien häufig im Gleichklang bewegen und ein Teil der Bewegung einer Einzelaktie durch die Bewegung eines Index erklärt werden kann. An die Wahl des Index sind dabei keine globalen Anforderungen gestellt. Um einen hohen Erklärungsgehalt zu erzielen, ist es sinnvoll, einen Index zu verwenden, der repräsentativ für die jeweilige Aktie ist – für große deutsche Aktien mag das der DAX sein, für mittelgroße eher der MDAX.

Aufspaltung der Varianz

Anhand Gleichung (6.1) kann die Varianz der Aktienrendite aufgespalten werden in einen indexgetriebenen und einen idiosynkratischen Anteil, wenn unterstellt wird, dass die beiden Renditebestandteile unkorreliert sind:

$$\text{Cov}(r_I, \epsilon_i) = 0; \quad (6.2)$$

$$\text{Var}(r_i) = \beta_i^2 \text{Var}(r_I) + \text{Var}(\epsilon_i). \quad (6.3)$$


In Anlehnung an das CAPM wird der indexgetriebene Anteil häufig auch systematisch, der individuelle unsystematisch genannt. Man muss sich dabei vor Augen halten, dass sich „systematisch“ hier explizit auf den gewählten Index und nicht auf den Markt im Sinne des CAPM bezieht.

Schätzung des Beta-Faktors empirisch gut möglich

Abbildung 6.1 stellt die täglichen Überrenditen des Marktes und der Siemens-Aktie für das Jahr 2015 grafisch dar. Man erkennt einen ausgeprägten positiven Zusammenhang. Die Regressionsgerade weist eine Steigung von 0,9 auf – diese entspricht dem Beta-Faktor der Siemens-Aktie,  $\beta_{SIE} = 0,9$ .

Beispielrechnung

Die Standardabweichung der täglichen Siemens-Renditen liegt hier bei 1,53%, die des DAX bei 1,49%. Skaliert auf eine Periode von einem Jahr (hier 253



**Abbildung 6.1.** Tagesrenditen vom DAX und der Siemens-Aktie im Jahr 2015. Die Regressionsgerade liefert einen Beta-Koeffizienten von 0,9.

Handelstagen) mit dem Faktor  $\sqrt{253}$  erhalten wir  $\text{Var}(r_{SIE}) = 0,244^2$  sowie  $\text{Var}(r_{DAX}) = 0,236^2$ . Der Betafaktor beträgt 0,9. Damit haben wir

$$0,244^2 = 0,9^2 \cdot 0,236^2 + \text{Var}(\epsilon_{SIE}),$$

also

$$0,0594 = 0,0452 + 0,0142.$$

Die Gesamtvarianz der Siemens-Aktie in Höhe von 0,0594 wird zu etwa 76 % (0,0452) durch die Varianz des DAX erklärt, der idiosynkratische Anteil beträgt 24 %.

Indexmodelle werden häufig im Rahmen der Portfoliooptimierung verwendet, da mit ihnen die Datenanforderungen massiv reduziert werden können. Zur Portfoliooptimierung nach Markowitz im  $n$ -Wertpapier-Fall (siehe Lehreinheit 5) benötigt man die vollständige Korrelations- bzw. Kovarianzmatrix mit  $n$  Varianzen und  $n \cdot (n - 1)/2$  Kovarianzen. Nimmt man als Anlageuniversum die 30 Aktien des DAX, so sind dies insgesamt 465 Daten. Im Einfaktormodell benötigt man lediglich  $n + 1$  Varianzen (die der Aktien sowie die des Index) und  $n$  Betafaktoren – im Beispiel also 61 Daten. In der Praxis sind die Anlageuniversen noch deutlich größer, was eine Reduktion der Datenanforderungen um so notwendiger macht.<sup>1</sup>

Reduktion der Datenanforderungen

<sup>1</sup> Bei  $n = 1.000$  reduziert sich der Umfang von 500.500 auf 2.001 Daten.

Vereinfachende  
Annahmen

Allerdings wird diese Reduktion des Datenvolumens erkaufte durch eine vereinfachende Annahme, die man an das Verhalten der Aktienkurse bzw. -renditen stellen muss: Es wird unterstellt, dass die idiosynkratischen Komponenten untereinander unabhängig sind, dass also

$$\text{Cov}(\epsilon_i, \epsilon_j) = 0 \quad \forall i, j \quad (6.4)$$

gilt. Dies stellt eine nicht unerhebliche Einschränkung an das Verhalten der Aktienkurse dar. Die Bedingung besagt, dass es jenseits des Index keine gemeinsamen Faktoren gibt, von denen zwei verschiedene Aktienrenditen abhängen. In der Realität werden insbesondere branchen- oder regionenspezifische Faktoren eine Rolle spielen. Solche Faktoren sind im Einfaktor-Indexmodell nicht vorgesehen.

Unter dieser Annahme lässt sich die Kovarianzmatrix berechnen. Für zwei Aktien  $i$  und  $j$  gilt:

$$\begin{aligned} \text{Cov}(r_i, r_j) &= \text{Cov}(\alpha_i + \beta_i r_I + \epsilon_i, \alpha_j + \beta_j r_I + \epsilon_j) \\ &= \beta_i \beta_j \text{Var}(r_I) + \beta_i \text{Cov}(r_I, \epsilon_j) + \beta_j \text{Cov}(\epsilon_i, r_I) + \text{Cov}(\epsilon_i, \epsilon_j) \\ &= \beta_i \beta_j \text{Var}(r_I), \end{aligned} \quad (6.5)$$

da alle Kovarianzen in der zweiten Zeile annahmegemäß null sind.

Für ein beliebiges Portfolio  $P$  mit Gewichten  $w_1, \dots, w_n$  ergibt sich die Rendite

$$r_P = \sum_{i=1}^n w_i \alpha_i + \left( \sum_{i=1}^n w_i \beta_i \right) r_I + \sum_{i=1}^n w_i \epsilon_i. \quad (6.6)$$

Die Varianz beträgt

$$\text{Var}(r_P) = \left( \sum_{i=1}^n w_i \beta_i \right)^2 \text{Var}(r_I) + \sum_{i=1}^n w_i^2 \text{Var}(\epsilon_i) \quad (6.7)$$

und ist auch wesentlich leichter zu berechnen als mit der Varianzformel (5.22), da keine Doppelsumme vorkommt.

### 6.1.2 Parameterschätzung im Einfaktormodell

Da wir im Weiteren einige Annahmen über die zeitabhängigen Bestandteile des Einfaktor-Indexmodells treffen wollen, fügen wir dem Faktormodell gemäß (6.1) nun einen Zeitindex hinzu:

$$r_{i,t} = \alpha_i + \beta_i r_{I,t} + \epsilon_{i,t}. \quad (6.8)$$

Wir unterstellen, dass Beobachtungen der Renditen  $r_i$  und  $r_I$  über  $n$  Zeitpunkte  $t = 1, \dots, n$  vorliegen. Das Modell repräsentiert einen Spezialfall eines **einfachen linearen Regressionsmodells**. Hierbei wird angenommen, dass die idiosynkratischen Komponenten  $\epsilon_{i,t}$  unabhängig und identisch verteilt sind mit

$$E(\epsilon_{i,t}) = 0 \text{ und } Var(\epsilon_{i,t}) = \sigma^2 \forall t. \quad (6.9)$$

Annahmen über die Residuen

Zur Konstruktion von Konfidenzintervallen und Teststatistiken wird überdies unterstellt, dass die idiosynkratischen Komponenten normalverteilt sind, also

$$\epsilon_{i,t} \sim \mathcal{N}(0, \sigma^2). \quad (6.10)$$

In diesem Fall sind auch die Aktienrenditen  $r_{i,t}$  normalverteilt mit

$$E(r_{i,t}) = \alpha_i + \beta_i r_{I,t}; \quad Var(r_{i,t}) = \sigma^2, \quad (6.11)$$

wobei die Aktienrenditen  $r_{i,t}$  bedingt (auf eine Ausprägung des Faktors) unabhängig sind. Im Zuge der linearen Regression werden die Modellparameter  $\alpha_i$  und  $\beta_i$  nach der Methode der kleinsten Quadrate geschätzt. Hierbei werden die Schätzer  $\hat{\alpha}_i$  und  $\hat{\beta}_i$  in der Form bestimmt, dass die Summe der quadratischen Abweichungen

Kleinste-Quadrate-Schätzer

$$\sum_t \hat{\epsilon}_{i,t}^2 = \sum_t (r_{i,t} - \hat{\alpha}_i - \hat{\beta}_i r_{I,t})^2 \quad (6.12)$$

bei gegebenen Daten  $(r_{i,t}, r_{I,t})$  minimiert wird.<sup>2</sup> Anhand der Schätzer  $\hat{\alpha}_i$  und  $\hat{\beta}_i$  erhält man die geschätzten Aktienkursrenditen:

$$\hat{r}_{i,t} = \hat{\alpha}_i + \hat{\beta}_i r_{I,t}. \quad (6.13)$$

Der Schätzer für die Aktienkursrenditen repräsentiert die Schätzung für den bedingten Erwartungswert der Aktienkursrenditen bei gegebenen Realisationen der Indexrenditen,  $r_{I,t}$ , und kann damit zur Prognose von  $r_{i,t}$  verwendet werden. Hat man das lineare Regressionsmodell ausgehend von den Realisationen  $(r_{i,t}, r_{I,t})$  spezifiziert, so stellt sich die Frage nach der Anpassungsgüte des Modells. Naiv könnte man versucht sein, über die Summe der quadrierten Störterme auf die Anpassungsgüte des Modells zu schließen. Dies birgt jedoch zwei Kernprobleme: Zum einen besitzt die Quadratsumme der Residuen keine absolute obere Schranke, zum anderen ist sie maßstabsabhängig. Damit ist die Quadratsumme der Störterme kein geeignetes Maß zur Quantifizierung der Anpassungsgüte. Stattdessen beruft man sich auf das so genannte **Bestimmtheitsmaß** ( $R^2$ ), um zu ermitteln, wie gut das Regressionsmodell die Variabilität in den zugrunde liegenden Daten erklärt. Das  $R^2$  ist in der

Geschätzte Aktienkursrendite

<sup>2</sup> Vgl. hierzu z. B. Fahrmeir, Kneib und Lang (2009), S. 90 ff.

Anpassungsgüte des Regressionsmodells

vorliegenden Situation definiert durch

$$R^2 = \frac{\sum_t (\hat{r}_{i,t} - \bar{r}_i)^2}{\sum_t (r_{i,t} - \bar{r}_i)^2} = 1 - \frac{\sum_t (r_{i,t} - \hat{r}_{i,t})^2}{\sum_t (r_{i,t} - \bar{r}_i)^2}, \quad (6.14)$$

wobei  $\bar{r}_i$  die mittlere Rendite über den Beobachtungszeitraum bezeichnet. Das heißt, das Bestimmtheitsmaß wird gegeben durch den Anteil der durch die Regression erklärten Quadratsumme an der zu erklärenden Quadratsumme. Naturgemäß nimmt  $R^2$  Werte aus dem Intervall  $[0,1]$  an. Allgemein gilt: Je höher der Wert für das Bestimmtheitsmaß, desto höher die Anpassungsgüte des Modells an die Daten. Für  $R^2 = 1$  liegt ein perfektes Modell vor, für  $R^2 = 0$  liefert das lineare Regressionsmodell keinerlei Erklärungsgehalt.

Da  $R^2$  üblicherweise anhand von Stichproben einer Grundgesamtheit ermittelt wird, ist in diesem Fall zu hinterfragen, ob der für das Bestimmtheitsmaß ermittelte Wert 'valide' ist. Anhand eines F-Tests lässt sich  $R^2$  auf statistische Signifikanz testen. Hierbei testet man die Hypothese, dass kein linearer Zusammenhang zwischen  $r_i$  und  $r_I$  besteht, das heißt, die Hypothese  $R^2 = 0$ . Für  $(n - 2)$  Freiheitsgrade ist die Teststatistik des F-Tests definiert als:

$$F = \frac{R^2}{1 - R^2} \cdot (n - 2). \quad (6.15)$$

Überschreitet der ermittelte F-Wert den zu einem vorgegebenen Signifikanzniveau zugehörigen kritischen F-Wert, so ist die Hypothese  $R^2 = 0$  auf diesem Niveau zu verwerfen. Im obigen Beispiel nimmt das  $R^2$  einen Wert von 0,762 an; bei  $n = 252$  Beobachtungen folgt

$$F = \frac{0,7616}{1 - 0,7616} \cdot 250 = 799. \quad (6.16)$$

Bei 250 Freiheitsgraden muss der F-Wert auf dem Signifikanzniveau von 99% (bzw. 95%) die kritische Größe  $F = 6,74$  (bzw.  $F = 3,88$ ) überschreiten, damit die Hypothese  $R^2 = 0$  verworfen werden kann. Bei F-Werten, die kleiner sind, kann diese Hypothese nicht mit ausreichender Sicherheit verworfen werden. Da der F-Wert im vorliegenden Beispiel die kritischen Niveaus deutlich überschreitet, kann davon ausgegangen werden, dass zwischen den Renditen  $r_i$  der Aktie und  $r_I$  des Index ein signifikanter Zusammenhang besteht.

Neben dem Bestimmtheitsmaß dienen üblicherweise der Standardfehler der Schätzung sowie die Standardfehler beziehungsweise Signifikanztests der Regressionskoeffizienten,  $\alpha_i$  und  $\beta_i$ , zur Überprüfung der Verlässlichkeit des Modells. Der **Standardfehler der Schätzung** gibt Auskunft über die Streuung der Residuen:

$$MSE = \sqrt{\frac{\sum_t \hat{\epsilon}_{i,t}^2}{n - 2}}. \quad (6.17)$$

Standardfehler als  
Streuungsmaß

Der **Standardfehler** von  $\hat{\beta}_i$  bestimmt sich indes zu:

$$se(\hat{\beta}_i) = \sqrt{Var(\hat{\beta}_i)} = MSE \cdot \frac{1}{\sqrt{\sum_t (r_{I,t} - \bar{r}_I)^2}}, \quad (6.18)$$

wobei der **Standardfehler** von  $\hat{\alpha}_i$  definiert ist als:

$$se(\hat{\alpha}_i) = \sqrt{Var(\hat{\alpha}_i)} = MSE \cdot \frac{\sqrt{\sum_t r_{I,t}^2}}{\sqrt{n \sum_t (r_{I,t} - \bar{r}_I)^2}}. \quad (6.19)$$

Die Standardfehler der Regressionskoeffizienten geben einen ersten Anhalt zur Streuung der Koeffizienten, das heißt, sie quantifizieren die Bandbreite der erwarteten Werte, die man bei einer Schätzung der Koeffizienten auf Basis einer anderen Stichprobe annehmen würde.

Unterzieht man die Regressionskoeffizienten einem Signifikanztest, so zielt dies auf die Frage ab, mit welcher Berechtigung sich die Null-Hypothese,  $\alpha_i = 0$  beziehungsweise  $\beta_i = 0$ , verwerfen lässt. Wäre beispielsweise der Regressionskoeffizient  $\beta_i = 0$ , so bestünde kein linearer Zusammenhang zwischen  $r_i$  und  $r_I$ . Beim **t-Test** wird der Schätzer des Regressionskoeffizienten in Beziehung zu seinem Standardfehler gesetzt:

$$t_{n-2}(\hat{\beta}_i) = \frac{\hat{\beta}_i}{se(\hat{\beta}_i)}, \quad t_{n-2}(\hat{\alpha}_i) = \frac{\hat{\alpha}_i}{se(\hat{\alpha}_i)}. \quad (6.20)$$

Überschreiten diese t-Werte die kritischen Werte auf einem vorgegebenen Signifikanzniveau, so bezeichnet man die Schätzer auf diesem Niveau als statistisch signifikant. Im obigen Beispiel gilt:

$$t_{n-2}(\hat{\beta}_i) = 28,3, \quad t_{n-2}(\hat{\alpha}_i) = -1,04. \quad (6.21)$$

Ein Vergleich mit den kritischen Werten der t-Verteilung zeigt, dass  $\hat{\beta}_i$  auf sehr hohem Niveau (weit über 99,99 %) statistisch signifikant ist, während  $\hat{\alpha}_i$  selbst auf einem Niveau von 90 % nicht als statistisch signifikant eingestuft wird.

Anhand der t-Werte lassen sich ebenso **Konfidenzintervalle** für die Schätzer der Regressionskoeffizienten angeben: Für ein Quantil  $q$  ergibt sich das  $(1 - q)$ -Konfidenzintervall für  $\beta_i$  gemäß:

$$[\hat{\beta}_i - t_{n-2,1-q/2} \cdot se(\hat{\beta}_i), \hat{\beta}_i + t_{n-2,1-q/2} \cdot se(\hat{\beta}_i)]. \quad (6.22)$$

In analoger Weise lässt sich ein Konfidenzintervall für  $\alpha_i$  angeben. Eine Beispielrechnung betrachten wir im Lehrvideo.

Statistische Signifikanz der Regressionskoeffizienten