

## **Vergleich makroökonomischer Modelle - Fehlermaße**

File: Modellvergleich.doc  
Status: Revidierte Fassung  
Version: 091113

Ein wichtiger Aspekt der Güte ökonomischer Modelle wird durch die Frage erfasst, wie sie die Daten ex post simulieren können, auf deren Grundlage sie berechnet wurden. Zwar muss die prognostische Leistungsfähigkeit vor allem daran gemessen, wie genau die echten ex ante-Prognosen ausfallen, aber diese hängen nicht nur von der Güte der Modelle ab, sondern auch von der Genauigkeit der Vorgaben und der Gültigkeit der Hypothesen, die der Prognose zugrunde liegen – und sei es nur die Hypothese, dass sich die geschätzten Modellparameter im Prognosezeitraum nicht wesentlich ändern werden.

Im folgenden handelt es sich ausschließlich um den speziellen Aspekt der ex post-Prognosegüte, und zwar nicht von Einzelgleichungs-, sondern von Mehrgleichungsmodellen. Es geht darum, die bekannten Methoden der Bewertung von Prognosen (z.B. Root Mean Squared Error, Mean Absolute Error, Mean Absolute Percentage Error, Theil Inequality Coefficient etc.), die beispielsweise im Rahmen eines solchen ökonometrischen Programms wie E-Views auf Einzelgleichungen angewendet werden, für die Bewertung von (beispielsweise aus mehreren Verhaltensgleichungen bestehenden) Modellen zu verallgemeinern.

Ein grundsätzlicher statistischer Ansatzpunkt besteht darin, als Maß für die Abweichung einer Prognose von den tatsächlichen Werten die Fehlerquadrate oder die Absolutwerte der Abweichungen zu benutzen. Bei diesem Ansatz kann allerdings ein Bias der Prognose im Sinne einer Über- oder Unterschätzung der tatsächlichen Werte nicht erfasst werden. Dieser für den Prognostiker nicht unwichtige Aspekt kann durch die Summation über die (tatsächlichen oder relativen) Abweichungen der Prognosen von den beobachteten Daten konstruiert werden.

Zwei Modelle werden sich, selbst wenn sie aufgrund derselben Datenbasis geschätzt worden sind, hinsichtlich der Abweichungen ihrer ex post-Prognosen von den beobachteten Daten unterscheiden. Je geringer diese Abweichung, um so besser ist die Prognosegüte. Im folgenden handelt es sich nicht nur um eine Bestimmung der absoluten Prognosegüte eines Modells, sondern auch um seine Güte im Vergleich zu einem anderen (Referenz-) Modell.

Streng genommen kann sich ein Vergleich nur auf diejenigen Variablen beziehen, die die verglichenen Modellen gemeinsam haben. Auch sollte das Objekt beider Modelle (die dargestellte Volkswirtschaft) und der Untersuchungszeitraum möglichst identisch sein. Was aber, wenn die Modelle für unterschiedliche Objekte, Untersuchungszeiträume und Variablen konstruiert sind? Für diese Fälle sollten einige Fehlermaße so allgemein konstruiert worden sein, dass ein Vergleich möglich bleibt: Verglichen wird, wie gut ein Modell „sein“ Objekt und „seiner“ wichtigsten Variablen simuliert.

Des Weiteren ist die Frage zu beantworten, ob alle endogenen Modellvariablen in den Vergleich einbezogen werden sollen oder nur eine Teilmenge. Die endogenen Variablen werden teils durch Verhaltensgleichungen, teils durch Identitäten determiniert.<sup>1</sup> Die Identitäten erzeugen aus exogenen Variablen und endogenen Variablen eine lineare Kombination, die dann eine weitere Variable bestimmt. Auf nicht sofort ersichtliche Weise duplizieren sich dadurch die Fehlerquadratsummen der endogenen Variablen, die durch Verhaltensgleichungen bestimmt werden, und erzeugen so ein Gesamtbild, das unter Umständen von dem Bild abweicht, das sich ergeben würde, wenn man allein die originär durch Verhaltensgleichungen bestimmten endogenen Variablen heranzieht. Wenn man diese Verzerrung vermeiden möchte, sollte sich eine vergleichende Bewertung ganzer Modelle allein auf die von Verhaltensgleichungen determinierten endogenen Variablen stützen.

Der Prognostiker ist in der Regel an ganz speziellen Variablen interessiert und bewertet dann die Prognosegüte eines Modells anhand ausgewählter Variablen (z.B. anhand der Prognose für das BIP oder eines Preisindex). Aber auch bei einem rein theoretischen Modellvergleich ohne praktische Prognoseabsicht kann sich die Situation ergeben, dass einige Variable, für die nämlich das Modell konstruiert wurde, wichtiger sind als andere, die beispielsweise nur eingebaut wurden, um das Modell in einem gewissen Maße zu endogenisieren, deren Prognose-Genauigkeit ansonsten aber zweitrangig ist.

Es geht also darum, die Prognoseleistung ganzer Modelle anhand ausgewählter Schlüsselvariablen zu vergleichen, um auf dieser Grundlage ein generelles Urteil über die relative Güte zweier Modelle fällen zu können. Sollte ein spezieller Vergleich zeigen, dass ein Modell *alle* verglichenen Variablen besser prognostiziert als ein anderes Modell, so dürfte klar sein, wie das „Gesamturteil“ ausfällt. In der Regel ist das Ergebnis eines Vergleichs aber gemischt: Einige Variablen werden gut, andere schlechter (ex post) vorausgesagt. In diesen Fällen wäre es günstig, ein einfaches, trotzdem aber komplexes Maß zur Verfügung zu haben, das uns die Entscheidung über die Modellgüte erleichtert.

---

<sup>1</sup> Im Allgemeinen handelt es sich um Gleichungen mit stochastischem Term (Verhaltensgleichungen, institutionelle und technologische Gleichungen) und ohne einen solchen (Identitäten, Definitionen, Gleichgewichtsbedingungen).

Die Konstruktion eines komplexen Maßes für den Modellvergleich erfordert eine irgendwie geartete Kombination der Abweichungsmaße der in den Vergleich einbezogenen Variablen. Wiederum aus der Sicht des Prognostikers wäre es angezeigt, eine an den praktischen Prognosebedürfnissen ausgerichtete Gewichtungsfunktion einzuführen, die die Bedeutung der einzelnen Variablen für die beabsichtigte Prognose reflektiert. Aus theoretischer Sicht könnte sich ebenfalls das Bedürfnis ergeben, bestimmte Variablen zu wichten, von denen man beispielsweise weiß, dass ihre Messgenauigkeit umstritten ist. Im folgenden wird unterstellt, dass diese Wichtung a priori, nämlich bei der Auswahl der Variablen, die in den Vergleich einbezogen werden, vorgenommen wird. Unter den ausgewählten Variablen soll ansonsten von einer Gleichgewichtung aller Variablen ausgegangen werden. Wer damit unzufrieden ist, kann jederzeit eine entsprechende Gewichtungsfunktion einfügen.

Wenn die ausgewählten Variablen gleichgewichtig in das (zu konstruierende) komplexe Maß eingehen, bleibt in vielen Fällen das Problem der unterschiedlichen Maßstäbe, mit denen die Variablen gemessen werden, zu lösen; allgemeiner formuliert handelt es sich um das Problem der unterschiedlichen Varianz der verglichenen Größen, die einen direkten Vergleich der Fehlerquadratsummen oder der Absolutwerte der Abweichungen wenig aussagefähig werden lassen. Man denke etwa an die Varianz des BIP im Vergleich zur Varianz des langfristigen Zinssatzes.

Im Falle der Absolutwerte der Abweichungen lässt sich das eben genannte Problem durch Teilen der Abweichungen durch das Niveau der beobachteten Werte und im Falle der Fehlerquadratsummen durch das Teilen durch die Varianz der betreffenden Variable lösen. Damit wird die Abweichung einer Prognose von den tatsächlichen Werten durch die Summe der relativen absoluten Fehler bzw. die unerklärte Varianz gemessen. Beide lassen sich jetzt über alle Variablen summieren, ohne dass Dimensionierungsunterschiede eine Rolle spielen. Das hier vorgeschlagene komplexe Maß ist das Mittel der Summe der Absolutwerte der relativen Fehler der verschiedenen Variablen (MAPE).

Im folgenden werden die Fehlermaße, die in erster Linie für den Vergleich derselben Variablen unterschiedlicher Modelle verwendet werden, und ihre Eigenschaften im einzelnen dargestellt. Zuvor aber eine Bemerkung zur

## 1. Definition des Prognosefehlers / Residuums

Im Rahmen der Regressionsrechnung wird der statistische Fehler definiert als Differenz zwischen beobachteter Größe und dem durch die Regressionsgleichung erklärten Teil dieser Größe; diese Differenz ergibt das Residuum, deren Fehlerquadratsumme in einer gewöhnlichen Regressionsgleichung minimiert wird. Auf dieselbe Weise wird der Prognosefehler im E-Views-Handbuch,<sup>2</sup> insbesondere bei der graphischen Darstellung im Rahmen der Forecast Evaluation, und in der einschlägigen Literatur definiert – allerdings nicht durchgängig. Jedoch spielt bei den meisten der verwendeten Maße das Vorzeichen keine Rolle, so dass eine abweichende Definitionen des Prognosefehlers als negatives Residuum sich in den meisten Maßen nicht niederschlägt. Im folgenden wird der Prognosefehler so wie im E-Views-Handbuch und damit in Übereinstimmung mit der Regressionsrechnung definiert.

$$\text{RES} = y_t - \hat{y}_t.$$

Rechentechnische Umsetzung:<sup>3</sup>

$$\text{series } \{\%v\_res\} = \{\%v\} - \{\%v\_sz\}$$

## 2. Die Fehlermaße im einzelnen

### 2.1 Mean Error (ME)

Formel:

$$\text{ME} = \frac{1}{h} \sum_{t=T+1}^{T+h} (y_t - \hat{y}_t)$$

Dieses Maß wird im E-Views-Handbuch nicht genannt. Es ist aber nützlich, um die Richtung der Abweichungen einer ex post-Prognose von den beobachteten Werten zu bestimmen. Das Vorzeichen des Prognosefehlers spielt dabei eine entscheidende Rolle. Letzteres wurde hier so definiert, dass, wenn ME positiv ist, die zugrunde liegende Variable durch die Simulation unterschätzt wird; wenn ME negativ ist, liegt eine Überschätzung vor. Durch die oben vorgenommene Definition des Prognosefehlers lautet die Interpretation des ME als Indikator für einen Bias der Prognose also immer umgekehrt wie sein Vorzeichen. Als Daumenregel kann man sich merken: Prognose +

<sup>2</sup> Vgl. das S.535.

<sup>3</sup> Die „Rechentechnische Umsetzung“ beschreibt Programmierungsbeispiele für E-Views, die aufeinander aufbauen.

Prognosefehler = beobachteter Wert. Sinngemäß trifft das auch auf die entsprechenden Mittelwerte zu.

## 2.2 Mean Absolute Error (MAE)

Formel:<sup>4</sup>

$$\text{MAE} = \sum_{t=T+1}^{T+h} |\hat{y}_t - y_t|/h$$

Rechentechnische Umsetzung:

```
series {%v_res_abs} = @abs({%v_res})
scalar {%v_mae} = @mean({%v_res_abs})
```

Der MAE ist nicht invariant gegenüber Transformationen des Maßstabes der zugrunde liegenden Variable. Er ist deshalb nur für den direkten Vergleich zweier Modelle anhand derselben Variable geeignet. Durch dieses Maß wird die durchschnittliche absolute Abweichung der ex post-Prognose von den beobachteten Werten erfasst: Es ist demnach unempfindlich gegenüber der Länge und der Periodizität des Stütz- und Simulationszeitraumes.

## 2.3 Mean Absolute Percentage Error (MAPE)

Formel:

$$\text{MAPE} = 100 \cdot \sum_{t=T+1}^{T+h} \left| \frac{\hat{y}_t - y_t}{y_t} \right| / h$$

Rechentechnische Umsetzung:

Berechnungsprobleme tauchen auf, wenn die Bezugsbasis – der beobachtete Wert – in einer Periode Null wird. Rein theoretisch wäre MAPE dann Unendlich. Um in diesem Fall die Rechnung wenigstens durchführen zu können (E-Views stoppt das Programm), wird der beobachtete Wert durch 0,00001 ersetzt. Die Programmierung lautet:

```
vector(@obs({%v})) obsval = {%v}
vector(@obs({%v})) {%v_ersatz}
```

---

<sup>4</sup> Bei diesem Maß spielt das Vorzeichen des Prognosefehlers keine Rolle. Korrekterweise müsste aber die Differenz umgekehrt notiert werden. In der vorliegenden Form stimmt die Formel mit der im E-Views Handbuch S.537 überein.

```

vector(@obs({%v})) {%v_res_rel}
vector(@obs({%v})) residu = {%v_res}

for !i = 1 to @obs({%v})
if obsval(!i) = 0 then
{%v_ersatz}(!i) = 0.00001
else
{%v_ersatz}(!i) = obsval(!i)
endif
{%v_res_rel}(!i) = residu(!i)/{%v_ersatz}(!i)
next

```

Das eigentliche Maß wird berechnet durch:

```

!sm = 0
for !i = 1 to @obs({%v})
!sm = !sm + @abs({%v_res_rel}(!i))
next
scalar {%v_mape} = 100*!sm/@obs({%v})

```

Eine zusätzliche Ergebniskontrolle sorgt dafür, dass sehr große Maße (die an sich Unendlich wären) nicht angezeigt werden.

MAPE ist skaleninvariant und weder von der Länge, noch von der Periodizität des Simulationszeitraumes abhängig.

## 2.4 Root Mean Squared Error (RMSE)<sup>5</sup>

Formel:

$$\text{RMSE} = \sqrt{\sum_{t=T+1}^{T+h} (\hat{y}_t - y_t)^2 / h}$$

Rechentechnische Umsetzung:

```

scalar {%v_res_ssq} = @sumsq({%v_res})
scalar {%v_res_ssq_sm} = {%v_res_ssq}/@obs({%v_res})
scalar {%v_rmse} = @sqrt({%v_res_ssq_sm})

```

RMSE ist skalenabhängig.

---

<sup>5</sup> Von manchen wird auch der Mean Square Forecast Error (MSFE) bevorzugt – das Quadrat des RMSE.

## 2.5 Root Mean Squared Percentage Error (RMSPE)

Formel:

$$\text{RMSPE} = \sqrt{\sum_{t=T+1}^{T+h} \left( \frac{\hat{y}_t - y_t}{y_t} \right)^2 / h}$$

Rechentechische Umsetzung:

```
vector(@obs(%v)) %v_res_rel_sq
!sm = 0
for !i=1 to @obs(%v)
  %v_res_rel_sq(!i) = (%v_res_rel(!i))*(%v_res_rel(!i))
  !sm = !sm + %v_res_rel_sq(!i)
next
scalar %v_rmspe = 100*@sqrt(!sm/@obs(%v))
```

## 2.6 Theil Inequality Coefficient (TIEC)<sup>6</sup>

In E-Views wird der folgende (veraltete) Theil-Koeffizient<sup>7</sup> verwendet:

Formel:

$$\text{TIEC}_1 = \frac{\sqrt{\sum_{t=T+1}^{T+h} (\hat{y}_t - y_t)^2 / h}}{\sqrt{\sum_{t=T+1}^{T+h} \hat{y}_t^2 / h + \sum_{t=T+1}^{T+h} y_t^2 / h}}$$

Rechentechische Umsetzung:

```
scalar %v_ssqr = @sumsq(%v)
scalar %v_ssqr_sm = %v_ssqr/@obs(%v)
scalar %v_sz_ssqr = @sumsq(%v_sz)
scalar %v_sz_ssqr_sm = %v_sz_ssqr/@obs(%v_sz)
scalar %v_tiec = %v_rmse/(@sqrt(%v_sz_ssqr_sm)+@sqrt(%v_ssqr_sm))
```

Es gilt  $0 \leq \text{TIEC} \leq 1$ , wobei 0 die perfekte Simulation anzeigt.

TIEC ist invariant gegenüber Veränderungen der Skala.

<sup>6</sup> Vgl. dazu [www.forecastingprinciples.com/data/definitions/theil's%20u.html](http://www.forecastingprinciples.com/data/definitions/theil's%20u.html)

<sup>7</sup> Theil, H. (1958), Economic Forecasts and Policy. Amsterdam: North Holland.

Angewandt auf Veränderungsraten - wenn  $y_t$  und  $\hat{y}_t$  Veränderungsraten bezeichnen -, ergibt sich mit diesem Koeffizient folgendes Problem:<sup>8</sup> Im Falle einer naiven Prognose (Veränderungsrate = 0) ist der Koeffizient = 1. Jede andere Prognose, sei sie nun schlechter oder besser als die naive, führt zu einem besseren Wert.

Dagegen weist der folgende, ebenfalls von Theil stammende Koeffizient keine ernsthaften Probleme auf:<sup>9</sup>

Formel:

$$\text{TIEC}_2 = \frac{\sqrt{\sum_{t=T+1}^{T+h} (\hat{y}_t - y_t)^2 / h}}{\sqrt{\sum_{t=T+1}^{T+h} y_t^2 / h}}$$

Rechentechnische Umsetzung:

```
scalar {%v_ssq} = @sumsq({%v})
scalar {%v_ssq_sm} = {%v_ssq} / @obs({%v})
scalar {%v_tiec} = {%v_rmse} / (@sqrt({%v_ssq_sm}))
```

Wiederum angewandt auf Veränderungsraten, kann dieser Koeffizient als der RMSE der Vorhersage – verglichen mit der eines no-change model – interpretiert werden. Koeffizienten kleiner als 1 zeigen eine Verbesserung gegenüber der naiven Vorhersage. Der Koeffizient wird im Falle einer Vorhersage, die schlechter ist als die naive, größer als 1.

## 2.7 Varianzzerlegung

Der Prognosefehler lässt sich wie folgt zerlegen (Ableitung der folgenden Fehlermaße):

$$\hat{y} - y = \left( \hat{y} - \frac{1}{h} \sum \hat{y} \right) - (y - \bar{y}) - \left( \bar{y} - \frac{1}{h} \sum \hat{y} \right)$$

Für das Quadrat gilt:

<sup>8</sup> Bliemel, F.W. (1973), Theil's forecast accuracy coefficient: A clarification. Journal of Marketing Research, 10, 444-446.

<sup>9</sup> Theil, H. (1966), Applied Economic Forecasting. Chicago: Rand McNally.

$$\begin{aligned}
(\hat{y} - y)^2 &= \left( \hat{y} - \frac{1}{h} \sum \hat{y} \right)^2 + (y - \bar{y})^2 + \left( \bar{y} - \frac{1}{h} \sum \hat{y} \right)^2 + \\
&- 2 \left( \hat{y} - \frac{1}{h} \sum \hat{y} \right) (y - \bar{y}) + 2 (y - \bar{y}) \left( \bar{y} - \frac{1}{h} \sum \hat{y} \right) - 2 \left( \hat{y} - \frac{1}{h} \sum \hat{y} \right) \left( \bar{y} - \frac{1}{h} \sum \hat{y} \right)
\end{aligned}$$

Die rechte Seite kann wie folgt vereinfacht werden:

$$\begin{aligned}
&= \left( \hat{y} - \frac{1}{h} \sum \hat{y} \right)^2 + (y - \bar{y})^2 + \bar{y}^2 - 2\bar{y} \frac{1}{h} \sum \hat{y} + \left( \frac{1}{h} \sum \hat{y} \right)^2 - 2\hat{y}y + 2y \frac{1}{h} \sum \hat{y} + 2\hat{y}\bar{y} - 2\bar{y} \frac{1}{h} \sum \hat{y} \\
&+ 2y\bar{y} - 2y \frac{1}{h} \sum \hat{y} - 2\bar{y}^2 + 2\bar{y} \frac{1}{h} \sum \hat{y} - 2\hat{y}\bar{y} + 2\hat{y} \frac{1}{h} \sum \hat{y} + 2\bar{y} \frac{1}{h} \sum \hat{y} - 2 \left( \frac{1}{h} \sum \hat{y} \right)^2
\end{aligned}$$

Vereinfacht:

$$= (y - \bar{y})^2 + \left( \hat{y} - \frac{1}{h} \sum \hat{y} \right)^2 - \bar{y}^2 - \left( \frac{1}{h} \sum \hat{y} \right)^2 - 2\hat{y}y + 2y\bar{y} + 2\hat{y} \frac{1}{h} \sum \hat{y}$$

Aufsummiert, durch  $h$  geteilt, noch weiter vereinfacht und denselben Term addiert und subtrahiert:

$$\begin{aligned}
\frac{1}{h} \sum (\hat{y} - y)^2 &= \frac{1}{h} \sum (y - \bar{y})^2 + \frac{1}{h} \sum \left( \hat{y} - \frac{1}{h} \sum \hat{y} \right)^2 + \bar{y}^2 + \left( \frac{1}{h} \sum \hat{y} \right)^2 \\
&- 2 \frac{1}{h} \sum \hat{y}y + 2\bar{y} \frac{1}{h} \sum \hat{y} - 2\bar{y} \frac{1}{h} \sum \hat{y}
\end{aligned}$$

Für die rechte Seite ergibt sich:

$$\begin{aligned}
&= s_{\hat{y}}^2 + s_y^2 - 2r_{\hat{y}y} s_{\hat{y}} s_y + \left( \frac{1}{h} \sum \hat{y} \right)^2 - 2\bar{y} \frac{1}{h} \sum \hat{y} + \bar{y}^2 \\
&= (s_{\hat{y}} - s_y)^2 + 2(1 - r_{\hat{y}y}) s_{\hat{y}} s_y + \left( \frac{1}{h} \sum \hat{y} - \bar{y} \right)^2
\end{aligned}$$

Abschließend wird noch durch die linke Seite geteilt:

$$1 = \frac{\left( \frac{1}{h} \sum \hat{y} - \bar{y} \right)^2}{\frac{1}{h} \sum (\hat{y} - y)^2} + \frac{(s_{\hat{y}} - s_y)^2}{\frac{1}{h} \sum (\hat{y} - y)^2} + \frac{2(1 - r_{\hat{y}y}) s_{\hat{y}} s_y}{\frac{1}{h} \sum (\hat{y} - y)^2}$$

Aufgrund dieser Formel definiert man:

### 2.7.1 Bias Proportion (BIASP)

$$\text{BIASP} = \frac{\left(\frac{1}{h} \sum \hat{y} - \bar{y}\right)^2}{\frac{1}{h} \sum (\hat{y} - y)^2}$$

Rechentechische Umsetzung :

```
scalar {%v_sz_sm} = @mean({%v_sz})
scalar {%v_sm} = @mean({%v})
scalar {%v_res_ssq} = @sumsq({%v_res})
scalar {%v_res_ssq_sm} = {%v_res_ssq}/@obs({%v_res})
scalar {%v_sz_bias} = ({%v_sz_sm} - {%v_sm}) * ({%v_sz_sm} -
{%v_sm}) / {%v_res_ssq_sm}
```

### 2.7.2 Variance Proportion (VARP)

$$\text{VARP} = \frac{(s_{\hat{y}} - s_y)^2}{\frac{1}{h} \sum (\hat{y} - y)^2}$$

Rechentechische Umsetzung :

```
scalar {%v_sm} = @mean({%v})
scalar {%v_sz_sm} = @mean({%v_sz})
scalar {%v_ssq} = @sumsq({%v})
scalar {%v_ssq_sm} = {%v_ssq}/@obs({%v})
scalar {%v_sa} = @sqrt({%v_ssq_sm} - ({%v_sm} * {%v_sm}))
scalar {%v_sz_sa} = @sqrt({%v_sz_ssq_sm} - ({%v_sz_sm} * {%v_sz_sm}))
scalar {%v_sz_var} = ({%v_sz_sa} - {%v_sa}) * ({%v_sz_sa} - {%v_sa}) / {%v_res_ssq_sm}
```

### 2.7.3 Covariance Proportion (COVP)

$$\text{COVP} = \frac{2(1 - r_{\hat{y}y}) s_{\hat{y}} s_y}{\frac{1}{h} \sum (\hat{y} - y)^2}$$

Rechentechische Umsetzung :

```
scalar {%v_sz_cov} =
2 * (1 - cor({%v}, {%v_sz})) * {%v_sa} * {%v_sz_sa} / {%v_res_ssq_sm}
```

Interpretation :

„The bias proportion tells us how far the mean of the forecast is from the mean of the actual series.

The variance proportion tells us how far the variation of the forecast is from the variation of the actual series.

The covariance proportion measures the remaining unsystematic forecasting errors.” (E-Views 5 Handbuch, S.538)

„If your forecast is ‚good‘, the bias and variance proportions should be small so that most of the bias should be concentrated on the covariance proportions.“ (Ebd., S.539)

### 3. Ein einfaches komplexes Maß?

Formal lassen sich aus allen diesen Maßen gleich gewichtete Durchschnitte über alle, in den Vergleich einbezogenen Variablen berechnen. Bei der Interpretation muss allerdings darauf geachtet werden, dass gleiche Wichtung nicht mehr vorliegt, wenn die Skaleninvarianz verletzt ist und Variablen unterschiedlicher Größenordnung im Spiel sind. Als ein sehr robustes Maß – sowohl hinsichtlich der Skaleninvarianz als auch hinsichtlich unterschiedlicher Längen und Periodizitäten des Simulationszeitraumes, erweist sich MAPE. Ein Vorteil dieses Maßes besteht darin, dass es Ausreißer nicht höher gewichtet als „normale“ Datenpunkte.

### 4. Abkürzungen

Die hier erläuterten Maße für den Modellvergleich sind:

ME = Mean Error, MAE = Mean Absolute Error, MAPE = Mean Absolute Percentage Error, RMSE = Root Mean Squared Error, RMSPE = Root Mean Squared Percentage Error, TIEC = Theil Inequality Coefficient, BIASP = Bias Proportion, COVP = Covariance Proportion, VARP = Variance Proportion.