



VIETATO L'ACCESSO
NO ENTRY
DEFENSE D'ENTRER
EINTRITT VERBOTEN

Vorsicht Hochspannung!

Risikomanagement in Energiemärkten (Teil III) Fortgeschrittene Spotpreismodelle und VaR-Ansätze

Im ersten Teil der Serie [siehe RISKNEWS 03/2004] wurde eine kurze Einführung in den Stromhandel in Deutschland gegeben. Weiterhin wurden Besonderheiten im Preisverhalten auf Strommärkten erläutert. Der zweite Teil [siehe RISKNEWS 04/2004] beschäftigte sich mit der Modellierung von Strompreisen, insbesondere der Berücksichtigung von Saisonalitäten sowie der stochastischen Modellierung der Preisprozesse. Der dritte Teil der Serie erläutert verfeinerte Methoden der Preismodellierung sowie Ansätze des Risikomanagements in Energiemärkten mit Hilfe des Value-at-Risk und RAROC-Konzepts.

Wie in den vorherigen Teilen der Serie bereits erwähnt, bieten klassische Modelle aus der Finanzwirtschaft angesichts der speziellen Eigenschaften der Ware Strom nicht immer die richtige Methodologie, um das Verhalten von Strompreisen abzubilden. Eine Schwäche klassischer Modelle ist die Annahme normalverteilter Zuwächse, wie sie z. B. bei der geometrisch Brownschen Bewegung (GBM) unterstellt wird. Strompreise weisen meist starke Preisspitzen und hohe Werte für Schiefe und Kurtosis auf, die von der GBM nicht ausreichend berücksichtigt oder modelliert werden. Daher werden die Kurtosis sowie die Wahrscheinlichkeit für extreme Preissprünge deutlich unterschätzt.

Strompreismodellierung mit alternativen Verteilungen

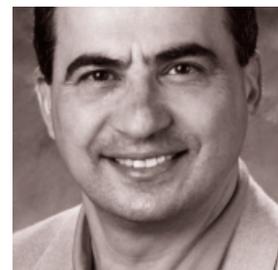
Eine Möglichkeit, diese Schwäche zu überwinden, war die Verwendung von Jump-Diffusions-Modellen [vgl. Cont; Tankov 2004]. In neueren Veröffentlichungen finden sich jedoch auch häufig Ansätze zur Modellierung der Returns auf Finanzmärkten mit alternativen Verteilungen. So schlagen Bibby und Sorensen (2003) die Verwendung der Klasse der verallgemeinerten hyperbolischen Verteilungen vor, wohingegen Rachev und Mittnik (2001) die Modellierung mit Hilfe der

alpha-stabilen Verteilung empfehlen. Beide Verteilungsklassen sind dank ihrer heavy-tailed-Eigenschaft auch in der Lage, Preisspitzen und extreme Returns abzubilden.

Die Klasse der verallgemeinerten hyperbolischen (generalized hyperbolic, GH) Verteilungen umfasst einige der klassischen statistischen Verteilungen wie etwa die Student t, die hyperbolische, die Normal Inverse Gauss (NIG) Verteilung, aber auch die Normalverteilung selbst. Im Folgenden wurden zum Vergleich der Anpassungsgüte aus der Klasse der GH-Verteilungen die hyperbolische sowie die NIG-Verteilung verwendet. Die hyperbolische Verteilung genügt der Dichtefunktion

$$f(x; \alpha, \beta, \delta, \mu) = \frac{\sqrt{\alpha^2 - \beta^2}}{2\alpha\delta K_1(\delta\sqrt{\alpha^2 - \beta^2})} \exp\left\{-\alpha\sqrt{\delta^2 + (x - \mu)^2} + \beta(x - \mu)\right\}$$

wobei K_1 die modifizierte Besselfunktion dritten Grades ist. Für die Dichte sowie zu Schätzalgorithmen und Implementierung der NIG-Verteilung sei etwa auf Weron (2004) verwiesen. Die genannten Verteilungen besitzen beide die heavy-tailed-Eigenschaft, wobei die NIG-Verteilung noch breitere Flanken als die hyperbolische Verteilung aufweist. Mit vier Parametern bieten die Verteilungen eine größere Flexibilität in der Anpassung als etwa die Normalverteilung, was



Prof. Svetlozar
(Zari) Rachev

ist Lehrstuhlinhaber am Institut für Statistik und Mathematische Wirtschaftstheorie an der Universität Karlsruhe und emeritierter Professor des Department of Statistics and Applied Probability der University of California in Santa Barbara. Zu seinen Forschungsgebieten zählen Mathematische und Empirische Finanztheorie, Ökonometrie, Wahrscheinlichkeitstheorie und Statistik. Er ist als Chief-Scientist der Finanzberatung FinAnalytica tätig.



Autor

Stefan Trück

ist wissenschaftlicher Mitarbeiter am Lehrstuhl für Statistik, Ökonometrie und mathematische Finanzwirtschaft der Universität Karlsruhe und Lehrbeauftragter an der BA Karlsruhe. Er beschäftigt sich u. a. mit der Modellierung von Kreditrisiken, Operational Risk und Risikomanagement in Energiemärkten.

leptokurtisch: Verteilungen mit positiver Kurtosis werden als leptokurtisch bezeichnet. Die Beobachtungen konzentrieren sich mehr an den Ausläufern und weniger im Zentrum als bei einer Normalverteilung. Das Maximum der Dichtekurve ist höher als das der Glockenkurve.

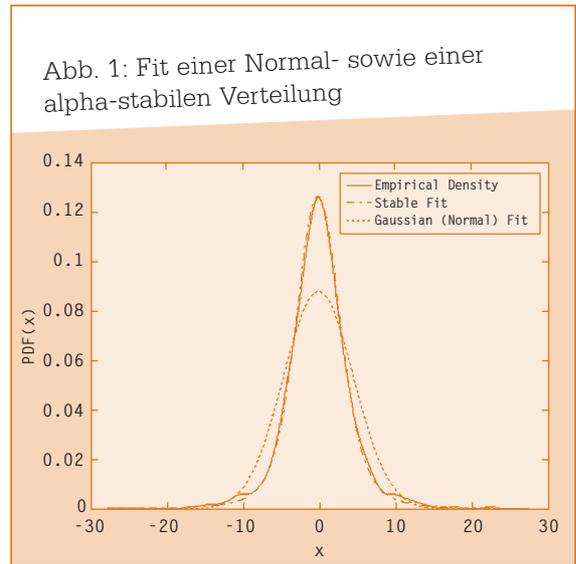
bei der Modellierung von Strompreisen zu deutlich besseren Ergebnissen führt [vgl. Eberlein und Stahl 2003].

Eine andere Alternative stellt die bereits erwähnte Verwendung einer alpha-stabilen Verteilung zur Modellierung der Returns dar. Diese kann als natürliche Verallgemeinerung der Normalverteilung angesehen werden und zählt ebenfalls zur Klasse der so genannten heavy-tailed Verteilungen [Rachev; Mittnik 2001]. Sie hat als weiteren Vorteil ebenso wie die Normalverteilung die Eigenschaft, dass die Summe zweier alpha-stabiler Verteilungen mit gleichem Stabilitätsindex α wieder alpha-stabil mit gleichem Index α verteilt ist. Da die Dichte der alpha-stabilen Verteilung nicht in geschlossener Form darstellbar ist, wird sie zumeist mit Hilfe der charakteristischen Funktion von X notiert:

$$E(e^{itx}) = \begin{cases} \exp(-\sigma^\alpha |t|^\alpha [1 - i\beta \text{sign}(t) \tan \frac{\pi\alpha}{2}] + i\mu t), & \alpha \neq 1 \\ \exp(-\sigma |t| [1 + i\beta \frac{2}{\pi} \text{sign}(t) \ln |t|] + i\mu t), & \alpha = 1 \end{cases}$$

Die alpha-stabile Verteilung wird durch vier Parameter α , β , σ und μ gekennzeichnet: α ist der so genannten Stabilitätsindex ($0 < \alpha \leq 2$), wobei für Werte von $\alpha < 2$ die Verteilung leptokurtischer als die Normalverteilung wird. β mit ($-1 \leq \beta \leq 1$) ist der Parameter, der die Schiefe der Verteilung bestimmt, σ ($\sigma \geq 0$) der so genannte scale-parameter und μ mit ($\mu \in \mathbb{R}$) der so genannte drift, der für $\alpha > 1$ dem Erwartungswert der Verteilung entspricht. Aufgrund der vier Parameter bietet auch die alpha-stabile Verteilung mehr Flexibilität zur Modellierung von Eigenschaften wie etwa Schiefe, höhere Kurtosis oder breitere Flanken (heavy tails). Die alpha-stabile Verteilung enthält als Spezialfall für $\alpha = 2$ die Normalverteilung, sowie für $\alpha = 1$ die Cauchy-Verteilung. Ihre Möglichkeiten zur Modellierung von Strompreisen verdeutlicht Abb. 1, welche die Anpassung einer Normalverteilung sowie einer alpha-stabilen Verteilung an desai-

sonalisierte Returns der Strombörse EEX für den Zeitraum 01. Januar 2001 bis 31. Dezember 2003 zeigt. Man sieht, dass die alpha-stabile Verteilung die empirische Verteilung der Returns sehr gut abbildet [vgl. auch Khindanova et al 2001 sowie Rachev 2004].



sonalisierte Returns der Strombörse EEX wieder. Als Gütemaße für die Anpassung wurde die Kolmogorov-Smirnov (KS) Distanz $K = \sqrt{n} \sup_x |F(x) - F_n(x)|$ zwischen empirischer $F_n(x)$ und geschätzter Verteilungsfunktion $F(x)$ sowie die Anderson-Darling-Statistik (AD) gewählt. Letztere verwendet ebenfalls die Distanz zwischen empirischer und geschätzter Verteilungsfunktion, gibt jedoch Abweichungen im Tail-Bereich (also bei extremen Preissprüngen) ein höheres Gewicht. Für beide Gütekriterien gilt: je kleiner der Wert der Teststatistik ausfällt, umso besser ist die Anpassung der Ver-

Tab. 1: Geschätzte Parameter und Anpassungsgüte unterschiedlicher Verteilungen

Verteilung	Geschätzte Parameter				Kolmogorov-Smirnov	Anderson-Darling
alpha-stabile	$\alpha = 1.510$	$\sigma = 2.900$	$\beta = 0.261$	$\mu = 0.490$	0.6877	0.5527
NIG	$\alpha = 0.047$	$\delta = 3.218$	$\beta = 0.003$	$\mu = 0.221$	0.9138	1.7890
Hyperbolisch	$\alpha = 0.209$	$\delta = 0.018$	$\beta = 0.000$	$\mu = 0.005$	1.8667	+INF
Normalverteilung	-	$\sigma = 11.455$	-	$\mu = 0.008$	6.9894	+INF

teilung. Man sieht, dass aufgrund der extremen Preisspitzen am Strommarkt die Verteilung mit den breitesten Flanken – somit die alpha-stabile Verteilung – den besten Fit liefert. Sowohl für das KS- als auch das AD-Kriterium liefert sie die kleinsten Abweichungen. Nach der alpha-stabilen Verteilung schneidet die NIG-Verteilung am zweitbesten ab, dann die deutlich weniger breitflankige hyperbolische Verteilung. Am schlechtesten schneidet die in vielen finanztheoretischen Modellen verwendete Normalverteilung ab.

Dies verdeutlicht auch Abb. 2, in der die Anpassungsgüte der Normalverteilung (dünne Linie), der hyperbolischen (gestrichelte Linie) sowie einer alpha-stabilen Verteilung (durchgezogene Linie) an die desaisonalisierten Spotpreise der Strombörse EEX für den betrachteten Zeitraum zu sehen ist. Im linken Teil der Abb. 2 ist dabei der Fit für die komplette Verteilungsfunktion dargestellt, im rechten der Fit im linken Tail-Bereich der Verteilungsfunktion. Dies geschah zur besseren Darstellung auf einer logarithmierten Skala – also für extreme Preissprünge, wobei die zehn größten bzw. kleinsten Werte nicht in der Abbildung dargestellt wurden.

Eine Anpassung von existierenden Modellen für Elektrizitätspreise unter Annahme alpha-stabil verteilter Returns kann daher durchaus als aussichtsreicher Ansatz für zukünftige Arbeiten angesehen werden.

Fortgeschrittene Ansätze der Spotpreismodellierung

Eine weitere Möglichkeit zur Modellierung von Spotpreisen an Strombörsen bieten etwas komplexere Zeitreihenmodelle, wie etwa GARCH-Modelle [vgl. Escribano et al 2002] mit stochastischer Volatilität sowie Regime-Switching-

Modelle [vgl. Huisman; Mahieu 2003], bei denen das Preisverhalten von Elektrizitäts-Spot-Preisen durch die Teilung der Zeitreihe in zwei getrennte Phasen modelliert wird. Burger et al (2003) stellten weiterhin ein so genanntes SARIMA-Modell zur Simulation von Spotpreisen an Strombörsen vor, das ein Zeitreihenmodell mit einem autoregressiven integrierten moving-average-Prozess (ARIMA) um eine für Strompreise typische saisonale Komponente erweitert.

Da die GARCH-Ansätze auch aus klassischen Modellen der Finanzwirtschaft bekannt sind, sollen hier als Beispiel die vor allem für Strommärkte besonders geeigneten Regime-Switching-Modelle vorgestellt werden. Hier wird das Preisverhalten von Elektrizitäts-Spot-Preisen durch die Teilung der Zeitreihe in zwei getrennte Regime mit unterschiedlichen zugrunde liegenden Prozessen modelliert. Phasen höherer Volatilität lassen sich dann gegebenenfalls mit einem Wechsel in ein anderes Regime modellieren. Der Umschaltvorgang wird gewöhnlich von einer Zufallsvariablen bestimmt, die einer Markovkette mit mehreren Zuständen folgt und die selbst nicht beobachtet werden kann. Für jeden Zeitpunkt können lediglich Wahrscheinlichkeiten dafür angegeben werden, dass sich der Prozess in Zustand $R = i$ befindet.

Im Folgenden wird die Idee der Regime-Switching-Modelle zunächst am einfachsten Fall verdeutlicht – einem Modell, das nur zwei unterschiedliche Zustände zulässt und für Strompreise erstmals von Huisman und de Jong (2003) verwendet wurde. Das Zwei-Regime-Modell differenziert zwischen einem so genannten Base Regime ($R = 1$), für das zumeist der klassische Mean-Reversion-Prozess herangezogen wird und einem Spike Regime ($R = 2$) mit höherer Volatilität. Der Spotpreis kann sich zu jedem Zeitpunkt sowohl im Mean Reversion als auch im Spike Regime befinden. Die Preisprozesse $Y_{t,1}$ für Regime 1 und $Y_{t,2}$ für Regime 2 werden als voneinander unabhängig angenommen. Die Variable R_t , die den gegenwärtigen Zustand bestimmt, ist hier eine Zufallsvariable, die einer Markov-Kette mit zwei möglichen Zuständen folgt, $R_t = \{1, 2\}$. Die Übergangsmatrix P enthält dann die Wahrscheinlichkeiten p_{ij} des Wechsels von Regime i zum Zeitpunkt t zu Regime j zum Zeitpunkt $t + 1$:

$$P = (p_{ij}) = \begin{pmatrix} p_{11} & p_{12} \\ p_{21} & p_{22} \end{pmatrix} = \begin{pmatrix} p_{11} & 1 - p_{11} \\ 1 - p_{22} & p_{22} \end{pmatrix}$$

Der gegenwärtige Zustand R_t einer Markov-Kette hängt dann nur vom vorigen Wert R_{t-1} ab, so dass gilt: $P\{R_t = j | R_{t-1} = i\} = p_{ij}$. Ein offensicht-



Dr. Rafal Weron

ist Assistant Professor am Institut für Mathematik der Technischen Universität Breslau. Seine Forschungsgebiete sind Finanzmathematik und stochastische Modelle im Risikomanagement. Er ist als Berater für verschiedene Banken und Energiegesellschaften tätig.

Eine Markovkette (nach Andrej Andrejewitsch Markov) ist ein diskreter stochastischer Prozess, bei dem die Wahrscheinlichkeit für den Zustand zum Zeitpunkt $t + 1$ nur von dem Zustand zum Zeitpunkt t abhängt. Dies bezeichnet man als Gedächtnislosigkeit oder auch Markov-Eigenschaft. Markovketten können die (zeitliche) Entwicklung von Objekten, Sachverhalten, Systemen etc. beschreiben, die zu jedem Zeitpunkt jeweils nur eine von endlich (oder abzählbar unendlich) vielen Ausprägungen annehmen können.

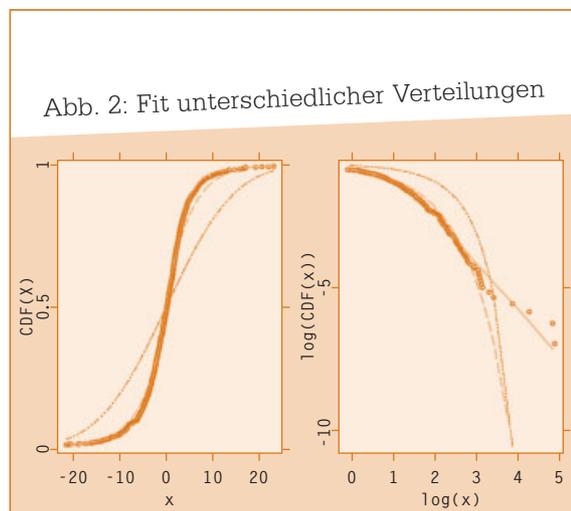


Abb. 2: Fit unterschiedlicher Verteilungen

licher Vorteil des Modells gegenüber den im letzten Teil der Serie vorgestellten Jump-Diffusion-Modellen ist die Möglichkeit, dass der Prozess nach einem Sprung ins Spike Regime mit Wahrscheinlichkeit p_{22} in diesem Regime verweilen kann, also mehrere aufeinander folgende Preise auf hohem Niveau oder mit großer Volatilität vom Modell erklärt werden können.



Es gibt viele Möglichkeiten, den stochastischen Prozess für das Base- bzw. Spike-Regime zu wählen, meist wird jedoch für das Base-Regime ein Mean-Reversion Prozess gewählt, wie er z. B. im letzten Teil der Serie beschrieben wurde. Für das Spike-Regime $R_t = 2$ bietet es sich aufgrund der höheren Volatilität und den Preisspitzen an, Verteilungen mit heavy tails zu verwenden. Bierbrauer et al (2004) schlagen etwa die Lognormal-Verteilung vor. Das Modell für die desaisonalisierten Preise hat dann die folgende Gestalt: der stochastische Prozess für das Base-Regime genügt der Gleichung $dY_{t,1} = (c_1 - \beta_1 Y_{t,1})dt + \sigma_1 dB_t$, für das Spike Regime gilt $\log(Y_{t,2}) \sim N(C_2, \sigma_2^2)$. Dann werden simultan unter Verwendung des so genannten EM-Algorithmus die Parameter $\theta = \{c_1, \beta_1, \sigma_1, c_2, \sigma_2, p_{11}, p_{22}\}$ der Übergangsmatrix sowie der stochastischen Prozesse für die beiden Regime geschätzt.

Der Algorithmus liefert nicht nur die Parameterschätzer, sondern auch für jeden beobachteten Wert Wahrscheinlichkeiten, dass sich der Prozess im Base- bzw. Spike-Regime befindet. Abb. 3 zeigt neben den desaisonalisierten logarithmierten Spotpreisen auch exemplarisch die geschätzten Wahrscheinlichkeiten dafür an, dass sich der Prozess im Spike-Regime befindet. Man sieht,

dass bei größeren Preissprüngen bzw. größerer Volatilität die Wahrscheinlichkeit für Regime 2 schnell sehr groß wird. Kehrt der Prozess wieder auf das mittlere Preisniveau zurück bzw. sinkt die Volatilität, ist die geschätzte Wahrscheinlichkeit für das Spike Regime wieder nahe Null.

Regime-Switching-Modelle bieten große Flexibilität bei der Modellierung – neben der Anzahl an Regimen ($R = 2, 3, \dots$) kann auch über die Wahl der stochastischen Prozesse im jeweiligen Regime eine Vielzahl an Variationen erreicht werden. Besonders für das Spike-Regime stellt sich die Frage, mit welcher Verteilung sich Spikes bzw. Phasen größerer Volatilität geeignet modellieren lassen. Da Spitzen sehr selten auftreten, aber gewöhnlich einen hohen Ausschlag aufweisen, empfiehlt sich die Verwendung von heavy-tailed Verteilungen wie etwa der Lognormal-, Weibull-, Pareto- oder alpha-stabilen Verteilung.

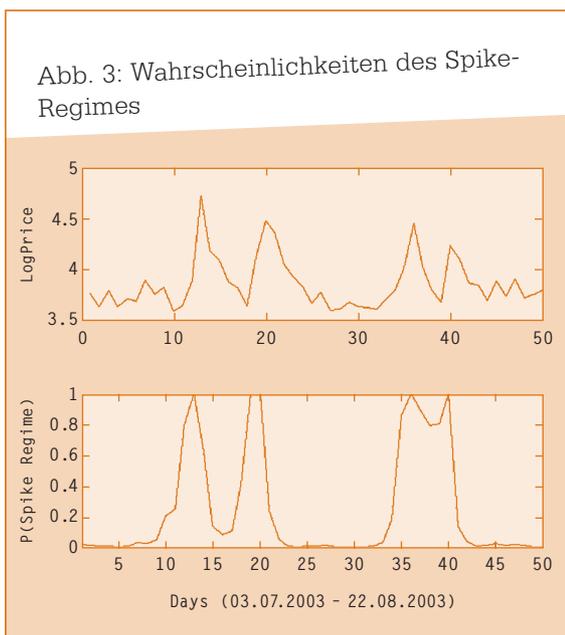
Huisman und de Jong (2003) schlagen ein Regime-Switching-Modell mit drei möglichen Zuständen vor, welches sich auch zur Bewertung von Optionen und Futures verwenden lässt. Bei dem Modell folgt auf einen Sprung in das Spike Regime ein sofortiger Sprung zurück in das Base Regime – das Modell hat insofern große Ähnlichkeit mit einem Jump-Diffusion-Ansatz. Eine Vielzahl anderer Regime-Switching-Modelle zur Anpassung an Strompreisdaten ist denkbar, so dass diese Modellklasse ebenso wie etwa GARCH- oder SARIMA-Modelle als ein vielversprechender Ansatz angesehen werden kann.

VaR und risiko-adjustierte Performance-Messung in Energiemärkten

Auf der Basis des geschätzten Prozesses für Elektrizitäts-Spotpreise lassen sich Preise für Derivative (wie z. B. die in Teil I der Serie vorgestellten Stromfutures) berechnen. Auch Optionen, wie sie an der skandinavischen Strombörse NORDPOOL gehandelt werden, können mit Hilfe der Modelle bewertet werden. Diese Instrumente spielen eine große Rolle, um ein adäquates Risikomanagement zu betreiben. Häufig sind für die verwendeten Prozesse jedoch keine geschlossenen Formeln zur Berechnung der Preise von Derivaten ableitbar, so dass die Bewertung auf der Basis von Simulationen geschieht. Hierzu wird mit Hilfe des geschätzten Prozesses eine große Anzahl an Preispfaden simuliert und dann aus den simulierten Spotpreisen jeweils der entsprechende Wert des Derivates berechnet.

Weiterhin lassen sich für in Energiemärkten tätige Unternehmen Risiko-Kennzahlen wie etwa

Abb. 3: Wahrscheinlichkeiten des Spike-Regimes



Value-at-Risk (VaR) berechnen bzw. risiko-adjustierte Performance-Measures (RAPMs) berechnen. Im letzten Abschnitt soll daher noch kurz auf die Verwendung solcher Kennzahlen eingegangen werden.

Auch beim Risikomanagement in Energiemärkten spielt die risiko-adjustierte Performance-Messung eine große Rolle. Gerade in sehr volatilen Märkten kann der erwartete Return nicht allein in Bezug zum investierten Kapital gesetzt werden, sondern muss auch das entsprechende Risiko berücksichtigen. Hierzu werden meist verschiedene Versionen des ursprünglich von Bankers Trust entwickelten Risk-adjusted-Return-on-Capital (RAROC) herangezogen. Der RAROC wird meist als Quotient aus erwartetem Return und dem ökonomischen Kapital definiert.

Das ökonomische Kapital ist hierbei der Betrag, der nötig ist, um das Überleben der Finanzinstitution auch im Falle eines Worst-Case-Scenarios zu sichern. Aufgrund dieser Definition bietet es sich an, den Value-at-Risk (VaR) für das ökonomische Kapital zu verwenden.

$$RAROC = \frac{\text{Expected Return}}{VaR}$$

Betrachtet man nun eine Investition in ein an der Strombörse gehandeltes bzw. ein vom Spotpreis an der EEX abhängiges Produkt, so fließt aufgrund der Definition des VaR vor allem die Varianz des Referenzproduktes, also des Spotpreises an der Strombörse, mit ein. Insbesondere aus Sicht des Risikomanagements ist es daher entscheidend, ein adäquates Modell für den Spotpreis zu haben.

Der RAROC-Ansatz eignet sich zwar zum risiko-adjustierten Vergleich verschiedener Investitionsmöglichkeiten, macht jedoch zunächst

keine Aussage darüber, ob die Investition auch lohnend ist. Daher spielt es für im Energiehandel tätige Unternehmen auch eine Rolle, so genannte hurdle rates μ bezüglich eines Vertrages zu setzen, d. h. es wird eine Entscheidungsregel der Form

$$\text{Investition in Asset } A \Leftrightarrow RAROC(A) > \mu$$

verwendet. Eine Investition kann als lohnend betrachtet werden, sofern das Projekt den Shareholder Value der Unternehmung steigert, also der RAROC größer ist als die Eigenkapitalkosten des Projekts. Dieser Ansatz wird häufig auch mit dem auf die Unternehmensberatung Stern Stewart & Co. Zurückgehende Economic Value Added (EVA) Konzept bezeichnet und lässt sich letztendlich auch auf Energiemärkte übertragen. Es gilt jedoch zu bedenken, dass bei der einfließenden Größe des VaR im Bankengeschäft davon auszugehen ist, dass praktisch jede risiko-behaftete Position jederzeit geschlossen werden kann. Energiemärkte müssen jedoch aufgrund der Eigenschaften des Gutes Strom als teilweise sehr illiquide angesehen werden. Da Optionen und Futures meist nur OTC gehandelt werden (vgl. Teil I), ist ein Glättstellen von Positionen mit Derivaten wie Futures nur begrenzt möglich. Eydeland und Wolyniec (2003) sowie Dahlgren et al (2003) schlagen daher etwa die Verwendung des Cash-Flow-at-Risk (CfAR) oder der Earnings-at-Risk (EaR) vor, die nicht die Voraussetzung beinhalten, dass Positionen schon vor Ende der Laufzeit geschlossen werden können. Empirische und theoretische Arbeiten zur risiko-adjustierten Performance-Messung und einer geeigneten Wahl von Risiko-Prämien für Energiekontrakte befinden sich allerdings erst im Anfangsstadium und werden in den nächsten Jahren mit weiter wachsenden Märkten sicher fortgeführt werden. ■

Quellenverzeichnis und Weiterführende Literatur: Bibby, B.; Sørensen, M.: Hyperbolic processes in finance, in: Rachev, S. (ed.): Handbook of Heavy Tailed Distributions in Finance, Elsevier Science, 211 – 248, (2003) / Bierbrauer, M.; Trück, S.; Weron, R.: Modelling electricity prices with regime switching models, Lecture Notes in Computer Science, Volume 3039, p. 859 – 867, Springer (2004) / Burger, M.; Klar, B.; Müller, A.; Schindlmayr, G.: A spot market model for pricing derivatives in electricity markets. Quantitative Finance, 4, 109 – 122, (2004) / Clewlow, L.; Strickland, C.: Energy Derivatives: Pricing and Risk Management, Lacima, (2000) / Cont, R.; Tankov, P.: Financial Modelling with Jump Processes, Chapman and Hall, (2004) / Dahlgren, R.; Liu, C. hen-Ching; Lawarrée, J.: Risk Assessment in Energy Trading, IEEE Transactions on Power Systems, Vol. 18, 2, 503 – 511, (2003) / Eberlein, E.; Stahl, G.: Both sides of the fence: a statistical and regulatory view of electricity risk, in: Energy & Power Risk Management 8, no. 6, 32 – 36, (2003) / Eydeland A.; Wolyniec, K.: Energy and Power Risk Management, Wiley Finance, (2004) / Escrivano, A.; Pena, J.; Villaplana, P.: Modelling electricity prices: international evidence, EFMA London Meetings, (2002) / Huisman, R.; de Jong, C.: Option pricing for Power Prices with Spikes, EPRI, 7.11, 12 – 16, (2003) / Huisman, R.; Mahieu, R.: Regime Jumps in Electricity Prices, Energy Economics, Volume 25, Issue 5, 425 – 434, (2003) / Johnson, B.; Barz, G.: Selecting stochastic processes for modelling electricity prices, Energy Modeling and the Management of Uncertainty, 3 – 21, (1999) / Khindanova, I.; Atakhanova, Z.; Rachev, S.: Stable Modeling in Energy Risk Management, Proceedings of the IFAC Symposium on Modeling and Control of Economic Systems, (2001) / Lucia, J.; Schwartz, E.: Electricity prices and power derivatives: Evidence from the nordic power exchange, Review of Derivatives Research 5, 5 – 50, (2002) / Pilipovic, D.: Energy Risk: Valuing and Managing Energy Derivatives, McGraw Hill, (1998) / Rachev, S. T.; Mitnik, S.: Stable Paretian Models in Finance, Wiley, (2001) / Rachev, S. T.; Mugele, C.; Trück, S.: Stable Modeling of Energy Prices, Working Paper, (2004) / Wengler, J.: Managing Energy Risk: a nontechnical guide to markets and trading, PennWell Publishing Company, (2001) / Weron, R.: Computationally Intensive Value at Risk Calculations in Gentle, J. et al: Handbook of Computational Statistics, Springer, 911 – 950, (2004) / Weron, R.; Bierbrauer, M.; Trück, S.: Modelling electricity prices: jump diffusion and regime switching, in Physica A, 336, p. 39 – 48, Elsevier (2004).

