
Methodische Herausforderungen und Chancen für die quantitative Schätzung von operationellen Risiken

INHALT

Einführung und Überblick	03
Aktuelle Regulatorische Entwicklungen	04
OpRisk Modelle unter Säule II	05
Bayessche OpRisk Modellierung	05
Technische Umsetzung und Einsatz von Probabilistischen Programmiersprachen	08
Zusammenfassung und Ausblick	10

EINFÜHRUNG UND ÜBERBLICK

Die quantitative Schätzung und Steuerung operationeller Risiken (OpRisk) sind in der Praxis häufig mit einigen Herausforderungen verbunden. Im Rahmen von operational Value-At-Risk Verfahren macht es insbesondere die oft nur spärlich vorhandene Datenbasis an historischen OpRisk Verlusten schwierig, die Parameter von Verlustverteilungen sowohl zuverlässig als auch über einen längeren Zeitraum stabil zu schätzen. Sowohl Datenqualitätsprobleme, wie auch einzelne, schwer vorzusehende Extremereignisse können schnell zu unrealistisch verzerrten Verlustverteilungen und zu erheblichen Schwankungen bei den endgültig ermittelten Kennzahlen führen.

Aus methodischer Sicht bietet es sich hier auf natürliche Weise an, Modelle vollständig im Sinne eines Bayesschen Ansatzes zu behandeln, was zusätzlich zu weiteren Vorteilen führt. So können auf solider theoretischer Basis sowohl Expertenschätzungen, aber auch Risikoszenarien in die Modellierung mit einfließen und Modellunsicherheiten besser eingeschätzt werden. Da eine technische Umsetzung derartiger Ansätze aufgrund der Komplexität der dafür notwendigen numerischen Verfahren bislang mit erheblichen Schwierigkeiten verbunden war, war die Diskussion von „Bayesian OpRisk“ bislang jedoch eher auf einen akademischen Expertenkreis beschränkt.

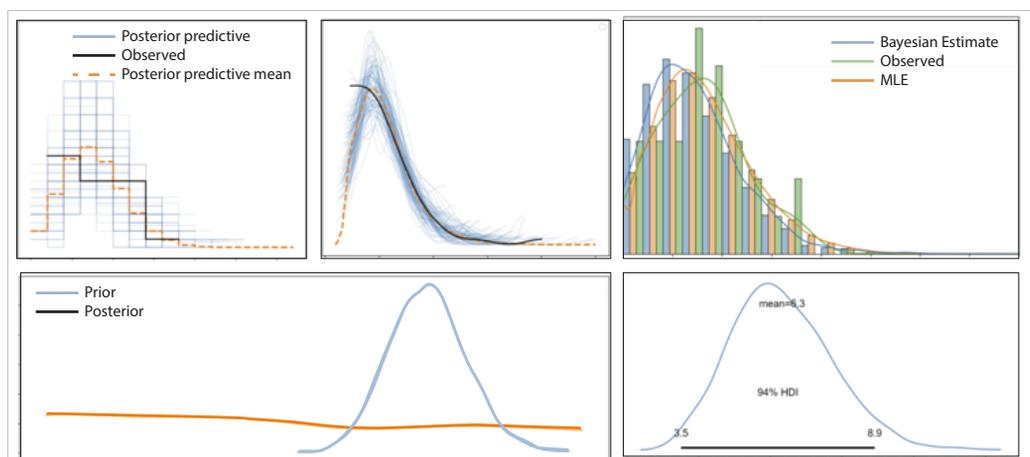


Abbildung 1 - Bayesian OpRisk: Illustrative Darstellung

Die rasante Entwicklung der letzten Jahre auf dem Gebiet des Maschinellen Lernens und die damit einhergehende Verfügbarkeit neuer technischer Werkzeuge ermöglicht es nun jedoch, Bayessche Modellierung und deren praktische Anwendung einem breiten Kreis an Anwendern zugänglich zu machen. Ziel dieses Artikels ist, die Bayessche Modellierung am Beispiel operationeller Risiken näher zu erläutern und in den weiteren Kontext der aktuellen regulatorischen Entwicklungen einzuordnen. Gerade vor dem Hintergrund der fehlenden Risikosensitivität des neuen Standardansatzes für operationelle Risiken und den neuen Anforderungen an den Einsatz von Modellen gemäß des neuen Abschnitts AT 4.3.5. im Entwurf der achten Novelle der MaRisk, gilt es hier rechtzeitig sicherzustellen, dass bankweit alle zur Schätzung und Steuerung eingesetzten Modelle auf methodisch soliden Fundamenten stehen.

AKTUELLE REGULATORISCHE ENTWICKLUNGEN

Als Teil des EU Banking Packages legte die EU-Kommission am 27. September 2021 den ersten Entwurf für die CRR III vor. Damit ist absehbar, dass die darin enthaltenen Vorschriften inkl. noch zu konkretisierender Details bis voraussichtlich 2025 umgesetzt werden müssen. Bezogen auf die Eigenmittelunterlegung operationeller Risiken ergeben sich daraus tiefgreifende Änderungen. Konnte bislang zur Ermittlung des Säule I Eigenkapitals für operationeller Risiken eines von drei Verfahren ausgewählt werden¹ (Basisindikatoransatz, Standardansatz, Fortgeschrittener Ansatz / AMA), so fällt diese Wahlmöglichkeit künftig weg. Stattdessen werden alle Institute verpflichtet, zukünftig den sogenannten Standardansatz für operationelle Risiken (SAOR) zu verwenden.

Der SAOR wurde ursprünglich vom Basler Ausschuss für Bankenaufsicht formuliert und in BCBS 424 in endgültiger Fassung vorgelegt. Darin war unter anderem vorgesehen das zur Unterlegung operationeller Risiken notwendige Eigenkapital auf Basis des sog. "Business Indicators" (BI) und des "Internal Loss Multipliers" (ILM) zu berechnen. Dabei sollte der ILM im Wesentlichen aus dem Durchschnitt der OpRisk Verluste aus den letzten 10 Jahren berechnet werden, was damit zu einer Risikosensitivität des OpRisk Eigenkapitals geführt hätte. Zur Überraschung vieler Institute wurde dieser Vorschlag jedoch nicht eins zu eins in den aktuellen Entwurf für die CRR III übernommen. Stattdessen ist nun vorgesehen, erforderliche Eigenmittel allein auf Basis des BI zu berechnen. Die Berechnung des ILM ist daher nicht mehr notwendig. Trotz dieser Vereinfachung der Berechnungsmethodik des SAOR sieht die CRR III jedoch weiterhin vor, dass Institute mit einem BI über 750 Millionen Euro verpflichtet sind, eine umfangreiche OpRisk Verlusthistorie vorzuhalten. Hierfür beinhaltet der vorliegende Entwurf der CRR III umfangreiche Vorgaben an Art und Umfang der vorzuhaltenden Daten, sowie umfassende Anforderungen an die damit verbundenen internen Prozesse.

Details zum neuen SAOR, wie etwa die genaue Berechnung des BI und die Details der Anforderungen an die

vorzuhaltende Verlustdatenhistorie, wurden bereits an anderer Stelle umfassend dargestellt und diskutiert. Auf eine tiefergehende Diskussion, insbesondere im Hinblick auf die dabei zu beachtenden Details bei der Anpassung interner Prozesse und IT-Systeme wird hier aufgrund des quantitativen und methodischen Fokus des Artikels verzichtet und stattdessen auf die üblichen Informationsquellen verwiesen².

Wichtig ist jedoch, darauf hinzuweisen, dass bisher verwendete OpRisk Ansätze und Modelle zur Berechnung und Steuerung des ökonomischen Kapitals unter Säule II von der Reform unberührt bleiben. So wird seitens der EU-Kommission explizit darauf hingewiesen, dass es möglich ist, bestehende Modelle "wie sie im Rahmen der AMA entwickelt wurden" [...] für die Zwecke des Verfahrens zur Beurteilung der Angemessenheit des internen Kapitals (ICAAP) zu verwenden.³

Auch aufgrund der fehlenden Risikosensitivität des SAOR wird damit eine adäquate Modellierung von operationellen Risiken unter Säule II umso wichtiger. Zusätzlich bietet sich hier die Chance für eine "Generalüberholung" bestehender Modellierungsansätze für operational Value-at-Risk Modelle auf Basis modernster Verfahren für stochastische und insbesondere Bayesscher Modellierung (und darauf aufbauende kausale Modelle).

1. Siehe z.B.

https://www.bafin.de/DE/Aufsicht/BankenFinanzdienstleister/Eigenmittelanforderungen/OperationelleRisiken/operationellerisiken_artikel.html

2. Siehe z.B.

https://www.d-fine.com/fileadmin/user_upload/dfine_OpRisk_WorkingPaper_final5.pdf für eine umfassende Diskussion.

OPRISK MODELLE UNTER SÄULE II

Trotz Einführung des SAOR bleibt weiterhin die Möglichkeit, im Rahmen der Säule II interne OpRisk Modelle für den ICAAP zu betreiben. Dazu können einerseits bestehende AMA-Modelle angepasst und weiterverwendet werden oder in nicht-AMA Instituten neu aufgesetzt werden. Aufgrund der fehlenden Risikosensitivität des SAOR könnte dies gerade für Institute, die den AMA bisher nicht verwendeten, eine verbesserte Steuerung operationeller Risiken ermöglichen.

Es ist ferner davon auszugehen, dass sich hier auch für die unter nationaler Aufsicht stehenden "Less Significant Institutions" (LSIs) zusätzliche Chancen für eine Modernisierung der Säule II OpRisk Praxis ergeben. Hierzu sei auch auf den ICAAP Leitfaden der Bafin von 2018 verwiesen, der mittel bis langfristig auch für die Prüfungspraxis bei LSIs relevant sein wird.

Weiterhin wird es gemäß der geplanten Modell-bezogenen Vorschriften in der achten Novelle der MaRisk (AT 4.3.5) zukünftig von entscheidender Bedeutung sein, dass grundsätzliche Modellannahmen, Parameterauswahl und Modellbeschränkungen begründbar und nachvollziehbar, sowie deren Erklärbarkeit sichergestellt sind. Insbesondere müssen Institute in der Lage sein, die "Genauigkeit, Stabilität und Konsistenz der [verwendeten] Verfahren regelmäßig zu analysieren"⁴. Als Beispiel für ein Modell, das derartige Anforderungen auf natürliche Weise erfüllt, wird dazu im nächsten Abschnitt ein vereinfachtes Bayessches OpRisk Modell und dessen Implementierung auf Basis modernster Technologie beschrieben.

BAYESSCHE OPRISK MODELLIERUNG

Üblicherweise wird zur Modellierung operationeller Risiken der sogenannte Verlustverteilungsansatz herangezogen. Vereinfacht gesprochen, wird dabei in einer Monte-Carlo Simulation mit Hilfe einer Verteilung von Ereignishäufigkeiten, sowie einer Verteilung von Verlusten je Ereignis ein operational Value At Risk, bzw. zu erwartender Gesamtverlust je Geschäftsjahr ermittelt (z.B. als 99.9% Quantil der simulierten Gesamtverluste). Da Verlusthöhen von der jeweiligen Art der Verluste bzw. Ereignisse abhängen und sich unterschiedliche Verlustereignisse untereinander beeinflussen können, werden typischerweise mehrere korrelierten Häufigkeits- bzw. Verlusthöhenverteilungen simuliert.

3. COM(2021) 664 final, S.32

4. „Entwurf der Änderungsversion zu den Mindestanforderungen an das Risikomanagement - MaRisk“, Juni 2022, S. 32

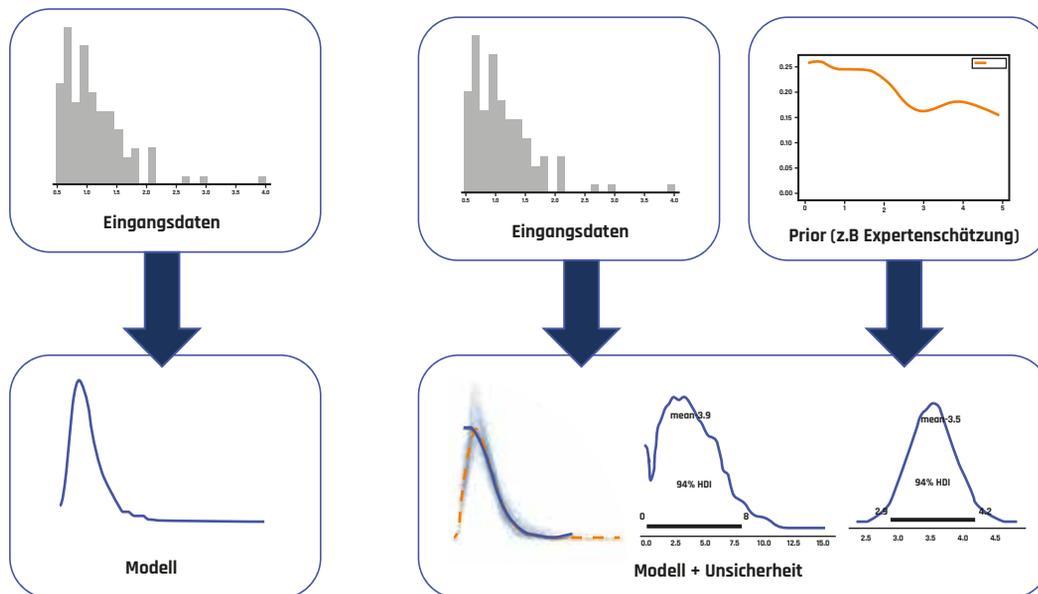


Abbildung 2 - MLE (links) und Bayesscher Ansatz (rechts) im Vergleich

Von zentraler Bedeutung für die endgültige Aussagekraft und Belastbarkeit der errechneten Kennzahlen ist die Schätzung der jeweiligen Verteilungsparameter aus den zur Verfügung stehenden Daten. Dazu wird meist der Maximum Likelihood-Schätzer (MLE) verwendet. Im Fall von Verlustereignissen aus operationellen Risiken stehen in der Praxis jedoch relativ wenig Daten zur Verfügung. Dies kann im Zeitverlauf zu starken Schwankungen der MLE-geschätzten Verteilungsparameter führen und die resultierenden Verlustverteilungen unrealistisch verzerren. Dies ist insbesondere der Fall bei einzelnen Extremereignissen. Zur Adressierung derartiger Probleme bietet sich natürlicherweise ein Bayesscher Modellansatz an, was im Folgenden anhand eines leicht vereinfachten Beispiels näher erläutert werden soll.

Üblicherweise wird z.B. zur Modellierung von Ereignishäufigkeiten X (d.h. konkret Anzahl von OpRisk Ereignissen eines bestimmten Typs pro Jahr) eine Poisson-Verteilung herangezogen. Die Verteilung hängt damit genau von einem zu schätzenden Parameter θ ab, der als die im Mittel erwarteten Anzahl von OpRisk Ereignissen pro Jahr interpretiert werden kann. Da keine oder nur sehr wenige Daten zur Verfügung stehen, aus denen θ geschätzt werden kann und Schätzungen daher mit einer sehr hohen Unsicherheit behaftet sind, nimmt man im Bayesschen Ansatz nun an, dass θ selbst wieder eine Zufallsvariable ist, mit sogenannter "A-Priori-Verteilung" (bzw. "Prior") $P(\theta)$. Die Verteilung $P(\theta)$ kann nun mit Hilfe einer Expertenschätzung festgelegt werden. Beispielsweise könnte eine Schätzung auf Basis von internen Umfragen in Fachabteilungen erfolgen, oder aber auch mit Hilfe von extern verfügbaren Daten zu OpRisk Ereignissen, wie sie auch sonst typischerweise in AMA-Modellen verwendet werden, durchgeführt werden. Ebenso könnte man für einzelne Szenarien jeweils eigene Prioren verwenden.

Im konkreten Fall der Poisson-Verteilung würde man $P(\theta)$ üblicherweise mit einer Gammaverteilung modellieren und deren Parameter α und β so bestimmen, dass Mittelwert und Varianz mit der Expertenmeinung (bzw. Umfrageergebnissen) übereinstimmen. Stehen nach einiger Zeit nun mehr beobachtete Daten für X zur Verfügung, so lässt sich die ursprüngliche, rein auf dem Prior $P(\theta)$ basierende Schätzung für θ , mit Hilfe der Bayesschen Formel

$$P(\theta|X) = \frac{P(X|\theta) P(\theta)}{P(X)},$$

aktualisieren. Im konkreten Fall bedeutet dies, dass sich der sogenannte "Posterior" $P(\theta | X)$, also die Wahrscheinlichkeit eines bestimmten Wertes für θ gegeben tatsächlich beobachteter Ereignisse X , mit der sogenannten "Likelihood" $P(X | \theta)$, d.h. der Wahrscheinlichkeit der beobachteten Daten unter Annahme des ursprünglichen geschätzten Werts für θ , des Priors $P(\theta)$ und der sogenannten "Evidenz" $P(X)$ ausdrücken lässt.

Wurde die Schätzung entsprechend dieser Vorschrift aktualisiert und der ursprüngliche Prior $P(\theta)$ durch den Posterior $P(\theta | X)$ ersetzt, so lässt dieses Verfahren jedes Mal wieder anwenden, wenn neue Daten zur Verfügung stehen und so die aktuelle Schätzung für θ aktualisieren. In der Praxis bleibt die Schätzung damit im Zeitverlauf relativ stabil, da unrealistische Parameterschätzungen von vornherein durch eine geeignete Wahl des Priors nur mit einer sehr geringen Wahrscheinlichkeit auftreten können (siehe Abbildung 3).

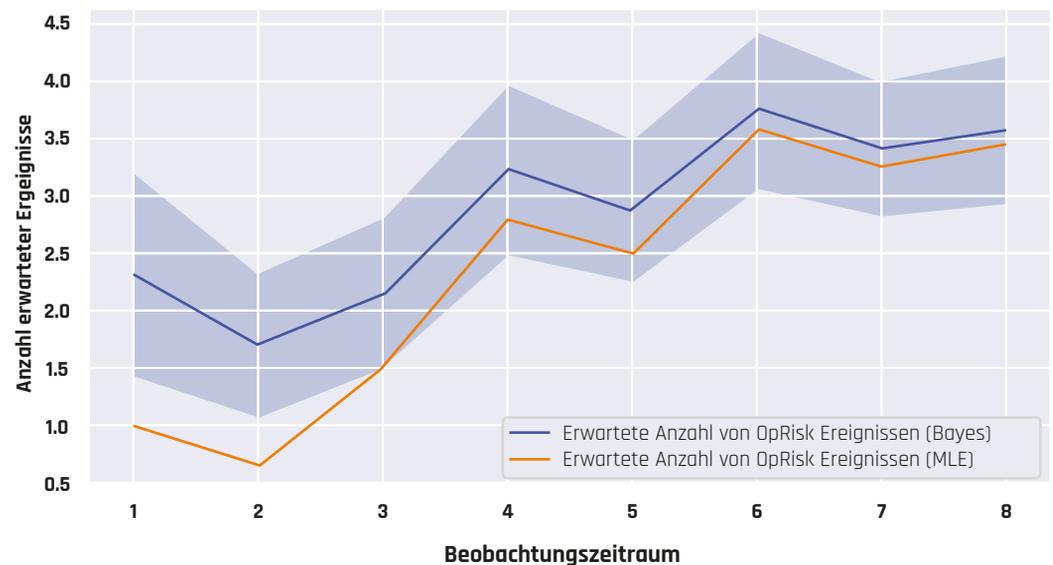


Abbildung 3 - Beispiel für eine Schätzung des Frequenzparameters einer Poisson-Verteilung zur Modellierung von Verlusthäufigkeiten. In den ersten Beobachtungszeiträumen stehen noch wenig, bzw. keine Daten zur Verfügung. Im konkreten Beispiel führt dies bei einem MLE Schätzer zu einer systematischen Unterschätzung der zu erwartenden Anzahl von zukünftigen OpRisk Ereignissen. Im Gegensatz dazu bleibt die Bayessche Schätzung auch in den ersten Beobachtungszeiträumen weitgehend stabil. Zusätzlich kann die Schätzungsunsicherheit ermittelt werden (hier visualisiert durch den hell-blauen Bereich um die Bayessche Schätzung).

Das obige Beispiel bezog sich rein auf die Modellierung und Bestimmung der Ereignishäufigkeiten. Analog kann jedoch auch zur Bestimmung der Verlusthöhenverteilung vorgegangen werden. Beispielsweise würde man im Fall von Lognormal-verteilten Verlusten zwei Priors einführen, d.h. jeweils einen Prior für die Parameter μ und σ , und das obige Vorgehen entsprechend anwenden. Das hier vorgestellte Beispiel stellt natürlich eine Vereinfachung der gängigen OpRisk Modellierungspraxis dar, in der auch Abhängigkeiten zwischen unterschiedlichen OpRisk Ereignisarten berücksichtigt werden sollten. Im Rahmen der Bayesschen Modellierung würde man diese Abhängigkeiten ebenfalls durch geschickte Wahl der A-Priori Verteilungen in das Modell integrieren. Dabei z.B. eingeführte Korrelationen können dann wieder analog zum obigen Vorgehen behandelt und geschätzt werden.

Zusammenfassend ergibt sich also, dass ein Bayesscher Ansatz nicht nur eine stabilere Schätzung operationeller Risiken erlaubt, sondern auch ausreichend Flexibilität bietet, um Expertenmeinungen, interne und externe Daten, sowie konkrete Szenarien methodisch korrekt und nachvollziehbar in einem einzigen Modell zu integrieren, auch im Fall einer nur spärlich vorhandenen Datenbasis. Da Parameter über passende Priors und damit Zufallsvariablen modelliert werden, lassen sich darüber hinaus Modellunsicherheiten auch besser einschätzen.

TECHNISCHE UMSETZUNG UND EINSATZ VON PROBABILISTISCHEN PROGRAMMIERSPRACHEN

Hat man sich nun in der Praxis auf ein stochastisches Modell $P(X | \theta)$ für beobachtete Daten X und Parameter θ festgelegt, besteht die wesentliche Aufgabe in der Bestimmung des Posteriors $P(\theta | X)$ mit Hilfe der Bayesschen Formel ("Bayessche Inferenz"). Leider ist es nur teilweise möglich, hier eine rein analytische Lösung zu bestimmen, so dass passende numerische Algorithmen verwendet werden müssen. Von den drei Bestandteilen $P(\theta | X)$, $P(\theta)$ und $P(X)$ in der rechten Seite der Bayesschen Formel sind lediglich $P(\theta | X)$ und $P(\theta)$ als Modellannahmen gegeben, $P(X)$ ist jedoch unbekannt. Daher wird letzteres via Marginalisierung von θ , d.h.

$$P(X) = \int p(X | \theta) p(\theta) d\theta,$$

allein durch bekannte Größen ausgedrückt (Hier für den Fall kontinuierlicher Zufallsvariablen mit bekannten Dichtefunktionen, analog ergibt sich im diskreten Fall eine Summe statt einem Integral). Die analytische Bestimmung dieses Ausdrucks ist im Allgemeinen nicht mehr möglich. Daher lässt sich der Posterior $P(\theta | X)$ außer in wenigen Spezialfällen nur numerisch und unter dem Einsatz von anspruchsvollen Verfahren approximieren. Insbesondere werden hier üblicherweise sogenannte Markov Chain Monte-Carlo Verfahren eingesetzt.

Auch wenn Bayessche Ansätze in der akademischen Literatur zur Modellierung operationeller Risiken bereits umfassend diskutiert und präsentiert wurden⁵, wurde von einer Umsetzung in der Praxis vermutlich oft abgesehen, da insbesondere die Implementierung von Markov Chain Monte-Carlo Verfahren für Bayessche Inferenz ein hochgradig nicht-triviales Problem darstellt. Aufgrund der rasanten Entwicklung der letzten Jahre im Bereich des Maschinellen Lernens ist es nun jedoch möglich, eine vollständig Bayessche Behandlung operationeller Risiken mit vergleichsweise geringen Aufwänden zu implementieren. Dies wird unter anderem durch sog. Probabilistische Programmiersprachen, wie etwa Stan⁶, PyMC⁷ oder Tensorflow Probability⁸ möglich. Diese stellen zusätzlich zu effizienten Implementierungen von MCMC-Verfahren auch ein umfangreiches Modellierungstoolkit zur Verfügung, was die Entwicklung von Modellen rapide beschleunigen kann. Ferner lassen sich Modelle bereits mit wenigen Zeilen Code in einer Standard-Python-Umgebung implementieren (siehe Abbildung 4). Bei allen drei erwähnten Lösungen handelt es sich ferner um Open Source Software, so dass keine Lizenzkosten anfallen.

5. Siehe z.B. Shevchenko, P.V. and Wüthrich, M.V. (2006) The Structural Modeling of Operational Risk via Bayesian Inference: Combining Loss Data with Expert Opinion. The Journal of Operational Risk, 1, 3-36.

6. <https://mc-stan.org/>

7. <https://www.pymc.io/welcome.html>

8. <https://www.tensorflow.org/probability/>

```

pymc_model = pm.Model()
with pymc_model:

    # Poisson Counts with Gamma Prior
    lambda_prior= pm. Gamma('lambda_prior', 1.0, 1.0)
    C= pm.Poisson('C', mu=lambda_prior, observed=counts_obs)

    # lognormal severity
    mu_prior= pm.Normal('mu_prior', 0, 10.0)
    sigma_prior= pm.Uniform('sigma_prior', 0.0, 10.0)
    severity= pm.LogNormal(
        'L', mu= mu_prior, sigma=sigma_prior, observed=severities_obs)

losses= []
C_pred= pm.Poisson('C_pred', mu=lambda_prior)
for k in range(0, max_events):
    losses.append(pm.LogNormal('L_pred' + str(k),
        mu= mu_prior, sigma=sigma_prior)*(k < C_pred))

```

Abbildung 4 - Beispiel für ein Verlustverteilungsmodell implementiert in Python mit PyMC.

Gerade im Umfeld operationeller Risiken bietet sich damit die Möglichkeit, mit verhältnismäßig geringen Aufwänden auch komplexere Modelle zu entwickeln, beispielsweise mit unterschiedlicher Behandlung von "short" und "long tails" oder expliziter Modellierung von Abhängigkeiten und Korrelationen zwischen unterschiedlichen Ereignisarten. Gleichzeitig bleiben Modelle weiterhin auf einer soliden mathematisch-methodischen Basis, so dass Modellannahmen, -Beschränkungen und -Unsicherheiten transparent und nachvollziehbar dokumentiert werden können.

ZUSAMMENFASSUNG UND AUSBLICK

Eine korrekte und belastbare Modellierung operationeller Risiken ist seit jeher mit erheblichen Herausforderungen verbunden. Die technischen Entwicklungen der letzten Jahre erlaubt es jedoch nun, auch fortgeschrittenere Ansätze wie den hier vorgestellten Bayesschen Ansatz mit vergleichsweise geringen Aufwänden zu implementieren. Vor dem Hintergrund des SAORs und dem damit zunehmendem Fokus auf Säule II bietet sich auch hier allgemein die Chance, bestehende Ansätze grundsätzlich zu überholen, deren methodische Angemessenheit sicherzustellen und aktuelle Innovationen aus dem Maschinellen Lernen unter Einhaltung regulatorischer Vorgaben in interne Prozesse mit aufzunehmen.

Auch werden die meisten Institute auch nicht umhinkommen, das aktive Management operationeller Risiken weiter zu stärken. Hier bietet sich ebenfalls der Einsatz von Methoden aus dem Maschinellen Lernen an, um aus der Vielzahl der zur Verfügung stehenden strukturierten und unstrukturierten Daten frühzeitig Gefahrenindikatoren zu ermitteln und damit Verluste nach Möglichkeit von vornherein zu beschränken.

Bei all diesen und ähnlichen Vorhaben stehen Ihnen unsere Experten selbstverständlich zur Verfügung.

Melden Sie sich bei uns und sprechen Sie mit unseren Experten über dieses spannende Thema. Wir beraten Sie gern, um eine pragmatische und kosteneffiziente Lösung für Sie zu entwerfen. Falls Sie Unterstützung in der praktischen Umsetzung, z.B. beim Backtesting, Datenaufbereitung oder Parameterisierung Ihres OpRisk Modells wünschen, kommen Sie gerne auf uns zu.

Referenzen

1. "Vorschlag für eine Verordnung des Europäischen Parlaments und des Rates zur Änderung der Verordnung (EU) Nr. 575/2013 im Hinblick auf Vorschriften für das Kreditrisiko, das Risiko einer Anpassung der Kreditbewertung, das operationelle Risiko, das Marktrisiko und die Eigenmitteluntergrenze (Output-Floor)", COM(2021) 664 final, 27.10.2021
2. Basel Committee on Banking Supervision, "Basel III: Finalising post-crisis reforms", BCBS 424, December 2017
3. Shevchenko, P.V. and Wüthrich, M.V. (2006) The Structural Modeling of Operational Risk via Bayesian Inference: Combining Loss Data with Expert Opinion. The Journal of Operational Risk, 1, 3-36.
4. https://www.bafin.de/DE/Aufsicht/BankenFinanzdienstleister/Eigenmittelanforderungen/OperationelleRisiken/operationellerisiken_artikel.html
5. BaFin, "Aufsichtliche Beurteilung bankinterner Risikotragfähigkeitskonzepte und deren prozessualer Einbindung in die Gesamtbanksteuerung ("ICAAP") - Neuausrichtung", Mai 2018
6. Bafin, "Entwurf der Änderungsversion zu den Mindestanforderungen an das Risikomanagement - MaRisk", Juni 2022

KONTAKT

Wir helfen unseren Kunden, langfristig wertvolle Ergebnisse zu erzielen.

Die United Consulting Group berät Unternehmen aus den Bereichen Finance, Asset Management und Insurance bei der Umsetzung ihrer wichtigsten Ziele. Sie möchten sich zu Fragestellungen im Bereich Riskomanagement, quantitative Methoden oder Datenanalyse mit den Experten der United Consulting Group austauschen?

Kommen Sie auf uns zu!

AUTOREN

Dr. Andreas Pfadler
Machine Learning Expert, UCG United Consulting GmbH, Frankfurt
andreas.pfadler@ucg.de

Wir bedanken uns herzlich bei Volker Bosserhoff, Raphael Fuchs, Yuri Ivanov und Robert Mach für ihre Beiträge bei der Entstehung dieses Papers



UCG United Consulting Group

Hamburger Allee 33
60486 Frankfurt am Main
Deutschland
kontakt@ucg.de

UCG United Consulting GmbH

Zirkusgasse 7 / 11
1020 Wien
Österreich
kontakt@ucg.at