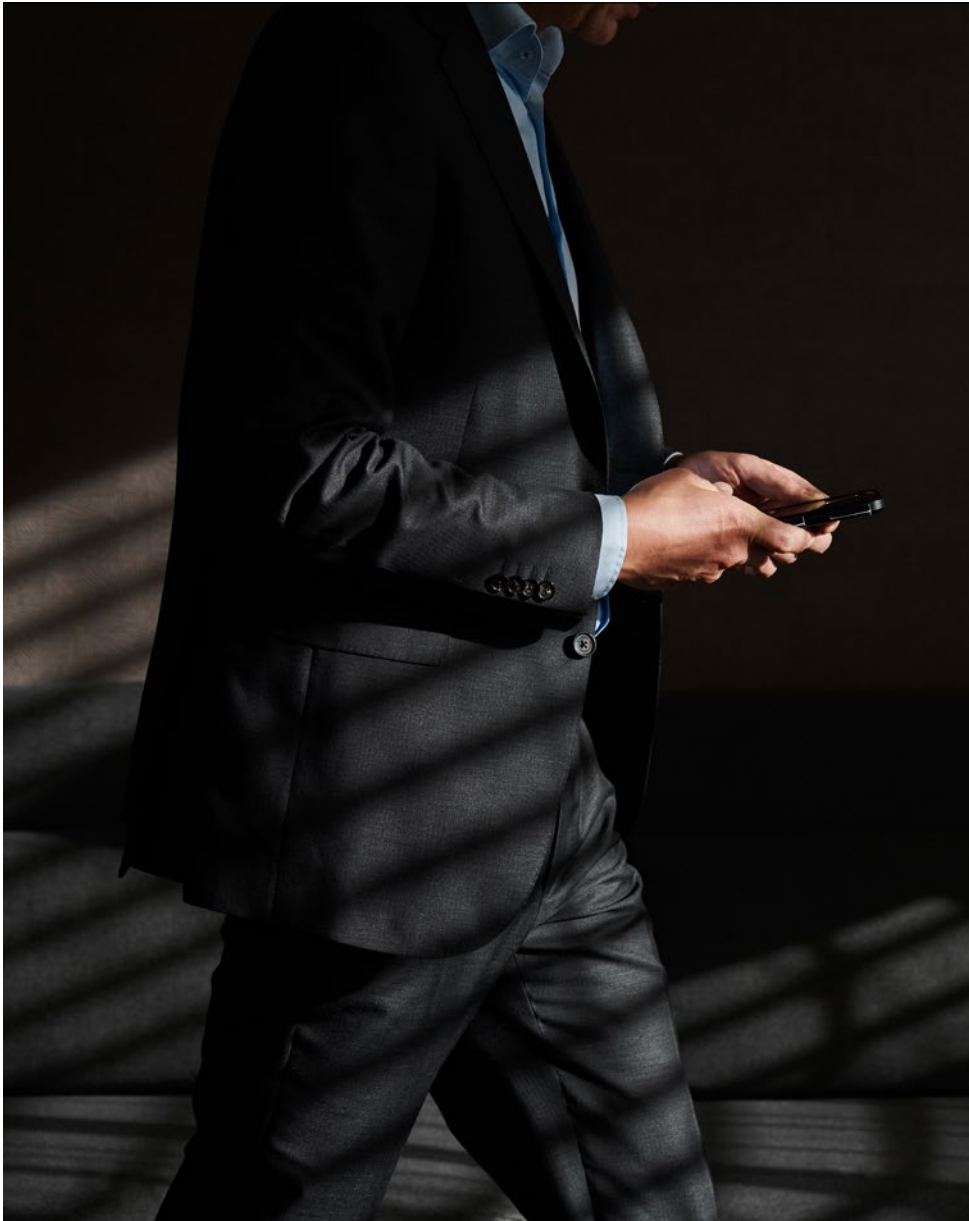


Relevant

News aus der Finanzindustrie



ARTIKEL

Explainable
Artificial Intelligence
Teil 2
Ein Use Case

2

ARTIKEL

DORA, die zweite Tranche
ist veröffentlicht.
Was die finalen Entwürfe
bereithalten.

11

September, 2024

Explainable Artificial Intelligence Teil 2

Ein Use Case

von Dr. Dieter Hierl, Dr. Roland Onderka, Dr. Pouya Kazemi und Dr. Simon Dentinger

Liebe Leserinnen und Leser, wir freuen uns, Ihnen unseren neuen Newsletter zu präsentieren, der an unseren letzten Beitrag über erklärbare künstliche Intelligenz ([Explainable Artificial Intelligence, XAI](#)) anknüpft.

Seit dem letzten Artikel, in dem wir einen allgemeinen Überblick über die Bedeutung und Notwendigkeit von XAI gegeben haben, ist viel passiert. Von besonderem Interesse sind für uns die Entwicklungen im Bereich der Large Language Models (LLMs) und der generativen KI. Obwohl LLMs und generative KI immer bessere Benchmarks erreichen und in Anführungszeichen intelligenter werden, ist ihr Einfluss auf die Industrie, außer in einigen spezifischen Bereichen, nicht so schnell oder grundlegend gewesen, wie es gehyped wurde [\[Link\]](#). Etwa 70% der Unternehmen hatten im Februar 2024 keine oder nur eine begrenzte Nutzung von KI in ihren Unternehmen. Herausforderungen sind Probleme wie Halluzinationen, Kosten, Bias und ethische Bedenken sowie die Schlüsselfaktoren Erklärbarkeit und Regulierung. Aufgrund der zunehmenden Bedeutung der Erklärbarkeit, insbesondere aus regulatorischer Sicht, werden wir in diesem Artikel zeigen, wie man KI erklärbar macht. Konkret werden wir ein Finanzmodell zur Vorhersage steigender Assetpreise mithilfe von AI als Spielwiese verwenden. Insbesondere werden wir die gängigsten XAI-Methoden, SHAP (Shapley Additive exPlanations) und LIME (Local Interpretable Model-agnostic Explanations), darauf anwenden und unsere Erfahrungen sowie die Herausforderungen, denen wir begegnet sind, teilen.

Lassen Sie uns gemeinsam erkunden, wie diese Methoden uns helfen können, die wichtigsten Inputparameter zu identifizieren und somit die Transparenz und Vertrauenswürdigkeit unserer Vorhersagemodelle zu erhöhen.

Überblick über das Finanzmodell

Unser Modell zur Vorhersage von steigenden Assetpreisen basiert auf einem umfassenden Ansatz, der Datenvorverarbeitung, Feature Engineering, Modellentwicklung und Performance-Evaluierung kombiniert. Hier ist eine Zusammenfassung der wesentlichen Schritte und Komponenten des Modells:

Datenbasis und Aufgabenstellung

Wir verwenden Daten von Infineon Technologies AG, einem führenden deutschen Halbleiterhersteller. Die Daten umfassen tägliche OHLC (Open, High, Low, Close) Werte von 2000 bis 2022. Ziel ist es, mit einem LSTM-Modell (Long Short-Term Memory) positive Kursbewegungen am nächsten Tag vorherzusagen und eine Buy-and-Hold-Strategie zu übertreffen.

Datenbeschaffung

Neben den Daten von Infineon beziehen wir auch tägliche OHLC-Daten anderer Halbleiterunternehmen und makroökonomische Indikatoren für Deutschland. Diese zusätzlichen Daten sollen helfen, makroökonomische Trends zu erkennen.

Feature Engineering

- ▶ **Zeitreihen-Features:** Hinzufügen von zeitlichen Merkmalen (Monat, Quartal, Wochentag usw.) und deren Fourier-Repräsentationen.
- ▶ **Technische Indikatoren:** Integration von Volatilitäts-, Momentum- und Trendindikatoren (z.B. ATR, BBANDS, RSI, DPO).

→

- ▶ **Makroökonomische Indikatoren:** Nutzung makroökonomischer Daten (BIP, Arbeitslosenquote, etc.) durch lineare Interpolation.
- ▶ **Lags und Rolling Windows:** Berücksichtigung von verzögerten und gleitenden Mittelwerten sowie EWMA (Exponentially Weighted Moving Average) Funktionen.

Explorative Datenanalyse (EDA)

- ▶ **Korrelationsmatrix:** Entfernung hoch korrelierter Features.
- ▶ **K-Means Clustering:** Gruppierung ähnlicher Zeitreihen und Reduktion der Features auf ein Zehntel der ursprünglichen Anzahl.
- ▶ **Varianzinflationsfaktor (VIF):** Berechnung der Multikollinearität und Beibehaltung von Features mit einem VIF unter 1000.
- ▶ **Feature Transformation:** Nutzung dieser Methoden zur Identifikation der wichtigsten Features. Das Boruta Python Package verwendet einen Random Forest, SHAP Python Package einen Gradient Boosting Classifier.

Insgesamt wurden 190 wesentliche Features identifiziert.

Modellaufbau und Training

- ▶ **Normalisierung und Datenaufbereitung:** Verwendung des `gen_scaler` zur Normalisierung und des `TimeseriesGenerator` zur Datengenerierung.
- ▶ **Baseline-Modell:** Initiales Modelltraining mit anschließender Hyperparameteroptimierung mittels Bayes'scher Optimierung.
- ▶ **Finales Modell** (siehe Abbildung 1): Das finale Modell weist eine Testgenauigkeit von 60.27% auf und ist für eine Long/Short-Strategie geeignet.

Performance-Evaluation und Backtesting

- ▶ **Performance-Metriken** (siehe Abbildung 2): Bewertung des Modells mittels ROC-Kurve, Konfusionsmatrix und weiteren Metriken wie Precision und Recall.
- ▶ **Handelsstrategie:** Anwendung des Modells auf Handelsstrategien, die im Vergleich zu einer Buy-and-Hold-Strategie signifikante Gewinne erzielte.

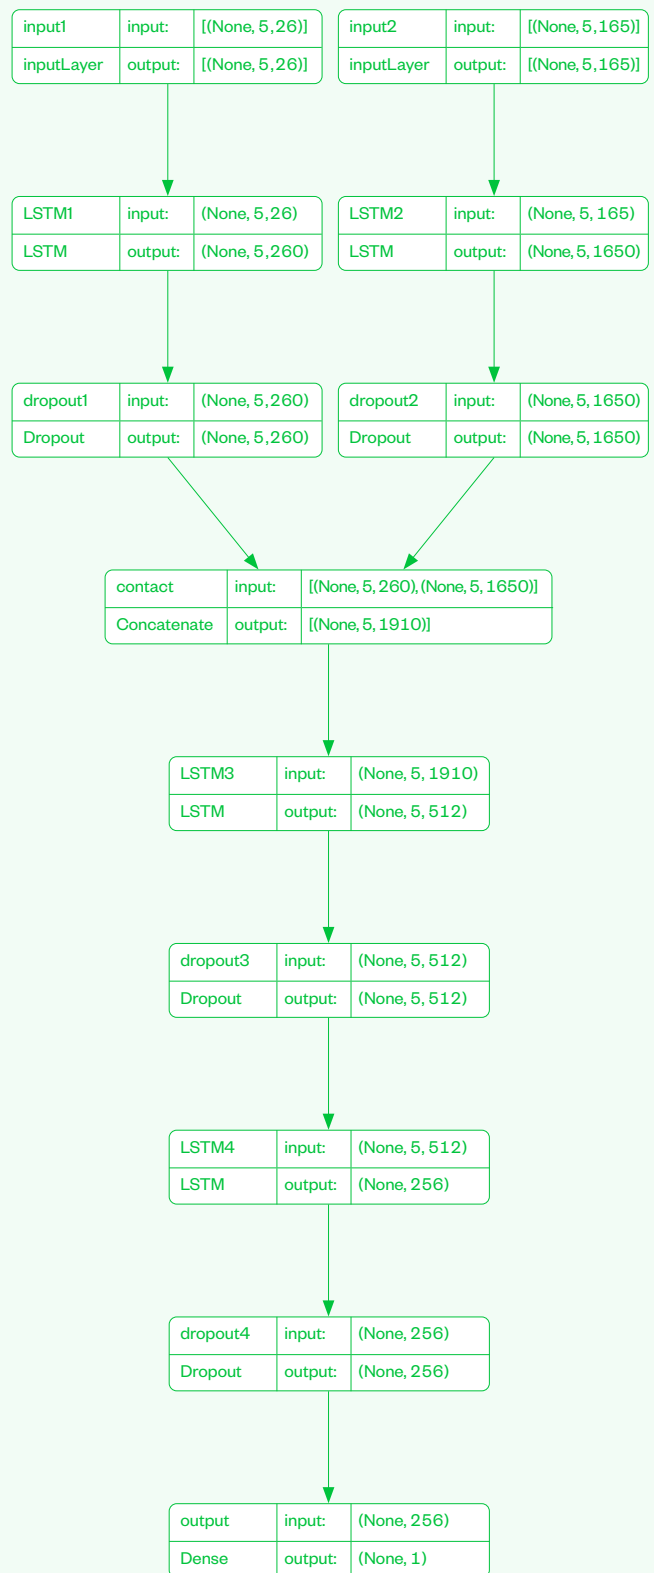
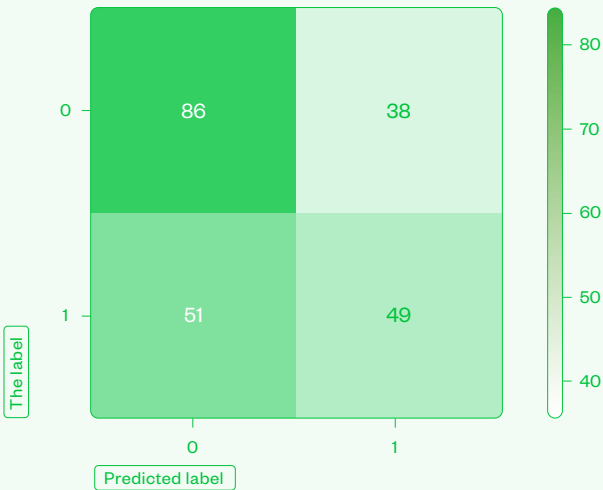


Abb. 1 Das Modell besteht aus zwei Eingaben, die jeweils durch eine LSTM- und Dropout-Schicht gehen, dann zusammengeführt werden und durch weitere LSTM-, Dropout- und schließlich eine Dense-Schicht gehen, um die endgültige Ausgabe zu erzeugen.

—>

Confusion matrix



ROC curve

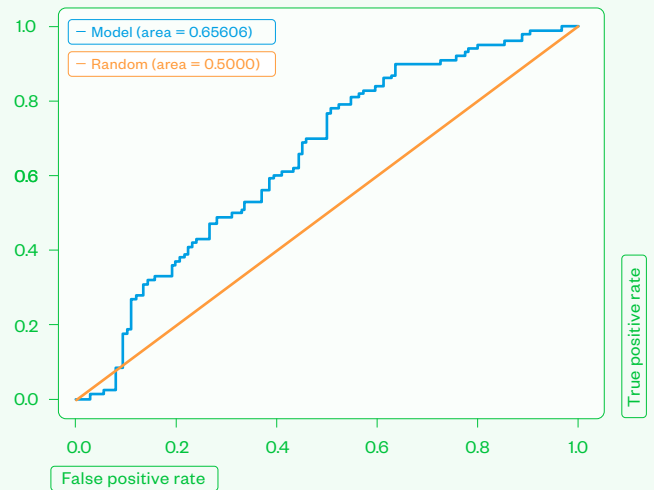


Abb. 2 Die Confusion Matrix gibt einen Überblick über die Verteilung der Vorhersageergebnisse und hilft, die Stärken und Schwächen des Modells in Bezug auf die beiden Klassen zu verstehen. Während False Positives (oben, rechts) nachteilig für eine Long-Strategie sind, verhalten sich die False Negative für eine Short-Strategie nachteilig. Die ROC Curve zeigt, dass das Modell eine gewisse Fähigkeit besitzt, zwischen den Klassen zu unterscheiden, da die AUC über 0.5 liegt. Allerdings ist die Leistung mit einer AUC von 0.6506 noch weit von einem perfekten Modell entfernt. Die ROC-Kurve und die AUC bieten eine visuelle und numerische Methode zur Beurteilung der Klassifikationsleistung des Modells im Vergleich zu einem zufälligen Klassifikator.

Test data with signals




Abb. 3 Hier sind nur die Long-Signale des Modells aufgetragen und die Zeiträume, in denen man nach dem Modell Long sein sollte, hervorgehoben.

Kumulative Summe der Werte

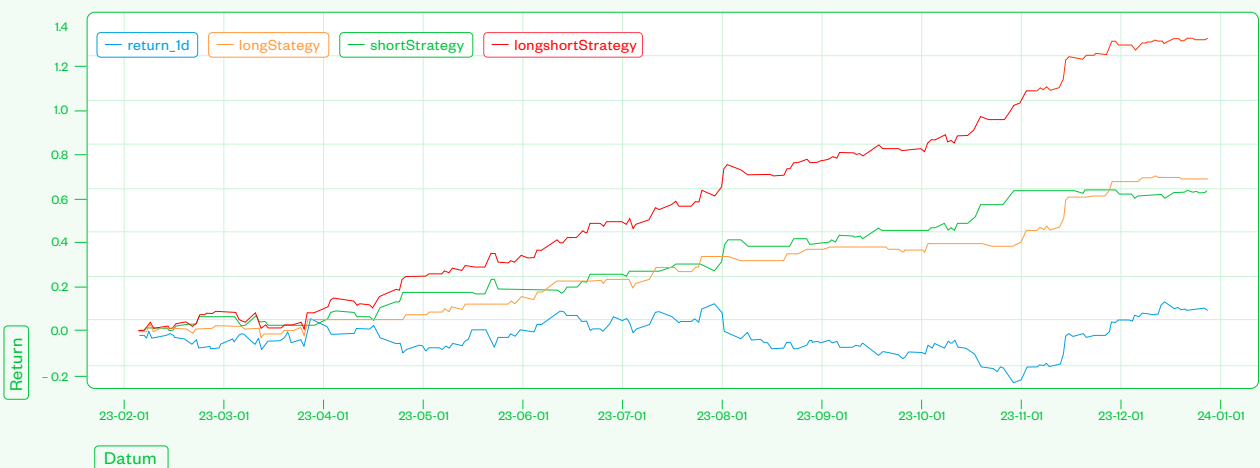


Abb. 4 Zusammenfassung der Returns der verschiedenen Strategien über den Backtestzeitraum. Diese Daten waren dem Modell zuvor nicht bekannt. Die Strategien, die sich auf das Modell stützen erzielten im Vergleich zu einer Buy-and-Hold-Strategie (return_id) sehr gute Ergebnisse.

Das Modell zeigt vielversprechende Ergebnisse bei der Vorhersage von Kursbewegungen und übertrifft eine einfache Buy-and-Hold-Strategie deutlich. Weitere Optimierungen und die Erweiterung auf andere Finanzinstrumente könnten das Potenzial dieses Ansatzes weiter steigern.

Diese umfassende Vorgehensweise stellt sicher, dass unser Modell nicht nur genaue Vorhersagen trifft, sondern auch in der Praxis umsetzbare Handelsstrategien ermöglicht.

Einführung in SHAP und LIME

SHAP (Shapley Additive exPlanations)

SHAP ist eine auf der Spieltheorie basierende Methode, die dazu verwendet wird, die Beiträge einzelner Merkmale zu den Vorhersagen eines Modells zu erklären. Die Methode basiert auf den Shapley-Werten, einem Konzept aus der kooperativen Spieltheorie, welches die faire Verteilung von Gewinnen oder Kosten unter den Beteiligten sicherstellt. Bei der Anwendung auf Machine Learning-Modelle berechnet SHAP den durchschnittlichen Beitrag jedes Merkmals zur Vorhersage, indem es alle möglichen Kombinationen von Merkmalswerten berücksichtigt. Diese Methode ist modellagnostisch, das heißt, sie kann unabhängig von der Art des zugrunde liegenden Modells angewandt werden.

LIME (Local Interpretable Model-agnostic Explanations)

LIME ist eine Methode, die lokale Ersatzmodelle verwendet, um die Vorhersagen eines komplexen Modells zu erklären. Dabei wird ein einfaches, interpretierbares Modell (z. B. lineare Regression) in der Nähe der zu erklärenden Vorhersage trainiert. LIME approximiert das Verhalten des komplexen Modells lokal um die Vorhersage, indem es kleine Veränderungen an den Eingabedaten vornimmt und die Auswirkungen auf die Vorhersage analysiert.

Vergleich von SHAP und LIME

Anwendungsbereich:

- ▶ SHAP: Bietet sowohl globale als auch lokale Erklärungen und ist daher vielseitig einsetzbar.
- ▶ LIME: Konzentriert sich auf lokale Erklärungen und eignet sich gut für die Analyse individueller Vorhersagen.

Rechenaufwand:

- ▶ SHAP: Sehr rechenintensiv, insbesondere für große Datensätze und komplexe Modelle.
- ▶ LIME: Weniger rechenintensiv als SHAP, aber die Genauigkeit kann darunter leiden.

Interpretierbarkeit:

- ▶ SHAP: Liefert intuitive und konsistente Erklärungen basierend auf einem mathematisch fundierten Ansatz.
- ▶ LIME: Bietet einfache und verständliche lokale Erklärungen, die leicht zu implementieren sind.

Robustheit:

- ▶ SHAP: Robust und konsistent aufgrund der Verwendung von Shapley-Werten.
- ▶ LIME: Kann instabiler sein, da die Ergebnisse stark von der Auswahl der lokalen Datenpunkte abhängen.

Beide Methoden haben ihre Stärken und Schwächen und können je nach Anwendungsfall und Zielsetzung ergänzend eingesetzt werden. Während SHAP eine umfassendere und robustere Methode darstellt, bietet LIME eine schnellere und einfachere Möglichkeit, lokale Erklärungen für spezifische Vorhersagen zu liefern.

Vorarbeiten für SHAP und LIME

In unserem Finanzmodell verwenden wir Zeitreihen-Generatoren, um in einer kompakten Art und Weise Trainings-, Validierungs- und Testdaten zusammen mit ihren abhängigen Variablen zur Verfügung zu haben. Diese Datenstruktur muss für den Einsatz in SHAP oder LIME wieder aufgebrochen werden.

Des Weiteren sind unsere unabhängigen Inputvariablen prinzipiell ebenfalls Zeitreihen, die eine gewisse Anzahl von Tagen zurückschauen. SHAP und LIME können aber nicht mit Zeitreihen arbeiten, so dass man die Zeitreihen- und Feature-Dimensionen zunächst in eine gemeinsame Dimension zusammenführen muss, ohne das jeweilige Tracking auf die Feature zu verlieren.



Anwendung von SHAP im Finanzmodell

Die aufbereiteten Inputvariablen werden dem SamplingExplainer des shap Python Pakets übergeben. Der Explainer hat eine Methode zur Berechnung der shap Werte.¹ Dies ist eine sehr Speicher aufwendige und Rechenzeit intensive Aufgabe. Daher haben wir uns auf 10 unserer 112 Batches beschränkt. Als Ergebnis bekommt man im summary_plot von shap folgende Auswertung (in [Abbildung 5](#)).

¹ Die Werte werden nach folgender Formel bestimmt:

$$\phi_i = \sum_{S \subseteq N \setminus \{i\}} \frac{|S|! \cdot (|N| - |S| - 1)!}{|N|!} \cdot [f(S \cup \{i\}) - f(S)]$$

S ist eine Teilmenge der Merkmale N, die nicht i enthält. |S| ist die Anzahl der Merkmale in der Teilmenge S. f(S) ist die Vorhersage des Modells mit den Merkmalen in der Teilmenge S. f(S ∪ {i}) ist die Vorhersage des Modells mit den Merkmalen in S plus dem Merkmal i.

Der Summary Plot für SHAP bietet eine visuelle Darstellung der wichtigsten Merkmale eines Modells und deren Einfluss auf die Vorhersagen. Hier sind die wesentlichen Schritte zur Interpretation des Summary Plots aus [Abbildung 5](#):

Merkmalsbedeutung (Feature Importance)

- ▶ **Vertikale Achse:** Listet die Merkmale (Features) nach ihrer Bedeutung auf. Die Merkmale in der Liste haben den größten Einfluss auf das Modell.
- ▶ **Horizontale Achse:** Zeigt die SHAP-Werte an. Diese Werte repräsentieren den Einfluss des jeweiligen Merkmals auf die Modellvorhersage. Ein positiver SHAP-Wert (SHAP value) bedeutet, dass das Merkmal die Vorhersage erhöht, während ein negativer SHAP-Wert die Vorhersage verringert.

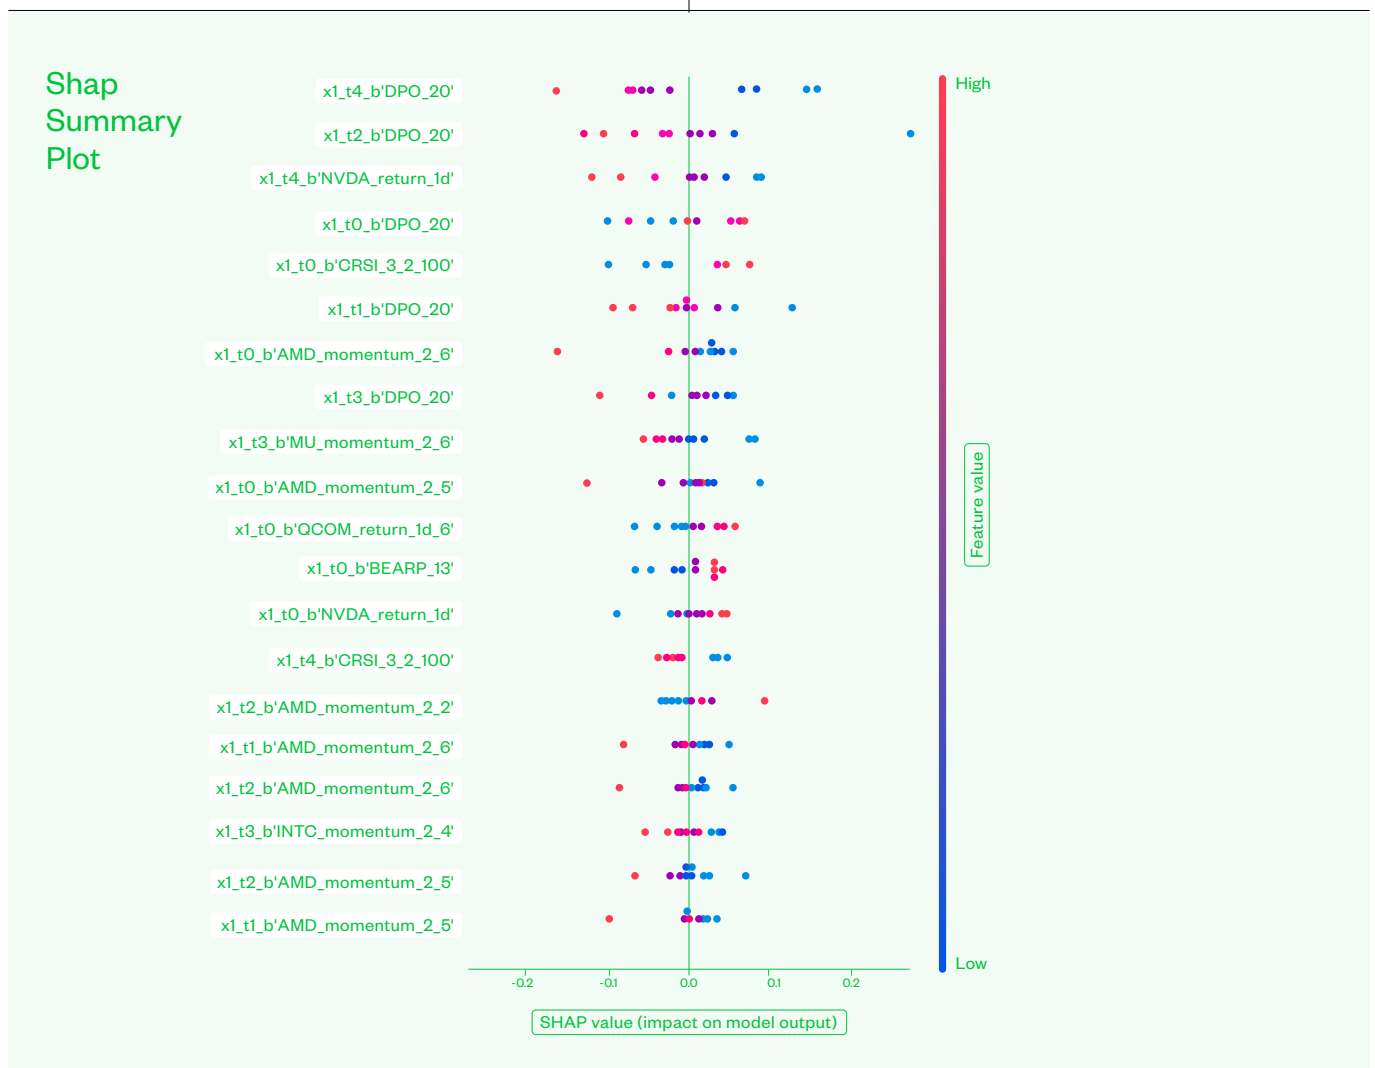


Abb. 5 Der SHAP Summary Plot zeigt, welche Merkmale den größten Einfluss auf die Modellvorhersagen haben und wie diese Einflüsse variieren. Merkmale mit breiterer Verteilung und intensiven Farben (rot und blau) sind besonders wichtig und tragen erheblich zur Entscheidung des Modells bei. Der Plot hilft, die Black-Box-Natur des Modells zu interpretieren und zu verstehen, welche Merkmale die Vorhersagen am stärksten beeinflussen.

Einflussrichtung (Impact Direction)

- **Farben:** Die Punkte sind farbcodiert und repräsentieren die Merkmalswerte. Typischerweise steht Rot für hohe Werte und Blau für niedrige Werte. Diese Farbcodierung hilft zu verstehen, ob hohe oder niedrige Werte eines Merkmals die Vorhersage erhöhen oder verringern.

Dichte der Punkte (Density of Points)

- **Punkte-Wolken:** Die Dichte der Punkte entlang der horizontalen Achse gibt an, wie oft verschiedene SHAP-Werte auftreten. Eine breite vertikale Punktwolke zeigt eine hohe Variabilität im Einfluss des Merkmals an, während eine schmale Punktwolke auf einen gleichmäßigeren Einfluss hindeutet.

Interpretation der Merkmalswerte

- **Hohe Werte (rote Punkte):** Wenn die roten Punkte auf der

Seite mit den positiven SHAP-Werten des Plots konzentriert sind, bedeutet dies, dass hohe Werte dieses Merkmals die Vorhersage erhöhen. Sind sie auf der linken Seite, verringern hohe Werte die Vorhersage.

- **Niedrige Werte (blaue Punkte):** Entsprechend bedeuten blaue Punkte auf der Seite mit positiven SHAP-Werten, dass niedrige Werte die Vorhersage erhöhen, und auf der linken Seite, dass sie die Vorhersage verringern.

Anwendung von LIME im Finanzmodell

Die aufbereiteten Inputvariablen werden dem LimeTabularExplainer des lime Python Pakets übergeben. Da unsere Daten bereits für das Finanzmodell normalisiert wurden, entfällt dieser Aufarbeitungsschritt. LIME analysiert immer nur einen Batch. Dabei wird mit der Methode explain_instance eine instance erzeugt und mit der Methode show_in_notebook lässt sich die Ausgabe in [Abb. 6](#) erzeugen. →



Abb. 6 Die hier gezeigte Zusammenfassung ausgewählter Instances zeigt auf der linken Seite ein Beispiel für einen hohen predicted value und auf der rechten Seite für einen niedrigen predicted value.

Die show_in_notebook-Ausgabe von LIME bietet eine visuelle und detaillierte Darstellung, wie einzelne Merkmale eine spezifische Vorhersage eines Modells beeinflussen. Hier ist eine Anleitung zur Interpretation der show_in_notebook-Ausgabe:

Globale vs. Lokale Erklärungen

- ▶ **Globale Erklärung:** Betrachtet das gesamte Modell und zeigt, welche Merkmale generell am wichtigsten sind.
- ▶ **Lokale Erklärung:** Konzentriert sich auf eine einzelne Vorhersage und zeigt, wie die Merkmale diese spezifische Vorhersage beeinflussen.

Interpretation der einzelnen Komponenten der LIME-Erklärung

Vorhersageinformation (Links)

- ▶ **Modellvorhersage:** Zeigt die genaue Vorhersage des Modells für das betrachtete Beispiel an (in [Abbildung 6](#) sind das die Instances 4 und 9).

- ▶ **Wahrscheinlichkeit:** Wenn das Modell probabilistisch wäre, zeigt es die Wahrscheinlichkeiten für die verschiedenen Klassen an.

Wichtige Merkmale und ihre Einflüsse (Mitte)

- ▶ **Merkmalsliste:** Eine Liste der wichtigsten Merkmale, die die Vorhersage beeinflussen haben.
- ▶ **Balkendiagramm:** Jedes Merkmal ist mit einem Balken dargestellt, der die Richtung und Stärke seines Einflusses auf die Vorhersage zeigt.
 - ▶ **Positive Balken:** Merkmale, die die Wahrscheinlichkeit der vorhergesagten Klasse erhöhen.
 - ▶ **Negative Balken:** Merkmale, die die Wahrscheinlichkeit der vorhergesagten Klasse verringern.
 - ▶ **Balkenlänge:** Die Länge des Balkens entspricht der Stärke des Einflusses des Merkmals auf die Vorhersage.



Abb. 7 Für die gleichen Instances wie in Abbildung 6 sind hier noch einmal die Balkendiagramme aufgeführt.

Merkmalswerte (Rechts)

- ▶ **Merkmalswerte:** Zeigt die tatsächlichen Werte der Merkmale für das betrachtete Beispiel.
- ▶ **Grenzwerte und Intervalle:** Wenn ein Merkmal kategorisch oder binär ist, zeigt LIME die spezifische Kategorie oder den Zustand. Wenn ein Merkmal kontinuierlich ist, zeigt LIME standardmäßig einen Wertebereich oder einen Mittelwert an.

Erfahrungen und Erkenntnisse

Verbesserte Modelltransparenz:

- ▶ Sowohl SHAP als auch LIME haben dazu beigetragen, die Entscheidungsprozesse unserer AI-Modelle transparenter und nachvollziehbarer zu machen. Dies ist besonders wichtig im Finanzsektor, wo Vertrauen und Nachvollziehbarkeit der Modellvorhersagen von großer Bedeutung sind.

Identifikation der wichtigsten Inputparameter:

- ▶ Mit Hilfe von SHAP konnten wir die wichtigsten Einflussfaktoren für unsere Modellvorhersagen auf globaler Ebene identifizieren. Dies hat uns ermöglicht, ein besseres Verständnis für die Haupttreiber der Assetpreise zu entwickeln.
- ▶ LIME hat uns wiederum detaillierte lokale Erklärungen für einzelne Vorhersagen geliefert, was besonders nützlich war, um spezifische Anomalien oder besondere Fälle zu analysieren.

Herausforderungen und Lösungen:

- ▶ Eine der größten Herausforderungen bei der Anwendung von SHAP war der hohe Rechenaufwand, insbesondere bei großen Datensätzen und komplexen Modellen. Durch Optimierungen und den Einsatz spezialisierter Software konnten wir jedoch diese Hürde überwinden.
- ▶ Bei LIME stellten wir fest, dass die Stabilität der Erklärungen variieren kann. Durch sorgfältige Auswahl der lokalen Datenpunkte und Validierung der Ergebnisse konnten wir jedoch zuverlässigere Erklärungen erzielen.

Schlussfolgerung

In diesem Newsletter haben wir uns intensiv mit der Anwendung von erklärbarer Künstlicher Intelligenz (XAI) im Bereich der Finanzmodellierung zur Vorhersage von steigenden Assetpreisen beschäftigt. Durch den Einsatz von SHAP und LIME konnten wir wertvolle Einblicke gewinnen und sowohl die Stärken als auch die Herausforderungen dieser Methoden in der Praxis identifizieren.

Bei Interesse an einem Austausch zu diesem oder ähnlichen Themen rund um die Themen Regulatory Reporting sowie Risiko können Sie sich gerne jederzeit bei den Autoren dieses Artikels melden.



Literaturverzeichnis

Kazemi, Dentinger, Onderka, Hierl (2023),

Explainable Artificial Intelligence: Licht in die Black Box bringen,
[NC Relevant Nr. 31, September 2023](#)

Kursa, M. B. & Rudnicki, W. R. (2010),

Feature Selection with the Boruta Package,
Journal of Statistical Software, 36(11), 1-13,
<https://doi.org/10.18637/jss.v036.i11>

Strumbelj, Erik and Igor Kononenko,

Shapley sampling values,
"Explaining prediction models and individual predictions with feature contributions."
Knowledge and information systems 41.3 (2014): 647-665

Lipovetsky, Stan and Michael Conklin,

Shapley regression values,
"Analysis of regression in game theory approach."
Applied Stochastic Models in Business and Industry 17.4 (2001): 319-330.

Lundberg, Scott (2019),

SHAP (SHapley Additive exPlanations),
<https://github.com/slundberg/shap>.

Pedersen, Thomas Lin, and Michaël Benesty (2019),

lime: Local Interpretable Model-Agnostic Explanations,
<https://CRAN.R-project.org/package=lime>.

Ribeiro, Marco Tulio, Sameer Singh, and Carlos Guestrin (2016),

"Why should I trust you?": Explaining the Predictions of Any Classifier."
In Proceedings of the 22nd ACM SIGKDD International Conference on
Knowledge Discovery and Data Mining, Kdd San Francisco, ca, 1135-44.
New York, NY: Association for Computing Machinery.

Autoren



Dr. Dieter Hierl

+49 171 65 64 76 6^{tel}

dieter.hierl@nagler-company.com



Dr. Roland Onderka

+49 151 61 05 96 18^{tel}

roland.underka@nagler-company.com



Dr. Pouya Kazemi

+49 160 96 77 43 17^{tel}

pouya.kazemi@nagler-company.com



Dr. Simon Dentinger

+49 151 29 19 41 67^{tel}

simon.dentinger@nagler-company.com

DORA, die zweite Tranche ist veröffentlicht. Was die finalen Entwürfe bereithalten.

von Alexander Klug und Sascha Peindl

Die zweite Konsultationsphase ist beendet, und am 17. Juli 2024 wurden nun die finalen technischen Regulierungs-(RTS) und Durchführungsstandards (ITS) sowie Richtlinien der noch ausstehenden Entwürfe veröffentlicht. Dieser Artikel liefert eine Übersicht über die notwendigen Schritte, um für die Anwendung des Digital Operational Resilience Act (DORA) gewappnet zu sein.

Mit 17. Januar 2025 findet die EU-Verordnung 2022/2554, DORA, Anwendung. Nach der Veröffentlichung der ersten Entwürfe Anfang dieses Jahres liefert die zweite Tranche an Entwürfen nun Informationen zu den folgenden Punkten:

1. Zeitliche Richtwerte

für Meldungen von schwerwiegenden Informations- und Kommunikationstechnologie (IKT) bezogenen Vorfällen

2. Schätzung

der jährlichen Gesamtkosten und -verluste verursacht durch schwerwiegende IKT-bezogene Vorfälle

3. Testen

von IKT-Tools, Systemen und Prozessen mittels Threat-Led Penetration Testing (TLPT)

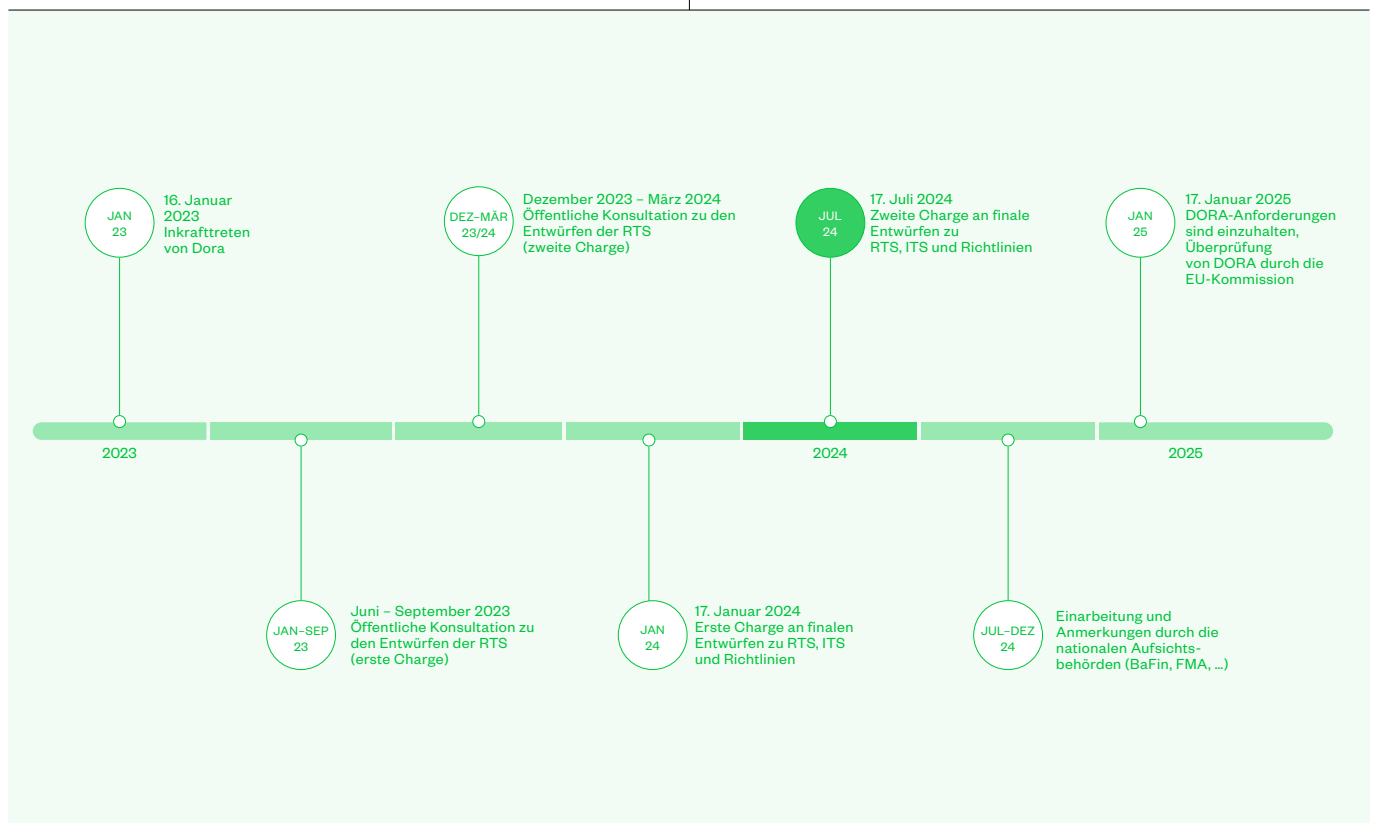


Abb.1 DORA Zeitplan

Etwaige Anmerkungen und detaillierte Ausführungen der nationalen Aufsichtsbehörden (BaFin, FMA, ...) werden in Anlehnung an die Veröffentlichungen der ESAs erwartet. Der zeitliche Horizont für die Entwicklung und Implementierung erfordert eine Fokussierung auf noch offene Punkte, um den DORA Zeitplan [3](#) (siehe [Abbildung 1](#)) fristgerecht einhalten zu können.

Meldungen von schwerwiegenden IKT-bezogenen Vorfällen

Schwerwiegende IKT-bezogene Vorfälle sind direkt an die zuständigen Behörden zu melden. Ausschlaggebend sind die Kriterien zur Klassifizierung eines IKT-bezogenen Vorfalls. Diese wurden bereits in der ersten Tranche definiert und beinhalten die folgenden Differenzierungen:

- ▶ System (kritisch oder unkritisch)
- ▶ Kunden, finanzielle Gegenparteien und Transaktionen
- ▶ Datenverlust
- ▶ Auswirkungen auf den Ruf
- ▶ Dauer des Vorfalls und Ausfallzeit des Services
- ▶ Geografische Verteilung
- ▶ Wirtschaftliche Auswirkungen

Neu in der Tranche 2 werden zeitliche Komponenten für die Übermittlung von relevanten Vorfällen vorgegeben. [Abbildung 2](#) zeigt, wann die einzelnen Berichte zu erfolgen haben. [1](#)

Um die Einheitlichkeit und Verständlichkeit der einzelnen Berichte aufrechtzuerhalten, wurde der konkrete Inhalt sowie entsprechende Vorlagen von den europäischen Aufsichtsbehörden festgelegt.

→



[Abb. 2](#) Zeitliche Richtwerte zur Meldung IKT-bezogener Vorfälle

Schätzung der Bruttokosten und -verluste

Auf Anfrage der zuständigen Behörden müssen Finanzinstitute eine Schätzung über die aggregierten jährlichen Kosten und Verluste, verursacht durch schwerwiegende IKT-bezogene Vorfälle, innerhalb des angeforderten Referenzjahres liefern. Dieses Referenzjahr kann hierbei vom jeweiligen Finanzinstitut festgelegt werden. Das Referenzjahr kann somit dem abgeschlossenen Kalenderjahr oder dem abgeschlossenen Rechnungsjahr entsprechen. Zur Abschätzung der Kosten und Verluste, wurden von den europäischen Aufsichtsbehörden, die nachfolgenden Schritte definiert:

- ▶ **a. Schätzung der Kosten und Verluste** jedes schwerwiegenden Vorfalls. Dabei ist zwischen direkten und indirekten Kosten und Verlusten zu unterscheiden.
- ▶ **b. Schätzung von finanziellen Rückflüssen**, welche unabhängig und zeitlich getrennt in Bezug auf den schwerwiegenden IKT-bezogenen Vorfall zufließen.
- ▶ **c. Konsolidierung der Ergebnisse** aus den Punkten 1 und 2 für alle schwerwiegenden IKT-bezogenen Vorfälle.

Die Basis der Berechnung liefern hier die Kosten, Verluste und finanziellen Rückflüsse aus den Bestandteilen des Jahresabschlusses, wie beispielsweise die GuV des Referenzjahres. Für die Übermittlung dieser Schätzung bei der jeweiligen zuständigen Behörde liefern die europäischen Aufsichtsbehörden eine entsprechende Vorlage.

Threat-Led Penetration Testing

Um die IKT-Tools, Systeme und Prozesse, welche rund um das DORA-konforme IKT-Risikomanagement eingesetzt oder neu eingeführt werden, ordnungsgemäß zu testen, liefern die neuesten Entwürfe Standards auf der Grundlage von Threat-Led Penetration Testing (TLPT) in Übereinstimmung mit dem TIBER-EU-Rahmen. TIBER-EU ist ein Rahmenwerk zum Testen und zur Verbesserung der Cyber Resilienz verschiedener Organisationen durch die Durchführung kontrollierter Cyberangriffe. Während Tests auf Basis des TIBER-EU Rahmens auf freiwilliger Basis durchgeführt werden können, ist TLPT im Zuge von DORA für ausgewählte Finanzinstitute verpflichtend. Wie der TIBER-EU Rahmen, basiert TLPT ebenso auf der Nachbildung der Taktiken, Techniken und Verfahren realer Akteure (Red Team Test), um so die Auswirkungen auf kritische Systeme von Finanzinstituten zu ermitteln.

Die Hauptunterschiede zwischen TLPT und dem TIBER-EU-Rahmen lassen sich wie folgt darstellen:

- ▶ Im Zuge von TLPT kann nicht nur eine national zuständige Behörde für alle zugehörigen Aufgaben verantwortlich sein, sondern einzelne Aufgaben können von unterschiedlichen Behörden übernommen werden.
- ▶ Einzelne Finanzinstitute fallen in die Zuständigkeiten europaweiter Behörden, wie Kreditrating-Agenturen in die der ESMA oder als bedeutsam gewertete Kreditinstitute in jene der EBA.
- ▶ Im Gegensatz zu TIBER-EU, welches die Verwendung von externen Testern vorschreibt, können für TLPT auch interne Tester verwendet werden.
- ▶ Zusätzlich zu den allgemeinen Testroutinen sind für TLPT auch Kollaborations-Übungen der unterschiedlichen Akteure und Teams vorgesehen (Purple Team Übungen).

Durch DORA sieht die BaFin das Rahmenwerk von TIBER-DE als nunmehr verpflichtend an. ⁽³⁾ Eine Anpassung für TIBER-EU sowie der nationalen Umsetzungen (TIBER-AT) wurde bereits von der EIOPA ⁽³⁾ als auch der FMA ⁽⁵⁾ angekündigt und wird voraussichtlich bis Ende des Jahres erfolgen. Ziel ist es, eine Angleichung an die TLPT-Anwendungen umzusetzen. Die verschiedenen am TLPT beteiligten Personen und Teams sowie der Ablauf können den RTS ⁽³⁾ entnommen werden.

Um Details hinter der Meldung von schwerwiegenden IKT-bezogenen Vorfällen, der Schätzung der Kosten und Verluste, verursacht von diesen Vorfällen, sowie zu TLPT genauer zu beleuchten, werden wir in den nächsten Wochen jeweils einen eigenständigen Artikel veröffentlichen.

Dies erfolgt anhand der angesprochenen technischen Regulierungs- und Durchführungsstandards, um Ihnen ein möglichst genaues Bild der Anforderungen liefern zu können.

Neben den zuvor genannten Punkten schreibt DORA auch die Aufstellung eines Informationsregisters für IKT-Drittanbieter vor. Um die Finanzinstitute bestmöglich bei der Umsetzung aller DORA-Vorgaben zu unterstützen, führen die europäischen Aufsichtsbehörden einen „Dry Run“ durch. Finanzinstitute konnten auf freiwilliger Basis ein Informationsregister anhand der bereitgestellten Vorlagen einreichen und erhalten im Zuge des „Dry Runs“ Feedback hinsichtlich der Datenqualität von den europäischen Aufsichtsbehörden. Zum Abschluss im Dezember 2024 soll ein entsprechender Bericht zur Datenqualität veröffentlicht werden.

—>

Wir bei Nagler & Company arbeiten seit Jahren für Banken, Versicherungen und Vermögensverwalter. Unsere Projekterfahrung reicht von der Automation über die Optimierung von Datenbanken und Schnittstellen bis hin zur Prozessgestaltung sowie der fachlichen Unterstützung in übergreifenden Projektstätigkeiten.

Wenn wir Sie als verlässlicher Partner bei Ihrem Projekt unterstützen können, oder Sie weitere Fragen zu diesem oder verwandten Themen haben, freuen wir uns auf Ihre Kontaktaufnahme.

Autoren



Alexander Klug

+43 676 94 83 73 0 ^{tel}

alexander.klug@nagler-company.com



Sascha Peindl

+43 676 95 30 64 0 ^{tel}

sascha.peindl@nagler-company.com

Literaturverzeichnis

①

https://www.eiopa.europa.eu/document/download/Odfbccfd-97b2-4076-9644-b5cf4566f06f_en?filename=JC%202024-33%20-%20Final%20report%20on%20the%20draft%20RTS%20and%20ITS%20on%20incident%20reporting.pdf

②

https://www.eiopa.europa.eu/document/download/9f9d0023-6667-4985-a7fd-b7b3d9f6e0d9_en?filename=JC%202024-29%20-%20Final%20report_DORA%20RTS%20on%20TLPT.pdf

③

https://www.eiopa.europa.eu/digital-operational-resilience-act-dora_en

④

https://www.bafn.de/SharedDocs/Veroeffentlichungen/DE/Fachartikel/2024/fa_bj_2402_DORA.html

⑤

<https://www.fma.gv.at/tiber-at/>

N&C RELEVANT, die Know-how News von Nagler & Company, informieren Sie über aktuelle Fragestellungen in der Finanzindustrie. Nagler & Company ist als mittelständisches Beratungshaus seit mehr als 25 Jahren auf die komplexen Aufgaben der Finanzindustrie spezialisiert. Unsere Consultants können Technologien einschätzen und sind mit den regulatorischen Rahmenbedingungen vertraut. Sie sind sicher im Umgang mit den mathematisch-quantitativen Anforderungen. Sie gestalten und optimieren Prozesse sowie Datenströme und Datenmodelle. Kurz – sie verstehen ihr Handwerk. Ohne Überheblichkeit. Auf Augenhöhe.

HERAUSGEBER

Dr. Nagler & Company GmbH
Hauptstraße 9
92253 Schnaittenbach

+49 9622 71 97 30 ^{tel}
+49 9622 71 97 50 ^{fax}

office@nagler-company.com
www.nagler-company.com

Wenn Sie Ihre E-Mail-Adresse
ändern oder unseren
Newsletter abbestellen wollen,
können Sie dies direkt auf
unserer Website vornehmen.