

Relevant

News aus der Finanzindustrie



ARTIKEL

Explainable Artificial Intelligence: Licht in die Black Box bringen

2

ARTIKEL

Effiziente Datenanalyse in der Finanzwelt: Atoti als leistungsstarkes Werkzeug

9

September, 2023

Explainable Artificial Intelligence: Licht in die Black Box bringen

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

Einleitung

Bei Themen wie dem Einsatz von Methoden künstlicher Intelligenz denkt man sicher nicht in erster Linie an Unternehmen aus der Finanzbranche. Aber häufig sind es gerade Finanzinstitute, die neue und hochmoderne Technologien wie z. B. künstliche Intelligenz (KI) früh übernehmen, was vor allem auf die stark wettbewerbsorientierte Natur der Finanzmärkte zurückzuführen ist, in denen sie agieren.

Zudem gibt es auf der regulatorischen Seite ständig steigende Anforderungen an diese Institute, wie beispielsweise die schnell wachsenden Basel Anforderungen für Banken und die Solvency II Anforderungen in der Versicherungsbranche, die sie dazu zwingen, ihren Technologiebedarf zu überdenken und zu modernisieren.

An der Technologiefrente haben sich diese Institute daher zunehmend in datengetriebene Unternehmen verwandelt, die eine Reihe von fortschrittlichen Tools nutzen, wie z. B. Data Warehouses (DWHs), Cloud-Technologien [NC], maschinelle Lernalgorithmen (MLAs) [NC], Automatisierungstools [NC], Customer-Relationship-Management (CRM) und Enterprise-Resource-Planning (ERP) Tools.

Die vielversprechendste und doch zugleich am schwersten fassbare dieser Technologien, die Finanzinstitute in vielerlei Hinsicht verbessern könnte, ist jedoch zweifellos die KI (englisch Artificial Intelligence (AI)). Obwohl KI-Methoden revolutionär sind, gelten sie im Allgemeinen doch als Black Box. In diesem Artikel wollen wir zeigen, dass KI nicht unbedingt immer eine Black Box sein muss, sondern dass die Entscheidungsprozesse der KI-Algorithmen transparenter gestaltet werden können und damit eine regelkonforme, vertrauenswürdige und erkenntnisgetriebene KI-Entwicklung und -Nutzung ermöglichen.

Ein zentraler Punkt der Regulierung von KI seitens der Aufsichtsbehörden ist ebenfalls die Transparenz und Nachvollziehbarkeit der komplexen KI-Modelle. Ein Beispiel hierfür ist der neue EU AI Act der Europäischen Union (EU). ¹

Um einen Überblick über die möglichen Vorteile von KI in der Finanzbranche zu geben und zu zeigen, wie KI in der Finanzindustrie aktiv und regelkonform genutzt werden kann, haben wir diesen Artikel in folgende Abschnitte unterteilt.

Nach einer Übersicht von bereits im Einsatz befindlichen KI Use-Cases in der Finanzbranche, stellen wir die bevorstehenden Herausforderungen für die Umsetzung von KI-Systemen durch den neuen KI-regulatorischen Rahmen, der von der EU vorgeschlagen wurde, vor und zeigen im letzten Abschnitt einige Techniken, um KI-Methoden erklären und diese Herausforderungen bewältigen zu können.

Anwendungsfälle von KI in der Finanzindustrie

Schon vor dem Hype um Chat-GPT hatten KI-Anwendungsfälle viele Bereiche moderner Finanzinstitute durchdrungen, von Back- bis Front-Office und von der Unterstützung operativer Tätigkeiten bis hin zu strategischen Themen sowie Entscheidungsfindung. Einige der bedeutendsten Anwendungsfälle in der Finanzbranche sind in [Tabelle 1](#) detailliert dargestellt.

→

Anwendungsfall und Beispiel	Beschreibung
Chatbots Sparkassen seit 2020 mit 200.000 gestellten Fragen pro Monat	Sofortige Antworten auf Kundenanfragen, Erleichterung grundlegender Transaktionen, Bereitstellung personalisierter Empfehlungen. Verbessert die Kundenzufriedenheit, verkürzt Reaktionszeiten, bietet rund um die Uhr Support.
Vermeidung von Abwanderungen (churn prevention) HSBC und UBS	Analysiert Kundenverhalten und Transaktionsdaten, um Anzeichen einer Abwanderung zu erkennen. Geht auf Bedenken ein und bietet personalisierte Strategien an, um Abgänge zu reduzieren und die Kundenbindung zu erhöhen.
(Halb-)Automatische Entscheidung für Marktanlagen JPMorgan Chase, Bank of America, Goldman Sachs, Morgan Stanley	Ermöglicht (halb-)automatische Entscheidungsprozesse, nutzt fortschrittliche Algorithmen und Datenanalysen, um Anlagestrategien zu optimieren und fundierte Entscheidungen voranzutreiben.
KI-verbesserte Prozessautomatisierung Deutsche Bank seit 2023	Optimiert sich wiederholende Aufgaben und Arbeitsabläufe, z. B. Dateneingabe, Dokumentenverarbeitung, behördliche Berichterstattung. Verbessert die betriebliche Effizienz, reduziert Fehler und setzt Personalressourcen frei.
Kreditwürdigkeitsprüfung ING Bank seit 2018	Nutzt verschiedene Datenquellen, einschließlich Finanzhistorie und Verhaltensmuster, um Kreditwürdigkeit einzuschätzen. Erhöht Genauigkeit, beschleunigt Bewertungsprozesse und verbessert Kreditvergabeverfahren.
Risiko-, Betrug- und Anomalieerkennung Citigroup, HSBC, Deutsche Bank	Ermöglicht erweiterte Risiko-, Betrugs- und Anomalieerkennung zur schnellen Identifizierung, Eindämmung und Abwehr von Bedrohungen, um Integrität und Sicherheit der Finanzgeschäfte zu gewährleisten.
Persönliche Finanzen Wells Fargo	Bietet zugeschnittene Empfehlungen und Ratschläge aufgrund finanzieller Ziele, Ausgabegewohnheiten und Risikoprofil einer Person. Befähigt Kunden, ihre Finanzen effektiv zu verwalten und ihre finanziellen Ziele zu erreichen.
Marketing BBVA	Nutzt Kundendaten und Verhaltensanalysen, um gezielte Kampagnen zu erstellen, Nachrichten zu personalisieren und Marketingstrategien zu optimieren. Verbessert Kundenbindung, Konversionsraten und Marketing-ROI.

Tab.1 Anwendungsfälle von KI in der Finanzbranche

Daneben gibt es noch viele andere Anwendungsfälle, die sich in den Anfangsstadien der Entwicklung befinden. Bisher hat die fehlende regulatorische Klarheit es den meisten KI-Tools ermöglicht, fast widerstandsfrei live zu gehen. Doch die sich verändernde regulatorische Landschaft erfordert mehr Transparenz im Entscheidungsprozess von KI-Anwendungen und zwingt Entwickler, bestimmte Standards einzuhalten. Im folgenden Abschnitt werfen wir daher einen kurzen Blick auf den EU AI Act.

Erste ganzheitliche Regulierung von KI: EU AI Act

KI-Techniken wie Large Language Models (LLMs) und Generative Pre-Trained Transformers (GPTs) haben das Potenzial, Aufgaben zu automatisieren, die Entscheidungsfindung zu verbessern und Wettbewerbsvorteile zu schaffen. Das volle Ausmaß ihres Einflusses und ihrer disruptiven Kraft auf unsere Gesellschaft ist jedoch noch unbekannt, was auch in der inhärenten Undurchsichtigkeit der KI-Tools begründet ist. Zudem fehlt in der Finanzbranche noch weitgehend ein regulatorischer Rahmen für KI. Um dieses Problem anzugehen, ergreift die EU entschlossene Maßnahmen mit der Einführung des EU AI Act, der bis Ende 2023 abgeschlossen sein soll. ⁽²⁾

Gemäß dem EU AI Act werden Tools basierend auf der KI-Funktionalität in drei Risikogruppen eingeteilt. Diese Risikogruppen sind inakzeptables Risiko, hohes Risiko und begrenztes Risiko. ⁽³⁾ Ein Beispiel für die Kategorie des inakzeptablen Risikos wäre ein von der Regierung betriebenes Social-Scoring-Tool. In die Gruppe des hohen Risikos fallen weit verbreitete CV-Scanning- oder Kreditbewertungsalgorithmen. Jede Gruppe hat ihre eigene Regelung. Wichtig zu beachten ist, dass sowohl der Nutzer als auch der Anbieter solcher Tools von diesem Gesetz betroffen sind. Trotz all dieser Entwicklungen ist es dennoch nicht einfach, KI zu beherrschen. Wie Tristan Harris vom Center for Humane Technology es ausdrückt: ⁽⁴⁾

„... mit einer neuen Technologie entdecken wir eine neue Klasse von Verantwortung. Wir brauchten das Recht auf Vergessenwerden nicht, bis Computer sich an uns für immer erinnern konnten, und wir brauchten das Recht auf Privatsphäre in unseren Gesetzen nicht, bis Kameras massenproduziert wurden.“

In diesem Sinne ist KI nicht anders und das Ziel ist es, diese neuen Klassen von Verantwortlichkeiten zu identifizieren, ohne Innovationen zu ersticken. Angesichts dieser Entwicklungen werden wir im folgenden Abschnitt einige Methoden

vorstellen, die hilfreich sind, um den Entscheidungsprozess der KI zu verstehen, und damit ihre Transparenz zu erhöhen.

Explainable AI

Die Methoden, die KI erklärbar machen, können unter dem Begriff Explainable AI¹ (XAI) zusammengefasst werden. Diese Techniken können überall dort angewendet werden, wo KI präsent ist, und bieten wertvolle Lösungen, um verschiedene Herausforderungen im gesamten KI-Entwicklungszyklus zu bewältigen. Die Herausforderungen umfassen dabei sowohl ethische Bedenken wie Voreingenommenheit, Fairness und Datenschutz, als auch technische Fragen in Bezug auf Datenqualität, Training, Verbesserung und Debugging.

XAI dient einem umfassenden Satz von Zielen. Ausgehend von wissenschaftlichen Quellen ⁽³⁾ ⁽⁵⁾ ⁽⁶⁾ haben wir sechs Schlüsselaspekte identifiziert, die in [Abbildung 1](#) dargestellt sind. Transparenz bedeutet, dass Menschen in der Lage sind, die inneren Abläufe des Systems zu verstehen. Vertrauenswürdigkeit wird erreicht, indem Erklärungen für die Entscheidungen und Handlungen der KI gegeben werden. Interpretierbarkeit stellt sicher, dass Fachexperten die Gründe für bestimmte Entscheidungen oder Handlungen nachvollziehen können.

Diese Aspekte erleichtern die menschliche Aufsicht, etablieren Mechanismen zur Fehlerberichterstattung und -korrektur, fördern die Rechenschaftspflicht und die Einhaltung ethischer und rechtlicher Standards. Schließlich ermöglicht ein tiefes Verständnis der KI schrittweise Verfeinerungen und Verbesserungen, erhöht die Skalierbarkeit und die potenzielle Anwendbarkeit auf benachbarte Bereiche. Lassen Sie uns einen Blick auf verschiedene Strategien werfen, um ML und KI interpretierbar zu machen.

—>

¹ Auch bekannt als Interpretable Machine Learning



Abb.1 Ziele von XAI

Strategien zur Verbesserung der Interpretierbarkeit von ML-Algorithmen können grob in zwei Hauptansätze unterteilt werden: intrinsische und post-hoc. ⁽⁷⁾ Zusätzlich gibt es aus Anwendungssicht zwei verschiedene Perspektiven: modellspezifisch und modellagnostisch. ⁽⁷⁾ Der Anwendungsbereich dieser Methoden umfasst sowohl die lokale als auch die globale Interpretierbarkeit, siehe [Tabelle 2](#).

Modell	Methode	Anwendungsbereich
Intrinsisch	Modellspezifisch	Lokal
Post-hoc	Modellagnostisch	Global

Tab. 2 Klassifizierung der XAI-Methoden

Im Folgenden werden wir kurz intrinsische modellspezifische und post-hoc modellagnostische Methoden vorstellen, da diese die einfachsten zu interpretierenden und damit die vielversprechendsten Methoden zur Bewältigung der Herausforderungen des EU AI Acts sind.

Intrinsische XAI-Ansätze konzentrieren sich auf die Nutzung der Modellinterna und setzen Techniken ein, um proaktiv die Komplexität des Modells zu begrenzen. So kann beispielsweise in einer polynomialen Regression die Anzahl der Merkmale oder der Grad der zulässigen Polynome einschränkt werden, um die Erklärungsfreundlichkeit zu fördern. Diese Methoden sind modellspezifisch, da jedes Modell seine eigenen technischen Überlegungen erfordert.

Auf der anderen Seite arbeiten post-hoc-Methoden mit vortrainierten Algorithmen und bestimmen die Wichtigkeit von Merkmalen, indem z. B. der Wert eines Merkmals verändert und die Auswirkung auf das Ergebnis beobachtet wird. Auf diese Weise kann die Wichtigkeit jedes Merkmals abgeleitet werden. Diese Methoden sind modellagnostisch und können je nach ihrem jeweiligen Geltungsbereich weiter in lokale und globale Ansätze unterteilt werden. ⁽⁷⁾

[Tabelle 3](#) gibt einen Überblick über die für XAI verfügbaren Methoden. Auf einige dieser Techniken gehen wir im Folgenden näher ein.

→

Anwendungsbereich	Beschreibung	Stärke	Methoden
Lokal	Bietet Erklärungen für individuelle Vorhersagen des Modells, indem es den Beitrag jedes Eingabemerkmals in der Umgebung des ausgewählten Datenpunkts hervorhebt.	Beschreibung der individuellen Vorhersagen eines Modells.	— LIME — SHAP
Global	Analysiert das durchschnittliche Verhalten des Modells, um die Bedeutung verschiedener Merkmale im gesamten Datensatz zu ermitteln.	Bestimmung der Gesamtwichtigkeit der Merkmale.	— partial dependence plot — Permutation Feature importance, — accumulated local effects — permutation feature

Tab. 3 Klassifizierung von modellagnostischen XAI-Methoden

Intrinsisch interpretierbare, modellspezifische Methoden

Wie bereits erwähnt, verfügen intrinsisch interpretierbare Modelle über eingebaute Mechanismen, die die Anpassung der Modellkomplexität erleichtern. Die Schlüsselmodelle für intrinsische Interpretierbarkeit umfassen lineare Regression, logistische Regression, verallgemeinerte lineare Modelle und Entscheidungsbäume.

Zum Beispiel kann im Falle von linearen Modellen verschiedene Techniken angewendet werden, um die Interpretierbarkeit zu verbessern, einschließlich, aber nicht beschränkt auf:

- ▶ **1. Merkmalsauswahl:** Auswahl einer Teilmenge relevanter Merkmale, die einen signifikanten Beitrag zu den Vorhersagen des Modells leisten, z.B. durch Nutzung von K-Mean oder selbstorganisierenden Karten. Dies hilft, das Modell zu vereinfachen, die Leistung und seine Erklärbarkeit zu verbessern.
- ▶ **2. Koeffizientenanalyse:** Durch Analyse der Koeffizienten des linearen Regressionsmodells kann man den Einfluss jedes Merkmals auf das prognostizierte Ergebnis verstehen. Positive oder negative Koeffizienten zeigen die Richtung und das Ausmaß des Einflusses an.

Post-hoc modellagnostische Methoden

Trotz ihrer breiten Anwendbarkeit erfordern modellagnostische Methoden eine sorgfältige Überlegung hinsichtlich ihrer Generalisierungsfähigkeiten. Diese Methoden können mit jedem Maschinenlernmodell verwendet werden, unabhängig von seiner zugrunde liegenden Architektur oder Komplexität.

(7) (8)

Betrachten wir zwei prominente lokale modellagnostische Methoden:

- ▶ **1. LIME (Lokale Interpretierbare Modellagnostische Erklärungen):** (8) LIME bestimmt die Merkmalswichtigkeit, indem es intrinsisch interpretierbare Modelle, wie lineare Approximationen, in der Nähe einer Entscheidungsgrenze nutzt. Es erstellt lokale Ersatzmodelle, die das Verhalten des ursprünglichen komplexen Modells nachahmen. Durch Analyse des Verhaltens dieser vereinfachten Modelle liefert LIME Einblicke in die relative Wichtigkeit verschiedener Merkmale für einzelne Vorhersagen. (7)

→

- ▶ **2. SHAP (SHapley Additive exPlanations):** ⑨ SHAP bestimmt die Merkmalswichtigkeit mithilfe von Shapley-Werten, einem Konzept aus der kooperativen Spieltheorie. Es berechnet den durchschnittlichen marginalen Beitrag jedes Merkmalswerts über alle möglichen Kombinationen oder Koalitionen von Merkmalen. ⑦ Durch Quantifizierung des Beitrags jedes Merkmals zum Vorhersageergebnis bietet SHAP ein umfassendes Verständnis der Merkmalswichtigkeit auf modellagnostische Weise.

In einem der nachfolgenden NC-Newsletter werden wir näher auf die Funktionsweise von LIME und SHAP eingehen.

Modellagnostische Methoden erleichtern die Interpretierbarkeit über verschiedene Maschinenlernmodelle hinweg, fördern Transparenz und liefern wertvolle Einblicke in den Entscheidungsprozess. Dennoch ist es unerlässlich, den Grad zu bestimmen, in dem ihre Interpretationen über den spezifischen Datensatz oder das Modell, das analysiert wird, hinaus angewendet werden können. Diese Bewertung stellt sicher, dass die aus diesen Methoden gewonnenen Erkenntnisse gültig und in breiteren Kontexten anwendbar sind, wodurch ihre allgemeine Zuverlässigkeit und Nützlichkeit gestärkt werden.

Auswahlkriterium

Das Auswahlkriterium für XAI-Methoden hängt von den Eigenschaften des KI-Algorithmus und den spezifischen Anforderungen der vorliegenden Aufgabe ab. Verschiedene Faktoren sollten berücksichtigt werden, um die Eignung einer Erklärungsmethode zu bestimmen.

Wir haben die folgenden Faktoren identifiziert (siehe z. B. ⑩):

- ▶ **1. Modellkomplexität:** Betrachten Sie die Komplexität des MLA selbst. Für einfachere MLAs sind intrinsisch interpretierbare Modelle möglicherweise besser geeignet. Bei komplexeren MLAs werden oft post-hoc-Methoden bevorzugt.
- ▶ **2. Gewünschter Grad an Erklärbarkeit:** Bestimmen Sie die spezifischen Ziele der Erklärbarkeit im gegebenen Kontext. Verschiedene XAI-Methoden stechen bei unterschiedlichen Aspekten heraus, wie z.B. das Verstehen individueller Vorhersagen oder das Bestimmen der globalen Merkmalswichtigkeit.

- ▶ **3. Ausmaß der Fachkompetenz:** Bewerten Sie die verfügbare Fachkompetenz. Einige Methoden erfordern ein tieferes Verständnis des zugrunde liegenden Modells oder fachspezifisches Wissen, während andere so konzipiert sind, dass sie auch für Nicht-Experten zugänglich sind.
- ▶ **4. Effizienz:** Bewerten Sie die Rechenanforderungen der XAI-Methoden. Betrachten Sie die Effizienz der Methoden, insbesondere bei der Verarbeitung großer Datensätze oder Echtzeitanwendungen.
- ▶ **5. Trade-offs:** Erkennen Sie die Trade-offs zwischen Interpretierbarkeit, Genauigkeit und Einfachheit. Verschiedene XAI-Methoden können eine unterschiedliche Gewichtung zwischen diesen Faktoren haben. Fachleute sollten diese Trade-offs bewerten, um die Methode auszuwählen, die ihren Präferenzen und Anforderungen entspricht.

Durch sorgfältige Berücksichtigung dieser Faktoren und Bewertung der Eigenschaften der XAI-Methoden für den KI-Algorithmus und den KI-Algorithmus selbst, können Fachleute die am besten geeignete Methode auswählen, um ihre spezifischen Anforderungen zu erfüllen und die Interpretierbarkeit des Maschinenlernsystems zu verbessern.

Fazit

Die zunehmende Verwendung von künstlicher Intelligenz (KI) in der Finanzbranche bedingt unmittelbar die dringende Notwendigkeit von Transparenz und Interpretierbarkeit in KI-Systemen. Die Einführung des AI-Acts der Europäischen Union und die sich ausweitende regulatorische Landschaft dienen als Katalysator für Erklärbarkeit und Rechenschaftspflicht in KI-Entscheidungsprozessen. Das Gebiet der Explainable AI (XAI) bietet eine Reihe wertvoller Techniken, um Herausforderungen wie Voreingenommenheit, Fairness, Datenschutz und Datenqualität in der KI-Entwicklung anzugehen. Darüber hinaus hat es das Potenzial, bisher unbekannte Beziehungen innerhalb von Daten aufzudecken und Organisationen einen Wettbewerbsvorteil zu verschaffen. Kontaktieren Sie uns, um mehr über XAI zu erfahren und wie Sie KI- und XAI-Techniken effektiv in Ihrem Unternehmen implementieren können.

Literaturverzeichnis

①

„The Artificial Intelligence Act,“ 2023.

Available: <https://artificialintelligenceact.eu/>

②

„EU AI Act: first regulation on artificial intelligence,“ 2023.

Available: <https://www.europarl.europa.eu/news/en/headlines/society/20230601STO93804/eu-ai-act-first-regulation-on-artificial-intelligence>

③

Christian Meske, „Explainable Artificial Intelligence: Objectives, Stakeholders, and Future Research Opportunities,“ 2020.

Available: <https://www.tandfonline.com/doi/full/10.1080/10580530.2020.1849465>

④

The Three Rules of Humane Tech. [Sound Recording].

„The Center for Humane Technology,“ 2023.

⑤

VERA LIAO, „Human-Centered Explainable AI (XAI): From Algorithms to User Experiences,“ 2022.

Available: <https://arxiv.org/abs/2110.10790>

⑥

Krzysztof Fiok, „Explainable artificial intelligence for education and training,“ 2021.

Available: <https://journals.sagepub.com/doi/10.1177/15485129211028651>

⑦

C. Molnar, „Interpretable Machine Learning,“ 2023.

Available: <https://christophm.github.io/interpretable-ml-book/>

⑧

Marco Tulio Ribeiro, „Why Should I Trust You?: Explaining the Predictions of Any Classifier,“ 2016.

Available: <https://arxiv.org/abs/1602.04938>

⑨

L. Lundberg, „A unified approach to interpreting model predictions,“ 2017.

Available: <https://arxiv.org/abs/1705.07874>

⑩

Tom Vermeire, „How to choose an Explainability Method? Towards a Methodical Implementation of XAI in Practice,“ 2021.

Available: <https://arxiv.org/abs/2107.04427>

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.

Autoren



Dr. Hamidreza Kazemi

+49 160 96 77 43 17 ^{mobile}

hamidreza.kazemi@nagler-company.com



Dr. Simon Dentinger

+49 151 29 19 41 67 ^{mobile}

simon.dentinger@nagler-company.com



Dr. Roland Onderka

+49 151 61 05 96 18 ^{mobile}

roland.underka@nagler-company.com



Dr. Dieter Hierl

+49 171 656 47 66 ^{mobile}

dieter.hierl@nagler-company.com

Effiziente Datenanalyse in der Finanzwelt: Atoti als leistungsstarkes Werkzeug

von Alexander Mitirev und Eric Kaufmann

In der heutigen schnelllebigen Finanzbranche ist es von entscheidender Bedeutung, Daten präzise und zügig zu analysieren. Dazu kann ein neues Python-basiertes Instrument verwendet werden, das große Datensätze mühelos durchleuchtet und in einfacher Form Einblicke verschafft. Der Name dieses Tools lautet „Atoti“ und ist ein BI-Instrument unseres Partners, des Softwareunternehmens ActiveViam.

Atoti ist jedoch mehr als nur ein Datenanalysetool; es ist eine umfassende Plattform mit einem eigenen Rechenkern, einer visuellen Darstellungsumgebung und einem Echtzeit-OLAP-Cube – alles in einem einzigen System vereint. Diese Plattform, die auf der Python-API basiert, kombiniert die Flexibilität und

Vielseitigkeit von Python mit der Leistung der ActiveViam-Technologie. Atoti ermöglicht die skalierbare Verarbeitung von Datensätzen in den Bereichen von wenigen Kilobytes bis mehreren Terabytes, ohne dabei die zugrundeliegende Logik zu beeinträchtigen.

Daten können in verschiedenen Formaten eingelesen, im Arbeitsspeicher verarbeitet und über eine benutzerfreundliche grafische Benutzeroberfläche (GUI) ausgewertet und geteilt werden. Innerhalb weniger Minuten kann aus einer Datei ein informatives Dashboard erstellt werden.

—>

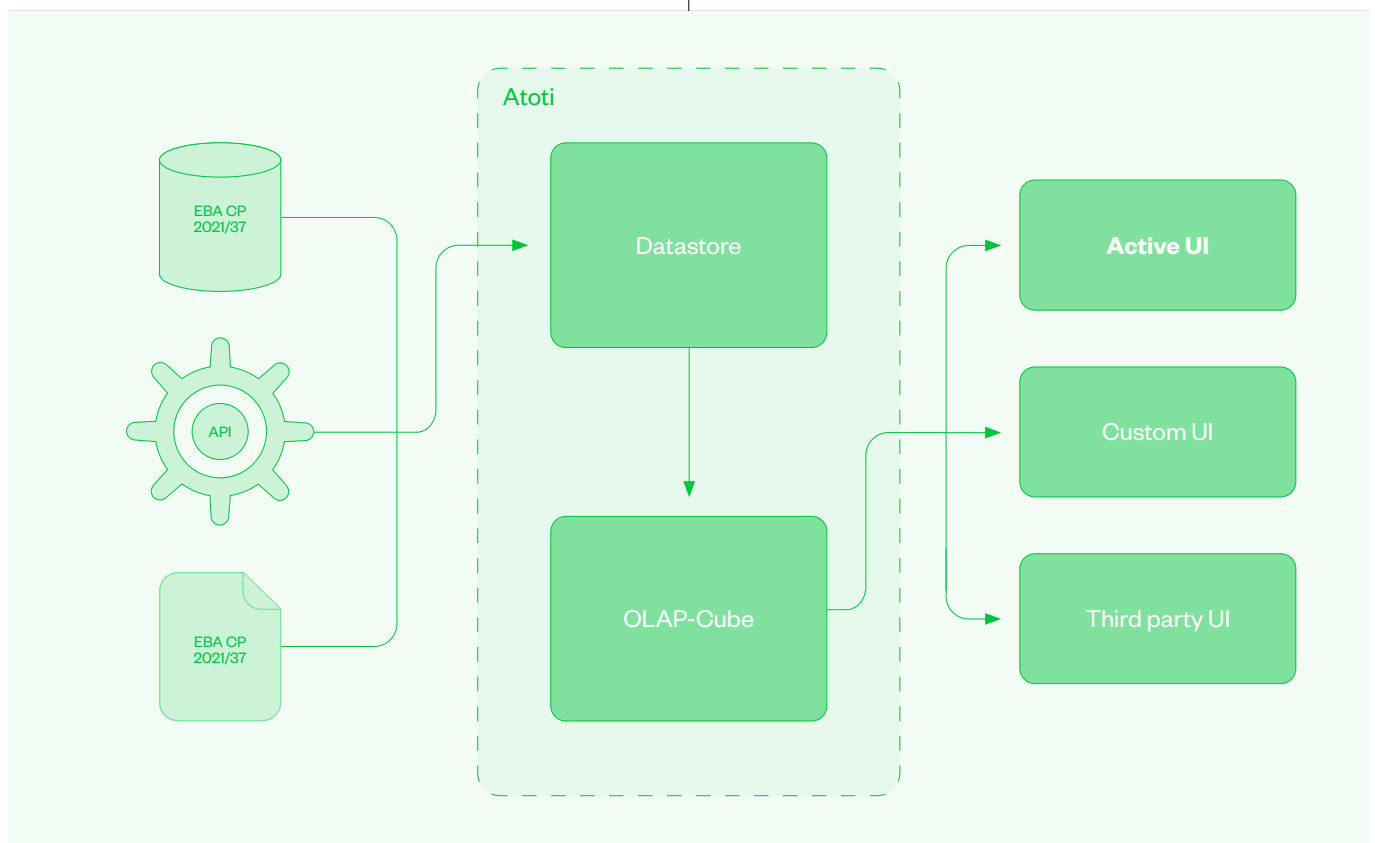


Abb.1

Die Datenverarbeitung mit Atoti erfolgt in nur wenigen Schritten:

- ▶ 1. Einlesen der Daten in den Arbeitsspeicher (In-Memory). Das stellt die unschlagbare Geschwindigkeit in weiteren Bearbeitungsschritten sicher.
- ▶ 2. Definition von Berechnungen. In diesem Kontext wird die Logik festgelegt, wodurch auch nicht-lineare Berechnungen ermöglicht werden.
- ▶ 3. Auswertung mithilfe der GUI. In diesem Schritt sind Datenanalyst*innen in der Lage, Erkenntnisse aus den vorliegenden Daten zu gewinnen.

Eine weitere Stärke von Atoti liegt in seiner Performance, die durch die In-Memory-Berechnungen gewährleistet wird. Gepaart mit einer Lazy-Evaluation der Metriken, werden die Kennzahlen erst dann berechnet, wenn sie benötigt werden.

Zusätzlich zu Atoti wird auch ActiveUI zur Verfügung gestellt – eine webbasierte GUI. Mit der ActiveUI wird es ermöglicht,

Daten umfassend zu analysieren und zu präsentieren. Durch die Verwendung von Pivot-Tabellen, verschiedensten Charts und Filtern können beliebig viele Dashboards erstellt werden. Nutzenden steht es frei Daten nach Bedarf zu aggregieren oder die Quellen durch Drill-Through-Ansichten zu erkunden. Somit wird ein bestmöglicher Einblick in die Daten gewährleistet.

Durch im Voraus definierte Berechnungen wird es ermöglicht, nicht-lineare Berechnungen für unterschiedliche Zusammenhänge sofort durchzuführen. Dies könnte beispielsweise die VAR - Kennzahl auf verschiedenen Portfolioebenen oder die Verzögerungen im Bahnverkehr Ihrer Region sein.

Für jede Berechnung besteht die Möglichkeit, Szenario-Simulationen durchzuführen. Diese Simulationen könnten beispielsweise zusätzliche Trades in einem Portfolio oder Rating-Migrationen von Top-10-Gegenparteien um 3 Ratingstufen sein.

→

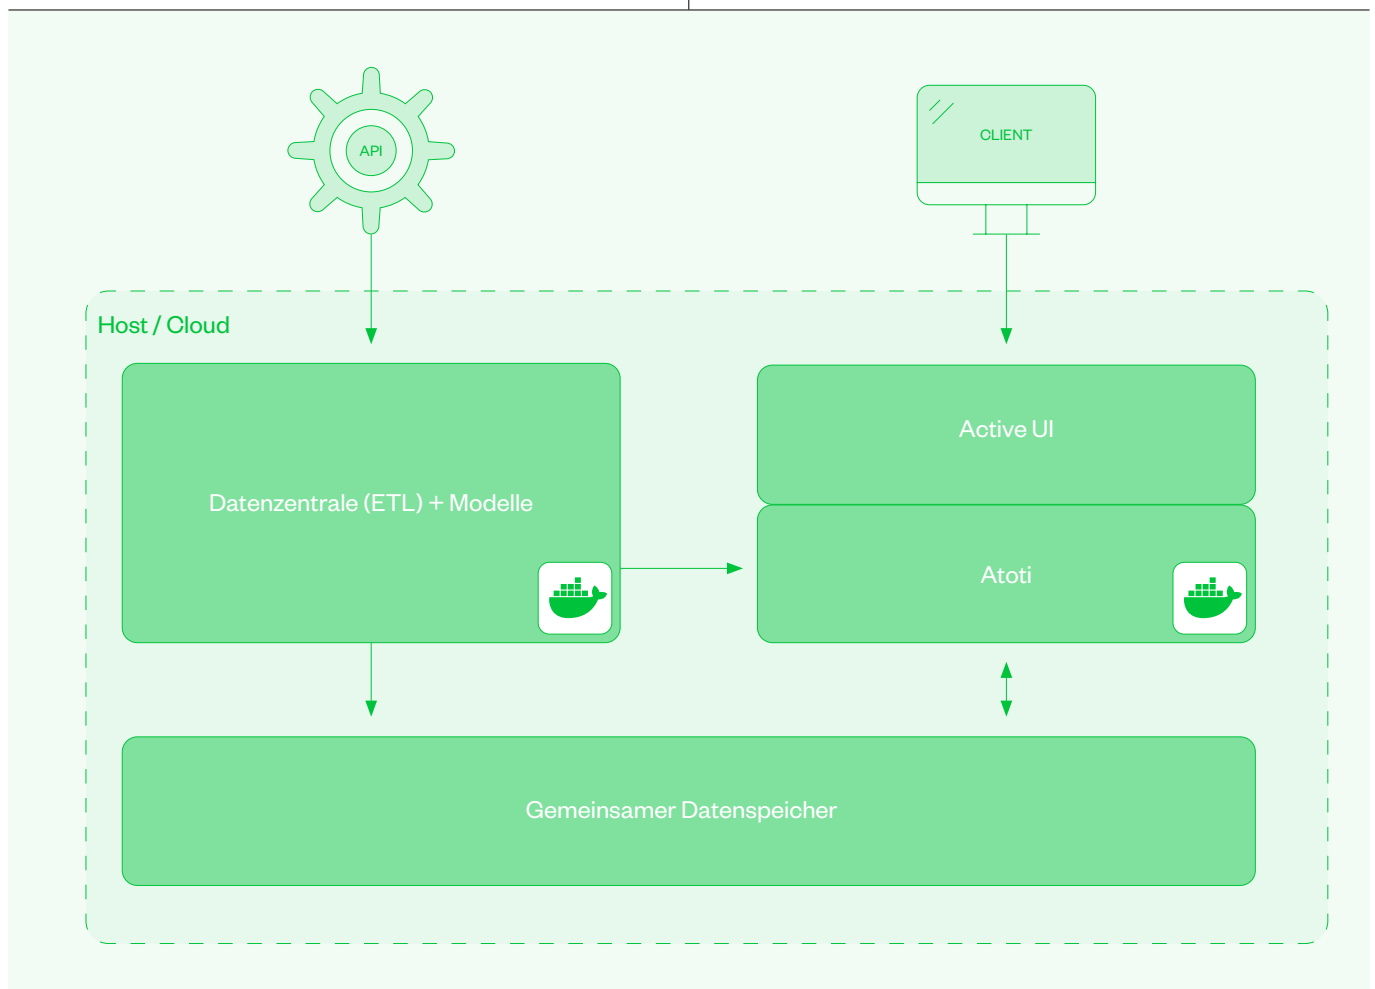


Abb. 2

Atoti kann jedoch nicht nur für schnelle Visualisierungen, sondern auch für große Projekte genutzt werden. In Synergie mit der Virtualisierungsplattform Docker konnten wir robuste Echtzeitanalyse-Lösungen entwickeln. Hierbei wurde die Kombination von zwei eigenständigen Docker-Containern verwendet, um eine skalierbare und effiziente Architektur zu schaffen, die eine gleichzeitige Datenverarbeitung und -analyse ermöglicht.

Der erste Docker-Container agiert dabei als Datenverarbeitungszentrale, welche Informationen aus vielfältigen Quellen extrahiert, verarbeitet und in Echtzeit zur Verfügung stellt. Dank dieser entkoppelten Struktur können Datenquellen reibungslos aktualisiert werden, ohne die Integrität der Metriken in Atoti zu gefährden.

Der zweite Docker-Container setzt schließlich die Plattform Atoti ein, um die Datenanalyse und -visualisierung zu realisieren. Durch das Bereitstellen der Echtzeitdaten des ersten Docker-Containers kann nun in einem zweiten Container ein Fokus auf die Entwicklung von Metriken und Dashboards gelegt werden. Atoti adaptiert dabei unmittelbar die neuen Daten, sodass ohne Neustarten der Plattform eine Aktualisierung der Dashboards erfolgt.

Nach diesem Prinzip konnten wir in eigenen Projekten bereits ein Dashboard für die tägliche Nutzung der Energieressourcen in der Bundesrepublik Deutschland entwickeln. In einem anderen Projekt haben wir einen neuen Index von Kryptowährungen erstellt und mittels der Benutzeroberfläche verschiedene KPIs und Entwicklungsprognosen dargestellt.

Die Möglichkeiten der Verwendung des Atoti-Frameworks sind nahezu grenzenlos. Mit einem reduzierten, jedoch für die meisten Use-Cases gänzlich ausreichenden Funktionsumfang ist Atoti in der Community-Edition auch vollkommen kostenfrei. Zudem stellt Atoti eine neuartige Lösung für die effiziente Datenanalyse in der Finanzwelt dar. Seine Kombination aus Python-Flexibilität, In-Memory-Verarbeitung und Echtzeit-OLAP ermöglicht eine schnelle und präzise Analyse großer Datenmengen. Die nahtlose Integration mit Docker eröffnet zudem die Tür zu individualisierten Echtzeitanalysen, die in der Finanzbranche einen großen Wert bieten. Durch die Vielseitigkeit und Leistungsfähigkeit von Atoti können Fachleute in der Finanzwelt innovative Einblicke gewinnen und fundierte Entscheidungen treffen, um die Herausforderungen der modernen Finanzbranche erfolgreich zu bewältigen.

Nagler & Company verfügt über langjährige Expertise im Design und Implementierung von BI-Lösungen in der Finanzindustrie. Wenn Sie Fragen zum Thema Atoti und moderne BI-Lösungen in Ihrem Hause haben, kontaktieren Sie uns gerne.

Autoren



Alexander Mitirev

+49 175 186 77 23 mobile

alexander.mitirev@nagler-company.com



Eric Kaufmann

+49 151 52 45 84 51 mobile

eric.kaufmann@nagler-company.com

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 20 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.