



Leidenschaft
fürs Leben.

Digitale Spuren als Prognoseinstrument - Innovatives Credit Scoring

Prof. Dr. Tea Riedel

14.05.2024

RMA Management Congress 2024
Hamburg



Ihre Referentin

Prof. Dr. Tea Riedel, MBR



- Seit 02/2024: Professorin für International Finance an der SRH Fernhochschule
- 2023-2024: Fachdozentin International Finance an der SRH Fernhochschule
- 2022-2023: Lehrbeauftragte an der Hochschule München
- Mehrjährige berufliche Erfahrung im Finanzbereich (letzte Position: Senior Associate Manager Financial Markets & Competitive Intelligence bei Siemens Financial Services GmbH)
- 2009-2014: Wissenschaftliche Mitarbeiterin und Doktorandin am Lehrstuhl für Kapitalmärkte und Finanzwirtschaft (LMU München)
- 2012: Master of Business Research, MBR (LMU München)
- 2008: Diplom BWL (LMU München)

Schwerpunkte in Lehre/Forschung:

- Corporate Finance
- Financial Management & Corporate Decisions
- Capital Markets & Portfolio Management
- Risk Management & Financial Derivatives

“All data is credit data, we just don't know how to use it yet”

(Douglas Merrill - CEO and founder of Zest AI)

Quelle: The New York Times, Archiv v. 25.03.2012, <https://archive.nytimes.com/query.nytimes.com/gst/fullpage-9A0CE7DD153CF936A15750C0A9649D8B63.html>.

Fragen

- Was sind digitale Spuren und eignen sich diese zu Prognosezwecken im Rating-Verfahren?
- Gibt es wissenschaftliche Erkenntnisse zu deren Informationsgehalt und Prognosegüte?
- Welche möglichen Implikationen und Herausforderungen ergeben sich durch die Verwendung alternativer Daten bzw. generell von Big Data und deren Auswertung durch KI-Systeme?
- Wie sieht das aktuelle regulatorische Umfeld aus?

Gliederung

01

Einleitung

02

Wissenschaftliche Studien

03

Mögliche Implikationen und Herausforderungen

04

Regulatorisches Umfeld

05

Fazit und Ausblick

Einleitung

01

Einleitung

- Gesellschaft und Wirtschaft erfahren zurzeit einen tiefgreifenden technologischen Wandel.
- Mit fortschreitender digitaler Vernetzung und dank neuer Technologien eröffnen sich neue Lösungswege für komplexere Probleme.
- Große Datenmengen bzw. Big Data und fortgeschrittene Anwendungsmöglichkeiten dieser Daten mittels Künstlicher Intelligenz treiben diese Entwicklung maßgeblich voran (im Folgenden gemeinsam abgekürzt: BDAI).
- Relevanz steigt durch das Zusammenspiel von Technologie, Unternehmertum und Konsumentenverhalten.
- Durch die Kombination von analytischen Verfahren und umfangreich verfügbaren Daten lassen sich neue Erkenntnisse gewinnen.

Revolution in der Nutzung von Daten

Digitalisierung

- Alltägliche digitale Aktivitäten: Zahlungen, soziale Kontakte, Suchmaschinen, Gesundheitsdaten, etc.
- Entwicklung von Datensätzen durch Ansammlung von Millionen Datenpunkten (Big Data)

Fortschritte im maschinellen Lernen

- Entwicklung neuer Algorithmen und Techniken
- Verarbeitung komplexer Datensätze
- Mustererkennung
- Unterschiedliche Quellen mit unterschiedlichen Formaten (Text, Bild, Ziffern, etc.)

Fortschritte in der Recheninfrastruktur

- Technologische und infrastrukturelle Entwicklung
- Training und Implementierung der maschinellen Lernalgorithmen
- Verbesserung der Hard- und Software und Netzinfrastruktur
- Schneller, kosteneffektiver und zugänglicher

Dynamik aus Technologie, Unternehmen, Verbrauchern und regulatorischem Umfeld



Wissenschaftliche Studien

02

Forschungsgegenstand

- Forschungsliteratur im Bereich des Credit Scorings beschäftigt sich primär mit der Untersuchung verschiedener **Klassifikationsverfahren und -algorithmen** sowie des **Informationsgehaltes verschiedener Variablen**.
- Ziel ist es, die Zuverlässigkeit und Effektivität der Risikobeurteilung im Hinblick auf Methodik und Datenqualität zu optimieren.
- Neuere Forschung betrachtet dabei den Informationsgehalt **alternativer Datenquellen bzw. digitaler Spuren** im Vergleich zu traditionellen Variablen (wie z.B. Finanzkennzahlen).
- Auch der Einsatz von Big Data unter Verwendung von KI-Systemen spielt dabei eine zunehmend wichtige Rolle in der Forschung.

Definition „Digitale Spuren“

"Die Datenspur, die Individuen beim **Nutzen digitaler Dienste** erstellen. Diese vom Nutzer generierten digitalen Fußabdrücke (oder auch „user-generated digital footprints“) gelten als **aktiv**, wenn Nutzer sie absichtlich mit ihren Online-Diensteanbietern teilen (z.B. Bild, Video, Tweet und Kaufbetrag) und als **passiv**, wenn sie sie unbeabsichtigt als unvermeidliches Artefakt ihrer digitalen Transaktion teilen (z.B. IP-Adresse, Kreditkartenherausgeber, etc.)."

Quelle: Loutfi (2022).

Überblick der Untersuchungsbereiche

**Konsumentenkredite
im Online-
Handel**

**Peer-to-Peer Lending
(P2P)**

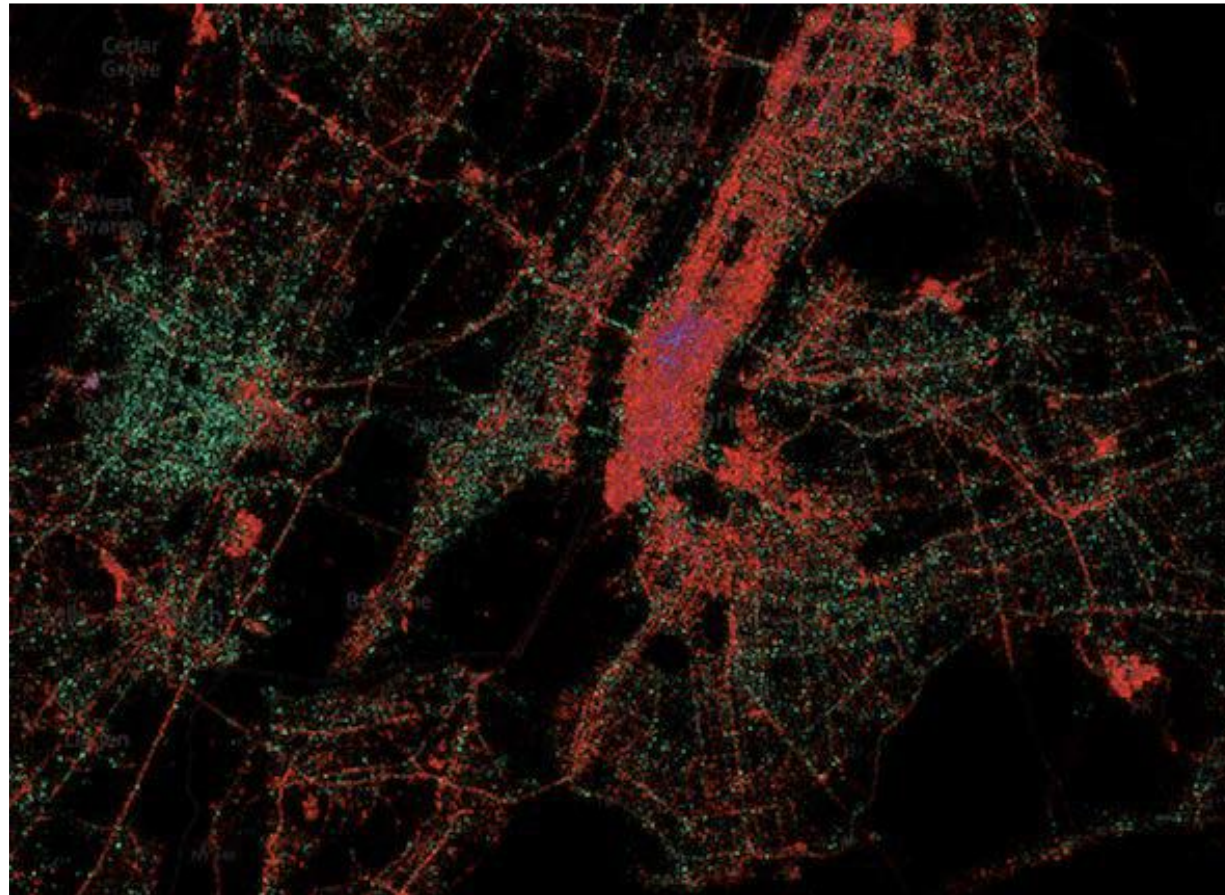
**Vergabe von
Kreditkarten**

**Corporate Credit
Ratings**

Digitale Spuren - Beispielstudien (1/4)

Variablen	Beschreibung	Bereich	Autor(en)/Jahr	Titel der Studie
Mobilgerät:				
Betriebssystem	Windows, iOS, Android	Konsumentenkredite	Berg et al. (2020)	On the Rise of FinTechs: Credit Scoring Using Digital Footprints
Gerät	Desktop, Tablet, Smartphone			Einkommen
E-Mail-Host	GMX, Yahoo, Gmail, Web, etc.			
Kanal	Bezahlte Klicks vs. organische Suche; Affiliate-Websites; Direkte Eingabe der URL			Charakter
Do-not-track-Einstellung	(ja/nein)			
Check-out-Time	Morgens, Nachmittags, Abends, Nachts			
Email Fehler	(ja/nein)			
Name in E-Mail	(ja/nein)			Reputation
Nr. in E-Mail	(ja/nein)			
Kleinbuchstaben	Vor- und Nachname, Adresse			

Beispiel - Verwendung von Betriebssystemen in New York



Rot= iOS
Grün = Android
Lila = Blackberry

Quelle: Abbildung entnommen aus Berg et. al (2020). Datenquelle: Gnip, MapBox, Eric Fisscher (Zeitraum 2011-2023).

Digitale Spuren – Beispielstudien (2/4)

Variablen	Beschreibung	Bereich	Autor(en)/Jahr	Titel der Studie
Web-basierte Merkmale:				
Anzahl Website-Besuche		Konsumentenkredite	Rozo et al. (2023)	The role of web browsing in credit risk prediction
Anzahl Kontositzungen				
Anzahl der verwendeten Mobilgeräte				
Anzahl AGB-Ansichten				
Web-Browser Verhalten u.a. Suchfrequenz		Konsumentenkredite	Wu et al. (2020)	Do consumer internet behaviours provide incremental information to predict credit default risk?
Social Media:				
Interaktionen in sozialen Netzwerken mit a) Look-a-Likes b) Bekannten c) engen Freunden	Microfinance – Kreditanträge ohne Bankhistorie. Datenquelle Lenddo	P2P Lending	Cnudde et al. (2015)	Who Cares About Your Facebook Friends?
Besuchte Seiten „Likes“				

Digitale Spuren – Beispielstudien (3/4)

Variablen	Beschreibung	Bereich	Autor(en)/Jahr	Titel der Studie
Textauswertung:				
Foto des Antragstellers		P2P Lending	Gao et al. (2018)	Words Matter: The Role of Texts in Online Credit Markets
Schriftliche Beschreibung des Antragstellers (Ziel, finanzielle Situation, etc.)	Sprachlicher Stil (Lesbarkeit, Tonfall, Täuschungshinweise) mit Hilfe von ML und linguistischen Maßen; Datenquelle Prosper			
Schriftliche Beschreibung des Antragstellers	Softe vs. harte Informationen; Rechtschreibfehler, Textlänge, positive emotionale Keywords; Datenquelle Smava und Auxmoney	P2P Lending	Dorfleitner et al. (2016)	Description-text related soft information in peer-to-peer lending-evidence
Mobilgeräte:				
Anrufrdatensätze bzw. Anrufnetzwerke	Social Media Analytics Techniken; Weitere Daten: Kredit- und Debitkonten	Kreditkarten	Oskarsdottir et al. (2019)	The value of big data for credit scoring: Enhancing financial inclusion using mobile phone data and social network analytics

Digitale Spuren – Beispielstudien (4/4)

Variablen	Beschreibung	Bereich	Autor(en)/Jahr	Titel der Studie
Social media:				
Anzahl Follower Anzahl an Content Anzahl Kommentare Anzahl Posts Negative vs. positive Reaktionen Negative vs. positive Kommentare Anzahl geteilter Posts Anzahl an Tagen seit letztem Post	Öffentlich zugängliche Unternehmensseiten auf Facebook, Sammlung von daten mit Hilfe Web-Crawler-Technologie; 35 Social-Media Variablen kombiniert mit 20 traditionellen Variablen	Corporate Credit Ratings	Putra et al. (2020)	A Credit Scoring Model for SMEs Based on Social Media Data
Kommentare & Posts	Big Data Analyse mit ML, bzw. Textanalyse - Diskussionsintensität, Satzpolarität (positiv, negativ), Stimmungswörter	Corporate Credit Ratings	Chen and Chen (2022)	Forecasting corporate credit ratings using big data from social media
Kommentare & Posts	ML-Model Textanalyse	Corporate Credit Ratings	Fei et al. (2015)	Credit Risk Evaluation Based on Social Media

Wesentliche Erkenntnisse

- **Empirische Evidenz** wissenschaftlicher Studien zeigt, dass Informationen aus digitalen Spuren durchaus eine **Vorhersagekraft** bei der Beurteilung der Kreditwürdigkeit aufweisen.
- Im Vergleich zu traditionellen Credit Scores zeigt sich teilweise sogar eine **bessere Trennschärfe**.
- Digitale Spuren stellen nicht nur Proxies für Kontrollvariablen wie Alter, Einkommen, etc. dar.
- Korrelationsanalysen zeigen zudem, dass digitalen Spuren **nicht hochkorreliert** sind mit traditionellen Credit Scores.
- **Digitale Spuren** werden daher **nicht** als **Substitut**, sondern als **Ergänzung** zu traditionellen Credit Scores betrachtet.
- **Kombination** beider Daten führt zu besten Ergebnissen.

Mögliche Implikationen und Herausforderungen

03

Finanzielle Inklusion

Finanzielle Inklusion durch digitale Spuren

Weltweit 1,4 Milliarden Erwachsene ohne Finanzzugang



Finanzielle Inklusion durch digitale Spuren

- Weltweit 1,4 Milliarden Erwachsene im erwerbsfähigen Alter ohne Zugang zu Finanzdienstleistungen und Bankhistorie (World Bank - Global Findex Studie, letzter Stand: 2021).
- Diese Zahl ist von 2,5 Milliarden im Jahr 2011, auf 2 Milliarden im Jahr 2014 und auf 1,7 Milliarden im Jahr 2017 gesunken. Nahezu alle in Entwicklungsländern.
- Laut Weltbank angetrieben durch Mobiltelefone und Internet, vor allem auch durch wachsende Zahl von FinTech-Unternehmen und anderen Akteuren mit innovativen Lösungen.
- Weiterhin hohe Erwartungen an digitale Fußspuren.

Datenqualität und Nutzung von Machine Learning-Methoden

Datenqualität und Repräsentativität

- Datengrundlage ist als **Ausgangspunkt und Erfolgsfaktor** anzusehen.
- Mit Hilfe von Machine Learning (ML)-Methoden können **unstrukturierte Daten** (wie z.B. Social Media Posts, Videos, Tweets, etc.) erschlossen werden und eine **Vielzahl an Einflussgrößen** einbezogen werden.
- **Problem des „Overfittings“**: Korrelationen zwischen Inputdaten, die keinen realen Zusammenhang darstellen, sondern auf zufälligen Eigenschaften beruhen.
- Daten müssen so **repräsentativ** wie möglich sein, so dass tiefes Verständnis für verwendeten Daten immer wichtiger wird.
- Hohe Erklärbarkeit der Modelle können Datengläubigkeit und „Blackbox“-Problemen entgegenwirken.

Quelle: Siehe dazu auch Konsultationspapier der BaFin und Bundesbank (2021).

Erklärbarkeit der Modelle

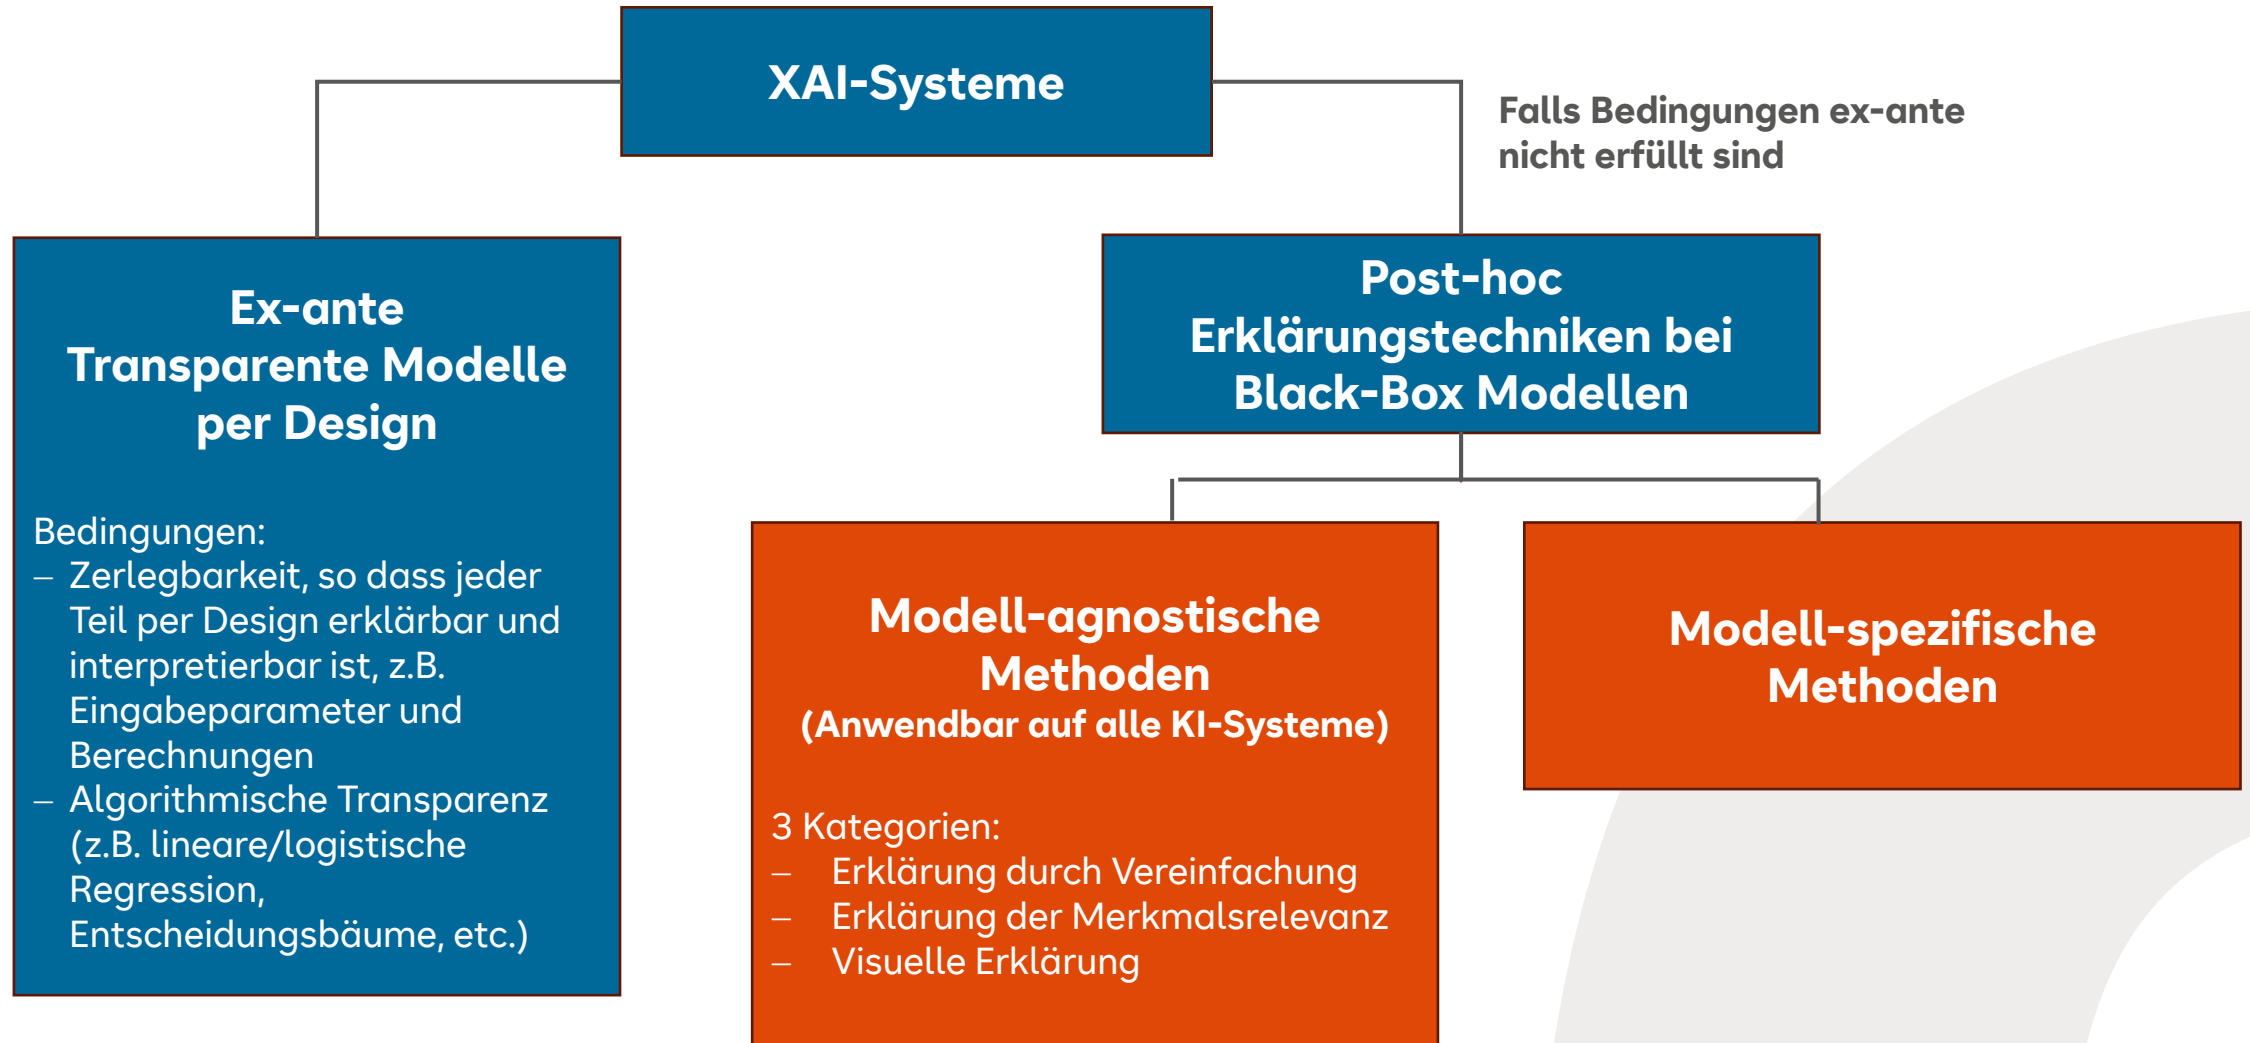
- Aufgrund der **„Blackbox“-Problematik** schwierig den funktionellen Zusammenhang zwischen Input und Output zu beschreiben und desto weniger im Detail nachvollziehbar.
- „Blackbox“-Eigenschaft kann als Preis für leistungsfähigere Modelle angesehen werden. Einbußen in der Nachvollziehbarkeit des Modells bzw. ein **höheres Modellrisiko** können durch erzielte **Vorteile in der Prognosekraft** gerechtfertigt sein.
- **Trade-off** zwischen **Performance** und **Erklärbarkeit**.
- Anstelle Nachvollziehbarkeit im Detail gewinnen daher die **Erklärbarkeit** und die **Plausibilisierung des Modellverhaltens** im Ganzen an Bedeutung.
- **„Explainable AI“ (XAI)-Techniken** als Lösungsansatz.

Quelle: Siehe dazu auch Konsultationspapier der BaFin und Bundesbank (2021).

Blick in die Forschung: Explainable AI (XAI)

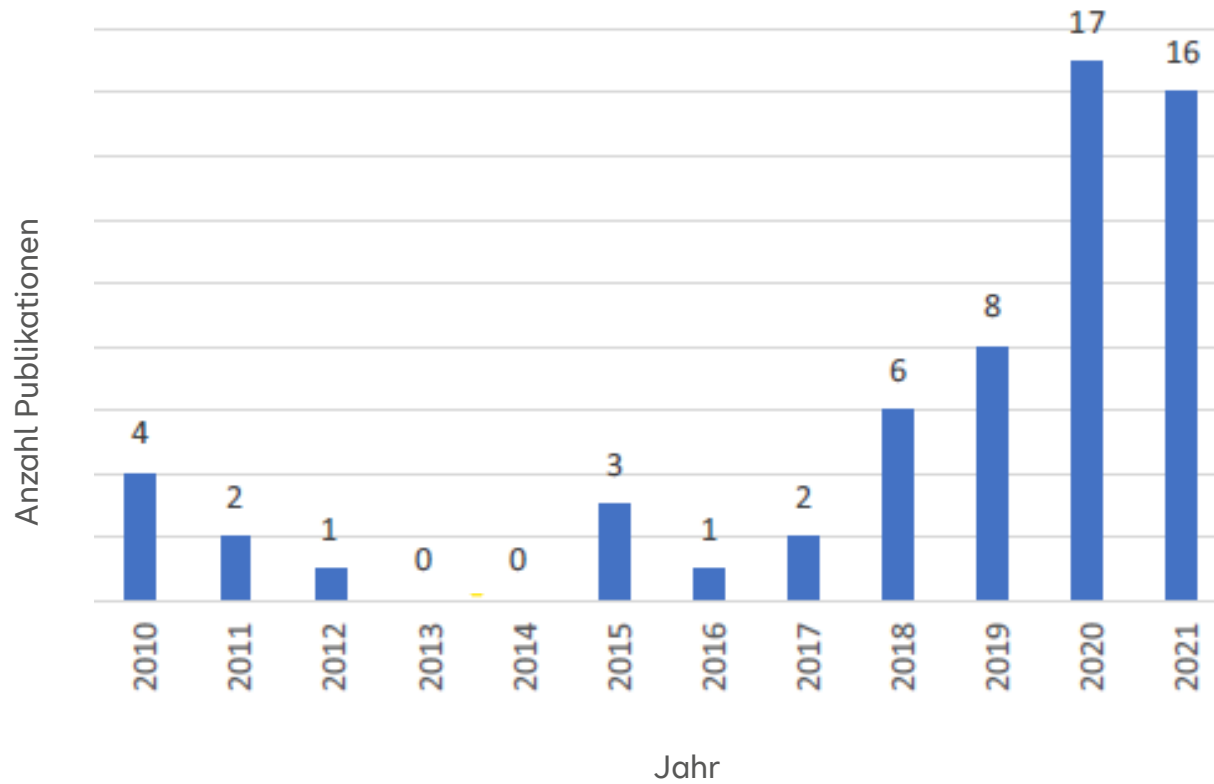
- In wissenschaftlichen empirischen Studien werden neben klassischen Verfahren (wie z.B. logistische Regressionen, etc.) vermehrt ML-Methoden eingesetzt.
- **„Black-Box“-Problematik** von ML erfährt ebenfalls **zunehmendes Forschungsinteresse**.
- Art der Eingabe und Ausgabe können beobachtet werden, aber nicht die genauen Verarbeitungsschritte.
- Explainable Artificial Intelligence (XAI) definiert als Unterklasse von KI-Systemen mit dem **Ziel der Erklärbarkeit** und **Interpretierbarkeit** von KI-Systemen.

Systematisierung von XAI-Systemen



Forschung im Bereich XAI

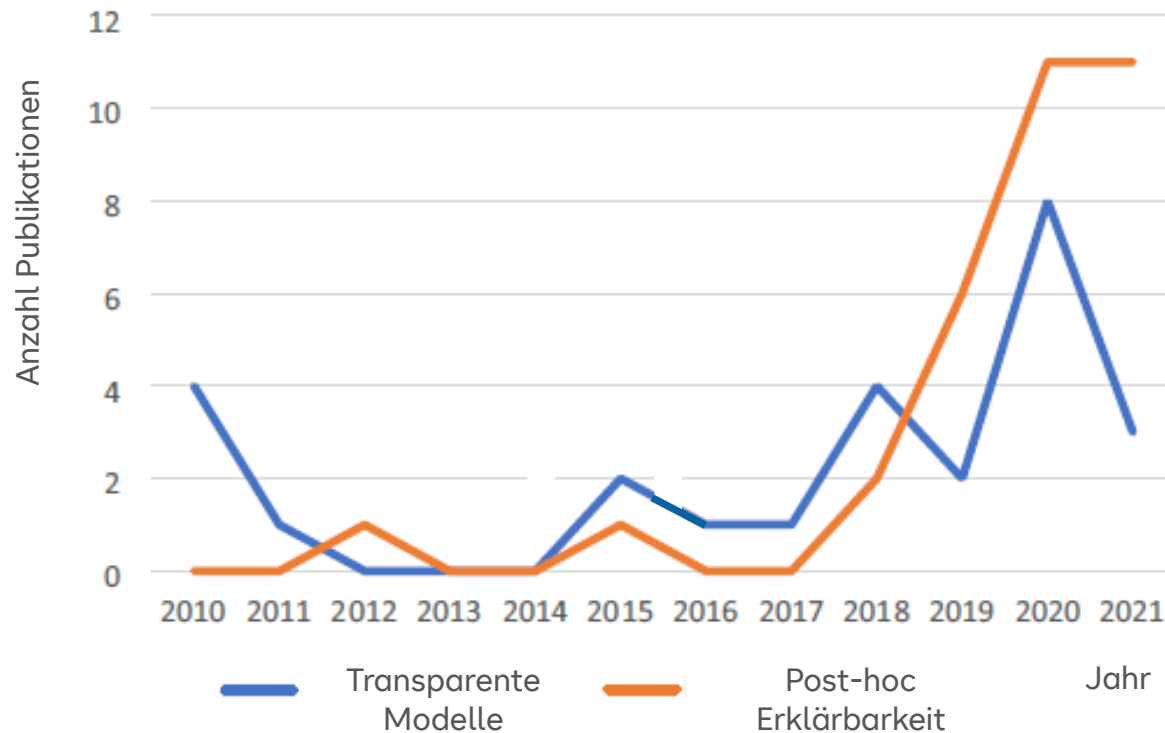
Publikationstrend im Bereich XAI-Forschung in Finance (n=60)



Quelle: Weber et al. (2023).

Forschung im Bereich XAI

Publikationstrend im Bereich XAI-Forschung in Finance (n=60), gegliedert nach transparenten Modellen oder Post-hoc Erklärbarkeit



Quelle: Weber et al. (2023).

Verbraucherschutz

Apple Card

Weiblich, Ehefrau, kreditunwürdig?

Die Apple Card soll Frauen weniger Kredit gewährt haben als Männern. Gelebte Bankenpraxis. Sich gegen Algorithmen zu wehren ist aber noch schwerer als gegen Bankberater.

Eine Analyse von **Lisa Hegemann**

21. November 2019, 15:56 Uhr / [283 Kommentare](#) / 

KI-Gutachten: Diskriminierung programmiert?

Marcel Fürstenau
30.08.2023

Künstliche Intelligenz (KI) hat anscheinend das Potenzial zur automatischen Benachteiligung. Das will die Bundesbeauftragte für Antidiskriminierung ändern.



IT Finanzmagazin

Das Fachmagazin für IT und Organisation bei
Banken, Sparkassen und Versicherungen

STRATEGIE

22. Oktober 2021

Wie steht es um die Fairness bei künstlicher Intelligenz? –
Das Beispiel der Kreditvergabe

Rechtswidrige Diskriminierung

Direkte Diskriminierung

- Diskriminierung aufgrund eines geschützten Merkmals, wie z.B. Alter, Geschlecht, ethnische Herkunft, etc. im Gegensatz zu einer anderen Person in einer vergleichbaren Situation

vs.

Indirekte Diskriminierung

- Scheinbar neutrales Kriterium führt dazu, dass Personen des geschützten Kreises diskriminiert werden
- Beispiel: Kriterium Teilzeitbeschäftigung = Frauen

Rechtswidrige Diskriminierung

- Gefahr, dass für einzelne Verbraucher **Zugang zu bestimmten Finanzdienstleistungen** (wie Krediten) unverhältnismäßig **eingeschränkt** wird.
- Benachteiligung durch geringere Produktauswahl, v.a. wenn **nicht nachvollziehbar**, dass dies aufgrund **personenbezogener Daten** geschieht.
- Auswertung digitaler Spuren bzw. Big Data mit Hilfe von Algorithmen könnte auf Merkmale abstellen, für die rechtlich eine Differenzierung verboten ist.
- Je größer Datenmenge, die ein KI-System verwertet, desto eher wird der Algorithmus ein weiteres **scheinbar neutrales Kriterium** (als Proxy) finden, welches dieselbe Vorhersage mit vergleichbarer Präzision erlaubt (**indirekte Diskriminierung**).
- Sowohl bei der Programmierung der Algorithmen als auch bei der Kontrolle der erzeugten Ergebnisse ist darauf zu achten, dass keine Diskriminierung entgegen geltender Rechtsvorschriften stattfindet.

Preisdiskriminierung

- Tiefere Einblicke in Kundencharakteristika und **bessere Vorhersage des Kundenverhaltens**.
- Durch Verknüpfung von **finanzwirtschaftlichen Transaktions- und Verhaltensdaten** mit Daten zu **Präferenzen** und **Bedürfnissen** lässt sich die Zahlungsbereitschaft und -fähigkeit auf Einzelkundenbasis offenlegen.
- Bei einer **(Massen-)Individualisierung** kann von jedem Kunden der Preis verlangt werden, den er maximal zu zahlen bereit ist (d.h. **Abschöpfung der Konsumentenrente***).
- Kritisch in Situationen, in denen Verbraucher ein Produkt (z.B. Kredit) akut benötigen, in der sie aber **faktisch keine Wahl** mehr haben zwischen verschiedenen Angeboten.

* Konsumentenrente = Differenz zwischen dem Preis, den ein Verbraucher für ein Produkt oder eine Dienstleistung maximal zu zahlen bereit ist, und dem Preis, den er tatsächlich am Markt zahlen muss,

Quelle: BaFin (2018).

Verbrauchervertrauen

- **Informationsasymmetrien**, wenn Kunden den Gegenwert der Daten, die sie zur Verfügung stellen sollen (Bezahlen mit Daten), und damit den faktischen Preis der Dienstleistung nicht kennen
- **Ziel:** Sensibilisierung der Verbraucher und **Vertrauen als wertschöpfender Faktor**.
- **Mögliche Lösungen:** Anonymisierte Analyse der Daten oder Datensouveränität der Verbraucher, d.h. Aufklärung über potenzielle Reichweite und Konsequenzen der Datennutzung, verlässliche Kontrollmöglichkeiten und Wahlfreiheit.

Handlungsfreiheit

- Mit Informationen, die sich aus digitalen Spuren ableiten lassen, können Verbraucher in ihrem **Verhalten beeinflusst** und in ihrer **Freiheit eingeschränkt** werden.
- Für Verbraucher schwer einzuschätzen, wer über welche Daten zu seiner Person verfügt und wie er sie auswertet.
- Verbraucher könnten gezwungen sein, ihr Verhalten zu ändern, entweder indem sie Online-Dienste nicht mehr nutzen oder ihr Verhalten anpassen, um ihre digitale Spur zu optimieren.
- Einige Variablen schwer manipulierbar, andere wiederum erfordern **Änderungen des Konsumentenverhaltens** mit Auswirkungen auf das alltägliche Leben.

Quelle: BaFin (2018).

Implikation für Finanzintermediäre und -märkte

FinTech vs. Finanzintermediäre

- Existenz von Finanzintermediären: Überlegene Fähigkeit, auf Informationen zuzugreifen und diese zu verarbeiten, die für die Prüfung und Überwachung von Kreditnehmern relevant sind.
- Digitale Spuren mit wertvollen Informationen zur Vorhersage von Zahlungsausfällen.
- Potentieller Ersatz für beziehungspezifische Informationen (z.B. Stammdaten, Transaktionsdaten), über die nur die Banken verfügen.
- Verringert die Kluft zwischen FinTechs und traditionellen Finanzintermediären.
- **Informationsvorsprung der Banken** durch alternative BDAI-Anbieter **bedroht**.

Systemrelevanz alternativer BDAI-Anbieter

- Unregulierte und dominante Anbieter von BDAI können Daten, die sie außerhalb des Finanzsektors gewinnen, auch im Finanzmarkt profitabel einsetzen.
- **Systemrelevanz** durch eigene Angebote der BDAI-Anbieter am Finanzmarkt.
- Systemrelevanz auch mittelbar, indem Finanzdienstleistungsbranche **Daten oder Infrastrukturen kostenpflichtig** zur Verfügung gestellt werden, wodurch **Abhängigkeiten** entstehen.
- Denn wenn sich die Erkenntnisse dieser BDAI-Anbieter für die Finanzdienstleistungsbranche als wertvoll erweisen, etwa für die präzisere Risikoeinschätzung, wird ein hoher Wettbewerbsdruck entstehen: Kaum ein Wettbewerber wird darauf verzichten wollen, auch auf diese Erkenntnisse zuzugreifen.

Regulatorisches Umfeld

04

Europäische Regelungen



	EU- Verbraucherkreditrichtlinie	EU-Datenschutz- Grundverordnung (DSGVO)	EU Artificial Intelligence Act („KI-Gesetz“)
	RL (EU) 2023/2225 des EU Parlaments und des Rates v. 18. Oktober 2023	VO (EU) 2016/679 des EU Parlaments und des Rates v. 27. April 2016	Mitte März 2024 vom EU-Parlament verabschiedet
Inhalt	Standardisiert Informationen und Rechte rund um Verbraucherkredite, einschließlich Werbung, Kreditverträge und vorzeitige Rückzahlung.	Schutz personenbezogener Daten, regelt deren Verarbeitung und stärkt die Rechte der EU-Bürger bezüglich ihrer Daten.	Regelungen zur Klassifizierung von KI-Systemen nach ihrem Risikoniveau, Anforderungen an hochriskante KI-Systeme, Transparenzpflichten und Maßnahmen zum Schutz der Grundrechte.
Ziele	Hohes Schutzniveau für Verbraucher in der gesamten EU und Binnenmarkt für Verbraucherkredite zu stärken (u.a. Diskriminierungsverbot). Transparenz fördern, damit Verbraucher fundierte Entscheidungen treffen können, und faire Wettbewerbsbedingungen.	Einheitliches Datenschutzniveau, Schutz der Bürgerrechte und Vertrauen in digitale Dienste, u.a.: 1) Zweckbindung und Datenminimierung 2) Grundsätze für die Verarbeitung personenbezogener Daten 3) Rechte der betroffenen Person	Gleichgewicht zwischen der Förderung der Innovation und der Technologienutzung und dem Schutz der Grundrechte und Sicherheit der Bürgerinnen und Bürger herzustellen. Vertrauen in KI-Technologien stärken.

„[...] Kreditgeber und Kreditvermittler, die den Preis ihrer Angebote für bestimmte Verbraucher oder bestimmte Verbrauchergruppen auf der Grundlage **automatisierter Entscheidungsfindung personalisieren**, [sollten] Verbraucher **eindeutig darüber informieren** [...]. [Sie sind] ferner verpflichtet, Verbraucher, die das Angebot erhalten, über die für die Personalisierung des Angebots **verwendeten Datenquellen zu informieren**.“ (Erwägungsgrund 46)

„Die Prüfung der Kreditwürdigkeit sollte auf Informationen über die finanzielle und wirtschaftliche Situation beruhen. Solche Informationen sollten im Einklang mit dem [...] **Grundsatz der Datenminimierung** notwendig und [...] für den Verbraucher **verhältnismäßig** sein [...]. Diese Informationen sollten **weder** besondere Kategorien **personenbezogener Daten** [...] **wie etwa** Gesundheitsdaten einschließlich Daten zu Krebserkrankungen noch Informationen **aus sozialen Netzwerken** umfassen.“ (Erwägungsgrund 55)

Artikel 6 Diskriminierungsverbot

„Die Mitgliedstaaten stellen sicher, dass die für die Gewährung eines Kredits zu erfüllenden Bedingungen Verbraucher, die ihren rechtmäßigen Aufenthalt in der Union haben, **nicht aufgrund ihrer Staatsangehörigkeit** oder ihres **Wohnsitzes** oder aus einem der in Artikel 21 der Charta der Grundrechte der Europäischen Union genannten Gründe **diskriminieren**, wenn diese Verbraucher in der Union einen Kredit beantragen oder einen entsprechenden Vertrag abschließen oder abgeschlossen haben.“

Die Möglichkeit, unterschiedliche Bedingungen für den Zugang zu einem Kredit anzubieten, die durch **objektive Kriterien hinreichend gerechtfertigt** sind, bleibt von Unterabsatz 1 unberührt.“

Artikel 18 Absatz (8)

Verpflichtung zur Prüfung der Kreditwürdigkeit des Verbraucher

„Für den Fall, dass die Kreditwürdigkeitsprüfung eine **automatisierte Verarbeitung personenbezogener Daten** beinhaltet, stellen die Mitgliedstaaten sicher, dass der Verbraucher das **Recht** hat, das **Eingreifen einer Person** aufseiten des Kreditgebers zu verlangen und zu erwirken [...]“

Artikel 22 Absatz (1)

Automatisierte Entscheidungen im Einzelfall einschließlich Profiling

„Die betroffene Person hat das **Recht, nicht** einer **ausschließlich** auf einer **automatisierten Verarbeitung** – einschließlich Profiling – beruhenden Entscheidung unterworfen zu werden, die ihr gegenüber rechtliche Wirkung entfaltet oder sie in ähnlicher Weise erheblich beeinträchtigt“

Bundesdatenschutzgesetz (BDSG)

§ 37a * Scoring

„[...] (2) Wahrscheinlichkeitswerte im Sinne des Absatzes 1 dürfen nur erstellt oder verwendet werden, wenn

1. für die Erstellung **folgende Daten nicht genutzt** werden:

- a) besondere Kategorien personenbezogener Daten im Sinne von Artikel 9 Absatz 1 der Verordnung (EU) 2016/679,
- b) der Name der betroffenen Person oder personenbezogene Daten aus ihrer **Nutzung sozialer Netzwerke**, [...]

3. die genutzten personenbezogenen Daten

- a) unter Zugrundelegung eines wissenschaftlich anerkannten mathematisch-statistischen Verfahrens **nachweisbar für die Berechnung der Wahrscheinlichkeit** des bestimmten Verhaltens **erheblich** sind und
- b) für keine anderen Zwecke verarbeitet werden. [...]

*Neuer § 37a BDSG am 7.2.2024 beschlossen in Anschluss an das SCHUFA-Urteil des EUGH v. 7.12.2023.

Bundesdatenschutzgesetz (BDSG)

§ 37a* Scoring

(4) Verantwortliche, die Wahrscheinlichkeitswerte im Sinne des Absatzes 1 erstellen, haben auf Antrag der betroffenen Person in **präziser, transparenter, verständlicher und leicht zugänglicher Form** in einer klaren und einfachen Sprache Folgendes mitzuteilen:

1. die für die Erstellung **genutzten personenbezogenen Daten** der betroffenen Person und **Kriterien**,
2. die **Gewichtung von Kategorien von Kriterien** und der einzelnen Kriterien zueinander, die den Wahrscheinlichkeitswert am stärksten beeinflussen,
3. die **Aussagekraft** des konkreten Wahrscheinlichkeitswerts und
4. die erstellten Wahrscheinlichkeitswerte und ihre Empfänger. [...]

*Neuer § 37a BDSG am 7.2.2024 beschlossen in Anschluss an das SCHUFA-Urteil des EUGH v. 7.12.2023.

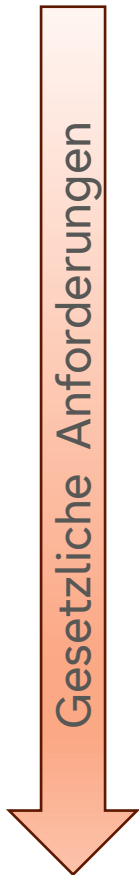
EU Artificial Intelligence Act („KI-Gesetz“)

„Vorschriften für KI, die auf dem Unionsmarkt verfügbar ist oder anderweitig Menschen in der Union beeinflusst, sollten daher **auf den Menschen ausgerichtet** sein, damit Menschen darauf vertrauen können, dass die Technik sicher angewandt wird und den Gesetzen, auch den Grundrechten, genügt.“ (Begründung Kapitel 1.1)

EU Artificial Intelligence Act („KI-Gesetz“)

- **Erste staatliches Gesetz** zur Regulierung künstlicher Intelligenz weltweit wurde im März 2024 verabschiedet, womit die meisten KI-Systeme bis 2026 den Anforderungen des Gesetzes entsprechen müssen.
- **Voraussetzungen für KI-Einsatz** für Hersteller, Anbieter, Händler und Nutzer.
- Ziel ist es, ein Gleichgewicht zu schaffen, um die Einführung von KI zu fördern und gleichzeitig die Rechte des Einzelnen auf eine **verantwortungsvolle, ethische und vertrauenswürdige Nutzung** zu wahren.
- Gemäß KI-Gesetz erfolgt eine Einteilung der Anwendung der **KI-Systeme nach Risikograden** abhängig von dem potenziellen Risiko, das sie für die Gesellschaft und Individuen darstellen.

Vier Risikogruppen nach KI-Gesetz

	Minimales Risiko	<ul style="list-style-type: none"> Keine zusätzlichen rechtlichen Verpflichtungen Anbieter solcher Systeme können freiwillig den Anforderungen an vertrauenswürdige KI nachkommen
	Geringes Risiko	<ul style="list-style-type: none"> Transparenzverpflichtungen, wenn bspw. Gefahr der Manipulation besteht (z.B. Chatbots)
	Hohes Risiko	<ul style="list-style-type: none"> KI-Systeme, die sich nachteilig auf die Sicherheit der Menschen oder ihre Grundrechte auswirken Kritische Bereiche wie Gesundheit, Verkehr, Bildung, Beruf Strenger Kriterienkatalog muss erfüllt sein
	Unannehmbares Risiko	<ul style="list-style-type: none"> Verbot schädlicher KI-Systeme, die Grundrechte verstoßen Keine biometrischen Echtzeit-Fernidentifizierungssysteme Kein „Social Scoring“

Risiko = Kombination aus der Wahrscheinlichkeit des Auftretens eines Schadens und der Schwere dieses Schadens

Credit Scoring als Hochrisiko-Anwendungsfall

- **KI-basierte Kreditwürdigkeitsprüfungen** durch Banken sowie Preis- und Risikobewertungen in der Lebens- und Krankenversicherung werden als **Hochrisiko-Anwendungsfälle** von KI angesehen. Daher müssen diese KI-Anwendungen **strengerer Anforderungen** genügen.
- Hohe Anforderungen, z.B. an Datenqualität, an Sicherheit, Funktionsweise, Dokumentation und Aufsicht durch Menschen sowie das Qualitäts- und Risikomanagement.
- KI-Systeme mit hohem Risiko werden sowohl vor dem Inverkehrbringen und während ihres gesamten Lebenszyklus bewertet.
- **Recht auf Beschwerde** über KI-Systeme und **Erklärung der Entscheidungen** auf Grundlage hochriskanter KI-Systeme.

Fazit und Ausblick

04

Digitale Spuren als Prognoseinstrument?

- Wissenschaftliche **empirische Evidenz belegt**, dass digitale Spuren durchaus **Vorhersagekraft** bei der Beurteilung der Kreditwürdigkeit aufweisen.
- In **Kombination** mit traditionellen Credit Scores können die **besten Ergebnisse** erzielt werden (Ergänzung und nicht Substitut).
- Aufgrund des regulatorischen Umfeldes und neuer Regulierungen wird allerdings der Einsatz bestimmter Daten erschwert bzw. verboten.
- Die **Repräsentativität und Relevanz der verwendeten Daten** und die **Erklärbarkeit der verwendeten KI-Modelle** rückt immer mehr in den Fokus.
- Neue Forschungszweige nehmen an Bedeutung zu („**Explainable AI**“).
- Trotz sehr **enger regulatorischer Grenzen** (v.a. bei Verbraucherkrediten) bietet der Einsatz digitaler Spuren im Credit Scoring **großes Potenzial** (z.B. Corporate Credit Ratings, Supply Chain Risk Management).

Vielen Dank für Ihre Aufmerksamkeit!

Prof. Dr. Tea Riedel
Professorin für International Finance

SRH Fernhochschule – The Mobile University
Kirchstraße 26
88499 Riedlingen
T +49 7371-93150
info@mobile-university.de
www.mobile-university.de

Literatur (1/2)

BaFin (2018): Big Data trifft auf künstliche Intelligenz.

BaFin und Bundesbank (2021): Maschinelles Lernen in Risikomodellen – Charakteristika und aufsichtliche Schwerpunkte.

Berg et al. (2019): On the Rise of FinTechs: Credit Scoring Using Digital Footprints, *Journal of Financial Studies*, 33, 2845-2897.

Chen and Chen (2022): Forecasting corporate credit ratings using big data from social media. *Expert Systems with Applications*. 207, 118042.

Cnudde et al. (2015): Who Cares About Your Facebook Friends? Credit Scoring for Microfinance, 2015018.

Dorfleitner et al. (2016): Description-text related soft information in peer-to-peer lending—evidence from two leading European platforms, *J. Bank. Finance*, 64, 169–187.

Fei et al. (2015): Credit Risk Evaluation Based on Social Media. *Procedia Computer Science*, 55, 725-731.

Gao et al. (2018): Words Matter: The Role of Texts in Online Credit Markets, *Journal of Financial and Quantitative Analysis*, 58 (1), 1-47.

Loutfi, A. (2022): A framework for evaluating the business deployability of digital footprint based models for consumer credit, *Journal of Business Research*, 152, 473-486.

Literatur (2/2)

Oskarsdottir et al. (2019): The value of big data for credit scoring: Enhancing financial inclusion using mobile phone data and social network analytics. *Applied Soft Computing*, 74, 26-39.

Parente, F. (2024): The AI Act and its impacts on the European financial sector.

Putra et al. (2020): A Credit Scoring Model for SMEs Based on Social Media Data. In: Bielikova, M., Mikkonen, T., Pautasso, C. (eds) *Web Engineering. ICWE 2020. Lecture Notes in Computer Science*, 12128, Springer.

Rozo et al. (2023): The role of web browsing in credit risk prediction. *Decision Support Systems*, 164, 113879.

Wu et al. (2020): Do consumer internet behaviours provide incremental information to predict credit default risk? *Econ. Poli. Stud.* 8 (4), 482-499.

Weber et al. (2023): Applications of Explainable Artificial Intelligence in Finance – a systematic review of Finance, Information Systems, and Computer Science literature. *Management Review Quarterly*, Springer.

World Bank (2012): *Can Digital Footprints Lead to Greater Financial Inclusion?*

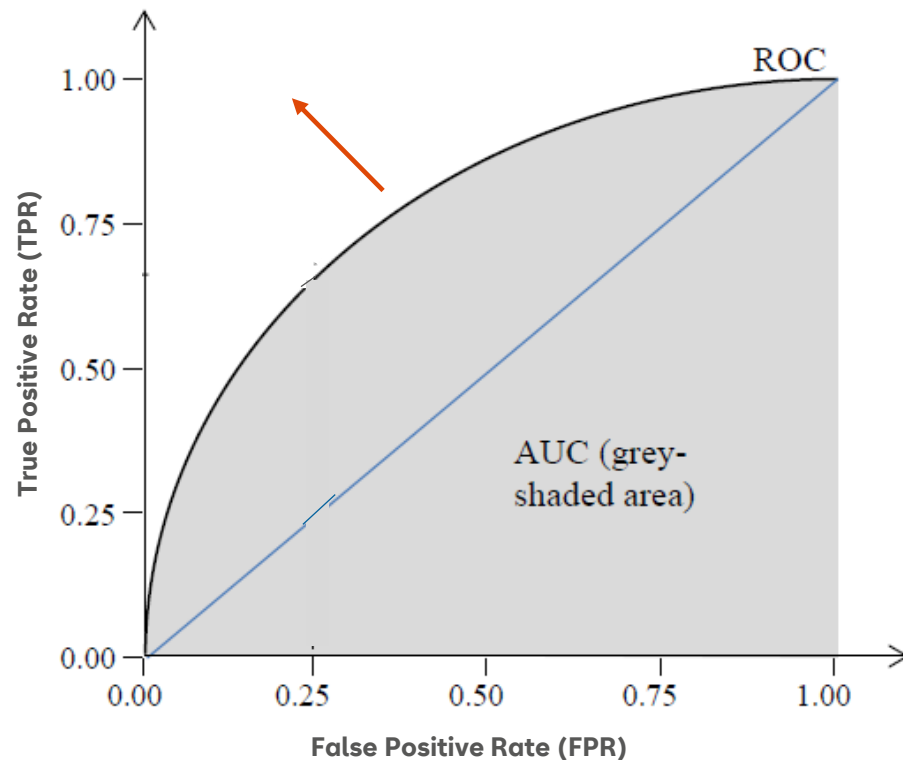
World Bank (2023): *Global Landscape: Data Trails of Digitally Included Poor (DIP) People.*

Anhang

Methodisches Vorgehen – Beurteilung der Trennschärfe

Methode: Viele Studien führen logistische Regressionen mit Default-Dummy als abhängige Variable durch.

Formale Analyse der Trennschärfe: Receiver Operating Characteristics (**ROC**) und Area-under-the-Curve (**AUC**)



Interpretation:

TPR = Anteil korrekt identifizierter positiver Fälle (Default) an allen tatsächlichen positiven Fällen im Datensatz.

FPR = Anteil tatsächlich negativer Fälle (kein Default), die fälschlicherweise positiv klassifiziert wurden.

AUC gibt Wahrscheinlichkeit an, dass ein zufällig ausgewählter positiver Fall eine höhere Wahrscheinlichkeit zugewiesen bekommt als ein zufällig ausgewählter negativer Fall, basierend auf dem Klassifikationsmodell.

AUC-Werte zwischen **[0 und 1]**, wobei ein Wert von 0,5 einem zufälligen Raten entspricht und Werte nahe 1 eine hohe Trennschärfe anzeigen.