

CONTROLLING

Herausgegeben von Ulrike Baumöl, Martin R. W. Hiebl, Andreas Hoffjan, Thorsten Knauer, Klaus Möller, Burkhard Pedell
Gegründet von Péter Horváth und Thomas Reichmann

www.zeitschrift-controlling.de

Juni 2023 · 35. Jahrgang · Verlage C.H.BECK · Vahlen · München · Frankfurt a.M.

3|2023

SCHWERPUNKT

BUSINESS CONTINUITY MANAGEMENT UND CONTROLLING

Durch vorausschauende Steuerung die Krisenreaktionsfähigkeit erhöhen

Kapitalmarktreaktionen auf
unternehmerische
Umweltverschmutzung

Business Impact-Analyse, Resilienz
und Controlling

Transparente Umweltbericht-
erstattung aus Sicht des
Controllings

In unruhigen Gewässern manövrieren.



Diederichs
Risikomanagement und Risikocontrolling
5. Auflage. 2023. 462 Seiten.
Gebunden € 79,-
ISBN 978-3-8006-6931-8
≡ vahlen.de/33736211

Gleißner
Grundlagen des Risikomanagements
4. Auflage. 2022. 786 Seiten.
Mit Software zur Risikoanalyse zum Download.
Gebunden € 65,-
ISBN 978-3-8006-6782-6
≡ vahlen.de/33282870

Crone/Werner
Modernes Sanierungsmanagement
6. Auflage. 2021. 644 Seiten.
Gebunden € 75,-
ISBN 978-3-8006-6591-4
≡ vahlen.de/32367908

Allert
Distressed M&A
2022. 341 Seiten.
Gebunden € 79,-
ISBN 978-3-8006-6586-0
≡ vahlen.de/32359859

Beyer/Kirchner-Khairy
Wert- und risikoorientiertes Controlling
2023. Rund 500 Seiten.
Kartoniert ca. € 39,80
ISBN 978-3-8006-5934-0
≡ vahlen.de/26280302

Jossé
Krisenmanagement und Business Continuity
2020. 108 Seiten.
Kartoniert € 18,90
ISBN 978-3-8006-6426-9
≡ vahlen.de/31347387

Durch die Zusammenarbeit von Business Continuity Management und Controlling die Resilienz des Unternehmens steigern

Liebe Leserinnen und Leser,

die Bedeutung organisationaler Resilienz muss vor dem Hintergrund der vielfältigen Krisen der jüngeren Vergangenheit sicherlich nicht mehr betont werden. Das Business Continuity Management, das im Fokus des vorliegenden Heftes steht, ist darauf ausgerichtet, die Fortführung der Geschäftstätigkeit und insbesondere die Bereitstellung der Produkte und Services des Unternehmens auch bei Eintreten schwerwiegender Ereignisse und Entwicklungen sicherzustellen. Kernelement ist die Business Impact-Analyse, die diejenigen Funktionen und Prozesse identifiziert, die dafür essenziell sind, und die Auswirkungen des Ausfalls von Ressourcen auf die Leistungserbringung abschätzt. Auf dieser Basis lassen sich dann auch – so weit, wie dies eben möglich ist – Mechanismen und Abläufe für das Management im Krisenfall ableiten und vorbereiten. Das Business Continuity Management hat somit große Potenziale, den Aufbau organisationaler Resilienz auf operativer Ebene voranzutreiben.

Das Controlling kann in vielfältiger Weise dazu beitragen, dass das Business Continuity Management und insbesondere die Business Impact-Analyse ihre Potenziale voll entfalten können. So kann es in der Konzeptionsphase bei der Priorisierung von Produkten und Services und bei der Ermittlung der Auswirkungen von Leistungsstörungen unterstützen. In der Implementierung kann es seine Kompetenzen in den Bereichen Planung, Informationsbeschaffung und kennzahlenbasierte Steuerung gewinnbringend einsetzen. Zusätzlich ist es dafür prädestiniert, Interdependenzen zwischen betroffenen Aktivitäten und Produkten zu analysieren und die Koordination mit dem Resilienzmanagement und anderen Unternehmensfunktionen herzustellen. Schließlich ist es auch im Krisenfall eine zentrale Stütze für das Management. Umgekehrt zieht das Controlling aus der Zusammenarbeit auch Vorteile, indem es Erkenntnisse für die Begleitung der Strategieentwicklung sowie für die Risikoidentifikation und die Prozessoptimierung gewinnt.

Im ersten Beitrag des Themenschwerpunkts erläutern *Melanie Kühlem* und ich zunächst die Vorgehensweise einer Business Impact-Analyse und diskutieren darauf aufbauend, welche Potenziale sie für den Aufbau von Resilienz im Unternehmen und in der Supply Chain hat. Abschließend analysieren wir, wie das Controlling dabei unterstützen kann, diese Potenziale zu heben. *Mike Bona-Stecki* widmet sich in seinem Beitrag dem Notfall- und Krisenmanagement in Banken. Ausgehend von den regulatorischen Rahmenbedingungen für Finanzdienstleister zeigt er die Anforderungen an das Notfallmanagement auf und erörtert, wie das Business Continuity Management im Gesamtkontext des Three Lines of Defense-Modells ausgestaltet werden sollte, um diese Anforderungen bestmöglich zu erfüllen.

Stefan Mayr, Alexander Josef Atzmüller und *Birgit Feldbauer-Durstmüller* betrachten Unternehmen, die in eine strategische Krise geraten und zum Sanierungsfall geworden sind. Anhand von zwei Sanierungsfällen aus der Unternehmenspraxis analysieren sie, wie das Sanierungsmanagement die Fortführung der Geschäftstätigkeit ermöglicht und wie ein Sanierungscontrolling dazu beitragen kann, einen stabilen Zustand herzustellen sowie eine strategische Neuausrichtung einzuleiten. Zum Abschluss des Themenschwerpunkts gibt Prof. Dr. *Christoph Müller*, Vorsitzender der Geschäftsführung der *Netze BW GmbH*, im Interview interessante Einblicke darin, wie ein Unternehmen, das zur kritischen Infrastruktur gehört, organisatorisch und steuerungsseitig mit den Herausforderungen der COVID-19-Pandemie umgegangen ist, um die Business Continuity sicherzustellen. Ausführlich geht er dabei auf die Bedeutung der Kommunikation nach innen und auf die Notwendigkeit ein, auch das private Umfeld der Mitarbeiterinnen und Mitarbeiter mit in das Business Continuity Management einzubeziehen, um für Krisenfälle gewappnet zu sein.

Ich wünsche Ihnen eine anregende und gewinnbringende Lektüre!

Ihr



Prof. Dr. **Burkhard Pedell** ist Inhaber des Lehrstuhls für Controlling an der Universität Stuttgart und Mitherausgeber der Zeitschrift *Controlling*.

Inhaltsübersicht

SCHWERPUNKT: Business Continuity Management und Controlling – Durch vorausschauende Steuerung die Krisenreaktionsfähigkeit erhöhen

Business Impact-Analyse, Resilienz und Controlling

Wie die Business Impact-Analyse mit Unterstützung durch das Controlling den Aufbau von Resilienz im Unternehmen und in der Supply Chain vorantreibt

Melanie Christine Kühlem, M. Sc., und Prof. Dr. Burkhard Pedell

4

Notfall- und Krisenmanagement in Banken

Aufbau eines Business Continuity Managements, Einordnung in die Organisation und besondere Herausforderungen im Finanzsektor

Mike Bona-Stecki, M. Sc.

13

Unternehmenssanierung aus Controlling-Sicht

Analyse anhand erfolgreicher Praxisfälle

Prof. Dr. Stefan Mayr, Mag. Alexander Josef Atzmüller, B. A., und Prof. Dr. Birgit Feldbauer-Durstmüller

21

Business Continuity im Fokus eines KRITIS-Unternehmens am Beispiel der Netze BW GmbH

Dr. Christoph Müller und Prof. Dr. Burkhard Pedell

27

Der Podcast zum Schwerpunkt dieses Heftes.

Prof. Dr. Burkhard Pedell im Interview unter

<https://bit.ly/zeitschrift-controlling-2023>



COMPACT

Biases in Controlling und Machine Learning

Wie sich Entscheidungsanomalien auswirken und bewältigen lassen

Andreas Oesinghaus, M. Sc.

31

Bestimmung des optimalen Aktienportfolios

Ein Machine-Learning-Ansatz in theoretischer Herleitung und praktischer Anwendung

Stefan Eckerle, Benedikt Gieger, Niklas Lederer, Raphael Rahn, Felix Werner und Prof. Dr. Philipp Pohl

35

WISSEN

Digitalisierung bei Corporate Mergers & Acquisitions

Entwicklung eines Reifegradmodells

Mirko Fischer, Dr. Alexander Herzfeldt, Dr. Sebastian Floerecke, Prof. Dr. Christoph Ertl, Prof. Dr. Hans-Martin Beyer und Michael Klawon

39

Kapitalmarktreaktionen auf unternehmerische Umweltverschmutzung

Eine Analyse der Informationsarten, Informationskanäle, Implikationen und Handlungsempfehlungen

Dr. Yassin Denis Bouzzine

48

Transparente Umweltberichterstattung aus Sicht des Controllings

Die Bedeutung von Greenwashing und wie das Controlling zu dessen Vermeidung beitragen kann

Prof. Dr. Christian Hofmann und Rafael M. Zacherl, MBR

53


IM DIALOG

Keep performing while transforming

Rolle der Finanzfunktion bei der GASAG AG in der Balance zwischen Transformation und Krisenbewältigung

Stefan Hadré und Prof. Dr. Burkhard Pedell

62



CONTROLLING UND DIGITALISIERUNG

KI im Controlling

Ann-Kathrin Gans, B. Sc. und Daniel Silveira Pereira, M. Sc.

67

LEXIKON

Relative Leistungsbeurteilung

Relative Performance Evaluation – RPE

Lisa Hörnig, M. Sc.

69

LITERATUR-TIPPS

Grundlagenliteratur zum Business Continuity Management/Fachbuch-Test

71

VERANSTALTUNGEN

Nachlese/Vorschau/Kongresse · Seminare · Workshops

75

Vorschau auf Heft 4/2023 und Impressum

80

Das aktuelle Heft · Archiv · Newsletter: www.zeitschrift-controlling.de



DIE HERAUSGEBER

Die *Controlling* gehört zu den wichtigsten Zeitschriften für Fach- und Führungskräfte im Finanz- und Rechnungswesen von Unternehmen und öffentlichen Institutionen. Sie liefert fundierte und anwendungsorientierte Beiträge für alle Controlling-Bereiche, zu allen Branchen und für unterschiedliche Unternehmensgrößen. Sie wird herausgegeben von:

Prof. Dr. Ulrike Baumöl, Executive Master of Business Engineering, Universität St. Gallen

Prof. Dr. Martin R. W. Hiebl, Lehrstuhl Management Accounting and Control, Universität Siegen

Prof. Dr. Andreas Hoffjan, Lehrstuhl Unternehmensrechnung und Controlling, Technische Universität Dortmund

Prof. Dr. Thorsten Knauer, Lehrstuhl Controlling, Ruhr-Universität Bochum

Prof. Dr. Klaus Möller, Lehrstuhl Controlling/Performance Management, Universität St. Gallen

Prof. Dr. Burkhard Pedell, Lehrstuhl für Controlling, Universität Stuttgart

Biases in Controlling und Machine Learning

Wie sich Entscheidungsanomalien auswirken und bewältigen lassen

Biases bzw. kognitive Verzerrungen begegnen uns täglich in verschiedenen Ausprägungen. Auch das Controlling ist betroffen – sowohl in den klassischen Funktionen und Methoden als auch bei neuen Technologien wie Machine Learning. Zur Vermeidung muss zunächst ein Bewusstsein für die Existenz und Entstehung von Biases geschaffen werden. Zudem sollten interne Kontrollen eingerichtet und Abläufe in Bezug auf die Anfälligkeit für Biases überprüft werden.

Andreas Oesinghaus

Andreas Oesinghaus, M. Sc. ist wissenschaftlicher Mitarbeiter und Doktorand am Lehrstuhl für Controlling/Performance Management der Universität St.Gallen.

1. Ursprung kognitiver Biases

Das menschliche Gehirn ist ein beeindruckendes Ergebnis der Evolution und enorm leistungsfähig. Jedoch hat das Gehirn Vereinfachungen entwickelt, um schnell auf neue Situationen reagieren zu können – früher absolut überlebenswichtig. Gesellschaft und Wirtschaft stellen inzwischen aber fundamental andere Herausforderungen, an die sich die menschlichen kognitiven Fähigkeiten jedoch (noch) nicht entsprechend anpassen konnten. Die kognitiven Verzerrungen, die aus diesen Vereinfachungen entstehen, sind vielfältig. Eines der prominentesten Beispiele ist die von *Kahnemann/Tversky* (1979) erforschte „Prospect-Theory“ die besagt, dass Verluste relativ zu einem Referenzpunkt stärker empfunden werden als Gewinne. Ein anderes Beispiel ist die „Availability Heuristic“ – Die Wahrscheinlichkeit eines Events wird höher eingeschätzt, wenn wir uns besser an Beispiele dessen erinnern können (*Tversky/Kahneman*, 1973). Zwar sind Controlling und Business Analytics die Funktionen, die datengetrieben arbeiten und die Rationalität von Entscheidungen sicherstellen sollen, jedoch bleiben auch diese nicht von Biases verschont.

2. Biases im Controlling und entsprechende Maßnahmen

Das Controlling als Business Partner des Managements bereitet Entscheidungen vor, koordiniert und stellt die Rationalität der Entscheidungen si-

cher. Folglich können Biases in diesem Umfeld großen Schaden verursachen. Sind diese bewusst, kann damit offen umgegangen und gegengesteuert werden. Folgende Beispiele zeigen die Bandbreite von Biases im Controlling.

Strategieimplementierung

Manager möchten glauben, dass die von ihnen gewählten und ausgeführten Initiativen erfolgreich sind. Entsprechend kann deren Interpretation von Kennzahlen verzerrt sein. Dieses „Motivated Reasoning“ beschreibt, dass Menschen in einer Weise Informationen akquirieren, bewerten und nutzen die mit ihren Wünschen und Zielen übereinstimmt. Trotz gleicher Datenlage und sogar ohne finanzielle Anreize tendieren Manager dazu, die von ihnen ausgewählten Initiativen besser zu bewerten (*Emett/Tayler*, 2013), was dazu führen kann, dass Initiativen weiterverfolgt werden, die eigentlich gestoppt werden sollten.

Das Controlling kann Maßnahmen ergreifen, um diesen Bias zu vermeiden: Erstens sollten Manager in die Auswahl der Kennzahlen involviert sein, mit denen ihre Initiative bewertet wird. Dadurch wird eine spätere andere Interpretation verhindert. Der Effekt von Motivated Reasoning auf die Initiative, wird so durch den Effekt von Motivated Reasoning auf die Kennzahlen ausgeglichen. Zweitens ist ein gutes Verständnis des großen Ganzen und der Zielhierarchie wichtig. So wird sichergestellt, dass die Kennzahlen auf die übergeordneten Ziele lenken (*Emett/Tayler*, 2013).

Forecasting

Ein anderes Beispiel ist das Bilden von Erwartungshaltungen. Hier spielen verschiedene Verfälschungen eine Rolle, am relevantesten sind „Availability Heuristic“ und „Representativeness Heuristic“. Bei ersterer wird unterbewusst die Verfügbarkeit der Erinnerung und bei letzterem die Ähnlichkeit zu einer Referenz als Grundlage für die Einschätzung der Wahrscheinlichkeit eines Events verwendet.

So wird z. B. bei der Erwartungshaltung über die Entwicklung eines Rohstoffpreises unterbewusst die vergangene Entwicklung einbezogen. Oft ein hilfreicher Referenzpunkt, ist die Vergangenheit jedoch nicht immer ein guter Indikator für zukünftige Entwicklungen. Jedoch verleitet die „Availability Heuristic“ dazu, die näher zurückliegende Entwicklung stärker zu berücksichtigen und durch die „Representativeness Heuristic“ wird davon ausgegangen, dass sich die zukünftige der vergangenen Entwicklung ähnelt. Das resultiert darin, dass Menschen tendenziell erwarten, dass sich positive Trends positiv und negative Trends negativ fortsetzen. Dieser Effekt wurde empirisch bereits zahlreich nachgewiesen, unter anderem bei Rohstoffen, Aktien, Inflationsraten und Immobilien.

Generell kann die Anfälligkeit für Biases nicht vermieden werden. Es gibt jedoch Hebel, um die Auswirkungen der Biases zu entschärfen. Ein erster Schritt ist, sich der Biases bewusst zu werden und die Entstehung der Erwartungshaltung nachzuvollziehen. Dabei kann es hilfreich sein, die Historie bewusst auszublenden und den Fokus auf Daten zu legen die einen direkten Bezug zur zukünftigen Entwicklung haben. Zudem sollte immer eine gegenseitige Validierung von menschlichem und datengetriebenem Forecast erfolgen.

Performance Review

Ein abschließendes Beispiel bezieht sich auf Performance Reviews. Typischerweise werden zuerst die Mitarbeiter gebeten, ihre Leistungen selbst einzuschätzen. Danach schreibt der Vorgesetzte eine Bewertung der Mitarbeiter. Viele dieser Formulare enthalten Boxen für Freitext, um eine personalisierte Bewertung mit Kritik und Vorschlägen zu formulieren. Studien haben jedoch gezeigt, dass bei Freitext die herangezogenen Kriterien und deren Priorisierung je nach bewertetem Mitarbeiter stark variieren. Zudem bekamen Männer tendenziell längere Reviews mit Fokus auf technische Fähigkeiten während sich Reviews von Frauen eher auf deren Kommunikation bezogen (Mackenzie et al., 2019).

Zur Vermeidung dieser Biases liegt die Abschaffung von Freitext nahe. Aufgrund der Möglichkeit für personalisierte Kritik sollte davon jedoch abgesehen werden. Vielmehr sollte beim Erstellen des Freitexts sichergestellt werden, dass für alle die gleichen Kriterien gelten. Dies kann zum Beispiel

mit einer Checkliste der zu berücksichtigenden Kriterien erfolgen.

Diese drei Beispiele zeigen, wie groß die Bandbreite und der Einfluss von Biases sein kann. Ein wichtiger erster Schritt ist immer das Bewusstsein für die Existenz dieser Biases zu schaffen.

3. Biases im Machine Learning und entsprechende Maßnahmen

Machine Learning (ML) ist inzwischen fester Bestandteil von Business Analytics in verschiedenen Bereichen. ML erlernt Muster aus Daten und kann diese anschließend verallgemeinert auf neue Daten anwenden. Die im vorherigen Abschnitt entscheidende Komponente Mensch spielt auf den ersten Blick keine Rolle. Jedoch können Biases auch beim ML auftreten.

Ein Beispiel, um eine Form der Entstehung von Biases im ML zu erläutern – zugegeben weit weg von typischen Anwendungen im Controlling, dafür umso anschaulicher – ist die Bilderkennung in der militärischen Anwendung. Es sollte ein ML Modell entwickelt werden, das auf Bildern freundliche von feindlichen Fahrzeugen unterscheiden kann. Beim Einsatz im Feld wurde jedoch eine schlechte Trefferquote festgestellt. Bei der Analyse der Daten, mit denen das ML Modell trainiert und getestet wurde, wurde festgestellt, dass Bilder von freundlichen Fahrzeugen fast ausschliesslich bei klarem Himmel, und Bilder von feindlichen Fahrzeugen fast ausschliesslich bei bewölktem Himmel aufgenommen wurden. Folglich hat das Modell gelernt die Klassifizierung anhand des Himmels vorzunehmen, nicht anhand der Fahrzeuge (vgl. Freitas, 2014).

Ein weiteres Beispiel, nun aus dem Business Analytics Umfeld, bezieht sich auf ein ML Modell, um online Angebotspreise festzulegen. Wie vom *Wall Street Journal* (Valentino-DeVries et al., 2012) berichtet hat ein Anbieter von Büroartikeln ML eingesetzt um je nach Standort des Kunden einen individualisierten Preis anbieten zu können. Dafür wurde unter anderem die Distanz zum nächsten Konkurrenten als Proxy für die Wettbewerbsintensität herangezogen. Dabei ist jedoch aufgefallen, dass Kunden aus ärmeren Regionen tendenziell höhere Preise bekommen als Kunden aus wohlhabenden Regionen.

Beispiele wie diese, bei dem ML Modelle Biases unterliegen und teilweise im Ergebnis sogar diskriminierend sind, gibt es viele. Zur Identifikation und Vermeidung von Biases beim Einsatz von ML gibt es entlang der Schritte der Entwicklung von ML Modellen verschiedene Ansatzpunkte (nach Fahse et al., 2021):

- **Sozial:** Ein sozialer Bias entsteht, wenn die Daten die in der Gesellschaft (also der Grundgesamtheit) vorhandenen Biases widerspiegeln. Ist eine Übertragung des Bias in das ML Modell

nicht gewünscht, sollten die Daten angepasst werden. In der Betrugsfallerkennung z. B. sind typischerweise >90 % der Daten „normale“ Fälle. Um den dadurch entstehenden Bias zu verringern, kann das Datenset ausgeglichen werden.

- **Messung:** Die Zielvariable sowie die herangezogenen Features werden durch Menschen definiert. Durch die Auswahl von imperfekten Proxies für die tatsächlich zugrundeliegende Problemstellung, kann nicht nur die Performance des Modells signifikant beeinflusst werden, sondern es können auch Biases entstehen.
- **Repräsentation:** Die verwendeten Daten sollten in den relevanten Dimensionen repräsentativ für die Grundgesamtheit sein. Wenn die Stichprobe nicht repräsentativ ist, sind Biases wahrscheinlich und die Genauigkeit des Modells beeinträchtigt. Gründe hierfür können in der Datenerhebung oder -verarbeitung liegen oder daran, dass sich die Welt zwischen Datenerhebung und Einsatz des Modells verändert hat, sodass die Daten nicht mehr repräsentativ für die Grundgesamtheit sind.
- **Label:** Zur Vorbereitung der Daten müssen oft Label für die einzelnen Datenpunkte vergeben werden. Z. B. in der Bilderkennung, muss dem ML-Modell mittels Labels zu verstehen gegeben werden was auf dem Bild zu sehen ist. Die Vergabe der Labels ist oft nicht eindeutig, sondern unterliegt subjektiven Einflüssen. Dadurch können menschliche Biases in das Datenset übertragen werden. Es empfiehlt sich daher jeden Datenpunkt von mehreren Menschen bewerten zu lassen und ein diverses Team einzusetzen.
- **Algorithmik:** Datensets bestehen häufig nicht ausschließlich aus quantitativen Datenpunkten. Oft müssen Daten übersetzt werden, sodass sie für ML verwendet werden können. Klassifikationen z. B. müssen erst in quantitative Faktoren transformiert werden, wobei unbewusst Biases in ein Datenset eingebracht werden können.
- **Evaluation:** ML Modelle werden anhand eines Training-Datensets trainiert und anhand eines Test-Datensets validiert und optimiert. Entspricht das Test-Datenset nicht den Charakteristika der Grundgesamtheit, wird das Modell nur auf ein Subset der Daten optimiert und Biases können entstehen.
- **Deployment:** Wird das ML Modell in einem anderen Zusammenhang verwendet als bei der Entwicklung vorgesehen, können ebenfalls Biases auftreten. Ein Modell, das die Wahrscheinlichkeit für den Zahlungsausfall von Kunden bewertet, für eine Annäherung des Zeitpunkts der Zahlung einzusetzen, liegt nahe, würde jedoch Verzerrungen unterliegen.
- **Feedback:** Nach der Implementierung eines ML Modells sollte das Modell nach und nach opti-

miert und regelmäßig überprüft werden. Wird jedoch das Ergebnis des Modells als Input für die Optimierung verwendet, können sich Biases verstärken. Sortiert ein ML Modell z. B. Artikel für einen Online-Shop unter anderem auf Basis der Anzahl der Klicks, variieren die resultierenden Klicks mit der Sortierung der Artikel. Eine Optimierung des Modells anhand der in der Zwischenzeit generierten Daten würde diesen Effekt nach und nach verstärken und so einen Bias zugunsten der gut platzierten Artikel hervorrufen.

Neben diesen konkreten Aspekten entlang der Schritte von ML, gibt es übergreifende Ansatzpunkte zur Vermeidung von Biases. Erstens sollte versucht werden die Funktionsweise und Ergebnisse von ML Modellen verständlich, erklärbar und interpretierbar zu machen. So ist es z. B. hilfreich zu wissen, anhand welcher Features der Daten das Modell bestimmte Aussagen trifft. Wäre ersichtlich gewesen, dass das Modell zur Erkennung der Militärfahrzeuge sich hauptsächlich auf die Farben des Himmels verlässt, wäre der Fehler früher erkannt worden. Jedoch muss darauf hingewiesen werden, dass interpretierbare Modelle tendenziell eine schlechtere Performance aufweisen als Black-Box Modelle, da diese deutlich komplexer sein können. Zweitens sollten interne Kontrollen eingesetzt werden, um die Qualität der entwickelten ML-Modelle sicherzustellen und diese nach der Implementierung regelmäßig zu prüfen. Drittens sollte das Bewusstsein für Biases geschärft werden. Zum einen ist es für die Data Scientists, die das Modell entwickeln, wichtig, in alle relevanten Diskussionen involviert zu sein, um das Verständnis für das Einsatzgebiet und die Zielsetzung zu stärken. Zum anderen sollte das Team möglichst divers sein und verschiedene fachliche und kulturelle Hintergründe vereinen.

4. Fazit

So datengetrieben das Controlling auch ist, es ist dennoch anfällig für Biases. Sowohl in den klassischen Methoden und Funktionen des Controllings als auch im für das Controlling noch neuen ML können Biases auftreten. Ansätze zur Identifikation und Vermeidung sind ähnlich vielfältig wie die Ursprünge der Biases. Als Grundlage für alle weiteren Maßnahmen ist es wichtig, ein Bewusstsein für die Existenz und die Ursprünge von Biases zu entwickeln. Zudem ist Aufklärung hinsichtlich der Funktionsweise und Vermeidung von Biases notwendig.

Literatur

- Emett, S. A./Tayler, W. B. (2013). Is Your Strategy Evaluation Biased? *Strategic Finance*, 95(5), 27–34.

- Fahse, T., Huber, V./van Giffen, B. (2021, 2021/03/09/). Managing Bias in Machine Learning Projects
- Freitas, A. A. (2014). Comprehensible classification Models: a position paper. *ACM SIGKDD Explorations Newsletter*, 15(1), 1–10.
- Kahneman, D./Tversky, A. (1979). Prospect Theory: An Analysis of Decision under Risk. *Econometrica*, 47(2), 263–292.
- Mackenzie, L. N./Wehner, J./Correll, S. J. (2019). Why Most Performance Evaluations Are Biased, and How to Fix Them. *Harvard Business Review*.
- Tversky, A./Kahneman, D. (1973). Availability: A heuristic for judging frequency and probability. *Cognitive Psychology*, 5, 207–232.
- Valentino-DeVries, J./Singer-Vine, J./Soltani, A. (2012, 2012/12/24). Websites Vary Prices, Deals Based on Users' Information. *The Wallstreet Journal*.