

MARCO SCHREYER
 MARCEL BAUMGARTNER
 T. FLEMMING RUUD
 DAMIAN BORTH

KÜNSTLICHE INTELLIGENZ IM INTERNAL AUDIT ALS BEITRAG ZUR EFFEKTIVEN GOVERNANCE

Deep-Learning-basierte Detektion von Buchungsanomalien in der Revisionspraxis

Die technologischen Fortschritte der künstlichen Intelligenz (KI) etablieren sich zunehmend als wertvolles Werkzeug für den internen Audit. Der nachfolgende Beitrag soll Anwendungsmöglichkeiten und Herausforderungen des Deep Learning, einer vergleichsweise jungen Teildisziplin der KI, anhand eines Praxisbeispiels der Nestlé S.A. aufzeigen.*

1. INTERNAL AUDIT UND TECHNOLOGISCHER WANDEL


Die aktuellen Entwicklungen in der Informationstechnologie, wie bspw. Cloud Computing, künstliche Intelligenz und das Internet der Dinge, resultieren derzeit in einer Vielzahl von unternehmerischen Bestrebungen, Geschäftsprozesse schrittweise zu digitalisieren. Diese digitale Transformation umfasst auch Enterprise-Resource-Planning (ERP)-Systeme und verändert nachhaltig die Erhebung digitaler Prüfnachweise. Bereits heute erfassen ERP-Systeme eine Vielzahl der für den internen Audit relevanten Informationen, wie z. B. Journalbuchungen, Prozessprotokolle oder Konzepte der organisatorischen Funktionstrennung. Art und Umfang der gespeicherten Unternehmensdaten ermöglichen die Anwendung neuartiger und digitaler Prüfverfahren, welche wesentlich zu einer Steigerung von Effektivität und Effizienz des internen und externen Audits beitragen können.

Entsprechend der Definition des Institute of Internal Auditors (IIA) erbringt der interne Audit «unabhängige und objektive Prüfungs- und Beratungsdienstleistungen, welche darauf ausgerichtet sind, Mehrwerte zu schaffen und Geschäftsprozesse zu verbessern» [1]. Zugleich sind Revisorinnen und Revisoren im Rahmen ihrer beruflichen Sorgfaltspflicht angehalten, den Einsatz technologiegestützter Datenanalyseverfahren zu berücksichtigen [2]. Um dieser Anforderung zu entsprechen und im Zeitalter einer zunehmend digitalisier-

ten Wirtschaft objektive und umfassende Prüfnachweise zu erbringen, ist der Berufsstand gefordert, innovativ zu handeln und etablierte Prüfverfahren kontinuierlich weiterzuentwickeln [3]. Infolgedessen investiert die Revisionspraxis zunehmend in den Aufbau von prüferischen Fähigkeiten im Bereich der KI [4]. Das zweckmässige Nutzen zeitgemässer Verfahren der KI durch den internen Audit verspricht, einen Beitrag zu objektiven und risikoorientierten Prüfergebnissen zu leisten [5].

2. KÜNSTLICHE INTELLIGENZ, MACHINE LEARNING UND DEEP LEARNING

Im Allgemeinen hat die KI zum Ziel, die kognitiven Fähigkeiten menschlicher Intelligenz zu modellieren, um selbstlernend intellektuelle Aufgaben zu bewerkstelligen [6]. Teilgebiete der KI umfassen u. a. das Machine Learning (ML). Der Begriff des ML bezeichnet ein Verfahren, das Computern die Fähigkeit verleiht, selbstständig, d. h. ohne explizite menschliche Anleitung bzw. Programmierung, ein oder mehrere Modelle für das Lösen einer Aufgabenstellung zu erlernen [7]. Die Eigenschaft des selbstständigen Lernens beschreibt den Umstand, dass sich die Modellqualität durch das Zuführen von Informationen bzw. Daten im Zeitverlauf kontinuierlich verbessern kann [8]. Im Rahmen eines solchen Lernprozesses ist das ML-Verfahren angehalten, relevante Zusammenhänge in den Daten zu erkennen, um aus diesen ein gewünschtes Lösungsverhalten abzuleiten.

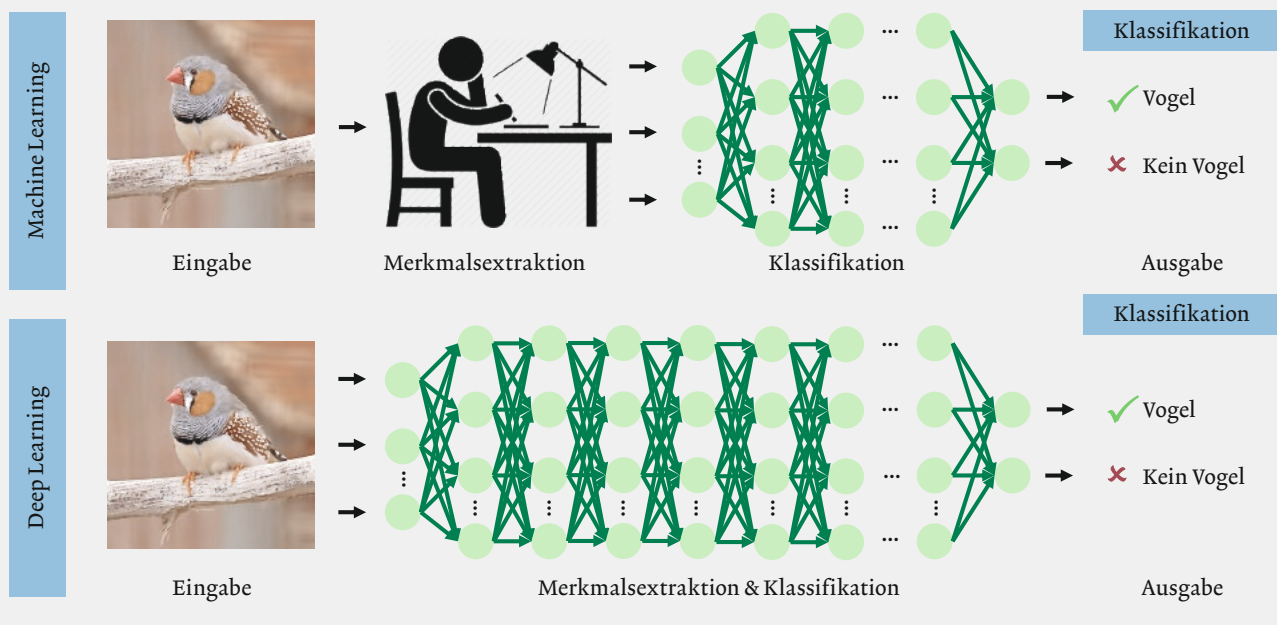


MARCO SCHREYER,
 WISSENSCHAFTLICHER
 MITARBEITER, LEHR-
 STUHL FÜR KÜNSTLICHE
 INTELLIGENZ UND
 MASCHINELLES LERNEN,
 INSTITUTE OF COMPUTER
 SCIENCE (ICS), UNIVERSITÄT
 ST. GALLEN



MARCEL BAUMGARTNER,
 STATISTIKER,
 DATA ANALYTICS EXPERTE,
 NESTLÉ INTERNAL AUDIT,
 SOCIÉTÉ DES PRODUITS
 NESTLÉ S.A.

Abbildung 1: **BILDKLASSIFIKATION DURCH MACHINE LEARNING (OBEN) UND DEEP LEARNING (UNTEN)** [9]



Im Kontext klassischer ML-Verfahren, z. B. dem Verfahren der Regression oder der Klassifikation, wird der Lernerfolg in hohem Grad durch den Umfang der eingebrachten menschlichen Expertise determiniert. Dieses Fachwissen ist notwendig, um in einem dem maschinellen Lernprozess vorgelagerten Schritt die für das zu erlernende Modell relevanten Datenmerkmale manuell aus den Rohdaten zu extrahieren bzw. aufzubereiten (vgl. *Abbildung 1* oben). Die aufbereitete Datenrepräsentation ermöglicht es, ML-Verfahren, Zusammenhänge in den Daten zu erkennen, um eine zuvor definierte Aufgabenstellung (z. B. die Klassifikation von Bildern) erfolgreich zu lösen. Die aufbereiteten Merkmale beeinflussen unmittelbar den Lernerfolg und die Ergebnisqualität des ML-Verfahrens.

Eine disruptive Weiterentwicklung dieser klassischen ML-Verfahren findet sich in der Teildisziplin des sog. Deep Learning (DL). Im Allgemeinen bezeichnen DL-Verfahren den Einsatz selbstlernender künstlicher neuronaler Netze. Hierbei handelt es sich um ein biologisch inspiriertes Verfahren, das sich an Aufbau und Funktionsweise des menschlichen Gehirns orientiert, um «intelligentes» Verhalten zu imitieren. In Analogie zu den Neuronen des menschlichen Kortex bestehen DL-Verfahren aus einer Vielzahl von Schichten

miteinander verknüpfter künstlicher Neuronen [10]. Das Attribut «tief» bezieht sich auf die hohe Anzahl von oftmals bis zu mehreren hundert Schichten künstlicher Neuronen. Zugleich ist die Grundidee des DL nicht neu und lässt sich auf die Entwicklung künstlicher neuronaler Netze [11] bzw. Neuronen [12] in den 1940er- bis 1950er-Jahren zurückführen. Die heutige erfolgreiche Renaissance tiefer künstlicher neuronaler Netze beruht im Wesentlichen auf:

- der Verfügbarkeit umfangreicher und auswertbarer Datenbestände;
- der Weiterentwicklung künstlicher neuronaler Netzarchitekturen; sowie
- der Verfügbarkeit leistungsstarker Prozessoren.

Im Unterschied zu den zuvor beschriebenen klassischen ML-Verfahren verfügen DL-Verfahren über die Fähigkeit, die für eine Aufgabenstellung relevanten Merkmale selbstständig aus den Rohdaten zu extrahieren (vgl. *Abbildung 1* unten). Eine manuelle Aufbereitung von Datenmerkmalen durch den Menschen entfällt. Ein solches synchrones Lernen relevanter Datenmerkmale und abgeleitetes Lösungsverhalten für eine Aufgabenstellung wird als sog. *End-to-end Learning* bezeichnet [13]. Zugleich ermöglichen DL-Verfahren, im Ver-



T. FLEMMING RUUD,
 PROF. EM., PH.D., WP (N),
 EMERITIERTER PROFESSOR
 FÜR BETRIEBSWIRTSCHAFTSLEHRE (INTERNAL
 AUDIT, INTERNAL CONTROL),
 UNIVERSITÄT ST. GALLEN



DAMIAN BORTH,
 PROF. DR., LEHRSTUHL FÜR
 KÜNSTLICHE INTELLIGENZ
 UND MASCHINELLES
 LERNEN, DIREKTOR AM
 INSTITUTE OF COMPUTER
 SCIENCE (ICS),
 UNIVERSITÄT ST. GALLEN

gleich zu den traditionell im internen Audit angewandten hypothesenbasierten Analyseverfahren, ein hypothesenfreies sog. *Unsupervised Learning* aus betriebswirtschaftlichen Datensätzen. Die Synthese beider Lernverfahren ermöglicht DL-Verfahren das selbstständige Erkennen von Regelmäßigkeiten z. B. in umfangreichen digitalen Journalbuchungen. Die zielgerichtete Kombination von End-to-end und Unsupervised Learning stellt deshalb eine wertvolle Ergänzung des Kanons revisorischer Datenanalysen dar [14].

Eine Anwendung solcher Lernverfahren soll im Folgenden anhand eines Praxisbeispiels zum Erkennen ungewöhnlicher Journalbuchungen, sog. Anomalien, in einer ERP-systembasierten Finanzbuchhaltung erläutert werden.

3. TIEFE NEURONALE AUTOENCODER-NETZE IM INTERNEN AUDIT

Im Kontext revisorischer Datenanalysen wird grundsätzlich angenommen, dass fehlerhafte oder unternehmensschädigende Handlungen Ausnahmetatbestände darstellen, die von den gewöhnlichen Handlungsmustern eines Unternehmens abweichen. Ein solches abweichendes Handeln wird innerhalb von ERP-Systemen durch ungewöhnliche Merkmalsausprägungen einer geringen Anzahl von Journalbuchungen erfasst, z. B. durch von der Regel abweichende kreditorsche Bankverbindungen oder Erfassungszeiten. Zugleich lässt eine Betrachtung der in ERP-Systemen erfassten Journalbuchungen die nachfolgenden charakteristischen Merkmalseigenschaften erkennen [15]:

→ Die umfangreiche Anzahl unterschiedlicher *Merkmalsausprägungen*, z. B. die Vielzahl der innerhalb von Journalbuchungen gebuchten Kreditoren, Hauptbuchkonten oder Belegarten.

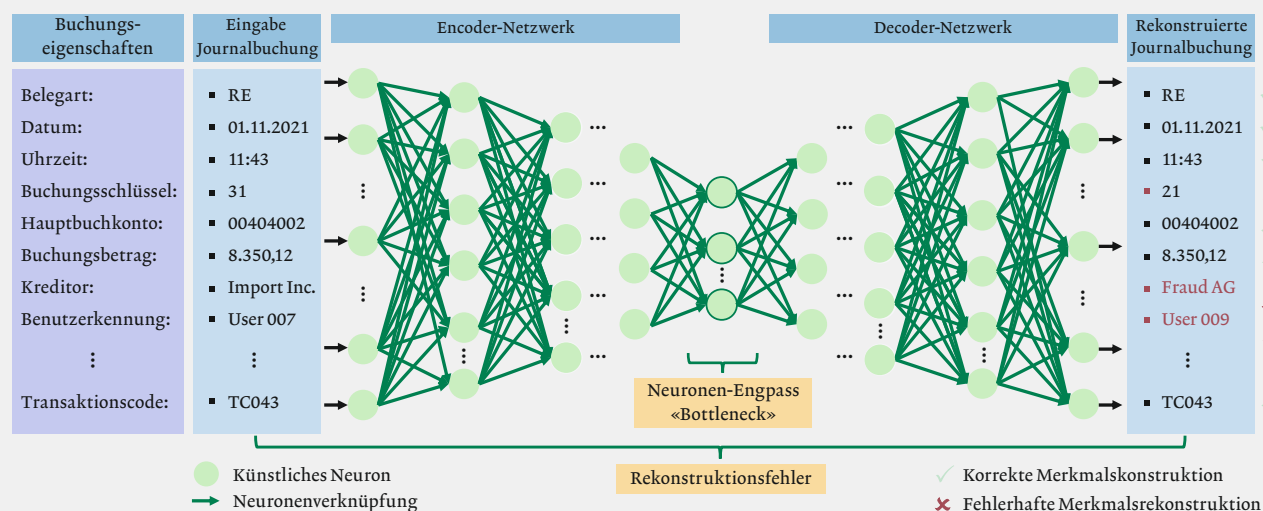
→ Die umfangreiche Anzahl unterschiedlicher *Merkmalsbeziehungen*, z. B. die Vielzahl der innerhalb von Journalbuchungen in Kombination gebuchten Belegarten, Buchungsschlüssel und Hauptbuchkonten.

Die Anwendung von DL-Verfahren ermöglichen (im Kontext des internen Audits) das Erlernen eines präzisen, nichtlinearen Modells beider Charakteristika (Ausprägung und Beziehung). Eine für das Unsupervised End-to-end Learning für das Erkennen komplexer Merkmalseigenschaften besonders geeignete Netzarchitektur findet sich in sog. tiefen neuronalen Autoencoder-Netzen (im Folgenden als Autoencoder bezeichnet).

Autoencoder bestehen aus zwei miteinander verknüpften neuronalen Netzen, die als Encoder- bzw. Decoder-Netzwerk bezeichnet werden [16]. Im Regelfall weisen beide Netze eine symmetrische Architektur auf und umfassen jeweils eine Vielzahl von Schichten künstlicher Neuronen. *Abbildung 2* zeigt die schematische Architektur eines Autoencoders. Die Zielsetzung des Autoencoder-Trainings besteht in der möglichst fehlerfreien Rekonstruktion der zugeführten Journalbuchungen. Um zu verhindern, dass der Autoencoder lediglich die zugeführten Buchungsmerkmale von der Eingabeschicht an die Ausgabeschicht weiterleitet, determiniert ein Bottleneck die Schnittstelle zwischen Encoder- und Decoder-Netzwerk. Die Modellierung des Engpasses erfolgt anhand einer signifikanten Reduktion der Neuronenanzahl in den inneren Netzwerkschichten und limitiert hierdurch die Lernkapazität des Autoencoders.

Im Verlauf des fortschreitenden Netzwerktrainings gelingt es dem Autoencoder, die in der Mehrheit der Journalbuchung enthaltenen Merkmalsausprägungen und -beziehungen zu erlernen [17]. Hierdurch ist der Autoencoder zunehmend in der Lage, die gewöhnlichen Buchungen der Finanzbuchhaltung nahezu fehlerfrei zu rekonstruieren. Zugleich können Anomalien, d. h. sehr seltene Merkmalsausprägungen und -beziehungen, aufgrund der limitierten Lernkapazität der inneren Netzwerkschichten nicht gelernt werden. Dies hat zur Folge, dass ungewöhnliche Buchungen einen erhöhten Rekonstruktionsfehler aufweisen. Die Höhe des Fehlers kann als Massstab für den Grad der unerwarteten Abweichung einer Journalbuchung von den gewöhnlichen Buchungsaktivitäten interpretiert werden. Anhand dieses

Abbildung 2: SCHEMATISCHER AUFBAU EINES TIEFEN NEURONALEN AUTOENCODER-NETZES UND BEISPIELHAFTER REKONSTRUKTION EINER JOURNALBUCHUNG [17]



Kriteriums ist es am Ende des Trainingsprozesses möglich, reguläre Journalbuchungen von Anomalien zu unterscheiden. Die praktische Anwendung eines solchen DL-Verfahrens wird im nachfolgenden anhand eines praktischen Beispiels bei Nestlé erläutert.

4. DETEKTION VON BUCHUNGSANOMALIEN DURCH DEN INTERNEN AUDIT DER NESTLÉ S.A.

Innerhalb des internen Audits der Nestlé S.A. werden datenanalytische Prüfverfahren seit mehr als zehn Jahren angewandt. In diesem Kontext wird u. a. zunehmend auch die Entwicklung analytischer Prüfverfahren auf der Grundlage von KI forciert. Aufgrund des weitreichenden Einsatzes von SAP-ERP-Systemen innerhalb der Nestlé-Landesgesellschaften steht die Analyse von digitalen Journalbuchungen im Fokus des prüferischen Vorgehens. Dabei werden die Buchungen grundsätzlich prozessual betrachtet unterschieden, z. B. in Buchungen des Einkaufsprozesses (Accounts Payables, SAP T-Code: FBL1N) und des Verkaufsprozesses (Accounts Receivables, SAP T-Code: FBL5N). Das durch den internen Audit zu prüfende Buchungsvolumen im Vertrieb einer Landesgesellschaft, wie z. B. der Nestlé Schweiz, umfasst mehr als eine halbe Million Journalbuchungen pro Geschäftsjahr.

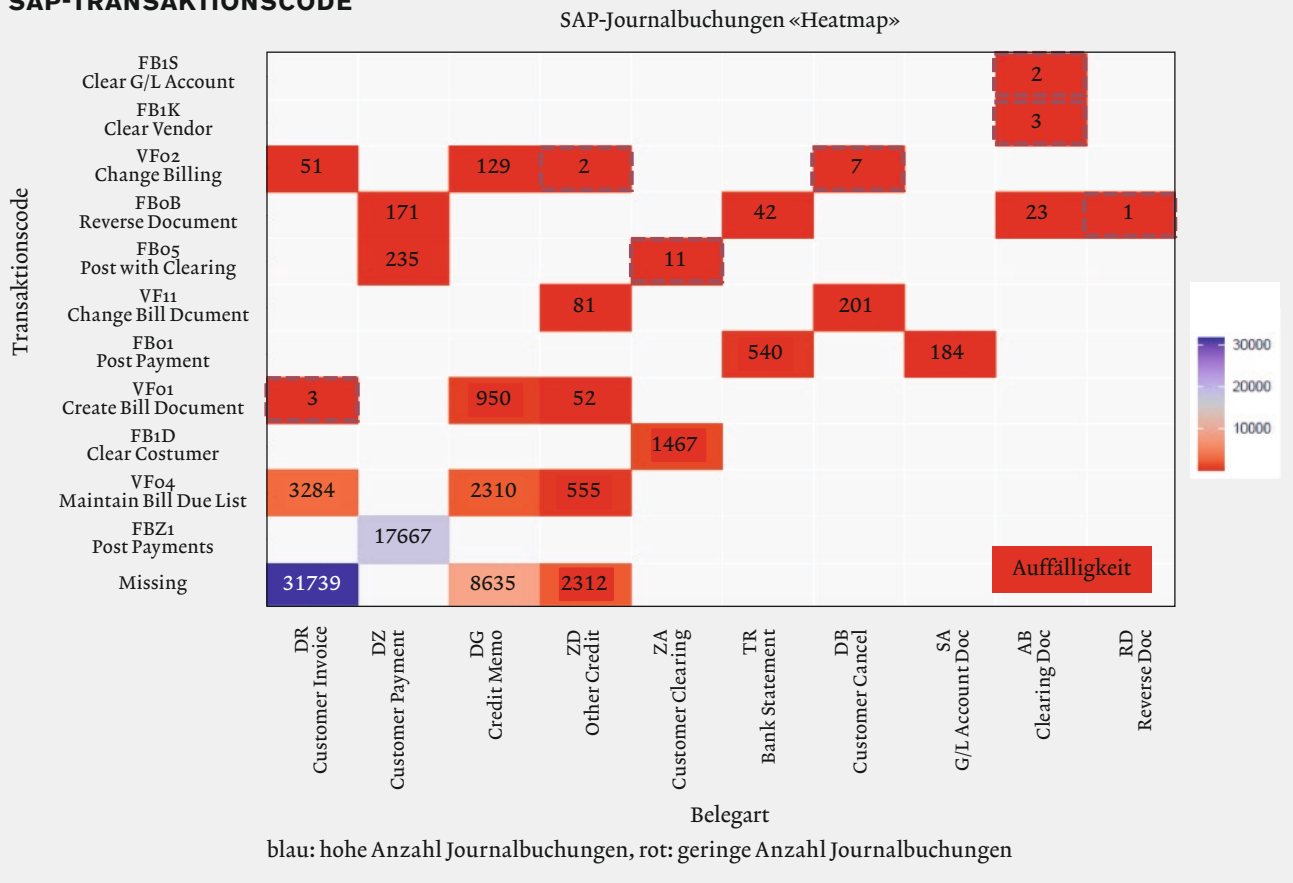
Im Rahmen der turnusgemäss stattfindenden Revision ausgewählter Nestlé-S.A.-Landesgesellschaften werden datenanalytische Prüfverfahren vor der Entsendung der jeweiligen Prüfungsteams durchgeführt. Zielsetzung der Analy-

sen ist es u. a., Anomalien in den Journalbuchungen der zu prüfenden Gesellschaft zu identifizieren und eine zielgerichtete Stichprobe ermittelter Auffälligkeiten abzuleiten. Den entsandten Prüfungsteams obliegt es anschliessend, vor Ort in der jeweiligen Landesgesellschaft, eine substantielle Prüfung der auffälligen Buchungen durchzuführen. Das Vorgehensmodell für das Ermitteln von Buchungsanomalien lässt sich im Wesentlichen in die drei nachfolgend beschriebenen Phasen untergliedern:

Phase 1: Extraktion, Validierung und Aufbereitung der Buchungsdaten

Innerhalb der ersten Phase werden Buchungsdaten der zu prüfenden Landesgesellschaft aus den zentralen SAP-ERP-Systemen exportiert, validiert und für nachfolgende Analysen aufbereitet. Bspw. wird in Abhängigkeit des Schwerpunkts der Prüfung nach ausgewählten Lieferantentypen bzw. internen und externen Debitoren gefiltert. Die Aufbereitung und nachfolgenden Analysen erfolgen überwiegend auf der Grundlage von in Open-Source-Programmiersprachen (wie bspw. R [18] und Python [19]) entwickelten Routinen. Innerhalb des internen Audits von Nestlé S.A. wurden in den letzten Jahren (auf Grundlage dieser Sprachen) eine Vielzahl analytischer Prüfroutinen entwickelt. Diese Entwicklungen ermöglichen es den Revisorinnen und Revisoren heute, Buchungsdaten effizient, d. h. mit geringem Zeitaufwand, zu importieren, aufzubereiten und zu analysieren.

Abbildung 3: HEATMAP VON AUSGEWÄHLTEN BUCHUNGSMERKMALEN: BELEGART UND SAP-TRANSAKTIONS-CODE



Phase 2: Analyseverfahren der uni- und multivariaten Statistik

Auf der Grundlage ausgewählter Buchungsmerkmale werden in der zweiten Phase uni- und multivariate statistische Analysen durchgeführt. Im Vordergrund steht hierbei u. a. die Analyse von niedrigdimensionalen Merkmalsausprägungen bzw. -beziehungen. *Abbildung 3* zeigt beispielhaft das Ergebnis einer Korrelationsanalyse der beiden Merkmale «Belegart» und «SAP-Transaktionscode». Die Darstellung in Form einer Heatmap visualisiert die in den Journalbuchungen enthaltenen Merkmalskombinationen anhand ihrer jeweiligen Eintrittswahrscheinlichkeit. Kombinationen, die eine vergleichsweise geringe Wahrscheinlichkeit aufweisen, sind entsprechend durch dunkelrote Zellen gekennzeichnet. Das Prüfungsteam ist dann angehalten, vor Ort die den ungewöhnlichen Merkmalskombinationen zugrunde liegenden Journalbuchungen bzw. Geschäftsvorfälle im Hinblick auf mögliche Fehler, Prozessabweichungen sowie dolose Handlungen zu prüfen.

Phase 3: Analyseverfahren der künstlichen Intelligenz

Innerhalb der dritten Phase werden die zuvor durchgeführten Analysen um Verfahren der KI erweitert. Das Ziel ist es, hochdimensionale und zugleich ungewöhnliche Merkmalsausprägungen bzw. -kombinationen zu erkennen. In diesem Kontext finden die in Kapitel 3 vorgestellten tiefen Autoencoder ihre Anwendung. Im Kontext des Beispiels resultieren Journalbuchungen des Vertriebsprozesses, die nicht den gewöhnlichen Buchungsaktivitäten des Vertriebs entsprechen, in einem erhöhten Rekonstruktionsfehler. Im Ergebnis resultiert diese dritte Phase in einer – der Höhe des Fehlers nach – sortierten Übersicht der analysierten Journalbuchungen. Anschliessend ist das lokale Prüfungsteam angehalten, Buchungen, deren Rekonstruktionsfehler einen festgelegten Schwellenwert überschreiten, vor Ort zu prüfen. Für die zielgerichtete Prüfung erhält das Revisionsteam eine ausführliche Erläuterung, weshalb eine Vertriebsbuchung durch den Autoencoder als Anomalie deklariert wurde.

Abbildung 4 zeigt das schematische Vorgehensmodell der autoencoderbasierten Anomalieerkennung für die Vertriebsbuchungen einer beispielhaften Nestlé S.A.-Landesgesell-

schaft. Das Training des Autoencoders erfolgte innerhalb einer virtuellen MS-Windows-Umgebung (basierend auf einem Intel-Xeon-2.3-GHz-Prozessor samt 32-GB-Arbeitspeicher). Die Encoder-Decoder-Struktur umfasste 11 Netzschichten bestehend aus insgesamt 2660 künstlichen Neuronen. Anhand des DL-basierten Vorgehens konnten beispielhaft die nachfolgenden (anonymisierten) Sachverhalte ermittelt werden, deren Journalbuchungen einen *erhöhten Rekonstruktionsfehler* aufweisen:

→ Innerhalb einer lateinamerikanischen Landesgesellschaft wurde die kreditorische Buchung zugunsten eines Debtors identifiziert, die manuell über ein selten verwendetes Gegenkonto erfasst wurde. Die Buchung weist einen signifikant erhöhten Betrag auf und wurde durch eine seltene Kombination von Buchungsschlüssel, debitorischem Nummernkreis und verwendeter Benutzererkennung gebucht.

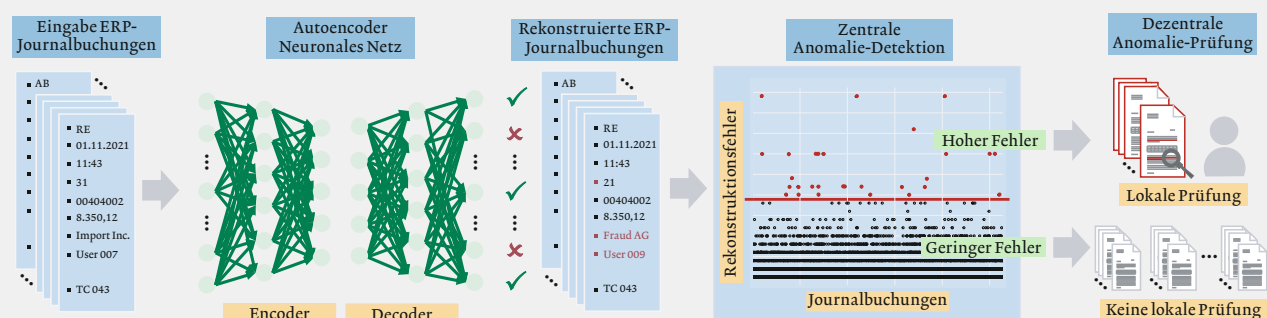
→ Innerhalb einer asiatischen Landesgesellschaft konnte eine geringe Anzahl debitorischer Buchungen detektiert werden, welche eine ungewöhnliche Kombination von Benutzererkennung, Buchungsschlüssel und Ausgleichskonto aufweisen. Anhand dieser Kombination wurden innerhalb sehr kurzer Zeit manuell offene debitorische Rechnungen ausgeglichen, die materielle Beträge aufweisen.

5. AKTUELLE HERAUSFORDERUNGEN FÜR DIE PRAXIS UND AUSBLICK

Innerhalb des internen Audits vollzieht sich zunehmend eine Transformation zu einer durch KI unterstützten Prüfung [20]. Die Anwendung von ML-Verfahren entwickelt sich zu einem wertvollen Werkzeug, welches in den verschiedenen Phasen des Prüfprozesses eingesetzt werden kann. Im internen Audit der Nestlé S.A. werden bereits heute die durch Autoencoder im Zusammenspiel mit Revisorinnen und Revisoren ermittelten Anomalien in einer entsprechenden Datenbank erfasst. Zielsetzung ist, die Erkennung solcher Anomalien kontinuierlich in regelbasierte Prüfroutinen zu überführen, um zukünftig Fehlerquellen oder Betrugsmuster noch effizienter zu erkennen.

Die durch Verfahren der KI unterstützte revisorische Datenanalyse birgt bereits bekannte Herausforderungen, welche u. a. die Datenextraktion, die Datenaufbereitung und

Abbildung 4: SCHEMATISCHES VORGEHENSMODELL DER AUTOENCODERBASIERTEN ANOMALIEERKENNUNG INNERHALB DER SAP ERP-VERTRIEBSBUCHUNGEN EINER NESTLÉ-S.A.-LANDESGESELLSCHAFT



den Datenschutz betreffen. Darüber hinaus sieht sich der interne Audit, infolge der Anwendung von DL-Verfahren, aktuell mit einer Reihe neuartiger Herausforderungen konfrontiert [21]. Fraglich ist im Besonderen, durch welche Mitglieder des internen Audits maschinelle Lernverfahren entwickelt und angewandt werden. Für einen nutzenstiftenden Einsatz bedarf es im Idealfall der Kombination von ausgereiften prüferischen und technischen Fachkenntnissen. So ist auch bei Nestlé S.A. eine wesentliche Herausforderung die Interpretation der durch Autoencoder erhaltenen Resultate. Für die zweckmässige Interpretation bedarf es Revisorinnen und Revisoren, die ein fundiertes Verständnis über:

- betriebswirtschaftliche Prozesse,
- unternehmensinterne ERP-Systeme und
- statistische Analyseverfahren aufweisen.

Mittelfristig werden Revisionsabteilungen deshalb zunehmend selbst herausgefordert sein, in die Ausbildung ihrer Revisorinnen und Revisoren zu investieren, um Expertise an der Schnittstelle von IT-technischen und prüferischem Wissen aufzubauen.

Abschliessend darf sicherlich die Frage gestellt werden, ob sich die primäre Aufgabenstellung des internen Audits grundsätzlich darin erschöpft, kontinuierlich Abweichungen und Fehler aufzuspüren, oder ob die Zielsetzung nicht vielmehr darin besteht, zu beurteilen, ob Prozesse innerhalb vorgegebener Toleranzgrenzen mehrheitlich funktionieren. Ob dies eine rein philosophische oder eine die Zukunft bestimmende Fragestellung ist, kann diskutiert werden. Seit geraumer Zeit sind Revisorinnen und Revisoren durch das IIA angehalten, ihr prüferisches Handeln zunehmend im Sinne eines Trusted Advisors zu interpretieren/auszuüben [22]. In dieser Rolle erbringt der/die interne Auditor/-in unabhängige und objektive Prüfungs- und Beratungsdienstleistungen, die darauf ausgerichtet sind, Mehrwerte u. a. innerhalb der Bereiche Risikomanagement, Steuerungs-, Kontroll- und Governance-Prozesse zu schaffen. Die Anwendung von Verfahren der KI kann Revisionsabteilungen künftig dabei unterstützen, dieses Ziel innerhalb ihrer Organisationen zu erreichen. ■

Fussnoten: *Die Autoren bedanken sich bei Yasmine Weiser (ehemals Bensultana), Monika Heyder und Michael Mommert für die zahlreichen, wertvollen Anregungen und die kritische Durchsicht des Manuskripts. Der Inhalt dieses Artikels spiegelt ausschliesslich die Meinung der Autoren wider, welche nicht notwendigerweise der offiziellen Position von Nestlé S.A. entsprechen. **1)** The Institute of Internal Auditors. Research Foundation, 2017. International Professional Practices Framework (IPPF). **2)** The Institute of Internal Auditors, 2012. International Standards for the Professional Practice of Internal Auditing 1220.A2, p. 6. **3)** Dai, J. and Vasarhelyi, M.A., 2016. Imagineering Audit 4.0. *Journal of Emerging Technologies in Accounting*, 13/1, pp. 1–15. **4)** Kokina, J. and Davenport, T.H., 2017. The Emergence of Artificial Intelligence: How Automation is Changing Auditing. *Journal of Emerging Technologies in Accounting*, 14/1, pp. 115–122. **5)** Ruud, F., Schramm, K. and Allgaier, A., 2021. Leitlinien zum Internen Audit, IIA Switzerland, 4. Auflage, pp. 125–126. **6)** Russell, S. and Norvig, P., 2016. *Artificial Intelligence: A Modern Approach*, Third Edition, Pearson Education Ltd., pp. 1–5. **7)** Samuel, A.L., 1959. Some Studies in Machine Learning Using the Game of Checkers. *IBM Jour-*

nal of Research and Development, 3/3, pp. 210–229. **8)** Bishop, C.M., 2006. *Pattern Recognition and Machine Learning*, Springer Science LLC, pp. 3–4. **9)** Gierbl, A.S., Schreyer, M., Borth, D. and Leibfried, P., 2021. Deep Learning für die Wirtschaftsprüfung – Eine Darstellung von Theorie, Funktionsweise und Anwendungsmöglichkeiten. *Zeitschrift für Internationale Rechnungslegung (IRZ)*, 7/8, pp. 349–355. **10)** LeCun, Y., Bengio, Y. and Hinton, G., 2015. Deep learning. *Nature*, 521/7553, pp. 436–444. **11)** McCulloch, W.S. and Pitts, W., 1943. A Logical Calculus of the Ideas Immanent in Nervous Activity. *The Bulletin of Mathematical Biophysics*, 5/4, pp. 115–133. **12)** Rosenblatt, F., 1958. The Perceptron: A probabilistic Model for Information Storage and Organization in the Brain. *Psychological review*, 65/6, p. 386. **13)** Bengio, Y., Courville, A. and Vincent, P., 2013. Representation Learning: A Review and New Perspectives. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35/8, pp. 1798–1828. **14)** Sun, T., 2019. Applying Deep Learning to Audit Procedures: An Illustrative Framework. *Accounting Horizons*, 33/3, pp. 89–109. **15)** Schreyer, M., Sattarov, T., Schulze, C., Reimer, B. and Borth, D., 2019. Detection of Accounting Anomalies in the Latent Space Using Adversarial

Autoencoder Neural Networks. arXiv preprint arXiv:1908.00734. **16)** Hinton, G.E. and Salakhutdinov, R.R., 2006. Reducing the Dimensionality of Data with Neural Networks. *Science*, 313/5786, pp. 504–507. **17)** Schreyer, M., Sattarov, T., Borth, D., Dengel, A. and Reimer, B., 2017. Detection of Anomalies in Large Scale Accounting Data Using Deep Autoencoder Networks. arXiv preprint arXiv:1709.05254. **18)** The R Project for Statistical Computing (<https://www.r-project.org>, abgerufen am 7.11.2021). **19)** The Python Programming Language (<https://www.python.org>, abgerufen am 7.11.2021). **20)** Zhang, C.A., Dai, J. and Vasarhelyi, M.A., 2018. The Impact of Disruptive Technologies on Accounting and Auditing Education: How Should the Profession Adapt? *The CPA Journal*, 88/9, pp. 20–26. **21)** Gierbl, A.S., Schreyer, M., Leibfried, P. and Borth, D., 2020. Künstliche Intelligenz in der Prüfungspraxis – Eine Bestandsaufnahme aktueller Einsatzmöglichkeiten und Herausforderungen. *Expert Focus*, 2020/9, pp. 612–617. **22)** Ruud, F. and Schramm, K., 2019. Erwartungen und Mehrwert des Internen Audits – Die Rolle wirksamer Kommunikation. *Expert Focus*, 2019/10, pp. 49–54.