

DIE KÜNFTIGE ROLLE VON BIG DATA UND MASCHINELLEM LERNEN IM HINBLICK AUF DIE WIRKSAMKEIT VON INSPEKTIONEN FÜR SICHERHEIT UND GESUNDHEIT AM ARBEITSPLATZ

Einleitung

Inspektionen sind wahrscheinlich das wichtigste politische Instrument, mit dem Arbeitsaufsichtsbehörden der Regierung sicherstellen, dass Unternehmen die notwendigen Schritte ergreifen, um die Vorschriften für Gesundheit und Sicherheit am Arbeitsplatz einzuhalten. Der Effekt von Inspektionen hängt jedoch von mehreren verschiedenen Faktoren ab. Ein grundlegender Faktor ist der Prozess der Auswahl von Inspektionsobjekten, d. h. zu inspizierende Unternehmen oder Standorte. Grundsätzlich stehen mindestens drei verschiedene Ansätze für die Auswahl zur Verfügung. Beim ersten Ansatz werden alle Unternehmen inspiziert, unabhängig von potenziellem Risiko, Unternehmensgröße, Art der Branche oder anderen Kriterien. Beim zweiten Ansatz werden Unternehmen auf der Grundlage zufälliger Stichprobenahmen ausgewählt, wobei für jedes Unternehmen, unabhängig von etwaigen Merkmalen, die gleiche Wahrscheinlichkeit besteht, ausgewählt zu werden. Hinsichtlich präventiver und wirtschaftlicher Bedingungen werden diese beiden Methoden in der Regel als ineffektiv angesehen (Blanc, 2013). Daher wählen die meisten Arbeitsaufsichtsbehörden Objekte auf Grundlage des dritten Ansatzes, nämlich des risikobasierten Ansatzes, aus. Kurz gesagt werden beim risikobasierten Ansatz Inspektionsobjekte auf Grundlage des Risikoniveaus ausgewählt.

Zwar ist der risikobasierte Ansatz ein essentieller Grundsatz für die meisten modernen Arbeitsaufsichtsbehörden, jedoch sind mit seiner Umsetzung in der Praxis erhebliche Herausforderungen verbunden. Der Hauptgrund für diesen Umstand ist, dass es an ausreichend ausgefeilten Methoden zur Risikoanalyse mangelt (Mischke et al., 2013). Ohne geeignete Methoden zur risikobasierten Priorisierung besteht die Gefahr, dass der risikobasierte Ansatz zu einem regierungspolitischen Statement ohne greifbare praktische Konsequenzen wird. Daher besteht die Notwendigkeit, Methoden zu entwickeln, mit denen Hochrisikounternehmen gezielt ausgewählt werden können (Weil, 2008).

Die meisten Arbeitsaufsichtsbehörden sammeln und speichern riesige Mengen an Daten zu ihren Inspektionsobjekten und -aktivitäten. Daher sind die Aufsichtsbehörden potenziell im Besitz großer und schnell wachsender Datenmengen, die heutzutage als „Big Data“ bezeichnet werden. Big Data werden in Kombination mit der Technologie für maschinelles Lernen zunehmend für verschiedene prädiktive Zwecke eingesetzt, indem Lehren aus versteckten Trends in den Daten gezogen werden. Zum Beispiel werden der prädiktive Wert von Big Data und Techniken für maschinelles Lernen in mannigfaltigen Bereichen getestet, wie z. B. Krebsprognose und Patientenergebnisse, Prognose von Insolvenzen, Prognose des Ölpreises, Aufdeckung von Steuerbetrug, Kriminalitätsprognose und Prognosen am Aktienmarkt. Die grundlegende Frage, mit der sich dieses Papier befasst, ist jedoch, ob die Nutzung von Big Data und maschinellem Lernen zur gezielten Auswahl von Inspektionsobjekten mit hohem Risiko für Arbeitsaufsichtsbehörden eine erfolgversprechende Option darstellt.

Risikobasierte gezielte Auswahl

Gemäß den von der Organisation für wirtschaftliche Zusammenarbeit und Entwicklung (OECD, 2014) dargelegten Grundsätzen der bewährten Praxis für die Ordnungspolitik sollten

Risikoanalyse und Risikobewertung für Arbeitsaufsichtsbehörden die Grundlage zur gezielten Auswahl von Inspektionsobjekten darstellen. Dies bedeutet, dass Unternehmen auf Grundlage einer Abschätzung der Wahrscheinlichkeit und Konsequenzen von Risikoelementen wie Unfällen, gesundheitsschädlicher Exposition und illegalen Arbeitsbedingungen zur Inspektion auszuwählen sind. Die Grundlage der risikobasierten gezielten Auswahl ist die Anerkennung der Tatsache, dass es aufgrund begrenzter Inspektionsressourcen nicht möglich ist, alle Risikobereiche und alle Risikoobjekte zu kontrollieren. Hinsichtlich der von den Arbeitsaufsichtsbehörden durchgeführten Inspektionen zur Gesundheit und Sicherheit am Arbeitsplatz bedeutet dies, dass einigen Problembereichen gegenüber anderen Priorität eingeräumt werden muss. Darüber hinaus müssen einige Unternehmen für die Inspektion gegenüber anderen priorisiert werden.

Der Grundsatz der risikobasierten gezielten Auswahl ist kein Novum. Vor fast 50 Jahren wurde im Rahmen der vom Robens Committee durchgeführten Bewertung des Systems für die Überwachung der Sicherheit und Gesundheit am Arbeitsplatz des Vereinigten Königreichs der risikobasierte Ansatz (kombiniert mit Selbstkontrolle) als ein Idealprinzip bei der Modernisierung der behördlichen Inspektionen eingeführt (Robens, 1972). Um die kosteneffektive Nutzung von Inspektionsressourcen zu gewährleisten, wurde im Robens Report gegenüber der Aufsichtsbehörde die Empfehlung ausgesprochen, dass diese ihre Ressourcen selektiv auf die schwerwiegendsten Problembereiche konzentriert und Unternehmen und Probleme priorisiert, die durch die systematische Analyse aller verfügbaren Daten zur Gesundheit und Sicherheit, z. B. Unfallstatistiken, technische Informationen und lokales Wissen der Aufsichtsbehörde, ermittelt worden waren.

Die Empfehlungen des Robens Report wurden von Arbeitsaufsichtsbehörden auf internationaler Ebene und in den EU-Mitgliedstaaten weitgehend übernommen. Die flächendeckende Anwendung des risikobasierten Ansatzes bedeutet, dass die meisten modernen Arbeitsaufsichtsbehörden den Ansatz, Ressourcen von Niedrigrisiko-Objekten abzuziehen und mehr Ressourcen für die Durchsetzung bei Objekten mit den höchsten Risiken zu bündeln, befürworten. Um dies zu ermöglichen, ist eine bestimmte Art von Datenanalyse erforderlich. Die Analysemethoden zur Ermittlung von Hochrisiko-Branchen und gefährdeten Gruppen von Arbeitskräften sind gut entwickelt. Solche risikobasierten Analysen stützen sich in der Regel auf nationale Statistiken, die sich zum Beispiel auf berufsbedingte Erkrankungen, Arbeitsunfälle und Expositionen während der Arbeitszeit beziehen. Die Analysen bilden die Grundlage von Inspektionskampagnen, strategischen Plänen sowie nationalen und sogar internationalen Prioritätsbereichen.

Weit weniger üblich als die breitgefächerten risikobasierten Analysen sind Methoden, die eine Priorisierung zwischen Unternehmen innerhalb einer Branche ermöglichen. Unter den Arbeitsaufsichtsbehörden ist ein üblicher Ansatz, um konkrete risikoreiche Unternehmen gezielt auszuwählen, sich auf das lokale Wissen von Inspektoren zu stützen. Manche Arbeitsaufsichtsbehörden, wie z. B. die in Dänemark und Schweden, haben die Einsatzmöglichkeit von Risikoeinstufungssystemen auf der Grundlage von additiven Skalen untersucht. Bei der Verwendung additiver Skalen erhält jedes Unternehmen Risiko-Punktwerte basierend auf mehreren Unternehmensmerkmalen (z. B. Größe, Art der Branche und Anzahl der registrierten Unfälle), die zu einer Punktwertsumme addiert werden; die Unternehmen mit den höchsten Punktwertsummen werden für die Inspektion priorisiert. Das Problem bei der Verwendung solcher additiver Skalen ist jedoch, dass sie eine relativ geringe prädiktive Validität haben, d. h., der Punktwert ist nicht besonders gut dafür geeignet, Hochrisiko-Unternehmen von Niedrigrisiko-Unternehmen zu unterscheiden.

Big Data und maschinelles Lernen

Der Prozess der Priorisierung zwischen Unternehmen ist mit der berühmten Suche nach der Nadel im Heuhaufen vergleichbar. In diesem Fall besteht der Heuhaufen potenziell aus Hunderttausenden möglichen Inspektionsobjekten, aber nur eine bestimmte Anzahl dieser Objekte

sind Nadeln, d. h. weisen ein nicht vertretbares Risikoniveau auf. Die Suche nach der Nadel im Heuhaufen ist zu einem großen Teil das, worum es bei Big Data und maschinellem Lernen geht.

Das übergeordnete Ziel von Algorithmen für maschinelles Lernen ist es, ein statistisches Modell zu liefern, mit dem Prognosen, Einstufungen, Abschätzungen oder ähnliche Aufgaben durchgeführt werden können. Im Bereich der Krebsprognose zum Beispiel setzen Forscher seit mehr als drei Jahrzehnten Algorithmen für maschinelles Lernen ein, um die Anfälligkeit für, das Wiederauftreten von und das Überleben bei Krebs vorherzusagen. Thematisch gesehen ist die Krebsprognose fernab von der risikobasierten gezielten Auswahl von Inspektionsobjekten angesiedelt. Beide sind jedoch Beispiele für prädiktive Herausforderungen bzw. für Probleme vom Typ „Nadel im Heuhaufen“.

Die beiden wichtigsten üblichen Arten von Algorithmen für maschinelles Lernen sind überwachtes Lernen und unüberwachtes Lernen. Beim überwachten Lernen besteht der Algorithmus aus einer abhängigen Variable (z. B. Risikoniveau), die basierend auf einem Satz unabhängiger Variablen vorherzusagen ist. Genaue Vorhersagen erfordern natürlich ein hohes Maß an Korrelation zwischen den unabhängigen Variablen und der abhängigen Variable. Beim unbeaufsichtigten Lernen gibt es keine vorherzusagende abhängige Variable; vielmehr ist es das Ziel des Algorithmus, die Daten anhand von Ähnlichkeiten in Gruppen (z. B. verschiedene Risikogruppen) zu unterteilen („clustern“). Im Gegensatz zu additiven Skalen wie denen, die von den Arbeitsaufsichtsbehörden Dänemarks und Schwedens untersucht wurden, verbessern die beim maschinellen Lernen verwendeten Algorithmen fortwährend ihre Vorhersagen, und zwar hauptsächlich mittels Versuch und Irrtum („Trial and Error“). Das bedeutet, dass die Maschine aus früheren Erfolgen (korrekten Vorhersagen) und Fehlern (falschen Vorhersagen) lernt und versucht, dieses Wissen einzufangen, um Vorhersagen basierend auf den eingegangenen Rückmeldungen präziser zu machen.

Nutzung von Big Data und maschinellem Lernen bei der Auswahl von Inspektionsobjekten

Algorithmen für überwachtes und unüberwachtes Lernen erfordern eine ausreichende Datenmenge, und zwar sowohl hinsichtlich der Anzahl der Beobachtungen als auch der Anzahl der Variablen, die in der Regel als „Features“ bezeichnet werden. Wie bereits erwähnt, sammeln und speichern die meisten Arbeitsaufsichtsbehörden riesige Mengen an Daten zu ihren Inspektionsobjekten und -aktivitäten. Die verfügbaren Daten beziehen sich in der Regel auf unternehmensspezifische Features, wie z. B. die Anzahl der Mitarbeiter, das Alter des Unternehmens, die industrielle Zugehörigkeit, die Anzahl früherer Inspektionen, die Ergebnisse früherer Inspektionen und Unfallmeldungen. Des Weiteren wächst die Datenmenge täglich durch die Aufnahme von Ergebnissen neuer Inspektionen. Im Prinzip sollten Algorithmen für maschinelles Lernen in diesem Fall, zumindest auf den ersten Blick, gut dafür geeignet sein, die Herausforderung einer gezielten Auswahl von Unternehmen unter Nutzung von Big Data anzugehen. Trotz dieser Tatsache wurden bisher nur wenige derartige Versuche unternommen. Es gibt jedoch einige nennenswerte Ausnahmen, die alle veranschaulichen, dass Big Data für Arbeitsaufsichtsbehörden sehr relevant sein könnten, wenn es darum geht, die Herausforderung der gezielten Auswahl von Inspektionsobjekten mit hohem Risiko zu überwinden.

Das erste Beispiel ist eine Forschungsstudie, in der die Eignung von Methoden für maschinelles Lernen für die Vorhersage von Unfällen am Arbeitsplatz bzw., konkreter gesagt, Stürzen auf Bodenhöhe, untersucht wurde (Matías et al., 2008). Trotz ihrer relativ präzisen Vorhersagen ist der Nachteil dieser Studie, dass die in den Algorithmen enthaltenen Features nicht die Art von Daten darstellen, die den Arbeitsaufsichtsbehörden im Normalfall vorliegen (z. B. Nutzung von persönlicher Schutzausrüstung und Reinhaltungspraktiken). Des Weiteren stellen Stürze auf Bodenhöhe nur einen winzigen Anteil der Risiken am Arbeitsplatz dar, mit denen sich Arbeitsaufsichtsbehörden befassen.

Das zweite Beispiel ist ebenfalls eine Forschungsstudie (Hajakbari und Minaei-Bidgoli, 2014). In dieser Studie wurde ein Punktwertsystem für die Vorhersage des Risikos von Unfällen am Arbeitsplatz entwickelt. Darüber hinaus gelangte man in der Studie zu dem Schluss, dass es möglich ist, das Risiko unterschiedlicher Arten von Unfällen am Arbeitsplatz auf Grundlage einiger allgemeiner Unternehmensmerkmale (Haupttätigkeit, Geschlechterverteilung, Anzahl der Mitarbeiter usw. eines Unternehmens) relativ präzise vorherzusagen. Des Weiteren schlussfolgerte man in der Studie, dass der Algorithmus genutzt werden konnte, um Arbeitsplätze zu identifizieren, welche regelmäßige Gesundheits- und Sicherheitsinspektionen erfordern. Die in dieser Studie verwendeten Daten wurden aus der Datenbank einer Arbeitsaufsichtsbehörde abgerufen. Der Nachteil der Studie ist jedoch auch hier, dass Unfälle am Arbeitsplatz nur eines der vielen Risiken am Arbeitsplatz darstellen, mit denen sich Arbeitsaufsichtsbehörden befassen. Darüber hinaus ist ein besonderes Problem, wenn man sich auf Verletzungsstatistiken stützt, dass diese Daten bekanntermaßen stark anfällig für Meldungslücken sind.

Das dritte Beispiel ist ein Instrument von der Norwegian Labour Inspection Authority (NLIA), mit dem Inspektoren bei der Auswahl von Unternehmen im Hinblick auf das Risiko unterstützt werden (Dahl et al., 2018). Das Instrument mit dem Namen Risk Group Prediction Tool (RGPT - Instrument für die Prognose von Risikogruppen) nimmt eine Differenzierung von Unternehmen in vier Gruppen basierend auf dem vorhergesagten Risiko vor: Unternehmen mit niedrigstem Risiko, niedrigem Risiko, hohem Risiko und höchstem Risiko. Je höher die Risikogruppe eines Unternehmens ist, desto höher ist die Wahrscheinlichkeit, dass bei einer zukünftigen Inspektion in diesem Unternehmen schwerwiegende Verstöße gegen die Vorschriften zu Sicherheit und Gesundheitsschutz aufgedeckt werden. Die Gruppe, der ein Unternehmen zugeordnet ist, ist für Inspektoren über die interne webbasierte Benutzeroberfläche der NLIA ersichtlich. Wenn also Unternehmen gezielt für die Inspektion ausgewählt werden sollen, werden Inspektoren über die Risikogruppen der Unternehmen informiert und können so eine risikoinformierte Auswahl treffen.

Das RGPT wurde auf der Grundlage prädiktiver Modellierung mithilfe eines Algorithmus für maschinelles Lernen unter Verwendung einer sogenannten binären logistischen Regressionsanalyse aufgebaut. Auf der Grundlage des Regressionsmodells werden alle Unternehmen in Norwegen (ca. 230.000) einer der vier Risikogruppen zugeordnet. Dies erfolgt in zwei Schritten. Im ersten Schritt sagt das Regressionsmodell die Wahrscheinlichkeit vorher, mit der bei einer zukünftigen Inspektion schwerwiegende Verstöße gegen die Vorschriften zu Sicherheit und Gesundheitsschutz aufgedeckt werden. Im zweiten Schritt zieht das Modell den vorhergesagten Wahrscheinlichkeitswert heran, um das Unternehmen einer Risikogruppe zuzuordnen.

Anfangs wurde das Instrument auf Grundlage von Registrierungen von ca. 35.000 Gesundheits- und Sicherheitsinspektionen entwickelt, die von der NLIA durchgeführt wurden. Die vom Instrument getroffenen Vorhersagen werden jedoch mit steigender Zahl der Inspektionen allmählich und automatisch immer präziser. Das bedeutet, dass der Algorithmus sich basierend auf den Rückmeldungen (richtige oder falsche Vorhersagen), die er erhält, wenn neue Inspektionen durchgeführt und in der Datenbank der NLIA registriert werden, eigenständig anpasst.

Das RGPT gehört zur Klasse der überwachten Lernalgorithmen, wobei Gesundheits- und Sicherheitsinspektionen, die schwerwiegende Verstöße aufdecken (abhängige Variable), auf Grundlage einer Reihe von Unternehmensmerkmalen (Features) vorherzusagen sind. Die Features, die das RGPT heranzieht, sind allgemeine Unternehmensmerkmale wie Unternehmensgröße, industrielle Zugehörigkeit, Anzahl früherer Inspektionen, Ergebnisse früherer Inspektionen, Alter des Unternehmens, geografischer Standort und Unfallmeldungen. Die prädiktive Validität des Instruments wird jeden Monat überprüft, und die bisherige Erfahrung (nach einer Testzeit von ca. 18 Monaten) zeigt, dass der Algorithmus es schafft, Unternehmen mit hohem Risiko extrem präzise auszuwählen. Das bedeutet, dass es wenige falsch-positive und wenige falsch-negative Ergebnisse gibt; d. h., bei wenigen Inspektionen in der Gruppe mit dem niedrigsten

Risiko werden schwerwiegende Verstöße aufgedeckt, während bei der überwiegenden Mehrheit der Inspektionen in der Gruppe mit dem höchsten Risiko schwerwiegende Verstöße aufgedeckt werden. Die Gruppen mit niedrigem und hohem Risiko liegen zwischen den beiden Extremen.

Die aus der Verwendung des von der NLIA entwickelten Instruments gewonnenen Erkenntnisse zeigen, dass es möglich ist, Inspektionsobjekte unter Verwendung von Big Data und maschinellem Lernen gezielt auszuwählen. Außerdem wurden von mindestens zwei anderen europäischen Arbeitsaufsichtsbehörden ähnliche Ansätze mit maschinellem Lernen mit vielversprechenden Ergebnissen getestet: vom schwedischen Zentralamt für Arbeitsumwelt (Ridemar, 2018) und vom niederländischen Inspectorate SZW (Jacobusse und Veenman, 2016). Das norwegische Instrument ist jedoch nicht zwangsläufig auf andere Arbeitsaufsichtsbehörden übertragbar, da seine Verwendung von der Art und Weise der Datenspeicherung, der Datenqualität, dem Datenzugriff und der Datenbankstruktur abhängig ist. Des Weiteren muss für die gezielte Auswahl von Unternehmen auf Grundlage des Instruments die Art und Weise, wie Risiko im Algorithmus definiert und operationalisiert wird, akzeptiert sein. Wie bereits beschrieben, basiert das Instrument auf der Definition von Risiko, welches Folgendes vorsieht: Je höher die Risikogruppe eines Unternehmens ist, desto höher ist die Wahrscheinlichkeit, dass bei einer Inspektion in diesem Unternehmen schwerwiegende Verstöße gegen die Vorschriften zu Sicherheit und Gesundheitsschutz am Arbeitsplatz aufgedeckt werden. Das bedeutet, dass sich das Instrument vorwiegend mit sogenannten Management- und Kontrollrisiken und nicht mit inhärenten Risiken befasst. Während Management- und Kontrollrisiken aus der Fähigkeit und Bereitschaft eines Unternehmens zum Risikomanagement (z. B. durch Einhaltung der einschlägigen Vorschriften) hervorgehen, entstehen inhärente Risiken aus der Art der Tätigkeit eines Unternehmens (z. B. Sturz aus großer Höhe, Exposition gegenüber Chemikalien und Belastung des Bewegungsapparats).

In der Praxis sind Management- und Kontrollrisiken und inhärente Risiken verwandt. Dies bedeutet jedoch nicht, dass zwischen den zwei Arten von Risiken zwangsläufig eine starke empirische Korrelation besteht. Wenn man sich also blindlings auf Instrumente verlässt, die Unternehmen zielgerichtet auf Grundlage einer Art von Risiken auswählen, kann es vorkommen, dass eine andere Art von Risiko übersehen wird. Innerhalb des norwegischen Regulierungssystems wird dieser Herausforderung dadurch Rechnung getragen, dass bei der Identifizierung von prioritären Bereichen, risikorexponierten Gruppen von Arbeitnehmern und Hochrisikobranchen die inhärenten Risiken hervorgehoben werden, während die Management- und Kontrollrisiken hervorgehoben werden, wenn konkrete Unternehmen gezielt ausgewählt werden.

Herausforderungen

Die Tatsache, dass Management- und Kontrollrisiken auf der einen Seite und inhärente Risiken auf der anderen Seite nicht zwangsläufig empirisch korreliert sind, stellt uns vor eine andere, wahrscheinlich noch größere Herausforderung bei der Anwendung von Big Data und Algorithmen für maschinelles Lernen auf die risikobasierte gezielte Auswahl. Die drei Beispiele für Instrumente für maschinelles Lernen exemplifizieren alle eine eindimensionale gezielte Auswahl, d. h. eine gezielte Auswahl basierend auf einer bestimmten Definition und Operationalisierung von Risiko. In der Arbeitswelt gibt es jedoch nicht nur eine bestimmte Art von Risiko. Daher müssen sich Überwachungsstellen mit mehreren Arten von Risiken befassen, z. B. Unfällen, chemischer Exposition, biologischer Exposition, psychosozialen Bedrohungen, Risikofaktoren für den Bewegungsapparat und Sozialdumping. Innerhalb dieser Arten von Risiken gibt es noch mehr Unterarten. Die Entwicklung von Risikomodellen, die diese Vielfalt erfassen, ist eine große Herausforderung, weil die verschiedenen Arten von Risiken nicht zwangsläufig korrelieren. Daher unterscheidet sich das Erfassen dieser Vielfalt enorm von der Vorhersage der Wahrscheinlichkeit einer bestimmten Art von Risiko (Dahl et al., 2018).

Eine zweite, aber damit zusammenhängende Herausforderung macht die risikobasierte gezielte Auswahl sogar noch komplexer. Dabei handelt es sich um den sogenannten „Political Pitfall“ (dt. politischen Fallstrick, Black, 2010). Obwohl Algorithmen für maschinelles Lernen insofern dynamisch sind, dass sie von Erfolgen und Fehlern lernen und sich an diese anpassen können, können sie keine unterschiedlichen politischen Sichtweisen berücksichtigen. Erstens ist der politische Kontext unstat. Daher sind die Arten von Risiken, die heute einer Priorisierung würdig sind, vielleicht schon morgen keiner Priorisierung mehr würdig. Zweitens ist der politische Kontext facettenreich. So hegen verschiedene Interessengruppen, z. B. Politiker, Arbeitgeber, Arbeitnehmer, die Medien und die Öffentlichkeit unterschiedliche Ansichten bezüglich der Frage, welche Arten von Risiken einer Priorisierung würdig sind. Dies veranschaulicht, dass „Risiko“ in der Arbeitswelt nicht zwangsläufig eine objektive Instanz, sondern vielmehr ein soziales Konstrukt ist.

Eine dritte zu berücksichtigende Herausforderung entsteht aus der Tatsache, dass, obwohl Arbeitsaufsichtsbehörden über riesige Mengen von Daten bezüglich ihrer Inspektionsobjekte verfügen, sich diese Daten in der Regel auf die Unternehmensebene beziehen und Daten auf Unternehmensebene nicht zwangsläufig die geeignetsten heranzuziehenden Daten sind (siehe beispielsweise Gunningham und Sinclair, 2007). In einer Datenbank wird ein konkretes Unternehmen in der Regel durch eine eindeutige Kennung, wie z. B. eine Organisationsnummer, identifiziert. Die Fähigkeit eines Algorithmus für maschinelles Lernen, einem bestimmten Unternehmen einen bestimmten vorhergesagten Risikowert zuzuordnen, ist vom Vorhandensein eindeutiger Kennungen abhängig. Es sind jedoch nicht alle potenziellen Inspektionsobjekte automatisch anhand einer eindeutigen Kennung identifizierbar. Zum Beispiel wird im Baugewerbe nicht zwangsläufig ein konkretes Unternehmen gezielt zur Inspektion ausgewählt, sondern eine vorübergehende Baustelle. Mit einem solchen vorübergehenden Charakter sind mindestens zwei Herausforderungen verbunden. Erstens sind Baustellen und andere vorübergehende Arbeitsstätten möglicherweise nicht durch eindeutige Kennungen identifizierbar. Zweitens bedeutet der vorübergehende Charakter, selbst wenn die vorstehend genannten Baustellen bzw. Arbeitsstätten identifizierbar wären, dass ein Algorithmus für maschinelles Lernen möglicherweise nicht die Gelegenheit hat, aus seinen prädiktiven Erfolgen und Fehlern zu lernen, bevor die Baustelle den Betrieb einstellt und die Unternehmen, welche auf der Baustelle tätig waren, zu neuen Konstellationen an einer neuen Baustelle umgezogen sind.

Schlussbemerkungen

Die vorstehend beschriebenen Herausforderungen veranschaulichen, dass mit der gezielten Auswahl von Inspektionsobjekten mit hohem Risiko durch Nutzung von Big Data und Techniken für maschinelles Lernen einige erhebliche Schwierigkeiten verbunden sind. Diese Herausforderungen bedeuten jedoch in keiner Weise, dass solche Techniken innerhalb eines risikobasierten Ansatzes nicht nützlich sind. Vielmehr veranschaulichen die Herausforderungen, dass eine risikobasierte gezielte Auswahl wahrscheinlich nicht davon profitiert, wenn sie ausschließlich auf Algorithmen für maschinelles Lernen gestützt wird. Das vorstehend angeführte Beispiel aus Norwegen verdeutlicht dies. Anstatt den Algorithmus Objekte direkt gezielt auswählen zu lassen, dürfen die Inspektoren risikoinformierte Entscheidungen auf der Grundlage der vom Algorithmus getroffenen Vorhersagen treffen. Hierbei werden künstliche und menschliche Intelligenz kombiniert, sodass sich die Stärken beider Komponenten jeweils ergänzen. Was Vorhersagen komplexer sozialer Ereignisse im Allgemeinen betrifft, ist die Kombination der beiden Arten von Intelligenz wahrscheinlich eine Notwendigkeit.

Literatur

- Black, J., 2010. Risk-based regulation: Choices, practices and lessons being learnt. In OECD 2010 (ed.), Risk and regulatory policy: Improving the governance of risk. OECD, Paris.
- Blanc, F., 2013. Inspection reforms: why, how, and with what results. OECD, Paris.
- Dahl, Ø., Kilskar, S. S., Skarholt, K., Rosness, R., 2018. Risikobasert tilsyn i de nordiske arbeidstilsynene. [Risikobasierte Arbeitsaufsicht-Inspektionen in den nordischen Ländern.] Nordischer Ministerrat, Kopenhagen.
- Gunningham, N., Sinclair, D., 2007. Factors impinging on the effectiveness of the Mines Inspectorate. Australische Nationaluniversität, Canberra.
- Hajakbari, M. S., Minaei-Bidgoli, B., 2014. A new scoring system for assessing the risk of occupational accidents: A case study using data mining techniques with Iran's Ministry of Labor data. Journal of Loss Prevention in the Process Industries 32, S. 443–453.
- Jacobusse, G., Veenman, C., 2016. On selection bias with imbalanced classes. International Conference on Discovery Science, Bari, S. 325–340.
- Matías, J. M., Rivas, T., Martín, J. E., Taboada, J., 2008. A machine learning methodology for the analysis of workplace accidents. International Journal of Computer Mathematics 85, S. 559–578.
- Mischke, C., Verbeek, J. H., Job, J., Morata, T. C., Alvesalo-Kuusi, A., Neuvonen, K., Clarke, S., Pedlow, R. I., 2013. Occupational safety and health enforcement tools for preventing occupational diseases and injuries. Cochrane Database of Systematic Reviews 2013, Ausg. 8, Art. Nr. CD010183.
- OECD, 2014. OECD Best practice principles for regulatory policy: Regulatory enforcement and inspections. Organisation für wirtschaftliche Zusammenarbeit und Entwicklung, Paris.
- Ridemar, A., 2018. Decision support for SWEA inspections. KTH Königliche Technische Hochschule, Stockholm.
- Robens, L., 1972. Safety and Health at Work: Report of the Committee 1970–1972. Her Majesty's Stationery Office, London.
- Weil, D., 2008. A strategic approach to labour inspection. International Labour Review 147, S. 349–375.

Verfasser: Øyvind Dahl Senior Researcher, SINTEF Digital — Safety and Reliability, Trondheim, Norway

Annick Starren, Europäische Agentur für Sicherheit und Gesundheitsschutz am Arbeitsplatz (EU-OSHA)

In dieser Publikation wird aus Gründen der besseren Lesbarkeit das generische Maskulinum verwendet. Weibliche und anderweitige Geschlechteridentitäten werden dabei ausdrücklich mitgemeint, soweit es für die Aussage erforderlich ist.