

BUDOUCÍ VÝZNAM DAT VELKÉHO OBJEMU A STROJOVÉHO UČENÍ PRO ÚČINNOST INSPEKČÍ BOZP

Úvod

Inspekce jsou pravděpodobně nejdůležitějším nástrojem politiky, který státní inspektoráty práce praktikují, aby zajistily, že společnosti (firmy) podniknou nezbytné kroky k dodržování předpisů v oblasti BOZP. Účinek inspekcí však závisí na několika různých faktorech. Jedním ze základních faktorů je proces výběru objektů inspekce, tj. společností nebo pracovišť, která mají být zkontrolována. V zásadě jsou k dispozici při nejmenším tři různé přístupy k jejich výběru. V rámci prvního přístupu se provádí inspekce všech společností bez ohledu na případné riziko, velikost společnosti, typ odvětví nebo jiná kritéria. Druhý přístup zahrnuje výběr společností na základě náhodného výběru vzorků, kde je pro každou společnost, bez ohledu na jakoukoli charakteristiku, stejně pravděpodobné, že bude vybrána. Pokud jde o preventivní a ekonomické podmínky, obě tyto metody jsou obvykle považovány za neúčinné (Blanc, 2013). Většina inspektorátů práce tak vybírá objekty na základě třetího přístupu, tedy přístupu založeného na rizicích. Stručně řečeno, přístup založený na rizicích zahrnuje výběr objektů inspekce na základě míry rizika.

Ačkoli přístup založený na rizicích je pro většinu moderních inspektorátů práce základním pravidlem, jeho uplatňování v praxi je značně problematické. Hlavním důvodem je to, že chybí dostatečně propracované metody pro analýzu rizik (Mischke a kol., 2013). Bez vhodných metod umožňujících stanovení priorit na základě rizik by se u přístupu založeného na rizicích mohlo stát, že se z něj stane oficiální politické prohlášení bez konkrétních praktických důsledků. Proto je třeba vypracovat metody, které umožní zaměřit se na vysoce rizikové společnosti (Weil, 2008).

Většina inspektorátů práce shromažďuje a ukládá obrovské množství údajů týkajících se jejich objektů inspekce a jejich inspekčních činností. Inspektoráty tak mají potenciálně velké a rychle rostoucí objemy dat, která se dnes označují jako „data velkého objemu“. Data velkého objemu v kombinaci s technologií strojového učení se používají ve stále větší míře pro různé prediktivní účely a slouží pro poučení se ze skrytých tendencí v datech. Prediktivní hodnota dat velkého objemu a technik strojového učení se testuje například v tak odlišných oblastech, jako je prognóza nádorových onemocnění a výsledky pacientů, předpověď bankrotu, vývoj ceny ropy, odhalování daňových podvodů, vývoj trestné činnosti a prognóza akciového trhu. Zásadní otázkou, kterou se v tomto dokumentu zabýváme, je však to, zda použití dat velkého objemu a technologie strojového učení s cílem zaměřit se na vysoce rizikové objekty inspekce je pro inspektoráty práce slibnou cestou.

Výběr na základě rizik

Podle zásad osvědčených postupů pro regulační politiku, které byly stanoveny Organizací pro hospodářskou spolupráci a rozvoj (OECD, 2014), by analýza rizik a hodnocení rizik měly být základem pro vybírání objektů inspekce inspektoráty práce. To znamená, že společnosti by měly být vybírány k inspekci na základě posouzení pravděpodobnosti a důsledků rizikových prvků, jako jsou úrazy, škodlivé expozice a nelegální pracovní podmínky. Základem výběru na základě rizik je přiznání toho, že z důvodu omezených zdrojů určených na inspekce není možné kontrolovat všechny rizikové oblasti a všechny rizikové objekty. Pokud jde o inspekce BOZP prováděné inspektoráty práce, znamená to, že některé problémové oblasti musí být upřednostněny před ostatními. Kromě toho musí být některé společnosti podrobeny inspekci přednostně před ostatními.

Zásada výběru na základě rizik není nová. V rámci hodnocení systému Spojeného království pro dohled nad BOZP provedeného Robensonovým výborem byl téměř před 50 lety v procesu modernizace regulačních inspekcí zaveden přístup založený na rizicích (v kombinaci se samoregulací) (Robens, 1972). Aby se zajistilo nákladově efektivní využívání zdrojů na inspekce, Robensova zpráva doporučila regulačnímu orgánu, aby své zdroje selektivně soustředil na nejzávažnější problémové oblasti a upřednostnil společnosti a problémy, které byly identifikovány na základě systematické analýzy všech dostupných údajů týkajících se BOZP, např. statistik úrazů, technických informací a znalosti místních poměrů ze strany inspektorátů.

Doporučení Robensovy zprávy byla široce přijata inspektoráty práce v mezinárodním měřítku i v členských státech EU. Rozšíření přístupu založeného na rizicích znamená, že většina moderních inspektorátů práce přijala myšlenku stažení zdrojů z objektů s nízkou mírou rizika a soustředění většího objemu zdrojů pro prosazování předpisů na objekty s nejvyšší mírou rizika. Aby to bylo možné, je nutný nějaký způsob analýzy dat. Analytické metody pro identifikaci odvětví s vysokou mírou rizika a skupin pracovníků vystavených riziku jsou dobře propracované. Takové analýzy založené na rizicích obvykle vycházejí z vnitrostátních statistik týkajících se například nemocí z povolání, pracovních úrazů a expozic na pracovišti. Analýzy tvoří základ inspekčních kampaní, strategických plánů a vnitrostátních, a dokonce i mezinárodních, prioritních oblastí.

Metody, které umožňují stanovení priorit napříč společnostmi v rámci odvětví, jsou mnohem méně běžné než široké analýzy založené na rizicích. Obvyklým přístupem inspektorátů práce ohledně výběru konkrétních společností vystavených rizikům je spoléhání se na znalosti místních poměrů ze strany inspektorů. Některé inspektoráty práce, například v Dánsku a Švédsku, prozkoumaly použitelnost systémů hodnocení rizik na základě aditivních měřítek. Při použití aditivních měřítek jsou každé společnosti přidělena bodová hodnocení rizik na základě několika charakteristik (jako je velikost, typ odvětví a počet registrovaných úrazů). Tato bodová hodnocení se sečtou a získá se tak celkový počet bodů. Společnosti s nejvyšším celkovým počtem bodů inspekci podstoupí přednostně. Problém s používáním takových aditivních měřítek je však v tom, že vykazují relativně nízkou úroveň prediktivní platnosti, tj. výsledek není příliš vhodný k tomu, aby oddělil společnosti s vysokou mírou rizika od společností s nízkou mírou rizika.

Data velkého objemu a strojové učení

Stanovení priorit napříč společnostmi je srovnatelný s nalezením jehly v kupce sena. V tomto případě je kupka sena potenciálně tvořena stovkami tisíc možných objektů inspekce, ale pouze určitý počet těchto objektů jsou jehly, tj. subjekty, u nichž je míra rizik neúnosná. Data velkého objemu a strojové učení je do velké míry právě hledáním jehel v kupce sena.

Hlavním cílem algoritmů strojového učení je poskytnout statistický model, který lze použít k provádění předpovědí, klasifikací, odhadů nebo podobných úkolů. Například v oblasti předpovědi nádorových onemocnění vědci používají již více než tři desetiletí algoritmy strojového učení pro předpověď náchylnosti k těmto onemocněním, jejich recidivy a přežití. Tematicky je předpověď nádorových onemocnění velmi vzdálená výběru objektů inspekce na základě rizik. V obou případech se však jedná o příklady prediktivních výzev nebo problémů typu jehly v kupce sena.

Dva hlavní běžné druhy algoritmů strojového učení jsou učení s učitelem a učení bez učitele. U učení s učitelem sestává algoritmus ze závislé proměnné (např. míra rizika), která se má předpovídat ze souboru nezávislých proměnných. Přesné předpovědi samozřejmě vyžadují vysokou míru korelace mezi nezávislými proměnnými a závislou proměnnou. U učení bez učitele neexistuje žádná závislá proměnná, která by se měla předpovídat, ale cílem algoritmu je seskupit data do skupin (např. různých rizikových skupin) podle podobnosti. Na rozdíl od aditivních měřítek, jako jsou ta, která zkoumají inspektoráty práce v Dánsku a Švédsku, algoritmy používané ve strojovém učení postupně zlepšují své předpovědi, zejména metodou pokusů a omylů. To znamená, že stroj se učí z minulých úspěchů (správných předpovědí) a chyb (nesprávných

předpovědi) a na základě obdržené zpětné vazby se pokouší tyto znalosti zužitkovat tak, aby předpovědi byly přesnější.

Využití dat velkého objemu a strojového učení při výběru objektů inspekce

Algoritmy učení s učitelem a bez učitele vyžadují dostatečný objem dat, pokud jde o počet pozorování i počet proměnných, obvykle označovaných jako „charakteristiky“. Jak již bylo uvedeno, většina inspektorátů práce shromažďuje a ukládá obrovské množství údajů o svých objektech inspekce a svých inspekčních činnostech. Dostupné údaje se obvykle týkají specifických charakteristik společnosti, jako je počet zaměstnanců, délka existence společnosti, skupina odvětví, počet předchozích inspekcí, výsledky předchozích inspekcí a oznámení úrazů. Kromě toho se v důsledku přidávání výsledků nových inspekcí množství údajů každým dnem zvyšuje. V zásadě by tedy řešení problému výběru společností s vysokou mírou rizika pomocí dat velkého objemu mělo být přinejmenším na první pohled vhodné pro algoritmy strojového učení. Navzdory tomu se uskutečnilo jen málo takových pokusů. Existuje však několik pozoruhodných výjimek, přičemž všechny ukazují, že data velkého objemu a strojové učení by mohly být pro inspektoráty práce velmi důležité pro řešení problému výběru objektů inspekce s vysokou mírou rizika.

Prvním příkladem je výzkumná studie, která zkoumala vhodnost metodiky strojového učení pro předpověď pracovních úrazů, nebo konkrétněji pádů na stejné úrovni (Matías a kol., 2008). Navzdory relativně přesným předpovědím je nevýhodou této studie to, že charakteristiky obsažené v algoritmech nejsou typem údajů, které inspektoráty práce normálně mají k dispozici (např. použití osobních ochranných pracovních prostředků a úklidové postupy). Kromě toho pády na stejné úrovni představují jen nepatrnou část rizik na pracovišti, kterými se inspektoráty práce zabývají.

Druhým příkladem je také výzkumná studie (Hajakbari a Minaei-Bidgoli, 2014). Tato studie vytvořila bodovací systém pro předpovídání rizika pracovních úrazů. Studie navíc dospěla k závěru, že lze poměrně přesně předpovědět riziko různých typů pracovních úrazů na základě některých obecných charakteristik společnosti (hlavní činnost společnosti, rozložení pohlaví, počet zaměstnanců atd.). Studie dále dospěla k závěru, že algoritmus by mohl být použit k identifikaci pracovišť, která je nutné podrobovat inspekcím BOZP pravidelně. Data použitá v této studii byla získána z databáze inspektorátu práce. Nevýhodou studie je však opět to, že pracovní úrazy představují pouze jedno z mnoha rizik na pracovišti, jimiž se inspektoráty práce zabývají. Zvláštním problémem, pokud se spoléháme na statistiku úrazů, je mimoto skutečnost, že tyto údaje jsou zřejmě velmi náchylné k podhodnocování.

Třetím příkladem je nástroj vyvinutý norským Úřadem inspekce práce (NLIA) na pomoc inspektorům při výběru společností s ohledem na riziko (Dahl a kol., 2018). Tento nástroj s názvem Nástroj pro predikci rizikových skupin (RGPT, z angl. *Risk Group Prediction Tool*) rozděluje společnosti do čtyř skupin na základě předpovězeného rizika: společnosti s nejnižší mírou rizika, s nízkou mírou rizika, s vysokou mírou rizika a s nejvyšší mírou rizika. Čím vyšší je míra rizika pro skupinu, do níž je daná společnost zařazena, tím vyšší je pravděpodobnost, že budoucí inspekce v této společnosti odhalí závažné odchylky od dodržování předpisů v oblasti BOZP. Skupina, ke které je společnost přiřazena, je pro inspektory viditelná prostřednictvím interního webového uživatelského rozhraní úřadu NLIA. Proto při výběru společností k inspekci jsou inspektoři informováni o rizikových skupinách společností a jsou tak schopni provádět výběr podle rizik.

Nástroj RGPT byl vytvořen na základě prediktivního modelování pomocí algoritmu strojového učení za pomoci tzv. binární logistické regresní analýzy. Na základě regresního modelu jsou všechny společnosti v Norsku (přibližně 230 000 společností) zařazeny do jedné ze čtyř rizikových skupin. To se provádí ve dvou krocích. V prvním kroku regresní model předpovídá, jak je pravděpodobné, že budoucí inspekce odhalí závažné odchylky od dodržování předpisů v oblasti

BOZP. Ve druhém kroku model používá předpovězenou hodnotu pravděpodobnosti k zařazení společnosti do rizikové skupiny.

Původně byl tento nástroj vyvinut na základě záznamů z přibližně 35 000 inspekci BOZP provedených úřadem NLIA. S rostoucím počtem inspekci se však předpovědi prováděné pomocí nástroje postupně a automaticky zpřesňují. To znamená, že se algoritmus sám nastavuje na základě zpětné vazby (správné nebo chybné předpovědi), kterou obdrží, když jsou prováděny nové inspekce a jsou zaznamenávány do databáze úřadu NLIA.

Nástroj RGPT spadá do třídy algoritmů učení s učitelem, kde inspekce BOZP, jejichž výsledkem jsou závažné odchylky (závislá proměnná), musí být předpovídány ze souboru charakteristik společnosti. Nástroj RGPT používá obecné charakteristiky společnosti, jako je její velikost, odvětvová skupina, počet předchozích inspekci, výsledky předchozích inspekci, délka existence společnosti, zeměpisné umístění a oznámení úrazů. Prediktivní platnost nástroje je prověřována každý měsíc a dosavadní zkušenost (po přibližně 18 měsících testování) je taková, že algoritmus dokáže mimořádně přesně vybírat společnosti s vysokou mírou rizika. To znamená, že existuje jen málo falešně pozitivních a falešně negativních inspekci, tj. málo inspekci v rámci skupiny s nejnižší mírou rizika vede k identifikaci závažných odchylek, zatímco velká většina inspekci v rámci skupiny s nejvyšší mírou rizika k identifikaci závažných odchylek vede. Skupiny s nízkou a vysokou mírou rizika spadají mezi oba tyto extrémy.

Zjištění, která jsou výsledkem použití nástroje vyvinutého úřadem NLIA, ukazují, že je možné zaměřit se na objekty inspekce pomocí použití dat velkého objemu a strojového učení. Podobné přístupy ke strojovému učení byly také testovány nejméně dvěma dalšími evropskými inspektoráty práce se slibnými výsledky: švédským Úřadem pro pracovní prostředí (Ridemar, 2018) a nizozemským inspektorátem SZW (Jacobusse a Veenman, 2016). Norský nástroj však nemusí být nutně uplatnitelný i jinými inspektoráty práce, protože jeho použití závisí na tom, jak jsou údaje uchovávány, na kvalitě údajů, přístupu k nim a struktuře databáze. Vybírání společností na základě nástroje zahrnuje navíc přijetí způsobu, jakým je riziko definováno a zohledněno v algoritmu. Jak je popsáno, nástroj je založen na definici rizika, což znamená, že čím vyšší je riziko pro skupinu, do které je společnost zařazena, tím vyšší je pravděpodobnost, že inspekce v této společnosti odhalí vážné odchylky od dodržování předpisů v oblasti BOZP. To znamená, že tento nástroj se primárně zabývá tzv. riziky řízení a kontroly, a nikoliv inherentními riziky. Zatímco rizika řízení a kontroly vyplývají ze schopnosti a ochoty společnosti řídit riziko (např. dodržováním příslušných předpisů), inherentní rizika jsou ta, která vyplývají z povahy činnosti společnosti (např. pád z výšky, expozice chemickým látkám a zatížení muskuloskeletálního systému).

Rizika spojená s řízením a kontrolou a inherentní rizika jsou v praxi propojena. To však neznamena, že oba typy rizik spolu nutně do velké míry empiricky souvisí. Pokud se tedy slepě spoléháme na nástroje, které se zaměřují na společnosti na základě jednoho typu rizik, může to vést k opomenutí jiného typu rizik. V norském regulačním systému je tato výzva řešena zaměřením se zejména na inherentní rizika při určování prioritních oblastí, skupin pracovníků vystavených rizikům a průmyslových odvětví s vysokou mírou rizika, zatímco rizika v oblasti řízení a kontroly hrají zásadní úlohu při konkrétním výběru společností.

Výzvy

Skutečnost, že rizika v oblasti řízení a kontroly na jedné straně a inherentní rizika na straně druhé nemusí nutně empiricky souviset, nás vede k další, pravděpodobně ještě větší výzvě při používání algoritmů dat velkého objemu a strojového učení pro výběr na základě rizik. Všechny tři výše uvedené příklady nástrojů strojového učení jsou příklady výběru na základě jednoho hlediska, tj. na základě jedné konkrétní definice a operacionalizace rizika. Ve světě práce však neexistuje jen jeden konkrétní typ rizik. Orgány odpovědné za prosazování předpisů se proto zabývají různými typy rizik, jako jsou např. úrazy, expozice chemickým látkám, vystavení biologickým látkám, psychosociální hrozby, rizikové faktory pro muskuloskeletální systém a sociální dumping.

V rámci těchto typů rizik existuje ještě více dílčích typů. Vývoj modelů rizik, které dokážou zachytit tuto rozmanitost, je velmi náročný, protože různé typy rizik spolu nemusí nutně souviset. Zachycení této rozmanitosti se tedy zcela liší od předpovídání pravděpodobnosti jednoho konkrétního typu rizika (Dahl a kol., 2018).

Druhá, ale také související výzva, ještě více komplikuje úkol výběru na základě rizik. Toto je tzv. politická past (Black, 2010). Přestože algoritmy strojového učení jsou dynamické v tom smyslu, že je možné se poučit z úspěchů a chyb a přizpůsobovat se jim, nemohou vzít v úvahu různé politické úhly pohledu. Zaprvé, politický kontext je nestálý. Typy rizik, která si zaslouží zvláštní pozornost dnes, si ji nemusí zasloužit zítra. Za druhé, politický kontext je mnohostranný. Různé zúčastněné strany, např. politici, zaměstnavatelé, zaměstnanci, sdělovací prostředky a veřejnost mají různé názory na to, jaké typy rizik si zaslouží zvláštní pozornost. To ukazuje, že riziko ve světě práce nemusí být nutně objektivní entitou, ale může být sociální konstrukcí.

Třetí výzva, která stojí za zvážení, souvisí se skutečností, že ačkoli inspektoráty práce mají obrovské množství údajů týkajících se jejich objektů inspekce, tyto údaje se obvykle vztahují přímo ke společnosti a údaje na úrovni společnosti nemusí být nutně nejhodnějšími údaji, které je třeba zvážit (viz například Gunningham a Sinclair, 2007). V databázi je jedinečná společnost obvykle identifikována jedinečným identifikátorem, jako je například číslo organizace. Schopnost algoritmu strojového učení přiřadit danou předpovězenou rizikovou hodnotu dané společnosti závisí na jedinečných identifikátorech. Všechny potenciální objekty inspekce však nejsou automaticky identifikovatelné na základě jedinečného identifikátoru. Například ve stavebnictví to není nutně konkrétní společnost, která je cílem inspekce, ale dočasné staveniště. S takovou dočasností souvisí přinejmenším dvě výzvy. Zaprvé, staveniště a jiná dočasná pracoviště nemusí být identifikovatelná na základě jedinečných identifikátorů. Zadruhé, i kdyby identifikovatelná byla, jejich dočasnost znamená, že algoritmus strojového učení nemusí dostat příležitost poučit se ze svých predikčních úspěchů a chyb, než přestane staveniště fungovat, a společnosti, které toto staveniště používaly, se přesunou v novém uskupení na nové staveniště.

Závěrečné poznámky

Výše popsané výzvy ukazují, že při výběru objektů inspekce s vysokou mírou rizika s využitím technik dat velkého objemu a strojového učení existují značné potíže. Tyto výzvy však nijak neznehodnocují užitečnost těchto technik v rámci přístupu založeného na rizicích. Výzvy spíše ukazují, že výběr na základě rizik pravděpodobně nebude plně spoléhat na algoritmy strojového učení. To dokládá výše uvedený norský příklad. Místo toho, aby algoritmus mohl přímo vybírat objekty, mohou inspektoři přijímat rozhodnutí za pomoci informací o rizicích na základě předpovědí, které algoritmus vytváří. To zahrnuje kombinaci umělé a lidské inteligence, kde každá z nich doplňuje silné stránky druhé inteligence. Pokud jde o předpovědi složitých společenských událostí obecně, je pravděpodobně nutné kombinovat oba tyto typy inteligence.

Použitá literatura

- Black, J., 2010. Risk-based regulation: Choices, practices and lessons being learnt. OECD 2010 (ed.), Risk and regulatory policy: Improving the governance of risk. OECD, Paříž.
- Blanc, F., 2013. Inspection reforms: why, how, and with what results. OECD, Paříž.
- Dahl, Ø., Kilskar, S. S., Skarholt, K., Rosness, R., 2018. Risikobasert tilsyn i de nordiske arbeidstilsynene. [Inspekce práce založené na rizicích ve skandinávských zemích.] Severská rada ministrů, Kodaň.
- Gunningham, N., Sinclair, D., 2007. Factors impinging on the effectiveness of the Mines Inspectorate. Australská národní univerzita, 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. Mezinárodní konference o objevené vědě, 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, Issue 8, Art. No CD010183.
- OECD, 2014. OECD Best practice principles for regulatory policy: Regulatory enforcement and inspections. Organizace pro hospodářskou spolupráci a rozvoj, Paříž.
- Ridemar, A., 2018. Decision support for SWEA inspections. KTH Royal Institute of Technology, Stockholm.
- Robens, L., 1972. Safety and Health at Work: Report of the Committee 1970-1972. Her Majesty's Stationery Office, Londýn.
- Weil, D., 2008. A strategic approach to labour inspection. International Labour Review 147, s. 349–375.

Autoři: Øyvind Dahl, Senior Researcher, SINTEF Digital – Safety and Reliability, Trondheim, Norsko.

Annick Starren, Evropská agentura pro bezpečnost a ochranu zdraví při práci (EU-OSHA).