

## A NAGY ADATHALMAZOK ÉS A GÉPI TANULÁS JÖVŐBENI SZEREPE AZ EGÉSZSÉGVÉDELMI ÉS BIZTONSÁGI ELLENŐRZÉSEK HATÉKONYSÁGÁBAN

### Bevezetés

A kormányzati munkavédelmi felügyelőségek számára valószínűleg az ellenőrzések jelentik a legfontosabb szakpolitikai eszközt annak biztosítására, hogy a vállalatok megtegyék a munkahelyi egészségvédelmi és biztonsági szabályoknak való megfeleléshez szükséges lépéseket. Az ellenőrzések hatása azonban több különböző tényezőtől függ. Az egyik alapvető tényező a vizsgálati alanyok, azaz az ellenőrizendő vállalatok vagy helyszínek kiválasztásának folyamata. Elvben legalább három különböző kiválasztási megközelítés áll rendelkezésre. Az első megközelítés szerint minden vállalatot ellenőrizni kell, függetlenül a potenciális kockázattól, a vállalat méretétől, az iparág típusától vagy bármely más szemponttól. A második megközelítés a vállalkozások véletlenszerű mintavétel alapján történő kiválasztását jelenti, ahol minden vállalkozás kiválasztásának – bármely jellemzőtől függetlenül – azonos a valószínűsége. A megelőzési és gazdasági feltételek szempontjából mindkét módszer általában eredménytelennek tekinthető (Blanc, 2013). Ezért a legtöbb munkavédelmi felügyelőség a vizsgálati alanyokat a harmadik, azaz a kockázatalapú megközelítés alapján választja ki. Röviden, a kockázatalapú megközelítés a vizsgálati alanyok kockázati szint alapján történő kiválasztását jelenti.

Bár a kockázatalapú megközelítés a legtöbb modern munkavédelmi felügyelőség számára alapvető elv, gyakorlatban való alkalmazása jelentős kihívásokkal jár. Ennek fő oka az, hogy nem állnak rendelkezésre kellően részletes kockázatelemzési módszerek (Mischke et al., 2013). A kockázatalapú rangsorolást lehetővé tevő megfelelő módszerek hiányában a kockázatalapú megközelítés azzal a kockázattal jár, hogy kézzelfogható gyakorlati következmények nélküli kormányzati politikai állásfoglalássá válik. Ezért olyan módszerek kidolgozására van szükség, amelyek lehetővé teszik a magas kockázatú vállalatok megcélzását (Weil, 2008).

A legtöbb munkavédelmi felügyelőség hatalmas mennyiségű adatot gyűjt és tárol az ellenőrzött alanyokról és ellenőrzési tevékenységeiről. Így a felügyelőségek potenciálisan nagy és gyorsan növekvő adatmennyiségekkel rendelkeznek, amelyeket manapság „nagy adathalmazoknak” neveznek. A gépi tanulási technológiával kombinált nagy adathalmazokat egyre gyakrabban használják különböző előrejelzési célokra az adatokban található rejtett tendenciákból való tanulás révén. A nagy adathalmazok és a gépi tanulási technológiák prediktív értékét például olyan különböző területeken tesztelik, mint a rákos megbetegedések előrejelzése és a betegekkel kapcsolatos eredmények, csődelőrejelzés, olajár-előrejelzés, adócsalás-felderítés, bűncselekmény-előrejelzés és tőzsdei előrejelzések. Az e dokumentumban tárgyalt alapvető kérdés azonban az, hogy a nagy adathalmazok és a gépi tanulási technológiák használata megfelelőnek ígérkezik-e a munkavédelmi felügyelőségek számára a magas kockázatú vizsgálati alanyok kiválasztása tekintetében.

### Kockázatalapú célmeghatározás

A szabályozási politika bevált gyakorlatainak a Gazdasági Együttműködési és Fejlesztési Szervezet által megfogalmazott elvei (OECD, 2014) szerint az ellenőrzési alanyok kiválasztásakor a munkavédelmi felügyelőségeknek a kockázatelemzést és -értékelést kell alapul venniük. Ez azt jelenti, hogy az ellenőrizendő vállalatokat olyan kockázati tényezők valószínűségének és következményeinek értékelése alapján kell kiválasztani, mint a balesetek, a veszélyes anyagoknak való kitettség és az illegális munkakörülmények. A kockázatalapú megközelítés alapját annak a

felismerése jelenti, hogy a korlátozott ellenőrzési erőforrások miatt nem lehet minden kockázati területet és minden kockázati alanyt ellenőrizni. A munkavédelmi ellenőrzési hatóságok által végzett egészségvédelmi és biztonsági ellenőrzések tekintetében ez azt jelenti, hogy bizonyos problémás területeket kiemelten kell kezelni másokkal szemben. Ezenkívül bizonyos vállalatokra fokozottabban kell összpontosítani, mint másokra.

A kockázatalapú kiválasztás elve nem új keletű. Közel 50 évvel ezelőtt a Robens-bizottság az Egyesült Királyság munkahelyi biztonsági és egészségvédelmi felügyeleti rendszerének értékelése során a kockázatalapú megközelítést (az önszabályozással kombinálva) mint ideális módszert vezette be a szabályozói ellenőrzés korszerűsítése keretében (Robens, 1972). Az ellenőrzési erőforrások költséghatékony felhasználásának biztosítása érdekében a Robens-jelentés azt ajánlotta a szabályozó hatóságnak, hogy erőforrásait szelektíven összpontosítsa a legproblémásabb területekre és állítson fel fontossági sorrendet az egészséggel és biztonsággal kapcsolatos valamennyi rendelkezésre álló adat – például baleseti statisztikák, műszaki információk és a felügyelőségek helyi ismereteinek – szisztematikus elemzése révén azonosított vállalatok és problémák között.

A Robens-jelentés ajánlásait a munkavédelmi felügyelőségek nemzetközi szinten és az uniós tagállamokban széles körben átvették. A kockázatalapú megközelítés elterjedése azt jelenti, hogy a legtöbb modern munkaügyi felügyelőség immár alkalmazza azt az elképzelést, hogy erőforrásait az alacsony kockázatú alanyoktól átcsoportosítja a legnagyobb kockázatú alanyokkal kapcsolatos jogérvényesítésre. Ennek lehetővé tétele érdekében bizonyos típusú adatelemzés szükséges. A magas kockázatú ágazatok és a kockázatnak kitett munkavállalói csoportok meghatározására szolgáló analitikai módszerek jól kidolgozottak. Az ilyen kockázatalapú értékelések jellemzően például a foglalkozási megbetegedésekkel, az munkabalesetekkel és a munkahelyi veszélyeknek való kitettségrel kapcsolatos nemzeti statisztikákon alapulnak. Az elemzések ellenőrzési kampányok, stratégiai tervek, valamint nemzeti, sőt nemzetközi prioritási területek meghatározásának alapját képezik.

A széles körű kockázatalapú elemzéseknél jóval kevésbé gyakoriak azok a módszerek, amelyek lehetővé teszik adott ágazaton belül a vállalatok rangsorolását. A munkavédelmi felügyelőségek körében a kockázatnak kitett konkrét vállalatok kiválasztásával kapcsolatos gyakori megközelítés a felügyelők helyi ismereteinek alapul vétele. Egyes munkavédelmi felügyelőségek, például a dán és a svéd felügyelőségek megvizsgálták az összegző skálán alapuló kockázati rangsorolási rendszerek használhatóságát. Összegző skálák alkalmazásakor minden vállalat kockázati pontszámot kap számos vállalati jellemző alapján (pl. méret, iparág típusa és regisztrált balesetek száma), amelyeket összeadnak és így összesített pontszámot kapnak, és az ellenőrzés során a legmagasabb összpontszámmal rendelkező vállalatokat sorolják előre. Az ilyen összegző skálák alkalmazásával azonban az a probléma, hogy előrejelző érvényességük viszonylag alacsony, azaz a pontszám nem különösen alkalmas a magas és az alacsony kockázatú vállalkozások elkülönítésére.

## Nagy adathalmazok és gépi tanulás

A vállalatok közötti rangsor kialakításának folyamata olyan, mintha tűt keresnénk a szénakazalban. Ebben az esetben a szénakazal több százezer potenciális ellenőrzési alanyt jelent, de ezen alanyok közül csak néhány számít tűnek, vagyis olyan vállalatnak, ahol a kockázat meghaladja a tolerálható szintet. A nagy adathalmazok és a gépi tanulás nagyrészt a tűk megtalálását jelenti a szénakazalban.

A gépi tanulási algoritmusok fő célja olyan statisztikai modell létrehozása, amely előrejelzések, osztályozások, becslések vagy hasonló feladatok elvégzésére használható. A rákkal kapcsolatos előrejelzések terén például a kutatók több mint három évtizede alkalmaznak gépi tanulási algoritmusokat a rákra való hajlam, valamint a rák kiújulásának és túlélésének előrejelzésére. Tematikus szempontból a rákkal kapcsolatos előrejelzések igen távol állnak a vizsgálati alanyok

kockázatalapú kiválasztásától. Ugyanakkor mindkét esetben az előrejelzéssel kapcsolatos kihívásokról, vagyis a „tű a szénakazalban” problémáról van szó.

A gépi tanulási algoritmusok két fő típusa a felügyelt tanulás és a felügyelet nélküli tanulás. A felügyelt tanulás esetében az algoritmus egy függő változóból (pl. kockázati szint) áll, amelyet független változók sorozatából kell megjósolni. A pontos előrejelzés természetesen a független változók és a függő változók közötti nagyfokú korrelációt tesz szükségessé. A felügyelet nélküli tanulás esetében nincsen előre jelzendő függő változó, hanem az algoritmus célja az adatok csoportokba (pl. különböző kockázati csoportokba) való besorolása a hasonlóság alapján. Az összegző skálákkal ellentétben – mint amilyeneket a dán és svéd munkavédelmi felügyelőségek tártak fel – a gépi tanulás során használt algoritmusok fokozatosan javítják előrejelzéseiket, elsősorban többszöri próbálkozások révén. Ez azt jelenti, hogy a gép tanul a korábbi sikereiből (helyes előrejelzések) és hibáiból (helytelen előrejelzések) és megpróbálja felhasználni ezeket az ismereteket annak érdekében, hogy a kapott visszajelzések alapján pontosabb előrejelzéseket adjon.

## Nagy adathalmazok és gépi tanulás felhasználása az ellenőrizendő alanyok kiválasztásában

A felügyelt és felügyelet nélküli tanulási algoritmusok elegendő mennyiségű adatot igényelnek mind a megfigyelések száma, mind a változók száma tekintetében, amelyeket általában „jellemzőknek” neveznek. Mint már említettük, a legtöbb munkavédelmi felügyelőség hatalmas mennyiségű adatot gyűjt és tárol az ellenőrzött alanyokról és ellenőrzési tevékenységeiről. A rendelkezésre álló adatok jellemzően olyan vállalatspecifikus jellemzőkre vonatkoznak, mint az alkalmazottak száma, a vállalat kora, az ágazati besorolás, a korábbi ellenőrzések száma, a korábbi ellenőrzések eredményei és a balesetek bejelentése. Ezenkívül az adatok mennyisége napról napra nő, ahogy az adatbázis az új ellenőrzések eredményeivel bővül. Elvben tehát a nagy kockázatú vállalatok nagy adathalmazok felhasználásával történő kiválasztásával kapcsolatos kihívás kezelésére – legalábbis első pillantásra – alkalmasnak kellene lenniük a gépi tanulási algoritmusoknak. Ennek ellenére ez idáig kevés ilyen próbálkozás történt. Van azonban néhány figyelemre méltó kivétel, amelyek mindegyike azt mutatja, hogy a nagy adathalmazok és a gépi tanulás rendkívül fontos lehet a munkavédelmi felügyelőségek számára, hogy megoldják a magas kockázatú vizsgálati alanyok kiválasztásával kapcsolatos kihívást.

Az első példa egy kutatási tanulmány, amely azt vizsgálta, hogy a gépi tanulási módszerek alkalmasak-e a munkahelyi balesetek, konkrétan szintbeli esések előrejelzésére (Matfias et al., 2008). A viszonylag pontos előrejelzések ellenére a tanulmány hátránya, hogy az algoritmusokban szereplő jellemzők nem olyan típusú adatok, amelyekkel a munkavédelmi felügyelőségek általában rendelkeznek (pl. egyéni védőfelszerelés használata és a megfelelő munkakörülmények biztosítása érdekében alkalmazott gyakorlatok). Továbbá a szintbeli esések a munkaügyi felügyelőségek által vizsgált munkahelyi kockázatoknak csak csekély részét teszik ki.

A második példa szintén egy kutatási tanulmány (Hajakbari és Minaei-Bidgoli, 2014). A tanulmány pontozási rendszert dolgozott ki a munkahelyi balesetek kockázatának előrejelzésére és arra a következtetésre jutott, hogy a különböző típusú munkahelyi balesetek kockázata viszonylag pontosan előre jelezhető bizonyos általános vállalati jellemzők (a társaság fő tevékenysége, a nemek megoszlása, alkalmazottak száma stb.) alapján. A tanulmány továbbá megállapította, hogy az algoritmust fel lehetne használni olyan munkahelyek azonosítására, ahol időszakos egészségvédelmi és biztonsági ellenőrzések szükségesek. A tanulmányban felhasznált adatok egy munkavédelmi felügyelőség adatbázisából származtak. A tanulmány hátulütője azonban ismét az, hogy a munkahelyi balesetek csak egyikét jelentik azon számos munkahelyi kockázatnak, amellyel a munkavédelmi felügyelőségek foglalkoznak. A sérülésekkel foglalkozó statisztikák alapul vételével kapcsolatos egyik konkrét probléma továbbá az, hogy ezeknek az adatoknak az esetében közismerten jellemző a ténylegesnél jelentős mértékben alacsonyabb bejelentési arány.

A harmadik példa a Norvég Munkaügyi Felügyeleti Hatóság (NLIA) által kifejlesztett eszköz, amelynek célja, hogy segítséget nyújtson az ellenőröknek a vállalkozások kockázati szempontból történő kiválasztásában (Dahl et al., 2018). A Kockázati Csoport Előrejelző Eszköz (RGPT) elnevezésű eljárás az előre jelzett kockázat alapján négy csoportba sorolja a vállalkozásokat: legalacsonyabb, alacsony, magas és a legmagasabb kockázatú vállalkozások. Minél magasabb egy adott vállalat kockázati besorolása, annál nagyobb a valószínűsége annak, hogy a vállalatnál a jövőben elvégzendő ellenőrzés az egészségvédelmi és biztonsági szabályoknak történő megfeleléstől való súlyos eltéréseket tár majd fel. A vállalatok besorolását az ellenőrök az NLIA intranetes webalapú felhasználói felületén keresztül tekinthetik meg. Ennek következtében adott vállalat ellenőrzésre történő kiválasztásakor az ellenőrököt tájékoztatják a vállalat kockázati besorolásáról, ami lehetővé teszi számukra a kockázaton alapuló kiválasztást.

Az RGPT-t prediktív modellezés alapján hozták létre úgynevezett bináris logisztikus regresszióanalízist felhasználó gépi tanulási mechanizmus segítségével. A regressziós modell alapján az összes norvégiai vállalatot (körülbelül 230 000) besorolják a négy kockázati csoport valamelyikébe. Ez két lépésben történik. Az első lépésben a regressziós modell előre jelzi annak valószínűségét, hogy egy jövőbeli ellenőrzés súlyos eltéréseket fog feltárni az egészségvédelmi és biztonsági szabályoknak való megfelelés területén. A második lépésben a modell az előre jelzett valószínűségi értéket használja fel valamely vállalat kockázati csoportba történő besorolásához.

Az eszközt kezdetben az NLIA által elvégzett körülbelül 35 000 egészségvédelmi és biztonsági ellenőrzésből származó nyilvántartási adatok alapján fejlesztették ki. Az eszköz által készített előrejelzések azonban az ellenőrzések számának növekedésével fokozatosan és automatikusan egyre pontosabbá válnak. Ez azt jelenti, hogy az algoritmus új vizsgálatok elvégzése és az NLIA adatbázisában való nyilvántartásba vétele során kapott visszajelzések (helyes vagy hibás előrejelzések) alapján kiigazítja önmagát.

Az RGPT a felügyelt tanulási algoritmusok csoportjába tartozik, ahol a súlyos eltéréseket eredményező egészségvédelmi és biztonsági ellenőrzések (függő változó) előrejelzése egy sor vállalati tulajdonság (jellemzők) alapján történik. Az RGPT olyan általános vállalati jellemzőket használ, mint a vállalat mérete, az ipari ágazat, a korábbi ellenőrzések száma, a korábbi ellenőrzések eredményei, a vállalat kora, a földrajzi elhelyezkedés és a balesetek bejelentése. Az eszköz előrejelző érvényességét havonta ellenőrzik, és az eddigi tapasztalatok (körülbelül 18 hónapos tesztelés után) azt mutatják, hogy az algoritmus rendkívül pontosan képes kiválasztani a magas kockázatú vállalatokat. Ez azt jelenti, hogy kevés a hamis pozitív és a hamis negatív előrejelzés, azaz a legalacsonyabb kockázati csoporton belül kevés ellenőrzés vezet súlyos eltérések feltáráshoz, míg a legmagasabb kockázati csoporton belül végzett ellenőrzések túlnyomó többsége súlyos eltéréseket tár fel. Az alacsony és magas kockázatú csoportok a két szélsőség között helyezkednek el.

Az NLIA által kifejlesztett eszköz alkalmazásának eredményei azt mutatják, hogy az ellenőrizendő alanyok kiválasztása lehetséges nagy adathalmazok és gépi tanulás felhasználásával. Legalább két másik európai munkavédelmi felügyelőség is tesztelt hasonló gépi tanulási módszereket ígéretes eredményekkel: a Svéd Munkakörnyezeti Hatóság (Ridemar, 2018) és az SZW holland felügyelőség (Jacobusse és Veenman, 2016). A norvég eszköz azonban nem feltétlenül ültethető át más munkavédelmi felügyelőségekhez, mivel használata az adatok tárolásának módjától, az adatok minőségétől, az adatokhoz való hozzáféréstől és az adatbázis szerkezetétől függ. Ezenkívül a vállalatoknak az eszköz alapján ellenőrzés céljából történő kiválasztása azzal jár, hogy elfogadják a kockázat algoritmusban történő meghatározásának és gyakorlati felhasználásának módját. Ahogy elmondtuk, az eszköz a kockázat olyan meghatározásán alapul, amely azt jelenti, hogy minél magasabb egy adott vállalat kockázati besorolása, annál nagyobb a valószínűsége annak, hogy a vállalatnál elvégzendő ellenőrzés az egészségvédelmi és biztonsági szabályoknak való megfeleléstől való súlyos eltéréseket fog feltárni. Ez azt jelenti, hogy az eszköz elsősorban az úgynevezett irányítási és ellenőrzési kockázatokkal, nem pedig az eredendő kockázatokkal

foglalkozik. Míg az irányítási és ellenőrzési kockázatok a vállalat kockázatkezelési képességéből és hajlandóságából erednek (pl. a vonatkozó szabályozásnak való megfelelés révén), az eredendő kockázatok a vállalkozás tevékenységeinek jellegéből adódnak (pl. magasból történő zuhanás, vegyi anyagoknak való kitettség és váz- és izomrendszeri megterhelés).

A gyakorlatban az irányítási és ellenőrzési kockázatok és az eredendő kockázatok kapcsolatban állnak egymással. Ez azonban nem jelenti azt, hogy a két kockázattípus szükségszerűen empirikusan szoros összefüggésben van egymással. Ezért ha vakon olyan eszközökre támaszkodunk, amelyek a vállalatokat az egyik kockázattípus alapján választják ki, akkor az a másik típus elmulasztását eredményezheti. A norvég szabályozási rendszerben ezt a kihívást az eredendő kockázatok hangsúlyozásával kezelik a kiemelt területek, a kockázatnak kitett munkavállalói csoportok és a magas kockázatú ágazatok meghatározásakor, míg kifejezetten a vállalatok kiválasztásakor az irányítási és ellenőrzési kockázatok a hangsúlyosak.

## Kihívások

Az, hogy egyrészt az irányítási és ellenőrzési kockázatok, másrészt az eredendő kockázatok empirikusan nem feltétlenül korrelálnak egymással, újabb – és valószínűleg még nagyobb – kihívást jelent a nagy adathalmazok és a gépi tanulási algoritmusok kockázatalapú célmeghatározásra való felhasználása terén. A fenti három gépi tanulási eszköz mindegyike az egydimenziós célmeghatározásra példa, azaz a célmeghatározás a kockázat egy konkrét meghatározásán és gyakorlati működtetésén alapul. A munka világában azonban a kockázatok nem csak egy konkrét típusba tartoznak. A végrehajtó hatóságok ezért többféle kockázattípussal foglalkoznak, például balesetekkel, vegyi anyagoknak való kitettséggel, biológiai kitettséggel, pszichoszociális veszélyekkel, váz- és izomrendszeri kockázati tényezőkkel és szociális dömpinggel. Ezekben a kockázattípusokon belül további altípusok léteznek. Az ilyen változatos kockázatok figyelembevételére alkalmas kockázati modellek kidolgozása igen nagy kihívást jelent, mivel a különböző típusú kockázatok nem feltétlenül vannak összefüggésben egymással. Ezért ennek a változatosságnak a figyelembevétele nagymértékben eltér egy adott típusú kockázat valószínűségének előrejelzésétől (Dahl et al., 2018).

Egy másik, ugyanakkor kapcsolódó kihívás még bonyolultabbá teszi a kockázatalapú célmeghatározást. Ez az úgynevezett politikai buktató (Black, 2010). Bár a gépi tanulási algoritmusok dinamikusak abban az értelemben, hogy képesek tanulni a sikerekből és hibákból és alkalmazkodhatnak azokhoz, nem vehetnek figyelembe különböző politikai szempontokat. Először is, a politikai környezet változékony. Ezért lehetséges, hogy a ma kiemelten kezelt kockázattípusokra holnap már nem biztos, hogy érdemes hangsúlyt fektetni. Másodsor, a politikai környezet sokféle. Ezért a különböző érdekelt felek, azaz a politikusok, munkáltatók, munkavállalók, a média és a közvélemény eltérő álláspontot képviselnek azzal kapcsolatban, hogy mely típusú kockázatokot érdemes kiemelten kezelni. Ez azt mutatja, hogy a kockázat a munka világában nem feltétlenül objektív jellemző, hanem társadalmi konstrukció.

Egy harmadik megfontolásra érdemes kihívás ahhoz a tényhez kapcsolódik, hogy bár a munkavédelmi felügyelőségek az ellenőrzött alanyokkal kapcsolatos hatalmas mennyiségű adattal rendelkeznek, ezek az adatok általában a vállalati szintre vonatkoznak, és nem feltétlenül a vállalati szintű adatokat a legmegfelelőbb figyelembe venni (lásd például: Gunningham és Sinclair, 2007). Az adatbázisban egy egyedi vállalkozást jellemzően egyedi azonosítóval, például szervezeti számmal azonosítanak. A gépi tanulási algoritmus azon képessége, hogy adott előre jelzett kockázati értéket hozzárendeljen egy adott vállalkozáshoz, az egyedi azonosítótól függ. A lehetséges ellenőrizendő alanyok azonban nem mind azonosíthatók automatikusan egyedi azonosítóval. Az építőiparban például nem feltétlenül egy-egy konkrét vállalatot vonnak ellenőrzés alá, hanem egy ideiglenes építkezési helyszínt. Az ilyen ideiglenes jelleg legalább két kihívást jelent. Először is, előfordulhat, hogy az építkezések és más ideiglenes munkavégzési helyszínek nem azonosíthatók egyedi azonosítókkal. Másodsor, még ha azonosíthatók is lennének, az

ideiglenes jelleg azt jelenti, hogy a gépi tanulási algoritmusnak adott esetben nincs lehetősége arra, hogy tanuljon előrejelzési sikereiből és hibáiból, mielőtt az építkezés befejeződik és a helyszínen dolgozó vállalkozások új felállásban más helyszínre települnek át.

## Záró megjegyzések

A fent ismertetett kihívások azt mutatják, hogy jelentős nehézségek merülnek fel a magas kockázatú ellenőrzési alanyok nagy adathalmazok és a gépi tanulási technikák alkalmazásával történő kiválasztása területén. Ezek a kihívások azonban semmilyen módon nem teszik kétségessé az ilyen technikák kockázatalapú megközelítésen belüli hasznosságát. A kihívások inkább azt mutatják, hogy a kockázatalapú célmeghatározás számára valószínűleg nem lesz előnyös, ha teljes mértékben gépi tanulási algoritmusokra támaszkodik. A fenti norvég példa ezt igazolja. Ahelyett, hogy lehetővé tennék az algoritmus számára, hogy közvetlenül válasszon ki alanyokat, az ellenőrök számára teszik lehetővé, hogy kockázaton alapuló döntéseket hozzanak az algoritmus által készített előrejelzések alapján. Ez a mesterséges és a humán intelligencia ötvözését jelenti, ahol mindegyik kiegészíti a másik erősségeit. Az összetett társadalmi eseményekre vonatkozó általános előrejelzéseket illetően a kétféle intelligencia ötvözése valószínűleg szükséges is.

## Hivatkozások

- Black, J., 2010. Risk-based regulation: Choices, practices and lessons being learnt. (Kockázatalapú szabályozás: Döntések, gyakorlatok és levont tanulságok.) Forrás: OECD 2010 (ed.), Risk and regulatory policy: Improving the governance of risk. (Kockázat és szabályozáspolitikai: A kockázattírányítás javítása.) OECD, Párizs.
- Blanc, F., 2013. Inspection reforms: why, how, and with what results. (Ellenőrzési reformok: miért, hogyan és milyen eredménnyel.) OECD, Párizs.
- Dahl, Ø., Kilskar, S. S., Skarholt, K., Rosness, R., 2018. Risikobasert tilsyn i de nordiske arbeidstilsynene. [Kockázatalapú munkaügyi ellenőrzések a skandináv országokban.] Északi Minisztertanács, Koppenhága.
- Gunningham, N., Sinclair, D., 2007. Factors impinging on the effectiveness of the Mines Inspectorate. (A bányafelügyelet hatékonyságát befolyásoló tényezők.) Ausztrál Nemzeti Egyetem, 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. (Új pontozási rendszer a munkahelyi balesetek kockázatának előrejelzésére: Esettanulmány adatbányászati technikák felhasználásával az iráni munkaügyi minisztérium adataival.) Journal of Loss Prevention in the Process Industries (Veszteségmegelőzés a feldolgozó ágazatokban folyóirat) 32, 443-453. o.
- Jacobusse, G., Veenman, C., 2016. On selection bias with imbalanced classes. (Kiválasztási torzítás kiegyensúlyozatlan osztályokban.) International Conference on Discovery Science, Bari, 325-340. o.
- Matías, J. M., Rivas, T., Martín, J. E., Taboada, J., 2008. A machine learning methodology for the analysis of workplace accidents. (Gépi tanulási módszertan munkahelyi balesetek elemzéséhez.) International Journal of Computer Mathematics 85, 559-578. o.
- 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. (A munkahelyi egészségvédelem és biztonság érvényesítésének eszközei foglalkozási betegségek és munkahelyi sérülések megelőzésére.) Cochrane Database of Systematic Reviews 2013, Issue 8, Art. No CD010183.
- OECD, 2014. OECD Best practice principles for regulatory policy: Regulatory enforcement and inspections. (A bevált gyakorlatokkal kapcsolatos elvek a szabályozáspolitikai számára: Szabályozói végrehajtás és ellenőrzések.) OECD (Gazdasági Együttműködési és Fejlesztési Szervezet), Párizs.
- Ridemar, A., 2018. Decision support for SWEA inspections. (Döntéshozatali támogatás SWEA ellenőrzésekhez.) KHT Svéd Királyi Műszaki Főiskola, Stockholm.
- Robens, L., 1972. Safety and Health at Work: Report of the Committee 1970-1972. (Munkahelyi egészségvédelem és biztonság: A bizottság jelentése 1970-1972) Her Majesty's Stationery Office, London.
- Weil, D., 2008. A strategic approach to labour inspection. (A munkaügyi ellenőrzés stratégiai megközelítése.) International Labour Review 147, 349-375. o.

Szerzők: Øyvind Dahl vezető kutató, SINTEF Digital — Biztonság és megbízhatóság, Trondheim, Norvégia

Annick Starren, Európai Munkahelyi Biztonsági és Egészségvédelmi Ügynökség (EU-OSHA)