

Preklad dokumentu:

WGP Wissenschaftliche Gesellschaft für Produktionstechnik *)

Stanovisko WGP

Umelá inteligencia vo výrobe

Ako môžu firmy využiť umelú inteligenciu



*) WGP: Vedecká spoločnosť pre výrobné technológie - združuje asi 50 katedier z nemeckých technických univerzít. Členmi spoločnosti sú profesori, ktorí vedú dané katedry. Bližšie informácie o členoch WGP nájdete na <https://wgp.de/en/about-us/institutes/>

»Stanovisko WGP: Umelá inteligencia vo výrobe«

Vedecká spoločnosť pre výrobné technológie (WGP e.V.) je združenie popredných nemeckých profesoriek a profesorov vedy o výrobe. Zastupuje záujmy výskumu a vzdelávania pred politikou, hospodárskou sférou a verejnosťou. Združuje 65 profesoriek a profesorov zo zhruba 40-univerzitných inštitútov a Fraunhofer-inštitútov v ktorých pôsobí zhruba 2000 vedkýň a vedcov z oblasti výrobných technológií. Členovia spoločnosti majú značnú reputáciu v nemeckej vede ako aj v medzinárodnom meradle a sú globálne zosieťovaní.

Laboratória členských inštitútov sú na vysokej technickej úrovni a umožňujú tak profesorom z WGP uskutočňovať v oblastiach ich zamerania výskum ako aj výuku zameranú na praktické využitie.

Spoločnosť WGP si stanovila za cieľ poukazovať na význam výroby a vedy o výrobe pre nemecké hospodárstvo. WGP zaujíma stanoviská k spoločensky relevantným témam počnúc priemyslom 4.0, cez energetickú efektívnosť až po 3D tlač.

Impressum

Vydal:

WGP Wissenschaftliche Gesellschaft für Produktionstechnik e.V.
zastúpená prezidentom Berend Denkena, Leibniz Universität, Hannover.

Zodpovední autori:

Jörg Krüger, Technische Universität Berlin (vedúci redaktor)
Jürgen Fleischer, Karlsruher Institut für Technologie
Jörg Franke, Friedrich-Alexander-Universität Erlangen-Nürnberg
Peter Groche, Technische Universität Darmstadt

OBSAH

»Stanovisko WGP: Umelá inteligencia vo výrobe«	2
1 Manažérske zhrnutie	4
Čo nové prináša UI?	4
Čo to znamená pre výrobné firmy?	4
Čo treba urobiť?	4
2 Prečo vzniklo toto stanovisko WGP?	6
Systematická realizácia nových potenciálov tvorby pridanej hodnoty	6
3 Definície pojmov	7
V centre pozornosti je slabá UI	7
Rôzne formy učenia	7
Augmentácia	8
Anotácia / označovanie dát	9
Modely typu čierna / šedá / biela skrinka	9
4 Potenciál UI pri zvyšovaní pridanej hodnoty vo výrobe	9
4.1 Dáta	11
4.2 Použitie dát	12
4.3 Posúdenie.....	15
4.4 Trénovanie a spätná väzba	15
5 Využitie dátovo založených verus procesne založených UI/SU riešení.....	16
6. Príklady použitia z výskumu WGP	17
6.1 CNC stroje a obrábanie	19
6.2 Manipulácia, montáž a robotika	21
6.3 Tok materiálu a logistika	21
7. Ako odporúčame konať	23
7.1 Ako analyzovať ciele, ktoré si má firma stanoviť	23
7.2 Nadobudnutie expertízy	23
7.3 Zbierať skúsenosti na jednoduchých úlohách	24
7.4 Identifikácia a využitie výrobnotechnického procesného know-how pre potreby SU	24
7.5 Systematické získavanie dát	25
7.6 Cielene prepájať know-how	25
7.7 Hodnotiť budúci potenciál	26
7.8 Cielene nasadzovať asistenčné systémy využívajúce UI-metódy	26
8 Odkazy.....	28

1. Manažérske zhrnutie

Vo využití umelej inteligencie (UI) sa skrýva značný potenciál zvyšovania výkonnosti výroby a tým aj konkurencieschopnosti nemeckého priemyslu. Vyžaduje to však prepojenie medzi kompetenciou v UI a výrobnou-technickou kompetenciou.

Čo nové prináša UI?

Aby sme dosiahli globálnu konkurencieschopnosť využitia UI v nemeckej výrobe, je potrebný **rýchly a systematický transfer z výskumu do praktického využitia**. Na to však doposiaľ chýbal ucelený **metodický model prístupu**.

Až doposiaľ (pozn. prekladateľa: tento dokument bol zverejnený v roku 2019) je uplatnenie UI vo výrobných technológiach orientované na dáta. T.j. využívajú sa dáta z technických výrobných procesov ako základ pre inteligentnú analýzu a pre funkcie, avšak nedochádza k systematickému a cieľavedomému využitiu znalostí o procesoch.

Toto stanovisko vychádza z postoja, že sa má uplatniť **model prístupu založený na procesoch namiesto modelu prístupu, založeného na dátach**, pretože to je najúčinnnejšie východisko pre systematickú integráciu UI-kompetencií so znalosťami o výrobných technológiach. **Vybrané príklady** z rozsiahlych výskumných prác inštitútov WGP, zameraných na integráciu UI a výrobných technológií jasne dokladajú veľký inovačný potenciál tohoto metodického nazerania. Tieto príklady sú zo širokého spektra výrobných technológií, počnúc strojmí na výrobu nástrojov a CNC strojmí, cez manipuláciu, montáž, robotiku až po tok materiálov a logistiku. Spája sa v nich expertná znalosť týchto domén s know-how z oblasti nasadenia výkonných postupov strojového učenia.

Čo to znamená pre výrobné firmy?

Tým, že toto stanovisko dáva do popredia orientáciu na procesy, poskytuje výrobným firmám orientáciu, ako môžu svoje doménové procesné a technologické know-how prepojiť s novými možnosťami, ktoré prináša UI. Vzniká tak metodická základňa na prepojenie automatického strojového učenia s hodnotnými skúsenosťami a vedomosťami, ktoré za veľa rokov nadobudli výrobní pracovníci firiem. Stanovisko poskytuje prehľad o rôznych modelových prístupoch, ktoré takto integrujú znalosť procesov a znalosť možností UI.

Pre zabezpečenie konkurencieschopnosti vo výrobe je rozhodujúce uchopiť nové druhy potenciálnej pridanej hodnoty včasnou a systematickou integráciou UI. To vyžaduje správne posúdenie jednotlivých príspevkov k pridanej hodnote, ktoré môžu vyplynúť z použitia nových metód, založených na UI, na systematickom použití príslušných softvérových nástrojov a k tomu potrebných dát. V neposlednom rade tieto potenciály závisia od toho, či zamestnanci vedia posúdiť spoľahlivosť UI-technológií v podmienkach výroby. V tomto stanovisku ide v zásade o to, tieto **jednotlivé faktory zhodnotiť z hľadiska ich potenciálu pre tvorbu pridanej hodnoty**.

Čo treba urobiť?

Toto stanovisko prináša osem **odporúčaní pre firmy**, ktoré boli odvodené zo skúseností inštitútov WGP z použitia UI v rozličných aplikačných doménach. Tieto odporúčania umožnia firmám systematicky a rýchlejšie identifikovať oblasti nasadenia UI s najväčšou potenciálnou pridanou hodnotou.

Najprv ide o nevyhnutnú východiskovú analýzu, **ktorý druh „inteligencie“** je potrebný pre daný stroj, robot alebo výrobné zariadenie, ako bude kontrolovaný proces učenia a **aké dáta budú základom procesu učenia**.

UI Systematický zber dát je najdôležitejším základom učenia UI-systémov. K tomu je potrebné **identifikovať zdroje dát** a analyzovať vzťahy medzi dátami využitím znalostí o procese. Ukázalo sa, že **simulačné postupy** majú zaujímavý potenciál pre rozšírenie bázy dát.

Ďalšia oblasť, kde firmy musia konať, súvisí s **prepojením človeka a UI**. Doposiaľ sa venuje veľmi málo pozornosti tomu, ako je možné pomôcť človeku, ktorý má stále väčšie poznávacie a senzorio-motorické schopnosti, prostredníctvom **asistenčných systémov na báze UI**. Aj túto možnosť vysvetľuje stanovisko na príklade.

Aby sa dosiahla nevyhnutná **úroveň expertízy** v oblasti UI, stanovisko odporúča **spoluprácu so skúsenými dodávateľmi alebo výskumnými pracoviskami**. Je to potrebné najmä pri spoločnej realizácii prvých zámerov, aby firma získala nevyhnutnú skúsenosť.

Pre **konkurencieschopnosť firmy** bude rozhodujúce, cielene identifikovať svoje **výrobno-technologické know-how**, ktoré je možné využiť na prepojenie so strojovým učením. Pre zUstalenie konkurencieschopnosti do budúcnosti je nutné vykonať **vyhliadkové analýzy scenárov** a tak identifikovať **nové modely tvorby pridanej hodnoty**.

2 Prečo vzniklo toto stanovisko WGP?

Téma *umelá inteligencia* sa výrazne dostala do povedomia verejnosti v roku 2018. Odvtedy média takmer denne informujú o nových pokrokoch v tejto oblasti. Krajiny považujú význam UI pre hospodársku politiku za taký veľký, že povyšujú rozvoj národných kompetencií v UI na úroveň strategickú priority.

Inštitúty WGP skúmajú už vyše 30 rokov aplikácie umelej inteligencie vo výrobe [1],[2]. Mnohé z metód UI však doposiaľ neboli natoľko výkonné a zrelé aby našli hospodárne uplatnenie v podnikovej praxi. Medzitým je však informatika v stave ponúknuť také algoritmy a výpočtový výkon, na ktorých mohol systematický výskum a vývoj v inštitútoch WGP ukázať celý rad aplikácií pre výrobu.

Systematická realizácia nových potenciálov tvorby pridanej hodnoty

V stanoviskách WGP „Priemysel 4.0“ [3] a „Priemyselné pracovisko 2025“ [4] sa už WGP zaoberala otázkami, súvisiacimi s UI. Napríklad autonómny systémami vo výrobe a ich vplyvom na charakter práce. Toto stanovisko má za cieľ odkryť **nové potenciály tvorby pridanej hodnoty pre výrobné technológie** v Nemecku. WGP sa pritom opiera o svoju jedinečnú doménovú kompetenciu v oblasti výrobných technológií v prepojení s aktuálnym technologickým vývojom v UI. Navyiac, ponúkame firmám pôsobiacim na trhu výrobných technológií **odporúčané postupy**, ktoré im umožnia využiť vlastné výrobné-technické know-how a dáta v kombinácii s UI na systematickú realizáciu nových potenciálov.

V súčasnosti sa v inštitútoch WGP realizujú mnohé výskumné a vývojové práce, v ktorých sa využíva UI na zlepšovanie výrobných procesov, strojov a zariadení. Stanovisko na príkladoch vysvetľuje, ktoré nové potenciálne pridané hodnoty sa dajú realizovať využitím špecifických znalostí vo firmách a ktoré **dodatočné kompetencie a štruktúry na to firmy musia vytvoriť**.

Osobitnou črtou skúseností, ktorými disponujú inštitúty WGP je, že ich výskumné a vývojové práce v oblasti UI a strojového učenia (SU) sa **typicky orientujú na procesy**.

Pri tomto tzv. „pull-“, prístupe je východiskom uplatnenia UI/SU konkrétna potreba optimalizovať určité výrobné procesy. To má zásadné dopady na zodpovedanie otázky, na ktoré dáta sa „nasadia“ postupy strojového učenia a ako sa dajú tieto dáta získať.

To sa líši od **mnohých skorších aplikácií** strojového učenia, ktoré sú dražované dátami. Čiže ich poháňkou bolo to, že boli k dispozícii dáta („push-“, prístup). Práve pokračujúca „senzORIZÁCIA“ strojov a zariadení v dôsledku nástupu priemyslu 4.0 vedie vo firmách k pribúdajúcemu zbieraniu dát, na ktorých by sa dali aplikovať učiace sa algoritmy vykonávajúce „inteligentnú analýzu dát“. V porovnaní s „informatickým“ dátovo motivovaným „push-“, prístupom ponúka „pull-“, prístup vychádzajúci z know-how o výrobných technológiách podstatne väčší potenciál využitia doménových znalostí o výrobe. Jedným z cieľov tohoto stanoviska je poukázať práve na potenciál takýchto procesne orientovaných postupov.

V novembri 2018 nemecká spolková vláda zverejnila svoju stratégiu v oblasti umelej inteligencie. V nej sa zaoberá rozvojom rámcových podmienok pre vznik firiem, štruktúrnymi zmenami vo svete práce, vo vzdelávaní a celoživotnom vzdelávaní a nakladaní s dátami [5]. Týmto stanoviskom predkladá WGP ďalší príspevok k posilneniu **konkurencieschopnosti výrobných podnikov v Nemecku**. Pri tom rozhodujúcu úlohu zohráva rýchlosť, s akou sa potenciál priemyslu využije a udržateľným spôsobom realizuje. No hoci sa už vyše 50 rokov intenzívne skúma oblasť strojového učenia, napr. na báze umelých neurónových sietí, stále je pomerne málo uplatnení vo výrobe. Predovšetkým chýba systematický postup na určenie, ktoré oblasti činností vo výrobe sa hodia na aplikáciu UI, resp. SU. A naopak, je aj nedostatok metód, ktorými je možné analyzovať rozličné SU-mechanizmy z hľadiska ich použiteľnosti v týchto výrobných činnostiach.

V neposlednom rade chýbajú hodnotenia **hospodárnosti nových postupov založených na využití UI/SU**. Osobitnú rolu v tom zohráva kompetencia podnikov, ktorá by im umožnila zhodnotiť spoľahlivosť a robustnosť týchto nástrojov. WGP vyplňa tieto medzery a v tomto stanovisku formuluje odporúčania postupu k rýchlemu a úspešnému dosiahnutiu potenciálov v tvorbe pridanej hodnoty využitím UI/SU vo výrobných podnikoch. Okrem toho dáva **odporúčania vedcom a politikom**, aby mohli cielene riešiť zásadné metodické otázky, súvisiace so systematickou implementáciou v priemysle.

3 Definície pojmov

S UI sa spájajú rôzne schopnosti, pri ktorých sa prejavy ľudskej inteligencie premietajú na počítače [5]. Príkladmi sú počítače rozumejúce reči alebo strojové videnie. Všeobecne platná konzistentná definícia UI však neexistuje. Technológie, ktoré prepožičiavajú počítačom tieto schopnosti často patria do domény označovanej ako strojové učenie (SU), čo je podoblasť UI.

V centre pozornosti je slabá UI

Samotný pojem UI sa často chápe rozdielne, treba ho bližšie špecifikovať. V strategickom dokumente spolkovej vlády, zverejnenom v novembri 2018 sa preto rozlišuje medzi „slabou“ a „silnou“ UI [5]. (Poznámka prekladateľa: Namiesto „silná UI“ sa často používa označenie „všeobecná umelá inteligencia - GAI“). Podľa dokumentu spolkovej vlády označuje silná UI systémy, ktoré disponujú „rovnakými intelektuálnymi schopnosťami ako človek alebo ho dokonca môžu predčiť“. Slabá UI sa naopak „zameriava na riešenia konkrétnych aplikačných problémov využitím metód matematiky a informatiky, pričom tieto systémy majú schopnosť sami sa optimalizovať. V tomto stanovisku sa bude pojem UI chápať ako **slabá UI zameraná na konkrétne aplikácie a schopná seba-optimalizácie**.

K ďalšiemu miešaniu pojmov dochádza prekrývaním technológií strojového učenia (SU) a **inteligentnej analýzy dát (data mining)**. Význam ostatne spomínanej činnosti výrazne narástol práve implementáciou postupov priemyslu 4.0. Príčinou je výrazný nárast množstva dát získavaných zo strojov, zariadení a procesov vo výrobe. Prispelo k tomu aj definovanie metodiky CRISP-DM (Cross-Industry Standard Process for Data Mining [6]), ktorá sa aplikuje aj na analýzu dát z výroby. VDMA (Zväz nemeckých výrobcov strojov a zariadení) vo svojom „Stručnom sprievodcovi strojovým učením v strojárstve“ [7] z roku 2018 definuje vzťah strojového učenia a inteligentnej analýzy dát takto: „Štatistika definuje, čo sa stalo; data mining vysvetľuje, prečo sa niečo stalo; strojové učenie predpovedá čo sa stane a ukazuje, ako sa dajú určité situácie optimalizovať alebo ako sa im dá vyhnúť“.

Je to predovšetkým pokrok v oblasti SU, ktorý v ostatných rokoch ukazuje nové potenciály uplatnenia umelej inteligencie vo výrobe. Preto sa v ďalšom bližšie zameriame na pojmy, ktoré súvisia s SU. Označenie SU sa používa na postupy, ktoré sa z dát dokážu naučiť podľa možnosti optimálne správanie a to bez toho, aby bolo potrebné explicitne programovať reakciu na každú situáciu [8]. Pritom sa rozlišuje medzi rozličnými princípmi učenia: učenie pod dohľadom (*supervised learning*), učenie bez dohľadu (*unsupervised learning*) a učenie so spätnou väzbou (*reinforcement learning*).

Rôzne formy učenia

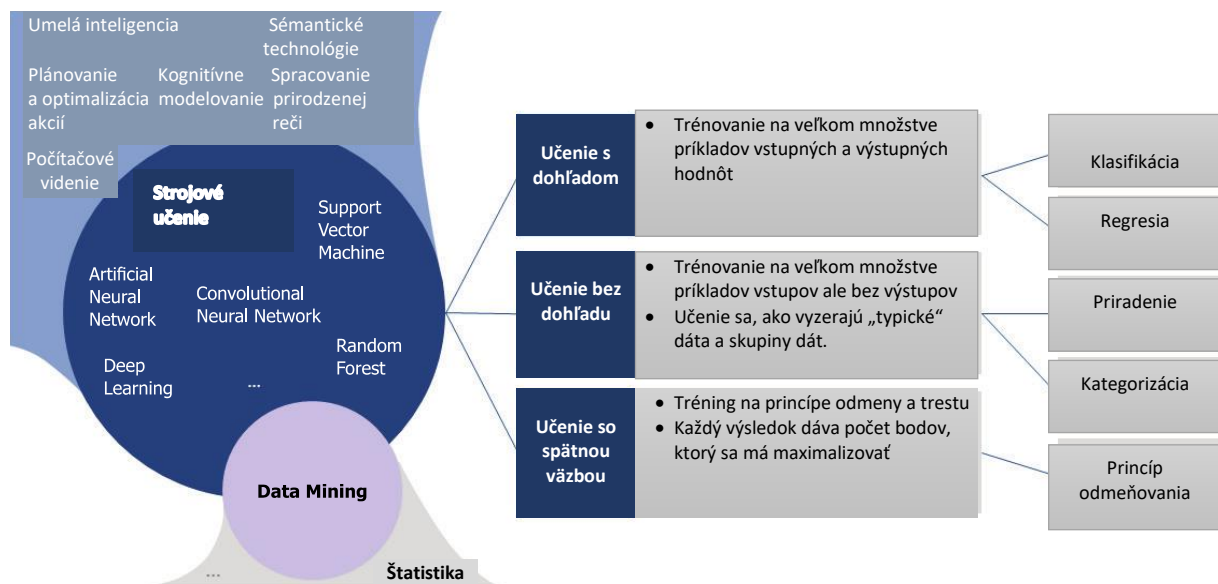
Pri **učení pod dohľadom** sú stroje trénované na veľkom množstve príkladov vstupných a výstupných údajov [7]. Zo vzťahu medzi vstupnými a výstupnými hodnotami dát sa dá vytvoriť funkčný súvis, ktorý umožní aj predpovedanie výstupných hodnôt zodpovedajúcich doposiaľ neznámym hodnotám vstupov. Identifikovanie tejto funkčnej závislosti medzi hodnotami na vstupe a na výstupe sa označuje regresia. Naopak pri klasifikácii ide o priradenie príznakov, ktoré sa dajú získať zo vstupných dát, k triedam objektov - sú to výstupné hodnoty klasifikátora. Základom tohoto procesu je rozpoznávanie vzorov (pattern recognition). Pri učení pod dohľadom takejto súvislosti je potrebné mať dostatočné

množstvo tréningových dát, v ktorých je správne priradenie medzi príznakmi a triedami objektov známe. V praxi je však bežné, že správne triedy objektov prislúchajúce k príznakom nie sú známe. V takom prípade musí byť správne priradenie medzi dátami dodatočne vygenerované tzv. anotáciou. Tento postup sa často označuje ako *labeling*.

Aj pri **učení bez dohľadu** je potrebná množina vzorových dát, avšak bez výstupných hodnôt. Výsledkom učenia je, že stroj (systém) sa naučí, ako vyzerajú „typické“ dáta, resp. skupiny údajov. Tréningové dáta sa síce dajú vytvoriť s malou prácnosťou, avšak nemusia pokrývať všetky možné situácie [7].

Učenie so spätnou väzbou je založené na princípe odmeňovania, ktorý vedie k tomu, že systém optimalizuje svoje schopnosti. Čiastočné kroky celkového riešenia sú hodnotené prideleným počtom bodov, pričom učiaci sa systém by sa mal snažiť získať maximum bodov [7]. Veľkou výzvou je však identifikovať vhodné odmeňovacie systémy.

Obr.1 znázorňuje vzájomnú súvislosť vyššie popísaných pojmov.



Obr. 1: Súvis medzi oblasťami umelej inteligencie a pojmami zo [7], [8]

Strojové učenie (SU, z anglického „machine learning“, SU) je označenie pre postupy, pri ktorých si softvér dokáže využitím dát natréňovať optimálne správanie, pričom nie je potrebné aby mal naprogramované reakcie na každú situáciu.

Ako sme uviedli v úvode, vidí WGP v technológiach SU osobitný potenciál systematickej tvorby novej pridanej hodnoty cestou využitia doménového a procesného know-how o výrobe. Popri doposiaľ vysvetlených základných pojmoch z oblastí UI, SU a data miningu preto teraz vysvetlíme aj pojmy, ktoré nadobudnú dôležitosť pri praktickom nasadení SU vo výrobe a súvisia so zapojením doménového know-how.

Augmentácia

Napriek výraznému pokroku v získavaní dát v dôsledku zosieťovania strojov a zariadení v dôsledku implementácie priemyslu 4.0 pretrvávajú veľké výzvy pri využití najnovších SU nástrojov vo výrobe. Jedna z veľkých výziev spočíva v tom, že podľa výberu cieľového procesu môže získanie potrebného

množstva dát trvať dlhý čas. Jedným z možných prístupov k obídenu tejto prekážky môže byť doplnenie (augmentácia) tých dát, ktoré sú už k dispozícii. Jedná sa o cieľnú modifikáciu dostupných dát tak, aby sa rozsah databázy zväčšil. Augmentácia sa uplatňuje napr. pri rozpoznávaní obrazov, napr. tým, že sa doplnia obrazy vytvorené rotáciou alebo zmenami osvetlenia a perspektívy v už existujúcich snímkach objektov.

Anotácia / označovanie dát

Označovaním (tzv. labelingom) sa vstupné dáta cielene spájajú so znalosťami o výstupných informáciách, ktoré dáta reprezentujú. Takýto postup je predpokladom pre učenie pod dohľadom zamerané na poznanie vzťahu medzi vstupnými a výstupnými hodnotami. Výskum UI sa čoraz viac zameriava na počítačovú podporu zjednodušovania a automatizácie praktickej anotácie dát pri strojovom učení pod dohľadom [9].

Modely typu čierna / šedá / biela skrinka

Pojmy „blackbox“ a „whitebox“ vyjadrujú rozličný stupeň poznania vstupno-výstupného správania sa systémov. Kým u whitebox modelov sa dá závislosť medzi vstupnými a výstupnými hodnotami veličín úplne vysvetliť, pri blackbox modeloch systémov sa táto závislosť dá popísať iba na základe vykonaných pozorovaní. Nesporná výhoda whitebox modelov, spočívajúca v ich úplnej predikovatelnosti je však často vykúpená veľkými nákladmi na ich zostavenie. Naproti tomu sú náklady na vytvorenie blackbox modelov často výrazne nižšie, čo je však vykúpené ich neistotou, resp. nižšou spoľahlivosťou. Týka sa to osobitne doposiaľ nevyskúšaných hodnôt vstupných dát.

Greybox modely, skladajúce sa z prvkov whitebox aj blackbox modelov, ponúkajú možnosť spájať prednosti oboch prístupov k modelovaniu systémov hľadaním optimálneho kompromisu medzi nákladmi na tvorbu modelu a jeho spoľahlivosťou. Takýto prístup profituje z narastajúcej výkonnosti SU nástrojov v oblasti automatického modelovania systémov.

Súčasný pokrok v modelovaní ponúkajú aj možnosti na rozhodujúcich miestach uplatniť špecifické doménové znalosti o procesoch, strojoch a zariadeniach v podobe zahrnutia deterministického popisu ich chovania.

4 Potenciál UI pri zvyšovaní pridanej hodnoty vo výrobe

Výrobný priemysel je jedným z oporných stĺpov nemeckého hospodárstva a poskytuje významný príspevok k životnej úrovni Nemecka. Štúdia z roku 2018, ktorú zadalo Spolkové Ministerstvo Hospodárstva a Energie (BMWi) predpovedá tomuto sektoru na roky 2019-2023 **dodatkový nárast v dôsledku uplatnenia UI** vo výške 31,4 Mld. EUR [8]. Z takých analýz sa dá odvodiť aj rastúci vplyv UI na výrobnú techniku. Jedna z často uvádzaných oblastí uplatnenia UI vo výrobe je prediktívna údržba strojov a zariadení. To však predstavuje iba malú časť spektra možných budúcich uplatnení UI v oblasti výrobných techník.

Inovativnosť a konkurencieschopnosť výrobných firiem je vo veľkej miere založená na vysoko kvalifikovaných znalostiach výrobných procesov, strojov a zariadení. Preto sa vynára **rozhodujúca otázka**, ktorou sa toto stanovisko zaoberá:

Ako sa dá toto výrobnotechnické know-how, ktoré pri konkurencii rozhoduje, **systematicky a metodicky** prepojiť s najnovšími technologickými pokrokmi v oblasti UI tak, aby to cielene podporilo inovácie, ktoré zvýšia hodnotu výrobkov ako aj efektívnosť procesov, strojov a zariadení a celých hodnotových reťazcov vo výrobe ?

Odpoveď na túto otázku získame, keď sa pozrieme najmä na vývoj SU-metód v ostatných rokoch. Nájdeme tu dva základné javy:

Rastúci výkon SU

Prvé pozorovanie nám ukazuje výrazné zvýšenie výkonnosti metód SU. Napr. vývoj tzv. konvolučných neurónových sietí (CNN) preukázal v reprezentatívnych benchmarkoch pokles chybovosti pri rozpoznávaní obrazov z takmer 30% v roku 2010 na cca. 3% v r. 2017 (obr. 2) [10].



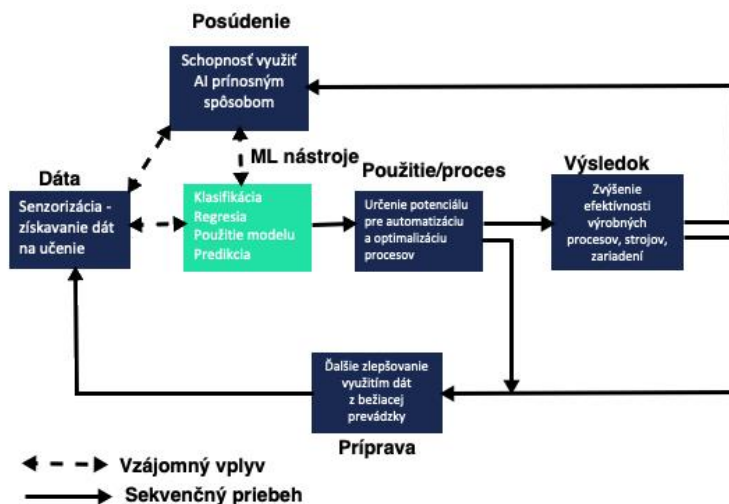
Obr. 2 Pokrok v rozpoznávaní obsahu obrazov od r. 2010 (podľa [10] a [11])

Široká dostupnosť nástrojov SU

Druhý pozorovaný jav, prispievajúci k razantnému vývoju strojového učenia je dostupnosť rozmanitých nástrojov SU. Združenie VDMA (Nemecké združenie výrobcov strojov a zariadení) uvádza vo svojom „Stručnom sprievodcovi strojového učenia vo výrobe strojov a zariadení“ [7] prehľad viac ako 20 platforiem a softvérových knižníc pre analýzu dát a strojové učenie, z ktorých mnohé sú k dispozícii ako Open Source. Mnohé z týchto nástrojov sú v takej podobe, že pri dobrých základných softvérových zručnostiach sa dajú v relatívne krátkom čase vytvárať jednoduché vzorové aplikácie. Tieto nástroje sú doplnené o širokú paletu návodov, spravidla dostupných v podobe digitálnych výukových prostredí na internete, obsahujúcich videostreamy. Aj WGP využíva časť týchto nástrojov v rámci aplikácií, ktoré sú výstupmi našich výskumných projektov, popísaných v kapitole 5.

Zlepšený pomer nákladov a prínosov

Spojenie oboch uvedených javov vedie k tomu, že sa pomer nákladov/prínosov týchto nástrojov a IT technológií na ktorých sú založené, trvalo zlepšuje. To má zasa za dôsledok, že sa zvyšuje úžitok opatrení vo firmách, ktoré spočívajú v nasadení UI a obzvlášť SU. Túto súvislosť ilustruje obr. 3. Základom sú **nástroje a technológie SU** a ich schopnosť **naučiť sa modely**, na základe ktorých môžu vznikáť predpovede. Príkladmi sú priradenie dát/vzorov k príslušnému objektu (klasifikácia) alebo predpoveď zmeny dát v budúcnosti (predikcia).



Obr. 3 Oblasti výroby, kde môže UI priniesť pridanú hodnotu

Pri uplatnení SU vo výrobe sa v centre pozornosti nachádzajú **nástroje a technológie SU** a ich schopnosť **naučiť sa modely** (procesov, javov, zariadení), ktorých využitím sa dajú predpovedať udalosti. Príkladmi toho sú napr. priradenie dát/vzorov k objektu (t.j. klasifikácia, rozpoznanie objektu) alebo predpovedanie toho, že v dátach dôjde k zmene (predikcia).

To vedie k tomu, že **rastie prínos opatrení, resp. procesov** v ktorých sú tieto UI-funkcie použité. Takými procesmi sú systematické generovanie dát pre potreby tréningu UI, rozpoznávanie tých procesov a činností, ktoré sú vhodnými adeptmi na automatizáciu a optimalizáciu, kontinuálne učenie sa zo zlepšených procesov. Firmy by si mali tiež zvyknúť opakovane posudzovať spoľahlivosť a robustnosť súvislostí, ktoré UI pomohla objaviť vo výrobných procesoch, strojoch a zariadeniach.

Práve v oblastiach *dáta, použitie a posúdenie* sa výrazne prejavuje potenciál a nevyhnutnosť systematicky využiť špecifické znalosti o výrobných procesoch, ktoré firma má. Na toto sa v ďalšom texte postupne zameriame.

4.1 Dáta

Mnohé z aktivít vo firmách, reagujúcich na fenomén priemysel 4.0 sa v uplynulých rokoch zamerali na omnoho lepšie zosieťovanie strojov a zariadení. To umožnilo výmenu dát, na základe čoho bolo možné efektívnejšie riadenie, reguláciu a dohľad nad zariadeniami a procesmi. Tieto výskumné a vývojové práce v oblasti „senzorizácie“ strojov a zariadení je teraz výborným základom pre získavanie dát pre strojové učenie, napríklad s cieľom včasného rozpoznanie porúch v zložitých výrobných procesoch.

Pri výbere a použití dát pre tvorbu modelov pomocou SU je však mimoriadne dôležité uplatniť existujúce know-how o základných procesoch danej výroby, s ktorými majú byť v súlade modely vytvorené pomocou SU. Ak má príslušný SU softvér napríklad automaticky rozpoznať korelácie a/alebo príčinné súvislosti medzi procesnými veličinami na báze metód

rozpoznávania obrazcov, potom je spravidla potrebná odborná kompetencia o danej výrobnej technológii, spracovaní signálov, dynamike strojov alebo použitých senzoch v kontexte danej výroby.

Ďalší potenciál pre získavanie dát je v **simulácii výrobných procesov**. Simulácia je ešte užitočnejšia vtedy, ak nie sú k dispozícii dáta zo sensorov, alebo by nasadenie sensorov bolo príliš nákladné alebo získavanie procesných dát nie je možné dostatočne „blízko“ k výrobnému procesu. Simulácia je obzvlášť atraktívnou cestou, ak by sa dáta z procesu museli zbierať za veľmi dlhé časové obdobie. Nové postupy, ktoré SU využíva, napr. „deep learning“, spravidla vyžadujú veľmi veľké množstvá dát aby z nich dokázali vydolovať ich hlbšie súvislosti. Preto výskumné projekty čoraz viac využívajú na tréning aj dáta generované simuláciou príslušných procesov.

Napríklad pri **analýze obrazov** sa problém nedostatočného množstva dostupných dát často rieši ich „augmentáciou“. Existujúce dáta sa cielene modifikujú aby sa zväčšila databáza. Existujúce snímky sa napríklad dopĺňajú o umelo generované snímky, ktoré vzniknú rotáciou alebo zmenou svetlosti či kontrastu existujúcich snímok (viď. kapitola 3).

Rastúca hodnota dát ako východiska pre zvyšovanie pridanej hodnoty výroby použitím strojového učenia vedie k tomu, že treba **systematicky identifikovať zdroje dát**. Vo výrobe sa využíva už teraz veľa implicitných znalostí a informácií, ktoré však nie sú zatiaľ používané na strojové učenie. Typickým príkladom sú dáta z optickej kontroly kvality a kontroly komponentov. Kontrola kvality alebo komponentov spravidla ústi do binárneho **rozhodnutia o kvalite výrobku alebo komponentu** (v poriadku/nie v poriadku) avšak iba zriedka niekto toto rozhodnutie **priradí k dostupným digitálnym dátam o výrobku či komponentu** a takisto toto priradenie neuloží do databázy. Takéto priradenie a jeho zapamätanie sa nazýva anotácia či labeling dát je však veľmi hodnotným predpokladom pre tzv. učenie pod dohľadom systému automatickej kontroly kvality. V našej výrobnej praxi je význam digitálneho ukladania dát (napr. snímok) a súbežne znalostí (v poriadku/nie v poriadku) pre potreby strojového učenia zatiaľ málo známe. Preto treba posilniť znalosti príslušného personálu. Súbežne treba vytvoriť doposiaľ neexistujúcu metodiku identifikácie zdrojov dát, z ktorých sa budú dať systematicky vyvodzovať potenciálne možnosti použitia UI-technológií. Príkladmi takýchto metodík sú všadeprítomné sémantické popisy, akými sú normy, eClass-modely alebo modely zariadení využívajúce ontológiu AutomationML.

4.2 Použitie dát

Už zmienená štúdia ktorú dalo vypracovať spolkové ministerstvo BMWI [8] spomína celý rad oblastí uplatnenia UI vo výrobe, ako sú:

- prediktívna analytika, napr. v dohľade a údržbe výrobných zariadení,
- optimalizácia využitia zdrojov (napr. optimalizácia plánovania výroby),
- kontrola kvality (napr. vlastností vstupných komponentov),
- inteligentné asistenčné systémy (napr. poskytujúce podporu pri výrobných procesoch),
- manažment znalostí (napr. dátové modely využívané pri komplexných inžinieringových procesoch),

- robotika (napr. učiace sa alebo samoregujúce sa systémy úchopu),
- autonómne jazdiace / lietajúce systémy (napr. autonómne prepravné systémy),
- inteligentná automatizácia (napr. automatizácia rutinných procesov vo výrobe alebo montáži),
- inteligentná sensorika (napr. predspracovanie dát pri monitorovaní výrobných zariadení).

Kapitola 6 poskytuje prehľad širokej palety výrobnotechnologických aplikácií, ktoré vyplynuli z konkrétnych výskumných a vývojových projektov členských inštitútov WGP. Ako bolo uvedené na začiatku 4. kapitoly, od uvedených a tiež ďalších aplikácií UI sa očakáva významný potenciál zvyšovania pridanej hodnoty. Významným faktorom konkurencieschopnosti bude to, ako sa firmám podarí tento potenciál identifikovať, uplatniť svoje výrobnotechnologické know-how a tak potenciál UI premeniť na konkurenčnú výhodu.

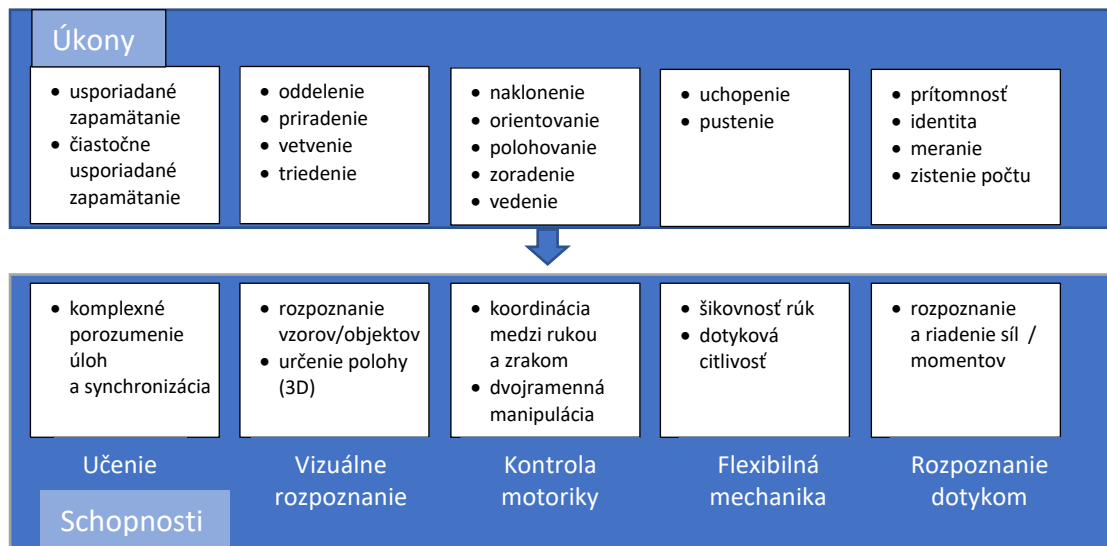
Systematické spojenie úkonov a schopností

Metodický prístup k identifikácii potenciálu UI sa dá dosiahnuť tak, že súbežne posudzujeme potreby firmy v oblasti optimalizácie a automatizácie výroby a špecifické schopnosti, ktorými disponuje UI/SU. Znamená to, že sa pokúšame párovať úkony vo výrobe so schopnosťami, ktoré sa pri nich vyžadujú.

Nasledujúci obr. 4 objasňuje túto vzájomnú priraditeľnosť na príklade rôznych úkonov z oblasti manipulácie. Smernica č.2860 Združenia nemeckých inžinierov (VDI) delí manipulačné úkony vo výrobe na skupiny, uvedené na obr.4. Obrázok priraduje k úkonom, vyskytujúcim sa napr. pri komplexných montážnych operáciach príslušné schopnosti, ktorými môžu disponovať systémy založené na UI, resp. SU.

Ľudské schopnosti, ktoré sú uvedené v dolnej časti obr. 4 (schopnosť učenia, motorická kontrola, haptické schopnosti) sú využívané pri montážnej manipulácii. Odborníci znalí výrobného procesu vedia posúdiť, ktoré z týchto schopností sú potrebné na vykonávanie výrobných úkonov, uvedených v hornej časti obr. 4. Následne je možné pristúpiť k posúdeniu, ktoré z týchto ľudských schopností a do akej miery je možné nahradiť tieto

schopnosti aktuálnymi alebo v blízkej dobe očakávanými schopnosťami UI/SU systémov, resp. nimi riadenými robotmi. Treba pritom aj zohľadniť, do akej miery sa dajú splniť podmienky pre získanie potrebných dát, resp. kvalifikovane odhadnúť spoľahlivosť technického riešenia.



Obr. 4 Systematické priradenie „úkonov“ (výrobnotechnická schopnosť) a „schopností“ (schopnosť UI) na príklade manipulačných činností

Okrem tohoto „základného prístupu“ k posudzovaniu využiteľnosti UI/SU existuje pre výrobo-technické aplikácie UI viacero ďalších potenciálnych oblastí, napr.:

- odhalenie technologických súvislostí dát pomocou SU-analýzy,
- odhalenie a štúdium logických súvislostí z priebehu procesov,
- integrácia sémantických znalostí v podobe hybridnej umelej inteligencie (hybridná UI je napr. kombinácia fyzického systému a umelej neurónovej siete),
- regulácia zložitých nelineárnych procesov (adaptívna regulácia, regulácia využívajúca predikciu na báze modelu, iteratívne sa učiaca regulácia, atď.),
- systémy učiace sa prispôsobovať človeku pri interakcii človek- stroj; zjednodušenie komunikácie medzi človekom a strojom napr. na báze výrazného zdokonalenia rozpoznávania reči.

Systematický vývoj asistenčných funkcií

Mimoriadny aplikačný potenciál poslednej z vyššie uvedených oblastí spočíva v tom, že sa schopnosti UI cielene využívajú na vývoj asistenčných funkcií. Také funkcie sa dajú identifikovať vo všetkých úrovniach automatizačnej pyramídy. Ide hlavne o tieto oblasti uplatnenia:

- asistovaný inžiniering (napr. využitie UI pri výbere prevádzkových prostriedkov alebo pri výbere vhodných kombinácií materiálov a technológií). Dá sa tu využiť schopnosť strojového učenia identifikovať komplexné súvislosti a ponúknuť vývojárovi doposiaľ neznáme alebo nezistiteľné varianty riešenia,

- spolupráca človek-robot (napr. zlepšenie prispôsobivosti robota človeku učeníím sa vzorcov správania človeka, resp. priebehu jeho pohybov),
- asistované programovanie robotov.

Využitie UI pri vývoji asistenčných systémov a funkcií je o.i. zaujímavou možnosťou tam, kde by získanie dostatočnej bázy dát trvalo dlhú dobu alebo konkrétne rámcové podmienky neumožňujú získať dostatok dát. V šiestej kapitole túto situáciu osvetlíme na príklade identifikácie komponentov.

4.3 Posúdenie

Možnosť nechať stroje aby sa sami učili vedie k otázke, ako dokážeme systémy na báze strojového učenia posudzovať, pokiaľ ide o ich spoľahlivosť a robustnosť. Na jednej strane sa ukazuje, že UI-systémy v určitých doménach - ako napr. analýze snímok z niektorých oblastí medicínskej diagnostiky - už dnes vykazujú **schopnosti, ktoré prevyšujú schopnosti človeka**. Na druhej strane je štruktúra takýchto systémov taká zložitá, že sa ich správanie dá charakterizovať len štatisticky, nedá sa však deterministicky popísať alebo dokázať. Toto značne sťažuje **zodpovedné rozhodnutie o nasadení** takéhoto riešenia vo výrobe a teda aj využitie jeho potenciálu zvýšiť pridanú hodnotu. Súčasne však v takej situácii rastie hodnota kvalifikovaného ľudského úsudku a rozhodnutia.

Nároky na nové kvalifikácie ľudí sa v budúcnosti zvýšia aj pri **zabezpečení kvality dát**, ktoré budú využívané na učenie výrobných systémov. Napríklad sa bude od expertov očakávať, aby vedeli posúdiť výpovednú hodnotu učiacich dát, ktoré súvisia s poruchovými stavmi a ktoré ovplyvnia správnu funkciu naučeného modelu. Výzva sa ešte výrazne zväčší, ak pôjde o použitie SU na neustále vylepšovanie modelov tým, že sa budú používať stále novšie procesné dáta (viď tiež nasledujúcu podkapitolu 4.4). Práve pri takýchto **procesoch so spätnoväzobnou slučkou** vzniká veľký potenciál neustáleho zvyšovania výkonu. Vzniká však dilema, že čím lepšie sa systém naučil rozpoznávať zmeny v dátach, tým viac hrozí, že nové dáta môžu fungovanie systému zhoršiť. Preto musí byť veľmi zodpovedne vykonávaná kontrola kvality dát, predtým, ako sa použijú v procese strojového učenia.

Treba vychádzať z toho, že v dohľadnej budúcnosti budú ľudia zodpovední za nasadenie UI vo výrobe ako aj za používané dáta. Ľudia nesúci túto zodpovednosť musia cielene nadobudnúť príslušnú kvalifikáciu. **Vieme si predstaviť vzdelanie „UI-inžiniera“** pre výrobný priemysel alebo spočiatku výrobného inžiniera so špecializáciou na strojové učenie. V oboch prípadoch sú nutné zásahy do študijných programov univerzít a osobitne aj stredných odborných škôl. Je to nevyhnutná podmienka využitia potenciálu rastu pridanej hodnoty prostredníctvom veľmi rýchlo sa rozvíjajúcich postupov strojového učenia. Rýchlosť, s akou sa firmy dokážu vysporiadať s touto výzvou bude v budúcnosti čoraz viac rozhodovať o ich konkurencieschopnosti.

4.4 Trénovanie a spätná väzba

Keď sú všetky existujúce dáta použité na trénovanie, prechádza ich hodnota na model, ktorý sa naučil použitý UI/SU nástroj. Na ďalšie zlepšenie modelu a teda získanie ďalšieho osahu sú potrebné dáta z nových výrobných zákaziek. Vynára sa otázka, ako sa dajú v záujme

neustáleho zlepšovania učiaceho procesu systematicky využívať dáta z výrobného procesu v podobe akejsi spätnej väzby vytvárajúcej akúsi regulačnú slučku.

Štruktúry tvoriace **regulačné slučky** sa nachádzajú na všetkých úrovniach výroby: od tých, ktoré riadia v reálnom čase operácie vo výrobných halách až po opakujúce sa procesy riadenia kvality. Z toho vyplýva, že pre systematické nasadzovanie spätiväzobných procesov SU-učenia sú vo výrobe vo všeobecnosti dobré predpoklady v zmysle skúseností a akceptancie. **Chýba však k tomu potrebná metodika a skúsenosť.**

Osobitnou výzvou je dilema spočívajúca v tom, že pri stále sa zlepšujúcom výkone systémov rastie aj riziko, že celkový výkon natrénovaného systému sa zrazu zhorší. Preto rastie dôležitosť kontroly dát z bežiackej výroby, používaných na učenie modelov ako aj trvalé hodnotenie výkonnosti systému. Ako sme už zmienili, vyžiada si to nové typy vzdelávania a doškoľovania UI-expertov vo výrobe.

5 Využitie dátovo založených verzus procesne založených UI/SU riešení

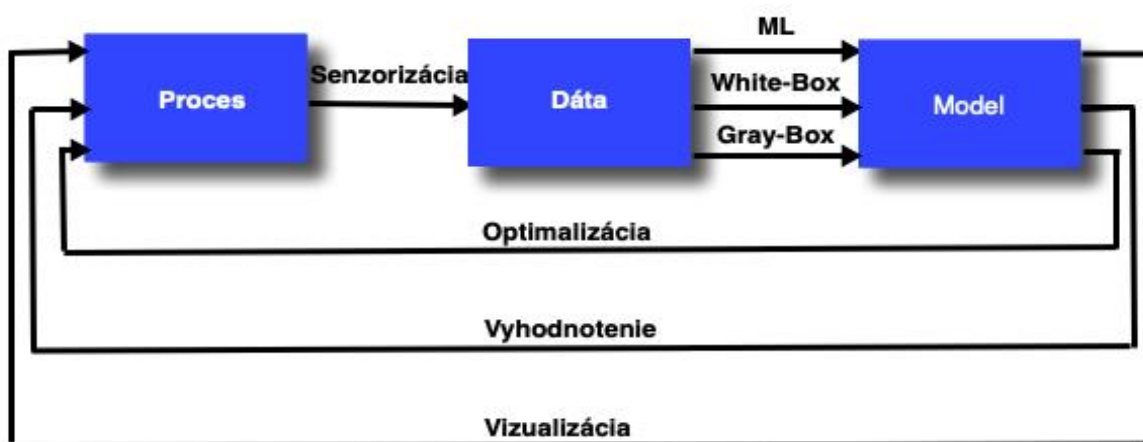
Ako sme v predchádzajúcej kapitole s využitím obr. 2 vysvetlili, vývoj a dostupnosť často voľne dostupných výkonných softvérových prostredí (frameworkov) zameraných na UI/SU vedie k tomu, že rastie hodnota doménového know-how, použiteľného na získavanie dát a na posudzovanie a nasadzovanie postupov strojového učenia. Mnohé firmy si už uvedomujú, akú hodnotu majú ich dáta z výrobných technológií. **Prístup k využitiu týchto dát je však veľmi rôzny.** Kým mnohé firmy zbierajú dáta aby ich mali k dispozícii pre neskoršie využitie, iné firmy sa už cielene pokúšajú dostať pomocou tzv. „inteligentnej analýzy dát“ k potenciálnym informáciám, obsiahnutým v dátach. Toto je prístup založený na hľadaní (explorácii) použiteľných informácií v dátach (v kapitole 1 sme ho označili ako „push - prístup“) ktorý je motivovaný dostupnosťou príslušných IT nástrojov. Tento prístup má abstraktný charakter a vyžaduje si relatívne málo doménových znalostí o výrobných technológiách firmy. Dá sa to považovať aj za výhodu. Je to však súčasne aj nevýhoda, pretože sa k získavaniu dát neprístupuje tak, aby **dôsledne vychádzalo z výrobného procesu.**

Mnohé doterajšie nasadenia postupov strojového učenia vo výrobe sú založené na „push“ princípe a teda na dátach a nie na procesoch. V súvislosti so „senzORIZÁCIU“ strojov a zariadení v súvislosti s nástupom priemyslu 4.0 firmy zhromažďujú veľké množstvá dát. „Exploratívny“ prístup založený na dátach síce tiež môže viesť k získaniu informácií, ktoré môžu zlepšiť výrobný proces, nie je však na to cielene zameraný. Preto umožňuje len **v obmedzenej miere priestor na uplatnenie hodnotného know-how o výrobnom procese.**

Ináč sa veci majú pri procesne-orientovanom „pull“ prístupe. Tento vychádza z výrobného procesu, v ňom použitých strojov, prostredia v ktorom výroba prebieha a v neposlednom rade z výrobných pracovníkov a je primárne zameraný na dohľad nad výrobou, reguláciu a optimalizáciu procesu. To má veľký vplyv na otázku, na ktoré dáta budú použité nástroje strojového učenia a tiež, ako sa dajú tieto dáta získať. Korelácie, vzájomné vplyvy a príčinné súvislosti tých rámcových podmienok, ktoré zásadným spôsobom ovplyvňujú výrobu

(proces, stroj, materiál, prostredie, človek) tvoria cenné doménové know-how. Tieto znalosti umožňujú cielené nasadenie SU. Z vedeckého pohľadu zostáva výzvou to, ako premietnuť do vhodných procesných modelov a SU postupov formy reprezentácie dát, spojené s rámcovými podmienkami a procesnými vplyvmi využitím greybox-modelovacieho prístupu. V porovnaní s push- prístupom, vychádzajúcim z dát a postupov dátovej analýzy ponúka výrobnotechnický a procesný pull- prístup podstatne väčší potenciál systematického využitia doménových znalostí z výroby pre dosiahnutie väčšej pridanej hodnoty.

Ak si znázorníme schému prístupu k použitiu strojového učenia vychádzajúceho zo znalostí výrobných technológií a procesov, dostaneme sa od obr. 3 k novej schéme, ktorá je na obr. 5.



Obr. 5 Procesne orientovaný "pull" prístup k využitiu ML vo výrobe

6. Príklady použitia z výskumu WGP

Osobitou črtou skúseností, ktoré sa premietli do tohoto Stanoviska je to, že výskumné a vývojové činnosti inštitútov WGP sú typicky orientované na procesy. Znamená to, že sa riadia pull- prístupom, pri ktorom pôvodný podnet na využitie UI/SU postupov reagoval na konkrétne potreby optimalizovať výrobné procesy. Vo výskumnej činnosti WGP sa v súčasnosti intenzívne využívajú metódy UI a osobitne SU na optimalizáciu výrobnotechnických procesov a zariadení. Ťažiská ich aplikácie sú najmä v oblastiach CNC strojov a obrábania, manipulácie/montáže/robotiky a materiálových tokov/logistiky.

Tabuľka 1 ukazuje výber z rýchlo rastúceho počtu výskumných prác WGP v oblasti výroby využívajúcej umelú inteligenciu. Aj vo svete je v oblasti výskumu výroby pozorovateľný výrazný nárast výskumných aktivít. To sa odráža aj v skokovom náraste počtu publikácií týkajúcich sa UI v popredných medzinárodných odborných žurnáloch z oblasti výrobnotechniky.

Aplikačná oblasť	Príklad použitia	Realizácia s SU	Vstupné veličiny	Výstupná veličina SU modelu	Č. ref.
CNC stroje / obrábanie					
Kontrola kvality/optimalizácia procesu	Priebežné hodnotenie kvality povrchu	Predikcia narušenia obrábaného povrchu využitím umelej neurónovej siete	Parametre triesky, parametre nástroja, dáta z riadiacej jednotky stroja	Stredná drsnosť povrchu	[12]
Kontrola kvality/optimalizácia procesu	Klasifikácia častíc (kov/nekov) pri analýze čistoty	Deep-learningový model založený na modeli Inception-ResNetV2	Obrazové dáta kovových a nekovových častíc	Klasifikácia častíc na kovové a nekovové	[13]
Kontrola kvality/optimalizácia procesu	Predpoveď geometrie a drsnosti povrchu a optimalizácia procesných parametrov pri vŕtaní	Bayesovské siete /GeNIe	Parametre vŕtania, sily, momenty	Polomer zatupenia nástroja, drsnosť povrchu a kruhovosť vrtu	[14]
Kontrola kvality	Identifikácia poškodení povrchu počas procesu	Učenie bez dohľadu	Snímky povrchu súčiastok	Lokalizované poškodenia	[15]
Dohľad nad procesom	Predikcia reznej sily	Naučenie neurónovej siete počas prvých sekúnd obrábania	Parametre rezania, prúdy v pohone, rýchlosť, zrýchlenie, trhnutie	Sily pri obrábaní	[16],[17]
Optimalizácia komponentov strojov	Optimalizácia poloaktívnych tlmiacich prvkov	Genetický algoritmus	Dáta z modelov na báze metódy konečných prvkov (FEM-modely)	Optimalizované štruktúry dutín v saniach sústruhu	[18]
Monitorovanie stavu	Monitorovanie stavu pohonu s guľôčkovou skrutkou	Klasifikácia stavu pomocou support vector machine (metóda učenia so spätnou väzbou)	Zrýchlenie (3-osý MEMS senzor)	Trieda stavu	[19], [20], [21]
Energetická efektívnosť výrobných strojov	Online optimalizácia energetického stavu (stojí, pohotovosť, pracuje) výrob.stroja pre minimalizáciu nákladov na energiu a špičkových záťaží	Učenie so spätnou väzbou (deep-Q-network), proximal policy optimization (PPQ), memory augmented policy optimization (MAPO)	Skutočná záťaž a stav stroja, cena energie, profil záťaže, hraničné hodnoty záťaže a spotreby	Cieľová záťaž a stav stroja	[22]
Optimalizácia riadenia procesu/rozpoznanie porúch	Rozpoznanie súvislosti viacerých procesných veličín pri práci s pružnými fóliami	Výber vhodného počtu klastrov pomocou elbow metódy/klastrovaním s k-Keans algoritmom	Záznam sensorových dát riadiacej jednotky stroja	Vhodný počet klastrov pre klastrovanie	[23]
Opatrebnosť nástrojov	Detekcia opotrebenia otočných rezných platničiek	Klasifikácia stavu s random forest klasifikátorom (ďalšie testované)	Spôsobovaný hluk (MEMS senzor)	Trieda opotrebenia	[24]
Dohľad nad procesom	Celostný dohľad nad procesom	Učenie s čiastočným dohľadom, učenie s dohľadom	Zvuk predmetu	Stavy zariadenia, chybové stavy, opotrebenie	[25],[26]
Manipulácia / montáž / robotika					
Automatizované uchopenie	Optimalizácia pri siahnutí do krabice	Deep-learning, transfer learning	3D pointcloud	Poloha súčiastky	[27],[28]
Kontrola kvality	Predikcia kvality pri povrchovej montáži (SMD) vo výrobe mikroelektroniky	Učenie s dohľadom (umelá neurónová sieť, rekurentná neurónová sieť, random forest klasifikácia)	Parametre procesu	Efektívnosť prenosu	[29]
Kontrola kvality	Detekcia anomálií pri viacstupňových montážnych procesoch	Učenie bez dohľadu (o.i. k-means algoritmus)	Parametre procesu	Anomálie ako praskliny, defekty alebo vytrhnutia	[30]
Kontrola kvality	Predikcia kvality pri laserovom bodovom zváraní	Učenie s dohľadom (o.i. umelé neurónové siete, podporné vektorové stroje, konvolučné neurónové siete)	Parametre strojov, obrazové dáta	Prechodový odpor a chyby zvarov	[31],[32]

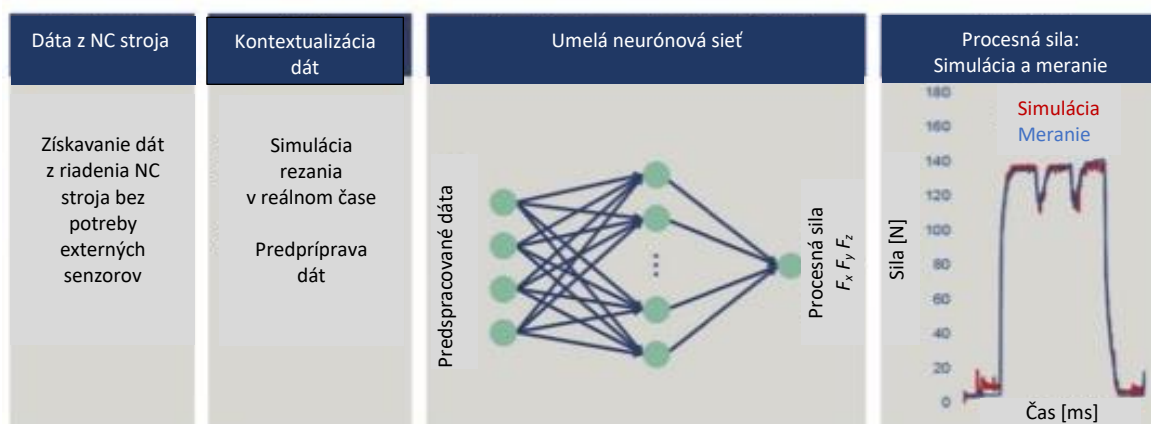
Kontrola kvality	Predikcia kvality pri ultrazvukovom krimpovaní vo výrobe elektrických strojov	Učenie s dohľadom (o.i. umelé neurónové siete, podporné vektorové stroje, konvolučné neurónové siete)	Parametre strojov, obrazové a akustické dáta	Prechodový odpor a ťahová sila	[33],[34]
Kontrola kvality	Navíjanie v drážkach	Konvolučné neurónové siete	Tomografická snímka rezu	Hodnotenie navíjacieho procesu	[35]
Tok materiálu / logistika					
Rozpoznávanie dielcov	Automatické rozpoznanie náhradného dielu pri výrobe turbín (> 50.000 dielcov)	Deep-learning, transfer learning	Snímky dielcov z 9 perspektív	Identita dielca	[36]
Riadenie priebehu	Automatické učenie PLC programov na riadenie tokov materiálov	Učenie so spätnou väzbou	Dáta z akčných prvkov a senzorov použitých v simulácii typu hardware-in-the-loop	Stratégia riadenia a čiastkové PLC programy	[37],[38]
Plánovanie zákaziek	Adaptívne plánovanie zákaziek v polovodičovom priemysle	Učenie so spätnou väzbou	Dáta zákaziek	Optimalizovaný sled zákaziek	[39],[40]

V nasledujúcom texte uvádzame stručné vysvetlenia príkladov z rôznych oblastí priemyslu.

6.1 CNC stroje a obrábanie

Obr. 6 ukazuje princíp dohľadu nad procesom frézovania s využitím umelej neurónovej siete. Natrénovanie neurónovej siete sa odohrá počas prvých sekúnd rezania s využitím procesných informácií, ktoré má NC-riadiaca jednotka (polohy osí, rýchlosti a ďalšie odvodené veličiny). Následne neurónová sieť dokáže s veľkou presnosťou predpovedať hodnoty procesných síl. Tieto predpovedané hodnoty sa využívajú ako referenčné hodnoty pre dohľad nad reálnymi hodnotami rezných síl [16],[17].

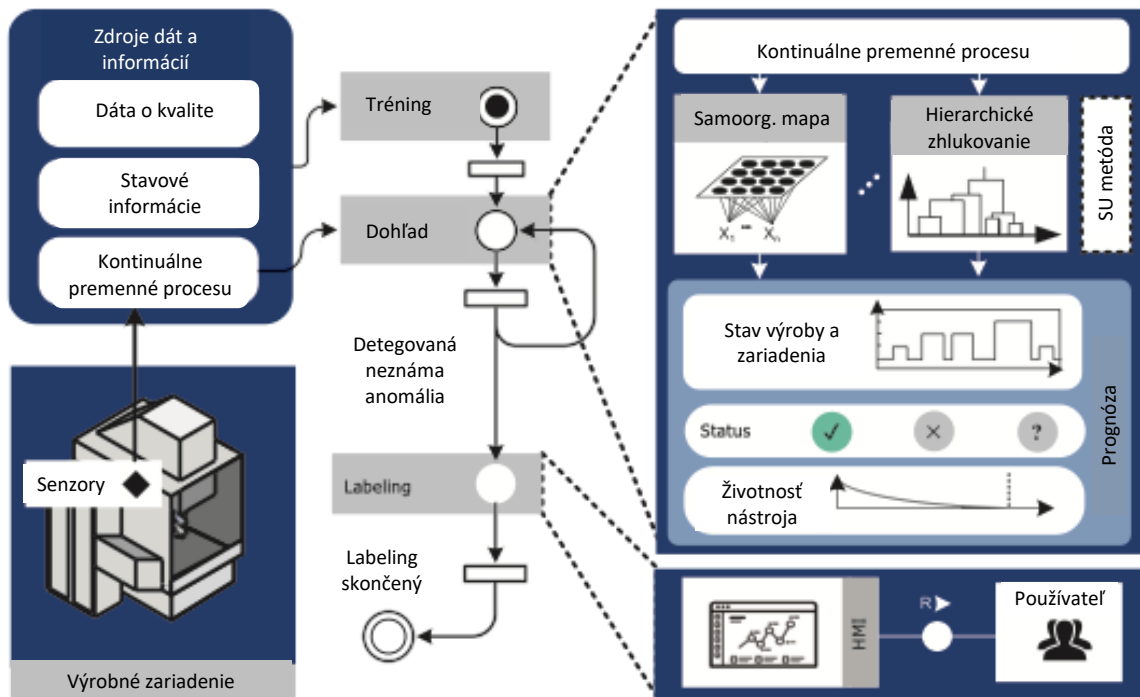
Toto využitie UI je príkladom veľkého potenciálneho úžitku a tvorby pridanej hodnoty, ktoré prináša SU pri simulácii zložitých výrobných procesov. **Klasické analytické modelovanie** by tu kvôli neznámym koeficientom reznej sily bolo možné len za cenu **väčších nákladov**. Natrénovaná neurónová sieť sa tieto parametre implicitne naučila. **Znalosti výrobných expertov sa tu uplatnia** pri výbere vhodných dát na tréning siete a pri hodnotení kvality a robustnosti simulácie reálneho procesu.



Obr.6: Dohľad nad procesom simuláciou reznej sily využitím umelej neurónovej siete

Popri postupoch, využívajúcich UI/SU učenie s dohľadom aj postupy s učením bez dohľadu alebo s čiastočným dohľadom majú svoj potenciál pri realizácii celkového dohľadu nad procesmi a výrobnými zariadeniami s minimálnymi zásahmi operátorov. Takéto postupy umožňujú použiť na tvorbu modelov väčšiu časť dostupných dát z procesov a zariadení, ktoré nie sú späté s priebežne sa vyvíjajúcim stavom procesu alebo zariadenia, resp. so sledovanou veličinou, ktorej hodnotu chceme klasifikovať a predikovať. Umožňuje to upustiť od veľmi nákladného generovania dát a ich labelingu, resp. od vytvárania trvalých informačných rozhraní napr. k PLC systémom. Namiesto takýchto zložitých opatrení sa dajú realizovať samostatné, prenosné systémy, ktorým postačí minimálny informačný vstup operátora. Postupy učenia s čiastočným dohľadom dokážu s využitím menšieho množstva labelovaných dát vygenerovať počiatočný odhad rozsahu relevantných vstupných veličín. Na základe toho a v kombinácii s použitím väčšej časti nelabelovaných dát sa dá dosiahnuť veľmi dobrá kvalita predikcie. Takto sa dajú aj učiace postupy bez dohľadu (napr. hierarchický clustering) povýšiť na učenie s čiastočným dohľadom [41]. Systémy dohľadu nad priemyselnými procesmi sa dajú realizovať aj s využitím čistého učenia bez dohľadu v kombinácii s existujúcimi à priori vedomosťami [42].

Príkladom možného použitia takýchto systémov je **procesný dohľad v subtraktívnej výrobe s využitím vydávaného zvuku**. Veľké množstvo variant použitých nástrojov, parametrov a stavov obrábacieho stroja spôsobuje, že množina hodnotených vzoriek zvuku bude veľmi rozsiahla. A teda aj vytvorenie kompletnej a plne olabelovanej tréningovej databázy môže byť nerentabilné. Takýto systém môže byť využitý na rozpoznanie stavu stroja ktorý zodpovedá interpretácii daného zvuku. Súčasne umožní detegovať odchýlku stroja od normálneho funkčného stavu (napr. klepanie, kolízie). Je možné tiež kvantifikovať mieru opotrebenia nástrojov tým, že sa do systému zaradí ďalšia analýza zvukov [25],[26] - vid' obr.7.



Obr. 7 Priebeh a architektúra dohľadového systému na báze SU na príklade obrábania (podľa [26])

6.2 Manipulácia, montáž a robotika

Nasledujúci príklad ukazuje aký môže byť potenciál simulácie procesov v inej podobe. Využívajúc virtuálne učiace prostredie sa tu simulujú manipulačné úkony pri „výbere súčiastky z krabice“ [28] - vid' obr. 8. Najprv sa pri simulácii fyzického prostredia vytvorili dáta (obrazové), ktoré boli olabelované a tie boli vstupom do tréningu procesného modelu, ktorý bol následne prenesený do reálneho robota. Aby tréningové dáta obsahovali aj rušivé faktory, ktoré obsahuje reálna situácia, simulácia fyzického prostredia zohľadňovala aj modely obrazového šumu, aký sa vyskytuje v reáli. Postup, ktorý bol zvolený ukazuje mimoriadny **potenciál tzv. transferového učenia** pre výrobnotechnické aplikácie. V predchádzajúcom príklade sme uvádzali, že na získanie dostatku učiacich dát (z vyberania z krabice v reálnych podmienkach) by bol potrebný veľmi dlhý čas. V článku [27] sa uvádza, že je možné získať simulované dáta využitím expertízy odborníka a výkonného výpočtového systému za niekoľko sekúnd až hodín. Príklad uvádza, že expertíza je najviac potrebná pri vizualizácii súčiastok, simulácii procesu uchopenia a simulácii rušivých vplyvov.

6.3 Tok materiálu a logistika

Ako príklad z tejto oblasti ukazuje obr. 9 **kamerový asistenčný systém na identifikáciu súčiastok** [36]. Ide tu o úlohu identifikovať veľký počet druhov rôznych súčiastok - v popisovanom príklade ich bolo cca. 1000 až 1500 z celkového počtu 50 000 súčiastok. Osobitosťou je tu skutočnosť, že pri každej súčiastke sa dá získať len veľmi malé množstvo obrazových dát pre potrebu tréningu. Podobne ako v predchádzajúcom príklade, aj tu

bola úspešne využitá učiaci metóda transfer learning. Pritom sa **využívala konvolučná neurónová sieť (CNN)** na to, aby boli spočiatku vytvorené všeobecne použiteľné príznaky vyskytujúce sa na akýchkoľvek snímkach (aj nepriemyselných predmetov) a tieto príznaky sa v poslednej vrstve CNN asociovali so „skromnými“ obrazovými dátami súčiastok. Bolo to **prvé využitie transferového učenia s priemyselnými dátami** a umožnilo zvýšiť úspešnosť rozpoznávania súčiastok oproti klasickým metódam **o viac než 20%** [36].

Tento príklad ukazuje osobitným spôsobom užitočnosť expertných znalostí výrobných techník. Kvôli malému množstvu tréningových dát by sa pri čisto dátovom prístupe dospelo k záveru, že zmysluplná automatizácia rozpoznávacieho procesu pre také množstvo súčiastok nemá zmysel, lebo dosiahnuteľná úspešnosť rozpoznávania je príliš nízka. Doposiaľ sa identifikácia súčiastok robila manuálne s pomocou katalógu, bolo to časovo náročné a chybové. **Podarilo sa však vyvinúť asistenčný systém**, ktorý pri zohľadnení detailnej znalosti priebehu procesu a dosiahnuteľnej úspešnosti rozpoznávania (napriek malému rozsahu učiacich dát) dokáže so spoľahlivosťou asi 80% rozlíšiť päť najpravdepodobnejších súčiastok a priradiť k nim ich referenčné fotografie z databázy. Takto podporený operátor následne zvolí príslušnú z piatich ponúknutých súčiastok. Týmto dvojstupňovým procesom skladajúcim sa z automatického predvýberu a následného rozhodnutia človeka dokáže tento asistenčný systém (nazvaný „LogicCube“) ušetriť veľa času a súčasne redukovať chybovosť v porovnaní s manuálnym postupom, využívajúcim katalóg.



Obr. 9: Kamerový asistenčný systém na identifikáciu súčiastok v logistike náhradných dielcov

Skúsenosti, získané vo výskumných prácach členských inštitútov WGP, môžu byť priamo využité pri tvorbe inovatívnych priemyselných riešení. Pri tvorbe tohoto odborného stanoviska sme analyzovali, ktoré skúsenosti sa získali s medzičasom už početnými softvérovými nástrojmi a SU knižnicami, dostupnými ako open source. Taktiež sme analyzovali, ktoré špecifické kompetencie z oblasti výrobnéj techniky a z oblasti strojového učenia sú potrebné pre tvorbu takýchto riešení. Naše zistenia, zohľadňujúce tieto skúsenosti sú formulované v nasledujúcich odporúčaniach.

7. Ako odporúčame konať

V tejto kapitole predkladáme odporúčania k implementácii aplikácií UI vo výrobe a to na základe skúseností WGP. Uvádzame operatívne odporúčania ako aj strategické perspektívne pohľady na problematiku.

7.1 Ako analyzovať ciele, ktoré si má firma stanoviť

Firma si musí najskôr zodpovedať otázku, aký druh „inteligencie“ stroja/zariadenia/roboťa si želá (napr. rozpoznanie stavu zariadenia, autonómne konanie, automatické prispôbenie zmenám ako sú opotrebenie nástroja alebo vlastnosti súčiastok, samostatné preplánovanie/preorganizovanie priebehu výroby, porozumenie ľudským pokynom alebo gestám v záujme zjednodušenia programovania, rozpoznanie súčiastok) resp. čo sa má stroj samostatne naučiť.

Ak sa má stroj samostatne učiť, potom hneď vyvstáva otázka, **kto skontroluje, či učenie prebehlo správne**, ešte predtým, kým stroj začne s naučenými vedomosťami pracovať. To súčasne znamená, že si firma musí premyslieť kedy a na akých dátach sa bude stroj učiť, predtým, než začne automaticky pracovať.

Každý z vyššie uvedených cieľov a druhov „inteligencie“ stroja je založený na IT štruktúre a vyžaduje si iný prístup k využitiu SU nástrojov.

Treba tiež analyzovať, či má z pohľadu firmy byť SU **vnútornou funkcionalitou stroja alebo jeho prídavnou funkciou**. Tým sa rozhoduje o tom, či má firma samotná nadobudnúť zásadnú expertízu alebo prenechá implementáciu technológie tretiemu subjektu. Vzhľadom na rastúcu dôležitosť SU však vážne odporúčame, aj v samotnej firme vytvoriť základnú mieru expertízy, ktorá sa môže uplatňovať aj v prípade strojov s jednoduchšou pridanou inteligentnou funkcionalitou. *(Poznámka prekladateľa: tento odstavec je orientovaný najmä na výrobcov výrobných strojov)*

7.2 Nadobudnutie expertízy

Pri nadobúdaní vlastnej expertízy vo firme sa odporúča, aplikácie využívajúce postupy UI spočiatku vyvíjať so skúsenými dodávateľmi alebo s výskumnými pracoviskami. Pritom môže firma získať hodnotné skúsenosti - napríklad o celkovom priebehu prác na takýchto projektoch, počnúc analýzou vhodných výrobných procesov z pohľadu ich vhodnosti na nasadenie postupov strojového učenia, cez získanie a prípravu dát až po tréning, validáciu a napokon testovanie modelu. Osobitne pri spolupráci s výskumnými pracoviskami sa ponúka taký prístup, pri ktorom zmiešaný tím, zložený z vlastných zamestnancov firmy a pracovníkov výskumného inštitútu spoločne plánujú riešenia a integrujú ich. Pritom prebieha aj potrebný transfer know-how do firmy.

7.3 Zbierať skúsenosti na jednoduchých úlohách

Keď už firma nadobudla skúsenosti v jednoduchých spoločne riešených projektoch alebo ak si vďaka dostatočne kvalifikovaným pracovníkom zohnala kompetencie zvonku, môže začať vytvárať vlastné aplikácie. Pritom je rozdiel, či ide o integráciu softvérových UI nástrojov s hotovou funkcionalitou do výrobných procesov či výrobkov alebo je potrebné natréňovať strojovým učením UI nástroj tým, že sa použijú vlastné dáta firmy.

V druhom prípade je možné siahnuť po niektorom z početných existujúcich SU nástrojov. Prehľad o týchto nástrojoch poskytuje „Quick Guide Machine Learning im Maschinen- und Anlagenbau“ vydaný VDMA (Združenie nemeckých výrobcov strojov a zariadení) [7]. Odporúčame firmám, aby vlastné skúsenosti získavali spočiatku na jednoduchých úlohách, napr. pri automatizovanej kontrole kvality s jednoduchým automatickým rozlišovaním výrobkov na dve triedy (v poriadku / nie v poriadku).

7.4 Identifikácia a využitie výrobnotechnického procesného know-how pre potreby SU

V rámci výskumných prác WGP zameraných na využitie metód UI vo výrobných technológiach sa zreteľne potvrdil prínos znalostí o výrobnotechnických procesoch. Takéto znalosti majú **mnohé firmy** v mnohorakej podobe a je to významná **súčasť ich kapitálu**. Správne využitie týchto znalostí spolurozhoduje o rýchlosti a úspechu použitia UI-metód. Preto odporúčame aby ste si uvedomili týchto **desať hlavných bodov zo skúseností z výskumu WGP** a na základe nich cielene preskúmali procesné know-how vo svojej firme:

1. Procesné znalosti sú rozhodujúce pre to, aby ste si vo výrobe kládli správne otázky, ktorými sa chcete zaoberať. Len tak budete mať kapacity správne nasadené a zmysluplne využité.
2. Procesné znalosti môžu pomôcť redukovať zložitost' problémov tým, že už na začiatku vylúčite irelevantné parametre a využijete známe súvislosti medzi parametrami. To môže zmenšiť potrebné množstvo dát a skrátiť neskôr dobu tréningu.
3. Procesné know-how môže pomôcť s dostupnosťou dát tým, že sa budú dať doplniť augmentáciou. Pritom sa generujú umelé dáta alebo sa existujúce dáta dopĺňajú o ďalšie aspekty. Robí sa to vhodnou manipuláciou procesu alebo dátovej vety alebo sa využije simulácia procesu.
4. SU ako nástroj nemá žiadnu znalosť o kontexte v ktorom sa nachádza. Preto ani nedokáže interpretovať vlastné výstupy. Jedine ten, kto má znalosť o procese môže hodnotiť, nakoľko je zvolený systém vhodný a nakoľko výsledok SU má/môže/smie ovplyvňovať príslušný výrobný proces.
5. SU je nástroj, ktorý dáva odpovede na otázky štatistického charakteru. Prevedenie otázok používateľov do príslušných matematických vyjadrení nie je možné bez procesných znalostí a poznania možností SU.
6. Akceptácia strojového učenia veľmi závisí od toho, do akej miery vieme spoľahlivo rozpoznať kritické stavy procesu a vyhnúť sa falošným alarmom. To zasa závisí od nastavenia parametrov učenia sa systému, resp. jeho citlivosti na zmeny hodnôt. Znalosti procesu a riešenej úpravy sú dôležité pre optimálne nastavenie citlivosti učiaceho mechanizmu na danú aplikačnú situáciu.

7. Dostupnosť anotovaných (labelovaných) dát je zásadný faktor efektívneho nasadenia SU. Pritom už v súčasnosti vzniká vo firmách veľa labelovaných dát, ktoré však nie sú počítačovo uchovávané. Špecifické doménové výrobnotechnické vedomosti o fyzikálnych vzťahoch obsahujú väzby (korelácie a príčinné súvislosti) medzi dátami a správaním sa procesov. Procesné znalosti v kombinácii s poznaním potrieb strojového učenia môžu pomôcť odhaliť tieto zdroje dát a sprístupniť dáta vo vhodnej podobe.
8. Relevantné veličiny nie sú vždy merateľné. Poznanie procesu môže čiastočne umožniť nepriame stanovenie hodnôt veličín tým, že sa oprie o známe vzájomné závislosti v procese. Tak sa dajú doplniť chýbajúce hodnoty veličín pre vstup do SU.
9. Vysoká kvalita dát je nutný predpoklad pre nasadenie SU. Moderné SU nástroje často disponujú schopnosťou vymykajúce sa hodnoty a šum merania implicitne spracovať. Takto dosiahnutá integrácia atypických dát môže čiastočne napomôcť zlepšiť možnosť zovšeobecnenia rozpoznaných vzorcov správania sa procesu. Aj v tom sa dá cielene využiť procesná znalosť.
10. Pri použití strojového učenia môže pomôcť rozdeliť celú úlohu na niekoľko čiastkových krokov. Dôsledkom môže byť zlepšenie výkonu systému tým, že nadobudne hierarchickú štruktúru. Pri takomto štruktúrovaní môže doménové know-how pomôcť s priradením dát alebo produktových, procesných či kvalitatívnych parametrov tak, aby bolo rozdelenie úlohy na úrovne vhodné.

7.5 Systematické získavanie dát

Nezávisle na tom, či si firma sama vyvíja riešenia alebo tým poverí partnera, najdôležitejším základom je existencia dát na učenie UI metód. Nasledujúce kroky hrajú dôležitú rolu pri systematickom získavaní dát:

- Identifikovanie zdrojov dát a s tým súvisiaci ďalší rozvoj senzORIZÁCIE, napr. cestou štandardných rozhraní medzi strojmi a zariadeniami.
- Identifikovanie vzťahov medzi dátami, ktoré sa tým stanú využiteľnými pre učenie s dohľadom.
- Zaznamenávanie a dokumentovanie vzťahu medzi získanými dátami a stavmi procesov, z ktorých boli dáta získané.
- Cielene použitie simulačných postupov na zväčšenie databáz („data farming“).

7.6 Cielene prepájať know-how

Firma, ktorá chce vo výrobe využívať postupy SU, potrebuje expertov, ktorí dokážu prijať zodpovedné rozhodnutie o nasadení takýchto postupov. Takíto ľudia však musia byť primerane vyškolení. Situáciu sťažuje to, že o absolventov z príslušných študijných smerov, zameraných na UI, je silný dopyt aj v rastúcich odvetviach, napr. v softvérovom priemysle. Aby však firma vedela zodpovedne rozhodovať o nasadení UI-metód vo výrobe, potrebuje aj fundované výrobnotechnické know-how. Len tak môže posúdiť riziko evt. nesprávnych rozhodnutí natrénovaného systému a na základe toho aj možné riziko pre výrobu. Experti, v ktorých sa spájajú obe vedomostné domény, „UI-inžinieri“ v súčasnosti nie sú univerzitami vzdelávaní. SU systémy sa učia prevažne štatistické rozdelenie príznakov. Vzniká tak odborné prepojenie k základom štatistiky, takej, aká sa využíva v zabezpečení a manažmente kvality, aby bola dosiahnutá garancia kvality výrobnotechnických procesov. Odporúčame preto **zriaďovanie zmiešaných tímov**, ktoré pri rozhodovaní o nasadení učiacich sa SU

systemov dokážu kombinovať štatistickú expertízu na posúdenie robustnosti naučených systémov s výrobnotechnickou expertízou.

7.7 Hodnotiť budúci potenciál

Obdobné zlepšovanie ako v oblasti rozpoznávania obrazcov, naznačené na obr. 2, prebieha aj v iných oblastiach uplatnenia SU. Podobne sa vyvíja potenciál uplatňovania strojového učenia v automatizácii výrobnotechnických procesov. Na uplatnenie SU sa zameriavajú mnohé súčasné výskumné a vývojové práce. Je dôvodné predpokladať, že tento pokrok bude pokračovať, keďže pozorujeme zrýchľovanie vývoja samotného strojového učenia. To však znamená, že môžeme vysloviť predpoklady o výkonnosti postupov strojového učenia v horizonte piatich rokov. Vychádzajúc z obr. 2 môžeme **extrapoláciou pokroku** za uplynulých desať rokov napríklad očakávať, že za ďalších 5 rokov sa zvyšková chybovosť pri rozoznávaní obrazcov zmenší z dnešných 3% na cca. 0,5%. To by znamenalo, že rozpoznávací systém natrénovaný na dostatočne kvalifikovaných priemyselných dátach bude rozlišovať súčiastky prakticky bez chýb. Robot, vybavený takouto schopnosťou bude mať podstatne vyššiu flexibilitu a spoľahlivosť pri rozpoznávaní a uchopovaní súčiastok. To otvorí úplne nové aplikačné možnosti v automatizácii manipulačných procesov.

Veľké firmy, ktoré úspešne vyvíjajú a nasadzujú UI-riešenia ale rovnako aj na túto oblasť sa špecializujúce startupy systematicky analyzujú rysujúce sa potenciály vyplývajúce z pokroku v oblasti UI. Cieľom je zavčas identifikovať nové modely tvorby pridanej hodnoty - napríklad pre predaj výrobkov - a tieto chrániť patentmi.

Vo výrobe však takéto výhľadové **analýzy scenárov** zatiaľ neboli používané, hoci takýto prístup má tiež potenciál na **zaistenie budúcej konkurencieschopnosti** podnikov. Preto odporúčame výrobným firmám ako aj dodávateľom výrobných zariadení vytvoriť si kompetenciu a expertízu na systematické využívanie takýchto potenciálov.

7.8 Cielene nasadzovať asistenčné systémy využívajúce UI-metódy

Pokrok v oblasti UI-metód vyvoláva očakávanie, že mnohé stroje, zariadenia a procesy budú môcť v budúcnosti pracovať úplne automaticky. Berúc do úvahy súčasné vysoké nároky na prispôsobivosť a flexibilitu výrobnotechnických procesov je však aj u technologicky najvyspelejších výrobných systémov často cítiť hranice možností plnej automatizácie. Preto aj v budúcnosti bude treba ľudskú inteligenciu na dosiahnutie a udržanie veľkej miery prispôsobivosti a flexibility vo výrobe.

Aby sa využil **potenciál tvorený spojením ľudskej a strojovej inteligencie**, odporúča sa tam, kde je to možné, podporiť vyspelejšie kognitívne a senzoricko-motorické schopnosti človeka využitím umelej inteligencie vo výrobe. Je to zaujímavé najmä tam, kde sú schopnosti človeka obmedzené kvôli únave ale aj kvôli prírodou limitovanej kapacite prijímania a spracovávaní informácií.

Naopak sa odporúča analyzovať, kde je možné v súčasnosti existujúce hranice učenia strojov kompenzovať schopnosťami človeka. Čiže človek by rozšíril limitované možnosti zariadení, podporovaných umelou inteligenciou.

Pri takýchto analýzach môžu pomôcť metodické prístupy ako je na obr. 4 znázornená súvislosť medzi úkonmi a schopnosťami. Stále však platí, že všeobecne použiteľné metodické modely pre cielenú identifikáciu a vývoj zmysluplných výrobnotechnických asistenčných funkcií ešte treba vyvinúť. Inštitúty WGP vnímajú ako veľkú výzvu systematické a účinné prepojenie rôznych foriem inteligencie - človeka a stroja - vo výrobe.

8 Odkazy

[1] Krüger, J.; Suwalski, I.: Fuzzy Logik und Neuronale Netze in der Maschinendiagnose. ZWF, 87 (1992) 11, S. 611-615

[2] Specht, D.: Wissensbasierte Systeme im Produktionsbetrieb. München; Wien: Hanser, 1989

[3] WGP e. V.: WGP-Standpunkt Industrie 4.0. Wissenschaftliche Gesellschaft für Produktionstechnik WGP e. V., Internet: https://wgp.de/wp-content/uploads/WGP-Standpunkt_Industrie_4-0.pdf, 2016

[4] WGP e. V.: WGP-Standpunkt Industriearbeitsplatz 2025, Wissenschaftliche Gesellschaft für Produktionstechnik WGP e. V., <https://wgp.de/wp-content/uploads/WGP-.pdf>, 2018

[5] Strategie Künstliche Intelligenz der Bundesregierung. November 2018. Internet: www.ki-strategie-deutschland.de

[6] Chapman, P.; Clinton, J.; Kerber, R.; Khabaza, T.; Reinartz, T.; Shearer, C.; Wirth, R.: CRISP-DM 1.0 Step-by-step data mining guide. 2000

[7] VDMA Software und Digitalisierung: Quick Guide Machine Learning im Maschinen und Anlagenbau. VDMA, 2018. Internet: sud.vdma.org

[8] Seifert, I.; Bürger, M.; Wangler, L.; Christmann-Budian, S.; Rohde, M.; Gabriel, P.; Zinke, G.: Potenziale der künstlichen Intelligenz im produzierenden Gewerbe in Deutschland - Studie im Auftrag des Bundesministeriums für Wirtschaft und Energie (BMWi) im Rahmen der Begleitforschung zum Technologieprogramm PAiCE – Platforms | Additive Manufacturing | Imaging | Communication | Engineering. Hrsg.: iit-Institut für Innovation und Technik in der VDI / VDE Innovation + Technik GmbH, 2018. Internet: https://www.bmwi.de/Redaktion/DE/Publikationen/Studien/potenziale-kuenstlichen-intelligenz-im-produzierenden-gewerbe-in-deutschland.pdf?__blob=publicationFile&v=8.

[9] Tremblay, J.; Prakash, A.; Acuna, D.; Brophy, M.; Jampani, V.; Anil, C.; To, T.; Cameracci, E.; Boochoon, S.; Birchfield, S.: „Training Deep Networks with Synthetic Data: Bridging the Reality Gap by Domain Randomization“, 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), Salt Lake City, UT, 2018, S. 1082–10828. doi: 10.1109/CVPRW.2018.00143

[10] Agrawal, A.; Gans, J.; Goldfarb, A.: Prediction machines. Boston, Massachusetts: Harvard Business Review Press. 2018

[11] Russakovsky, O.; Deng, J.; Su, H.; Krause, J.; Satheesh, S.; Ma, S.; Huang, Z.; Karpathy, A.; Khosla, A.; Bernstein, M.; Berg, A. C.; Fei-Fei, L.: ImageNet Large Scale Visual Recognition Challenge. IJCV, 2015

[12] Brecher, C.; Epple, A.; Fey, M.; Königs, M.; Neus, S.; Wellmann, F.: Lernende Produktionssysteme. In:

Tagungsband zum AWK – Aachener Werkzeugmaschinen Kolloquium – Internet of Production für agile Unternehmen. Aachen, 18.-19. Mai 2017. Aachen: Apprimus, 2017, S. 135–161

[13] Zwinkau, R.; Möhle, R.; Frentrup, S.; Deuse, J.: Metall/Nichtmetall-Klassifikation von Partikeln mit Deep Learning. JOT - Journal für Oberflächentechnik 58: S. 50–57, 2018

[14] Wang, X., Eiseler, R., Moehring, H.-C.: Prediction and Optimization of Machining Results and Parameters in Drilling by using Bayesian Networks. Production Engineering, 2019 (in review)

[15] Eigenbrod, H.; Hüttel, M.: Wenn jede Oberfläche anders ist: Selbstlernende Verfahren zur Prüfung von strukturierten Oberflächen Inspect: World of Vision. 17(5), 2016, S. 72-74

[16] Königs, M.; Wellmann, F.; Wiesch, M.; Epple, A.; Brecher, C.: A scalable, hybrid learning approach to process-parallel estimation of cutting forces in milling applications. In: Tagungsband zum 7. WGP-Jahreskongress. Aachen, 5.-6. Oktober 2017. Aachen: Apprimus, 2017, S. 425–432 (ISBN: 978-3-86359-555-5)

[17] Brecher, C.; Wiesch, M.; Epple, A.: Entwicklung eines Kraftschätzmodells beim Fräsen. Anwendung eines modernen, hybriden Lernansatzes auf Basis künstlicher neuronaler Netze zur prozessparallelen Ermittlung der Prozesskraft anhand maschineninterner Daten. In: ZWF – Zeitschrift für wirtschaftlichen Fabrikbetrieb. 112. Jg., November 2017, Nr. 11, S. 792–796 (ISSN: 0947-0085)

[18] Burtscher, J.; Fleischer, J.: Adaptive tuned mass damper with variable mass for chatter avoidance. CIRP Annals, Volume 66, Issue 1, 2017, S. 397–400

[19] Uhlmann, E.; Laghmouchi, A.; Geisert, C.; Hohwieler, E.: Smart wireless sensor network and configuration of algorithms for condition monitoring applications. Journal of Machine Engineering 17 (2017), No. 2, 2017, S. 45–55, ISSN 1895-7595

[20] Uhlmann, E.; Laghmouchi, A.; Ehrenpfordt, R.; Hohwieler, E.; Geisert, C.: Intelligentes Elektroniksystem für Condition Monitoring in Industrie 4.0: Mikroelektromechanisches Elektroniksystem zur Zustands-, Verschleiß-, Prozess- und Anlagenüberwachung. ZWF, Vol. 111, No. 12, Hanser, 2016, S. 855–857, ISSN 0947-0085

[21] Laghmouchi, A.: Adaptives Entwicklungstool zur intelligenten Konfigurierung von Condition-Monitoring-Algorithmen. Stuttgart: Fraunhofer Verlag, 2017, zugl.: Berlin, TU, Diss., Berichte aus dem Produktionstechnischen Zentrum Berlin, ISBN: 978-3-8396-1222-4

[22] Bakakeu J, Tolksdorf S, Bauer J, Klos H-H, Peschke J, Fehrl A et al. An Artificial Intelligence Approach for Online Optimization of Flexible Manufacturing Systems. AMM 2018;882: S. 96–108

- [23] Uhlmann, Eckart; Pastl Pontes, Rodrigo; Laghmouchi, Abdelhakim; Bergmann, André: Concept of sustainable data for a selective laser melting machine. *Procedia manufacturing* 21 (2018), S. 655–662, Global Conference on Sustainable Manufacturing (GCSM), 2017, Haifa, ISSN: 2351-9789
- [24] Verbundprojekt AMELI4.0: Mikro-elektromechanisches Elektroniksystem zur Zustandsüberwachung in der Industrie 4.0: Abschlussbericht zum Teilvorhaben AMELI4.0 – Data: Verschleiß-, Anlagen- sowie Prozessmonitoring durch intelligente, autonome Multi-Sensorsysteme. Bericht: Claudio Geisert. Projektleitung: Eckhard Hohwieler. Fraunhofer-Institut für Produktionsanlagen und Konstruktionstechnik. Zeitraum: 1. Dezember 2015 bis 30. November 2018. Förderkennzeichen BMBF 16ES0444
- [25] Kißkalt, D.; Fleischmann, H.; Kreitlein, S.; Knott, M.; Franke, J.: A novel approach for data-driven process and condition monitoring. *Production Engineering*. 12, S. 525–533 2018
- [26] Kißkalt, D.; Mayr, A.; Lindenfels, J.; Franke, J.: Towards a Data-Driven Process Monitoring for Machining Operations Using the Example of Electric Drive Production. In: 2018 8th International Electric Drives Production Conference (EDPC). IEEE; 2018, S. 1–6
- [27] Kleeberger, K.; Landgraf, C.; Huber, M. F.: Large-scale 6D Object Pose Estimation Dataset for Industrial Bin-Picking. To appear at 2019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), Macau, China, November 2019
- [28] Spenrath, F.; Pott, A.: Using Neural Networks for Heuristic Grasp Planning in Random Bin Picking. In: *IEEE / Robotics and Automation Society: IEEE CASE 2018: 14th IEEE International Conference on Automation Science and Engineering*. 20 to 24 August 2018, Munich, Germany. IEEE, 2018, S. 258–263
- [29] Seidel, A.; Mayr, A.; Schäfer, F.; Kißkalt, D.; Franke, J.: Towards a Smart Electronics Production Using Machine Learning Techniques. In: 42nd International Spring Seminar on Electronics Technology: Advances in Printed and Ceramic Microsystems, 2019, Wroclaw, Poland
- [30] Sand, C.; Kunz, S.; Hubbert, H.; Franke, J.: Towards an inline quick reaction system for actuator manufacturing using data mining. In: 2016 6th International Electric Drives Production Conference (EDPC). IEEE; 2016, S. 74–79
- [31] Mayr, A.; Lutz, B.; Weigelt, M.; Gläbel, T.; Seefried, J.; Kißkalt, D.; Franke, J.: Elektromotorenproduktion 4.0 – Potenziale des maschinellen Lernens in der Elektromotorenproduktion am Beispiel des Laserschweißens von Hairpins. *ZWF*, 2019;114(3):S. 145–149
- [32] Mayr, A., Lutz, B.; Weigelt, M.; Gläbel, T.; Kibkalt D, Masuch M et al. Evaluation of Machine Learning for Quality Monitoring of Laser Welding Using the Example of the Contacting of Hairpin Windings. In: 2018 8th International Electric Drives Production Conference (EDPC). IEEE; 2018 - 2018, S. 1–7
- [33] Mayr, A.; Meyer, A.; Seefried, J.; Weigelt, M.; Lutz, B.; Sultani, D.; Hampl, M.; Franke, J.: Potentials of machine learning in electric drives production using the example of contacting processes and selective magnet assembly. In: 2017 7th International Electric Drives Production Conference (EDPC). IEEE; 2017 - 2017, S. 1–8
- [34] Weigelt, M.; Mayr, A.; Seefried, J.; Heisler, P.; Franke, J.: Conceptual design of an intelligent ultrasonic crimping process using machine learning algorithms. *Procedia Manufacturing* 2018;17:S. 78–85
- [35] Halwas, M.; Binder, D.; Fleischer, J.: Systematische Analyse des Lagenaufbaus von Wicklungen in Nuten elektrischer Maschinen mittels räumlicher Bildgebung und maschinellen Lernens, www.umformtechnik.net, 2018, S. 1–10
- [36] Krüger, J., Lehr, J., Schlüter, M., Bischoff, N.: Deep learning for part identification based on inherent features. *CIRP Annals - Manufacturing Technology* 68 (2019). <https://doi.org/10.1016/j.cirp.2019.04.095>
- [37] Jaensch, F., Csiszar, A., Scheifele, C., Verl, A.: Digital Twins of Manufacturing Systems as a Base for Machine Learning. In 2018 25th International Conference on Mechatronics and Machine Vision in Practice (M2VIP) (S. 1–6). IEEE
- [38] Jaensch, F., Csiszar, A., Kienzlen, A., Verl, A.: Reinforcement Learning of Material Flow Control Logic Using Hardware-in-the-Loop Simulation. In 2018 First International Conference on Artificial Intelligence for Industries (AI4I) (S. 77–80). IEEE
- [39] Kuhnle, A.; Jakubik, J.; Lanza, G.: Reinforcement learning for opportunistic maintenance optimization, *Production Engineering*, Band 1, 2018, S. 33–41
- [40] Stricker, N.; Kuhnle, A.; Sturm, R.; Friess, S.: Reinforcement learning for adaptive order dispatching in the semiconductor industry, *CIRP Annals - Manufacturing Technology*, 2018, S. 511–514
- [41] Chapelle, O., Scholkopf, B., Zien, A., Semi-supervised learning (chapelle, o. et al., eds.; 2006) [book reviews]. *IEEE Transactions on Neural Networks*, 20(3), 2009, S. 542–542
- [42] Alhoniemi, E.; Hollmén, J.; Simula, O.; Vesanto, J.: Process Monitoring and Modeling Using the Self-Organizing Map. *Integrated Computer-Aided Engineering*, 6, 1999, S. 3–14