

Program

Digitalna transformacija robotiziranih tovarnih prihodnosti

DIGITOP

Rezultat 1.2:

Metodološke osnove za zajem veščin in znanja operaterjev

Projekt/RRP	DIGITOP/RRP1.3
Vrsta dokumenta	Poročilo
Verzija dokumenta	1.0
Sodelujoči partnerji	IJS-E8, IJS-E2, ULFE-LAK
Avtorji	Aljaž Osojnik, Martin Žnidaršič, Bernard Ženko, Žiga Stržinar, Miha Glavan, Goran Andonovski
Datum priprave	31. 1. 2025

Kazalo

1	POVZETEK	3
2	IDENTIFIKACIJA PROBLEMA.....	3
3	METODOLOŠKI PRISTOPI.....	4
3.1	NA PODATKIH OSNOVANE METODOLOGIJE	5
3.1.1	<i>Napovedno modeliranje z metodami strojnega učenja</i>	<i>5</i>
3.1.2	<i>Priporočilni sistemi.....</i>	<i>6</i>
3.1.3	<i>Mehki sistemi.....</i>	<i>7</i>
3.2	PRISTOPI NA OSNOVI EKSPlicitNO PODANEGA EKSPERTNEGA ZNANJA	8
3.2.1	<i>MAUT.....</i>	<i>8</i>
3.2.2	<i>DEX.....</i>	<i>9</i>
3.2.3	<i>Hibridni pristopi</i>	<i>10</i>
3.3	KOMBINACIJA PODATKOVNIH IN EKSPERTNIH PRISTOPOV	10
4	ZAKLJUČKI	10
	BIBLIOGRAFIJA	11

1 Povzetek

Poročilo obravnava metodološke osnove za zajem veščin in znanja operaterjev v proizvodnih procesih. Zajemanje veščin operaterjev temelji na zbiranju ekspertnega znanja in merjenju tehnoloških parametrov, ki vplivajo na njihove odločitve. Cilji zajemanja veščin operaterjev so lahko podpora operaterjem pri sprejemanju odločitev, izboljšanje simulacij proizvodnih procesov ter olajšanje izobraževanja novih operaterjev. Poglavitna izziva v tem postopku sta zajem vseh relevantnih podatkov, vključno s skritimi kriteriji odločanja, in izbira ustrezne metodologije. Poročilo predstavi metodologije, ki temeljijo na podatkih, metodologije, ki izhajajo iz eksplicitno podanega ekspertnega znanja, ter hibridne pristope, ki združujejo vidike obeh skupin metodologij.

Na podatkih osnovane metodologije vključujejo napovedno modeliranje z metodami strojnega učenja, priporočilne sisteme in mehke sisteme. Strojno učenje omogoča analizo operaterjevih odločitev na podlagi zgodovinskih podatkov, priporočilni sistemi omogočajo prenos najboljših praks med operaterji in situacijami, mehki sistemi pa s pomočjo novih podatkov izpopolnjujejo pravila oblike ČE-POTEM. Metode, ki temeljijo na eksplicitno podanem ekspertnem znanju, kot sta MAUT in DEX, omogočajo strukturirano predstavitev odločitev na osnovi več-parametrskih modelov in logičnih pravil. Poročilo omeni tudi hibridne pristope, ki omogočajo celovitejšo digitalizacijo operaterjevih veščin, a zahtevajo tako merjenje podatkov, tj., tehnoloških parametrov, kot tudi eksplicitno podano ekspertno znanje, zato njihova uporaba zahteva več vloženega truda.

Kljub metodološkemu pregledu v dokumentu do časa priprave ni bilo mogoče pridobiti ustreznih podatkov za praktično implementacijo metod. Nadaljnje aktivnosti v okviru projekta DIGITOP bodo usmerjene v prilagoditev teh metodologij za konkretne primere, pri čemer bo poročilo služilo kot pregledni dokument za izbiro metodologije za zajemanje veščin operaterjev specifičnega proizvodnega procesa.

2 Identifikacija problema

Naloga zajemanja veščin operaterjev proizvodnih procesov je v splošnem sestavljena iz dveh korakov, **zbiranja ekspertnega znanja operaterja oz. meritve tehnoloških parametrov, ki na operaterjeve odločitve vplivajo, in uporaba teh informacij za izdelavo modela operaterjevih veščin**. Model, ki ga na ta način ustvarimo, naj, kar se da zvesto, opisuje odločitve, ki jih operater sprejema pri upravljanju proizvodnega procesa. Taki modeli so lahko, na primer, uporabljeni za pomoč operaterju pri upravljanju procesa, simulaciji situacij, ki se med proizvodnim procesom lahko zgodijo, ali pa izobraževanju novih operaterjev. Izdelava samega modela veščin operaterjev je odvisna od metodološkega pristopa, ki ga uporabimo, in proizvodnega procesa, ki ga modeliramo.

Metodologije za zajemanje znanja veščin operaterjev lahko v grobem razdelimo v dve skupini: tiste, ki primarno temeljijo na zbranih meritvah tehnoloških parametrov, ki jih bomo označili kot **na podatkih osnovane metodologije**; ter tiste, ki neposredno modelirajo operaterjevo eksplicitno podano ekspertno znanje in jih zato imenujemo **metodologije na osnovi ekspertnega znanja**. Nabor takih metodologij, kot tudi nekaterih redkejših **hibridnih pristopov**, ki združujejo vidike obeh skupin metodologij, je opisan spodaj.

Zajemanje veščin operaterjev proizvodnega procesa je kompleksna naloga, ki je odvisna od več faktorjev. Za uspešen zajem veščin operaterjev moramo meriti (vse) tehnološke parametre, ki na proizvodni proces vplivajo oz. na podlagi katerih se operater odloča. Če operater proizvodni proces upravlja na podlagi kriterijev, ki niso zajeti; na primer, operater proizvodni proces upravlja na podlagi viskoznosti neke snovi, ki jo oceni na podlagi

njenega izgleda, ta, morebiti ključna, informacija ni zajeta in ne more bit uporabljena. V takih primerih je treba v procesu formalizacije vpeljati nove koncepte, ki sovpadajo s kriteriji na podlagi katerih se operaterji odločajo, in njihovo znanje opredeliti s temi koncepti. To zahteva neposredno komunikacijo z operaterjem, ki pa v vseh primerih ni mogoča. Če ta proces vendarle lahko izpeljemo, je priporočena uporaba metodologij za formalizacijo znanja, ki temeljijo na ekspertnem znanju. Če to ni mogoče ali pa so merjeni (digitalizirani) vsi tehnološki parametri, na podlagi katerih operaterji sprejemajo odločitve in vplivajo na proizvodni proces, potem so primernejše na podatkih osnovane metodologije.

Za uspešen zajem vrednosti tehnoloških parametrov je pogosto potrebno združevanje vrednosti, ki se merijo na različne načine, na primer, preko fizikalnih senzorjev, ERP/MES sistemov ali digitalnih dvojčkov. Pomemben korak zajema znanja operaterjev je **opredelitev vseh virov informacij, ki jih operater uporablja za sprejemanje odločitev**, tako v smislu dosegljivosti kot kvalitete meritev. Pomemben vidik zajemanja vrednosti tehnoloških parametrov je zajemanje tudi v primerih, ko operater proizvodnega procesa ni spremenil. S tem metodam za zajemanje znanja omogočimo, da v izdelani model vključijo tudi znanje o “pravilnem” delovanju proizvodnega procesa oz. primere v katerih operaterjeva intervencija ni potrebna.

Ker sta med cilji zajemanja veščin operaterjev pomoč pri upravljanju proizvodnega procesa in pomoč pri izobraževanju in uvajanju novih operaterjev, želimo, da se znanja formalizirajo na način, ki je uporaben v teh kontekstih. Zato želimo, da formalizirano znanje oz. model sovпада z aktivnostjo operaterja. Če operater neko odločitev sprejme le na koncu proizvodnega procesa, naj tudi model odločitev predlaga, sprejme ali simulira obnašanje na isti časovni točki, tj., na koncu procesa, ne pa skozi celoten proces. Ključno je torej, da se zajame in modelira znanje človeškega operaterja, ne pa neposredno proizvodnega procesa, čeprav bi to morda bilo možno iz merjenih vrednosti tehnoloških parametrov. Na primer, operater v kontekstu neke šaržne proizvodnje ocenjuje kakovost vmesnih stanj šarže in na koncu procesa z dodajanjem dodatnih materialov doseže želeno kvaliteto. V tem primeru želimo, da je model na isti časovni točki kot operater zmožen sprejeti, predlagati ali simulirati dodajanje ustreznih materialov za doseganje želene kvalitete vmesnega proizvoda. Modeli znanja so torej primarno namenjeni delovanju v enakih ali sorodnih kontekstih kot tistih, v katerih operaterji uporabljajo znanje za upravljanje proizvodnih procesov.

3 Metodološki pristopi

Za modeliranje ekspertnega znanja je eden od ključnih elementov dobro poznavanje nalog, ki jih želimo modelirati, njihovega konteksta in njihovih lastnosti (Shaw in Woodward, 1990). V času izvajanja Aktivnosti 1.3 ti elementi pri praktičnih problemih modeliranja ekspertnega znanja v projektu še niso bili povsem znani, zato smo pripravili širši nabor metod, s katerimi ga lahko podpremo. V grobem gre za metode, ki temeljijo na empiričnih podatkih in metode, ki temeljijo na eksplicitno podanem ekspertnem znanju. Slednje so primerne za strukturirane naloge, pri katerih izvajalci lažje izrazijo svoje akcije ali miselne procese, medtem ko na podatkih temelječe metode predstavljajo rešitev v primerih, ko je znanje, ki ga želimo modelirati večinoma tacitno, torej takšno, ki ga je težko izraziti ali opisati miselne procese, ki jih vključuje.

3.1 Na podatkih osnovane metodologije

Na podatkih osnovane metodologije modeliranja predstavljajo učinkovit pristop za analizo večšin operaterjev in predvidevanja oz. napovedovanja njihovega delovanja pri upravljanju proizvodnih procesov. Te metodologije temeljijo predvsem na meritvah vrednosti tehnoloških parametrov, ki so nato obdelane s, na primer, statističnimi metodami ali metodami strojnega učenja.

3.1.1 Napovedno modeliranje z metodami strojnega učenja

V nadaljevanju opisujemo nekaj najbolj uporabnih metod strojnega učenja za napovedno modeliranje, in sicer odločitvena drevesa, ansambelske pristope in umetne nevronske mreže.

- **Odločitveno drevo** (angl. *decision tree*) je preprost model, ki se ga lahko naučimo s strojnim učenjem in vhodne primere razvršča v podmnožice na podlagi vrednosti atributov (lastnosti) teh primerov. Drevo predstavlja odločitve in njihove možne rezultate v obliki drevesa, kjer notranja vozlišča predstavljajo logične teste povezane z vrednostjo atributov, veje predstavljajo rezultate teh testov in listi (končna vozlišča) predstavljajo odločitve ali napovedane vrednosti. Interpretacija modela se začne v korenskem vozlišču, ki predstavlja celoten nabor učnih podatkov in se nadaljuje po vejah proti listom, ki predstavljajo podmnožice med seboj podobnih primerov. Odločitvena drevesa so priljubljena zaradi svoje razumljivosti, enostavnosti implementacije in zmožnosti obravnavanja kategoričnih in numeričnih spremenljivk. V primeru zajemanja večšin operaterja bi listi drevesa predstavljali različne možne odločitve operaterja, do katerih lahko pridemo, če so izpolnjeni določeni pogoji v proizvodnem procesu oz. atributi.
- **Ansambelske metode** (angl. *ensemble methods*) združujejo več preprostih modelov v en sam model, ki naj bi bil bolj točen kot posamezni modeli. V praksi so posamezni modeli največkrat odločitvena drevesa, ki pa se med seboj razlikujejo. Razlikovanje posameznih osnovnih modelov običajno dosežemo z naključnim vzorčenjem bodisi primerov ali atributov. Ansambelski modeli so tipično veliko bolj točni kot posamezni modeli, vendar niso več človeku razumljivi. Med najbolj uspešne ansambelske metode sodita metodi naključnih gozdov (angl. *random forest*) in "gradient boosting".
- **Umetna nevronska mreža** (UNN, angl. *artificial neural networks*) je kompleksen model, ki se grobo zgleduje po strukturi in funkciji bioloških nevronov. Posamezen umetni nevron je predstavljen kot vozlišče z več uteženimi vhodi, izhod nevrona pa določa aktivacijska funkcija, ki je izračunana na vsoti teh uteženih vhodov. Za aktivacijsko funkcijo tipično uporabljamo sigmoidno funkcijo, v zadnjem času pa tudi druge funkcije (npr. ReLU, GELU). Celotna UNN je sestavljena iz več plasti, vključno z vhodnimi, skritimi in izhodnimi plastmi. Vsaka plast predstavlja nelinearno transformacijo podatkov, kar omogoča modelu, da se nauči kompleksnih vzorcev in odvisnosti. Pri učenju UNN moramo določiti vrednosti uteži vhodov pri vsakem nevronu, za kar uporabljamo algoritem vzratnega razširjanja napake (angl. *backpropagation*). UNN so tipični modeli tipa "črna škatla", kar pomeni da človeku niso razumljivi.

Omenjene tri metode se razlikujejo tako po razumljivosti modelov (odločitvena drevesa so človeku razumljiva, ansambli bolj težko, UNN pa sploh ne), kot tudi po računski zahtevnosti učenja (odločitvena drevesa so računsko nezahtevna, ansambli so malo bolj zahtevni, UNN pa, odvisno od velikosti, običajno zelo zahtevni). Razumljivost modelov je še posebej pomembna, kadar formalizirano znanje operaterjev želimo uporabiti za učenje novih

operaterjev, saj možnost razlage izbranih ukrepov izboljša učni proces. Poleg tega moramo upoštevati tudi to, da UNN za učenje običajno zahtevajo bistveno več podatkov kot preostali dve metodi.

Strojno učenje se sicer za analizo in modeliranje operaterjevih veščin uporablja že dolgo časa in obstaja več študij, ki predstavljajo praktične primere uporabe na različnih industrijskih področjih (Chester et al., 1992; Bratko & Šuc, 2002; Wenskovitch et al., 2022, Kozhubaev et al., 2023; Hofmann et al., 2024),

3.1.2 Priporočilni sistemi

Priporočilni sistemi izhajajo iz prodajnega sektorja, kjer se uporabljajo, da na podlagi podobnosti kupcev in njihovih preferenc sklepamo na želje in potrebe določenega kupca. Pristop omogoča sklepanje na podlagi povratnih informacij uporabnikov, kot so ocene zadovoljstva, interesi za določene izdelke, ipd. Priporočilni sistemi med zbranimi informacijami identificirajo relacije med parametri, ki jih nato generalizirajo na podobne uporabnike in/ali produkte. S tem se ustvarijo personalizirana priporočila, ki so prilagojena preferencam in interesom uporabnikov. Končni cilj priporočilnih sistemov so sezname personaliziranih priporočil za katere se predvideva, da bodo določenemu uporabniku najbolj všeč oz. ga bodo zanimale (t.j. ocene primernosti posameznih produktov). Predlogi z najvišjimi ocenami potem sestavljajo uporabniku prilagojen seznam najbolj primernih izdelkov/storitev.

Priporočilne sisteme običajno razvrščamo v naslednje tri osnovne kategorije:

- Pri **vsebinskem filtriranju** (angl. *content-based filtering*) priporočila temeljijo na podlagi iskanja podobnih predmetov, ki jih je uporabnik že ocenil oz. si ogledal v preteklosti, pri čemer se kot mere podobnosti upoštevajo različne značilnosti in lastnosti ponujenih predmetov (npr. besedila, avtorji, oznake, kategorije, barve, slike).
- Pri **sodelovalnem filtriranju** (angl. *collaborative filtering*) so priporočeni predmeti tisti, ki so bili v preteklosti všeč ljudem s podobnim okusom in preferencami. Ti sistemi temeljijo na relacijah med uporabniki in skupaj z ocenami in preferencami podobnih uporabnikov, poskušajo odkriti predmete, ki bodo najverjetneje všeč aktualnemu uporabniku. Pri tem se predpostavlja, da bodo imeli podobne kupci podobne preference.
- **Hibridni priporočilni sistem** (angl. *hybrid recommender system*) združuje elemente različnih priporočilnih pristopov (npr. upoštevanje podobnosti izdelkov in prenos povratnih informacij podobnih uporabnikov).

V literaturi obstajajo številni raznoliki pristopi in izpeljanke za izvedbo priporočilnih sistemov. Uporaba prevladuje v prodajnem sektorju za ponujanje uporabniku najbolj relevantnih vsebin/izdelkov, njihovo uporabo pa je zaznati tudi na drugih področjih, npr. priporočilni sistemi se lahko uporabljajo v medicini za personalizirano zdravljenje (Verboven et al., 2022, Kakulapati et al., 2018), pri razvoju novih marketinških strategij (Zhou et al., 2022), ipd.

Problem zajema veččin operaterjev je mogoče formulirati analogno problemom, ki jih obravnavajo priporočilni sistemi za marketinške namene. Na primer za problem izbora najbolj primerne recepta šaržne proizvodnje glede na trenutne proizvodne razmere lahko analogno formuliramo priporočilni sistem na sledeči način:

- trenutne proizvodne razmere/stanje opišemo kot skupek lastnosti različnih kupcev,
- različne recepte/manipulativne proizvodne akcije predstavimo kot nabor izdelkov priporočilnega sistema, in
- kazalnike učinkovitosti proizvodnje (kvaliteta, produktivnost) predstavljajo povratno informacijo o primernosti (oceni) določenega produkta (v našem primeru recepta).

Z uporabo koncepta sodelovalnega filtriranja je mogoče zajeti veščine operaterjev na način, da priporočilni sistem iz zgodovinskih podatkov odločitev operaterjev identificira najboljše prakse operaterjev (npr. najboljši recepti za določene pogoje). Dobre prakse pa se nato preko priporočil lahko prenesejo na podobne proizvodne pogoje. Prednost takšnega pristopa je, da se lahko na podobne proizvodne pogoje in na manj izkušene uporabnike prenašajo dobre prakse, ki so se v preteklosti že izkazale za učinkovite. S tem se izognemo problemom ekstrapolacije naučenega znanja izven področja učenja, ki lahko poda dvomljive rezultate sploh v primerih slabo pogojenega problema (premalo raznolikih podatkov, prenaučenost modela, ipd.). Seveda pa je slabost takšnega pristopa, da ostajamo v domeni že videnih rešitev (receptov) in ne raziskujemo možnosti novih boljših rešitev. To pa je mogoče rešiti z dodatnimi naključnimi ali načrtnimi variacijami že znanih receptov in vključevanju na novo dobljenih ocen učinkovitosti (vrednosti KPI-jev). Prednost priporočilnih sistemov je tudi jasna formalizacija znanja (razložljivost določenega priporočila), saj je vedno mogoče poiskati konkretne zgodovinske primere na podlagi katerih je bilo izvedena sugestija za določeno akcijo.

Obstaja več pristopov za implementacijo sodelovalnih priporočilnih sistemov: sodelovalni filtrirni modeli ter generični modeli na podlagi značilk (v tem kontekstu so to tehnološki parametri). Eden izmed enostavnejših pristopov so sodelovalni filtrirni modeli na podlagi spomina, kjer sklepanje izvaja na podlagi ocene podobnosti med uporabniki (oz. procesnega poteka). Pri takšnem pristopu se na podlagi zgodovinskih primerov poišče primerljive procesne pogoje in iz teh rešitev izbrati tiste z najbolj ugodnim končnim izplemom. Za iskanje primerljivih procesnih pogojev se lahko uporabijo metode rojenja (angl. *swarming*) in vrednotenja bližine podatkovnih vektorjev. Pri končnem izboru najboljšega recepta pa je potrebno tudi upoštevati možnost definiranja različnih kriterijev optimalnosti, ki bodo na podlagi več primerljivih podobnih primerov iz preteklih podatkih rangirali njihovo primernost.

3.1.3 Mehki sistemi

Za uspešno formalizacijo znanja operaterjev proizvodnih procesov je ključno, da se metode za modeliranje prilagodijo kompleksnosti realnih situacij in obstoječim omejitvam pri zajemu podatkov. V tem kontekstu se mehki sistemi na podlagi podatkov, kot so samorazvijajoči-se mehki sistemi (angl. *Evolving Fuzzy Systems*, EFS), izkažejo za izjemno uporabne, saj omogočajo dinamično prilagajanje modelov novim informacijam ter združujejo formalizacijo človeškega znanja in analizo podatkov. Mehki sistemi temeljijo na principih ČE-POTEM pravil, kar

omogoča obravnavo kompleksnih sistemov na človeku razumljiv in transparenten način. Ključne prednosti teh sistemov vključujejo integracijo obstoječega znanja operaterjev, dinamično prilagajanje in sprotno učenje, kjer se procesni parametri lahko posodablajo, ter upoštevanje heterogenih podatkovnih virov (senzorjev, ERP/MES sistemov) z različno kakovostjo in stopnjo dostopnosti. EFS kot posebna nadgradnja mehkih sistemov omogočajo sprotno prilagajanje modelov na podlagi nenehnega dotoka podatkov, kar je še posebej koristno v proizvodnih procesih, kjer je treba modele redno posodabljati, da sledijo spremembam v vedenju operaterjev ali tehnoloških parametrov.

Uporaba mehkih sistemov na osnovi mehke logike je razširjena tudi pri razvoju inteligentnih vmesnikov, ki omogočajo bolj naravno, prilagodljivo in tolerantno interakcijo med človekom in strojem. Primeri teh vmesnikov vključujejo prilagodljive vmesnike (Ribeiro in Moreira, 2003), kjer mehka logika omogoča naravno jezikovno iskanje v podatkovnih bazah ter podajanje odgovorov v naravnem jeziku, na primer ocenjevanje finančnega zdravja podjetij ("Finančno zdravje je povprečno (43 %), ker je denarni tok nad povprečjem (61 %), solventnost je zelo nizka (14 %), finančna avtonomija je visoka 55 %"). Drugi primeri vključujejo vmesnike tolerantne na napake (Pornpanomchai et al., 2001), kjer mehka logika pomaga pri prepoznavanju slabo napisanih ročnih znakov in zagotavlja natančnost pri interpretaciji ročnega pisanja. Prilagodljivi vmesniki (Mäntytjärvi in Seppänen, 2003), se osredotočajo na kontekstno prilagoditev aplikacij v realnem času, kjer uporabniško okolje vključuje več hkratnih in nepopolno prepoznanih kontekstov, pri čemer mehka logika omogoča nemoteno prilagajanje brez nenadnih sprememb. Prav tako so bili razviti vmesniki za asistenco operaterjem, kjer mehka logika modelira situacijske in analitične reprezentacije za simulacijo ko-pilota, ki razmišlja in sprejema odločitve v nepopolnih in negotovih razmerah. Poleg tega vmesniki z uporabo inteligentnih agentov (Agah in Tanie, 2000), uporabljajo mehke agente za razumevanje uporabnikovih namenov, kar omogoča prilagodljivo delovanje sistema z zmanjšanim vložkom uporabnika. Ti primeri poudarjajo široko uporabnost mehkih sistemov pri ustvarjanju inteligentnih vmesnikov, ki podpirajo prilagodljivost, zanesljivost in uporabniško izkušnjo v različnih kontekstih.


3.2 Pristopi na osnovi eksplicitno podanega ekspertnega znanja

Ti pristopi temeljijo na znanju ekspertov/operaterjev in so običajno uporabljeni za zasnovo ekspertnih sistemov ali sistemov za modeliranje odločitev. Za modeliranje eksplicitnega ekspertnega znanja, moramo le-tega zajeti in shraniti v ustrezni predstavitvi, oziroma formalizmu. Običajno se za zajem uporabljajo metode kot so: intervju, zbiranje odgovorov na specifična vprašanja, zapisovanje razlag in beleženje poteka reševanja naloge (National Research Council, 1992). Za zapis ekspertnega znanja pa je na voljo množica formalizmov, med katerimi običajno izberemo takega, ki najbolj ustreza predvideni uporabi, ki je lahko namenjena človeku, računalniškemu sistemu sklepanja ali obema. V nadaljevanju bomo predstavili formalizme te vrste, ki smo jih identificirali kot primerne za uporabo v nalogah, ki jih pričakujemo v projektu DIGITOP. Posledično so to formalizmi, ki so primerni predvsem za predstavitev proceduralnega in deklarativnega znanja, torej o dejstvih in procesih.

3.2.1 MAUT

Metode več-kriterijskega modeliranja in analize odločitvenih problemov so namenjene reševanju kompleksnih odločitvenih problemov. Zelo razširjena in praktično uporabna podmnožica teh metod so več-parametrski

hierarhični modeli. Pri teh probleme razgradimo na podprobleme, podatke o problemih pa predstavimo z atributi, katerih ocene hierarhično združujemo, dokler ne dobimo ene ali več ocen na nivoju abstrakcije, ki nas zanima. Atributom priredimo oceno s funkcijo koristnosti ali vrednosti - preslikavo, ki atributu določa vrednost na podlagi vrednosti neposredno podrednih atributov. Tako so atributi povezani v hierarhično strukturo, ki ji pravimo hierarhija modela. Pri tem včasih ločeno poimenujemo attribute kot osnovne in sestavljene: osnovni atributi so tisti, katerih vrednosti poda uporabnik ali izhajajo iz podatkov in predstavljajo vhode modela. Sestavljeni atributi pa so tisti, katerih vrednosti izračunamo s funkcijami koristnosti iz vrednosti osnovnih ali sestavljenih atributov. Posplošen primer hierarhije je prikazan na Sliki 1, kjer so atributi X_{121} , X_{122} , X_{131} in X_{132} osnovni atributi, F_{12} , F_{13} in F_1 so funkcije koristnosti, X_{11} , X_{13} in X_1 so sestavljeni atributi.



Slika 1 Primer hierarhije sestavljene z MAUT metodologijo.

V večini metodologij več-parametrskega modeliranja so vrednosti atributov numerične. Tako je tudi v zelo splošni metodologiji MAUT (Keeney in Raiffa, 1993), ki jo smatramo za eno od najprimernejših za formaliziranje postopkov v problemih projekta DIGITOP. Osnovni atributi so v tem primeru torej numerični, in predstavljeni v različnih enotah. Slednje onemogoča njihovo primerjavo in souporabo zato jih običajno s funkcijo koristnosti skaliramo na poenoten interval, najpogosteje na interval $[0,1]$. Najpogosteje za funkcijo koristnosti v uporabljamo preprost linearen ali odsekoma linearen model, za združevanje več atributov pa aditivni agregacijski model, ki sešteje skalirane vrednosti atributov, utežene s pripadajočimi utežmi.

3.2.2 DEX

Formalizem DEX je, podobno kot MAUT, hierarhičen več-parametrski pristop ki pa za razliko od MAUT in ostalih klasičnih pristopov predvideva kvalitativne attribute. Kvalitativni pristop se je v praksi zelo izkazal, predvsem v kompleksnih odločitvenih problemih, ki so vsebovali veliko elementov, ki jih je težko formalizirati (Bohanec et al., 2013). Predvidevamo, da bodo problemi, obravnavani v DIGITOP večinoma taki, da jih bo mogoče natančno formalizirati, zato metodologija DEX morda ne bo potrebna. A ker se v praksi pogosto izkaže, da je del ekspertnega znanja kvalitativen, bomo imeli pripravljeno tudi to metodologijo.

Funkcije koristnosti v DEX-u so predstavljene kot če-potem pravila. Spremenljivke, ki jih običajno uporabljamo v teh modelih so kategorične z majhnim številom (2 do 5, običajno ne več kot 10) ordinalnih ali nominalnih vrednosti. Podobno kot pri metodologiji MAUT in model definiran s hierarhijo, funkcijami koristnosti in z zalogami vrednosti osnovnih in sestavljenih atributov.

3.2.3 Hibridni pristopi

V praksi so pogoste tudi situacije, ko je del relevantnih atributov za modeliranje numerične, del pa kvalitativne narave. V tem primeru lahko uporabimo hibridne modele. Za hibridne modele v splošnem sicer ni na voljo orodij in jih za take primere običajno posebej razvijamo, ampak določene razširitve metodologije DEX omogočajo nekatere od hibridnih načinov modeliranja, na primer numerične ali verjetnostno porazdeljene vhodne vrednosti ter uporabo verjetnostnih in mehkih funkcij koristnosti. Če bo v projektu DIGITOP prišlo do potrebe po hibridnem, delno numeričnem, delno kvalitativnem modeliranju, bomo uporabili primerno razširitev metode DEX ali skušali razviti razširitev, ki bi ustrezala našim potrebam.

3.3 Kombinacija podatkovnih in ekspertnih pristopov

Pri modeliranju ekspertnega znanja lahko tudi kombiniramo pristope, ki temeljijo na podatkih s pristopi, ki so osnovani na eksplicitno podanem znanju. V splošnem bi na ta način lahko v obeh smereh uporabili izhodne vrednosti modela ene vrste kot vhodne podatke v model druge vrste. V praksi pa je precej bolj običajno, da so eksplicitni modeli na višjem nivoju abstrakcije, podatkovni modeli pa so bližje meritvam in nizkonivojskim konceptom, zato se običajno strojno naučeni modeli uporabijo za pridobivanje vhodnih podatkov za ekspertno-podane modele in ne obratno.

Metodologijo in programsko opremo za tovrstni način modeliranja smo v preteklosti razvili za potrebe modeliranja ekspertnih odločitev na področju rehabilitacije v okviru mednarodnega raziskovalnega projekta SAAM (Žnidaršič et al., 2019). Za potrebe projekta DIGITOP smo preverili aplikativnost obstoječe implementacije in ključne elemente morebitnih prilagoditev. V primeru potrebe po uporabi te metodologije bo temu sledila priprava ločenega repozitorija za programsko kodo in razvoj potrebnih nadgradenj.

4 Zaključki

To poročilo služi kot pregled metodologij, ki se lahko uporabijo za zajemanje, formalizacijo in digitalizacijo veščin operaterjev proizvodnih procesov. Predstavimo nabor metodologij, ki so primerne v različnih kontekstih, kjer jih v glavni meri ločimo glede na način pridobivanja znanja. Tako ločimo metodologije, ki model operaterjevega znanja zgradijo na podlagi meritev tehnoloških parametrov, in metodologije, ki za izdelavo modela uporabijo neposredno podano ekspertno znanje operaterjev. Obravnavamo tudi hibridne metodologije, ki uporabljajo obe vrsti informacij.

Žal do časa priprave tega poročila ni bilo mogoče pridobiti dejanskih podatkov, na katerih bi lahko demonstrirali predstavljene metodologije. Kljub prizadevanjem partnerjev, so se prvi obravnavani procesi izkazali kot

neprimerni za nalogo zajemanja, formalizacije in digitalizacije veščin operaterjev. Končni proizvodni proces, ki bo obravnavan v RRP 4 in 8, je bil uspešno identificiran v naslednji iteraciji, a žal zaradi projektne strukture ni bilo časa za izvedbo predstavljenih metodologij v tem poročilu. Ne glede na to, projekt zaradi tega ni v zamudi.

Bibliografija

- Agah, A., & Tanie, K. (2000). Intelligent graphical user interface design utilizing multiple fuzzy agents. *Interacting with Computers*, 12, 529–542.
- Bohanec, M., Žnidaršič, M., Rajkovič, V., Bratko, I., & Zupan, B. (2013). DEX methodology: three decades of qualitative multi-attribute modeling. *Informatica*, 37(1).
- Bratko, I., & Šuc, D. (2002). Using machine learning to understand operator's skill. V T. Hendtlass & M. Ali (ur.), *Developments in Applied Artificial Intelligence. IEA/AIE 2002. Lecture Notes in Computer Science* (vol. 2358). Springer.
- Chester, G. G., Kuespert, D. R., & McAvoy, T. J. (1992). Modeling human operators using neural networks. *ISA Transactions*, 31(3), 81–90.
- Hofmann, J., Becker, M., & Kubik, C. et al. (2024). Machine learning-based operator assistance in roll forming. *Production Engineering Research and Development*.
- Kakulapati, V., Balaram, V. S., & Reddy, S. (2018). Collaborative filtering recommendation systems for personalized medicines. *International Journal of Engineering Research in Computer Science and Engineering*, 5, 220–224.
- Keeney, R. L., & Raiffa, H. (1993). *Decisions with multiple objectives: Preferences and value tradeoffs*. Cambridge University Press.
- Kolski, C., & Malvache, N. (2006). Intelligent interfaces based on fuzzy logic: Example with a human-error-tolerant interface approach. V *Studies in Fuzziness and Soft Computing* (vol. 201, str. 339–366).
- Kozhubaev, Y., Ovchinnikova, E., Krotova, S., Murashov, Y., & Nushtaev, N. (2023). Implementation of a neural network in overhead crane control. V *E3S Web of Conferences* (vol. 389, str. 01035). EDP Sciences.
- Mäntyjärvi, J., & Seppänen, T. (2003). Adapting applications in handheld devices using fuzzy context information. *Interacting with Computers*, 15, 521–538.
- National Research Council. (1992). *In the mind's eye: Enhancing human performance (4 Modeling Expertise)*.
- Pornpanomchai, C., Batanov, D. N., & Dimmitt, N. (2001). Recognizing Thai handwritten characters and words for human-computer interaction. *International Journal of Human-Computer Studies*, 55, 259–279.
- Ribeiro, R. A., & Moreira, A. M. (2003). Fuzzy query interface for a business database. *International Journal of Human-Computer Studies*, 58, 363–391.
- Shaw, M. L., & Woodward, J. B. (1990). Modeling expert knowledge. *Knowledge Acquisition*, 2(3), 179–206.

Verboven, L., Calders, T., Callens, S., Black, J., Maartens, G., Dooley, K. E., Potgieter, S., Warren, R. M., Laukens, K., & Van Rie, A. (2022). A treatment recommender clinical decision support system for personalized medicine: Method development and proof-of-concept for drug-resistant tuberculosis. *Medical Informatics and Decision Making*, 22, 56.

Wenskovitch, J., Jefferson, B., Anderson, A., Baweja, J., Ciesielski, D., & Fallon, C. (2022). A methodology for evaluating operator usage of machine learning recommendations for power grid contingency analysis. *Frontiers in Big Data*, 5, 897295.

Zhou, C., Leng, M., Liu, Z., Cui, X., & Yu, J. (2022). The impact of recommender systems and pricing strategies on brand competition and consumer search. *Electronic Commerce Research and Applications*, 53.

Žnidaršič, M., Ženko, B., Osojnik, A., Bohanec, M., Panov, P., Burger, H., Matjačić, Z., & Debeljak, M. (2019). Multi-criteria modelling approach for ambient assisted coaching of senior adults. V *Proceedings of the 11th International Joint Conference on Knowledge Discovery, Knowledge Engineering and Knowledge Management – Volume 2: KEOD* (str. 87–93). SciTePress.