Evolúcia rozvrhovania operácií v digitálnej ére: Od optimalizácie k inteligentným systémom

From Optimization to Intelligence: The Evolution of Operations Scheduling in the Digital Age

Martin Mišút[1]

Abstrakt

Rozvrhovanie operácií prechádza v digitálnej ére zásadnou transformáciou z izolovaného optimalizačného problému na komplexný, dátovo riadený proces rozhodovania. Tento článok poskytuje analytický prehľad vývoja rozvrhovania v kontexte Industry 4.0, so zameraním na zmeny v povahe problému, metodologické prístupy a technologické predpoklady jeho riešenia. Pozornosť je venovaná klasifikácii rozvrhovacích problémov a komparácii hlavných prístupov, vrátane exaktných metód, heuristík, metaheuristík a prístupov založených na umelej inteligencii. Článok zároveň analyzuje úlohu kľúčových technológií, ako sú internet vecí, kyber-fyzické systémy, digitálne dvojčatá a cloudové infraštruktúry, ktoré umožňujú realizáciu dynamického a adaptívneho rozvrhovania.

Na základe kritickej analýzy sú identifikované hlavné obmedzenia existujúcich prístupov, najmä rozdiel medzi teoretickými modelmi a ich praktickou implementáciou. Zároveň sú diskutované aktuálne trendy, vrátane prechodu k dátovo riadeným a hybridným prístupom, decentralizovaného rozhodovania a integrácie environmentálnych a ľudských faktorov.

Výsledky poukazujú na to, že budúci vývoj rozvrhovania smeruje k inteligentným, autonómnym a adaptívnym systémom schopným reagovať na dynamické podmienky v reálnom čase.

Kľúčové slová

Rozvrhovanie, Industry 4.0, umelá inteligencia, digitálne dvojča, dynamické rozvrhovanie, hybridné prístupy k rozvrhovaniu

Abstract

Operations scheduling is undergoing a fundamental transformation in the digital age, evolving from an isolated optimisation problem into a complex, data-driven decision-making process. This paper provides an analytical review of scheduling in the context of Industry 4.0, focusing on changes in problem characteristics, methodological approaches, and enabling technologies. The paper examines the classification of scheduling problems and compares major solution approaches, including exact methods, heuristics, metaheuristics, and artificial intelligence-based techniques. It further analyses the role of key technologies such as the Internet of Things, cyber-physical systems, digital twins, and cloud infrastructures, which enable dynamic and adaptive scheduling.

Based on a critical assessment, the main limitations of current approaches are identified, particularly the gap between theoretical models and real-world implementation. The paper also discusses emerging trends, including the shift toward data-driven and hybrid methods, decentralised decision-making, and the integration of sustainability and human-centric considerations.

[1] Ekonomická univerzita v Bratislave, Fakulta hospodárskej informatiky, Katedra aplikovanej informatiky, Dolnozemská cesta 1, 852 35 Bratislava, martin.misut@euba.sk.

The findings indicate that future scheduling systems will evolve toward intelligent, autonomous, and adaptive solutions capable of responding to dynamic conditions in real time.

Key words
operations scheduling; Industry 4.0; digital twin; artificial intelligence; dynamic scheduling; hybrid scheduling methods

JEL classification
M110, C630

1 Úvod

Výrobný sektor prechádza výraznou transformáciou v dôsledku rýchleho rastu rozsahu výroby a zosilnenej globálnej konkurencie. Tradičné výrobné prístupy, založené prevažne na manuálnej práci, už nedokážu uspokojiť komplexné a dynamické požiadavky moderných priemyselných systémov. Na riešenie týchto výziev sa čoraz viac využívajú pokročilé technológie, ako sú internet vecí (IoT), umelá inteligencia (AI) a automatizované systémy, ktoré umožňujú modernizáciu výrobných procesov, zvyšovanie efektívnosti a dosahovanie vyššej flexibility (Ouahabi et al., 2024).

Tieto technologické inovácie transformujú výrobné procesy zavedením vyššej úrovne automatizácie a inteligencie, pričom optimalizujú využitie zdrojov, znižujú prevádzkové náklady a výrazne zvyšujú kvalitu a efektívnosť produkcie (Zhang et al., 2025).

Koncept Industry 4.0 predstavuje jeden z najvýznamnejších trendov v oblasti výroby a zásadne mení prístup k rozvrhovaniu výroby. Zavedenie inteligentných a prepojených systémov zvyšuje flexibilitu, efektívnosť a schopnosť reagovať na zmeny v reálnom čase. Kľúčovým prvkom tejto transformácie je integrácia kyber-fyzických systémov, internetu vecí, umelej inteligencie a dátovej analytiky, ktoré umožňujú spracovanie veľkého množstva dát v reálnom čase a podporujú optimalizované rozhodovanie (Mourtzis, 2022).

Tieto technológie umožňujú prechod od reaktívneho k prediktívnemu rozvrhovaniu, pri ktorom je možné predvídať a eliminovať potenciálne poruchy ešte pred ich vznikom. Zároveň však zvyšujú komplexnosť rozvrhovacích úloh, čo si vyžaduje využitie pokročilých metaheuristických algoritmov, napríklad evolučných a metód kolektívnej inteligencie (swarm intelligence), na riešenie viac-kriteriálnych optimalizačných problémov (Zhang et al., 2025).

Moderné výrobné systémy, ako napríklad inteligentné továrne využívajúce autonómne roboty, si vyžadujú hybridné rozvrhovacie modely schopné zohľadniť rôzne schopnosti strojov, obmedzenia zásobníkov a blokovacie podmienky (Shakeri et al., 2025). Nástroje založené na umelej inteligencii, ako sú digitálne dvojčatá (Digital Twin, DT) a algoritmy strojového učenia, umožňujú dynamickú simuláciu a optimalizáciu procesov v reálnom čase.

V dôsledku týchto zmien sa rozvrhovanie transformuje zo statickej a izolovanej funkcie na kľúčový strategický nástroj podporujúci konkurencieschopnosť v ére inteligentnej výroby. Tento článok analyzuje uvedené trendy s cieľom poskytnúť komplexný prehľad aktuálneho stavu poznania.

Hoci problematika rozvrhovania je predmetom výskumu už niekoľko desaťročí, prechod k prostrediam Industry 4.0 priniesol nové výzvy, ktoré zatiaľ nie sú v literatúre systematicky spracované. Existujúci výskum je často fragmentovaný naprieč rôznymi oblasťami, ako sú optimalizačné metódy, umelá inteligencia a kyber-fyzické systémy (CPS), pričom chýba ich integrácia do jednotného analytického rámca.

Napriek množstvu štúdií zameraných na konkrétne typy rozvrhovacích problémov (napr. job shop, flow shop, flexible job shop) absentuje systematické porovnanie ich výkonnosti v

dynamických, dátovo riadených a vysoko prepojených prostrediach. Najmä vplyv dostupnosti dát v reálnom čase, neistoty systému a viac-kriteriálnej optimalizácie na rozvrhovacie stratégie nie je dostatočne preskúmaný.

Ďalším problémom je rastúca medzera medzi teoretickými modelmi a ich praktickou implementáciou. Mnohé prístupy vychádzajú zo zjednodušených predpokladov, ktoré nezodpovedajú komplexnosti moderných výrobných systémov charakterizovaných vysokou variabilitou, decentralizovaným rozhodovaním a neustálymi poruchami.

Preto existuje potreba komplexného prehľadového článku, ktorý nielen sumarizuje existujúce prístupy, ale ich aj kriticky analyzuje z hľadiska aplikovateľnosti, obmedzení a vývoja v kontexte digitálnej transformácie a identifikuje nové výskumné smery.

2 Súčasný stav

2.1 Definícia problému

Rozvrhovacie problémy predstavujú základnú kategóriu v operačnom výskume (Allahverdi et al., 2008) a nachádzajú široké uplatnenie v rôznych praktických oblastiach. Ich podstatou je alokácia obmedzených zdrojov na viacero úloh za daných obmedzení s cieľom optimalizovať jednu alebo viacero výkonnostných metrík (Priore et al., 2001).

Proces rozvrhovania zahŕňa priraďovanie úloh k zdrojom a určovanie poradia úloh na jednotlivých zdrojoch, čím sa definujú ich začiatky a konce. Efektívne rozvrhovanie je kľúčové pre dosiahnutie cieľov, ako sú energetická efektívnosť, minimalizácia nákladov, znižovanie emisií a optimalizácia využitia zdrojov (Zhang et al., 2024).

Rozvrhovací problém je možné definovať ako optimalizačný problém, ktorého cieľom je alokovať zdroje na úlohy v čase tak, aby boli splnené dané obmedzenia a optimalizované vybrané kritériá. Ide o základný problém v oblastiach ako výroba, logistika, projektové riadenie či informatika (Serrano-Ruiz et al., 2024).

2.2 Klasifikácia problémov rozvrhovania

Rozvrhovacie problémy možno klasifikovať podľa rôznych kritérií, pričom medzi najvýznamnejšie patrí typ výrobného systému, počet zdrojov a štruktúra technologických postupov. Medzi základné kategórie patria problémy s jedným strojom, paralelnými strojmi, flow shop, job shop a flexible job shop (Ruiz & Vázquez-Rodríguez, 2010).

Problémy s jedným strojom predstavujú najjednoduchší typ rozvrhovania, pri ktorom sa všetky úlohy spracovávajú na jednom zariadení. Napriek svojej jednoduchosti majú význam v teoretických štúdiách aj v praktických aplikáciách, ako je plánovanie úloh na serveroch alebo v jednoduchých výrobných procesoch.

Pri problémoch s paralelnými strojmi je k dispozícii viacero zariadení schopných vykonávať rovnaké operácie. Tieto problémy sa ďalej delia na identické, uniformné a neidentické stroje v závislosti od ich výkonových charakteristík. Cieľom je efektívne rozdelenie úloh medzi stroje s cieľom minimalizovať celkový čas spracovania alebo oneskorenia.

Flow shop problémy sú charakterizované tým, že všetky úlohy prechádzajú rovnakou postupnosťou operácií. Tento typ rozvrhovania je typický pre sériovú výrobu, napríklad v automobilovom priemysle. Optimalizácia poradia úloh má významný vplyv na celkový výkon systému.

Job shop problémy umožňujú, aby každá úloha mala vlastnú technologickú postupnosť operácií. Ide o flexibilnejší, ale zároveň výrazne zložitejší typ problému, ktorý je typický pre kusovú výrobu. Tieto problémy patria medzi NP-ťažké, čo znamená, že ich riešenie je výpočtovo náročné.

Flexible job shop predstavuje rozšírenie job shop problému, pri ktorom je možné vykonávať operácie na viacerých alternatívnych strojoch. Tento typ je obzvlášť relevantný pre moderné výrobné systémy, kde existuje vysoká miera flexibility a redundancie zdrojov (Lei et al., 2024).

Okrem uvedených kategórií existujú aj ďalšie typy rozvrhovacích problémov, ako sú hybridné výrobné systémy, projektové rozvrhovanie, rozvrhovanie v reálnom čase a viac-kriteriálne rozvrhovanie, ktoré reflektujú komplexnosť moderných aplikácií.

2.3 Prečo je potrebné zlepšiť tradičné metódy rozvrhovania v súčasných podmienkach

V rýchlo sa meniacom prostredí moderného priemyslu sa tradičné metódy rozvrhovania čoraz viac ukazujú ako nedostatočné (Marzia, AlejandroVital, & Azab, 2023). Existuje niekoľko faktorov, ktoré poukazujú na potrebu pokročilejších rozvrhovacích riešení.

Jedným z hlavných faktorov je rastúca komplexnosť operácií, keďže moderné výrobné prostredia sú charakterizované vysokou variabilitou sortimentu a nízkymi objemami výroby (high-mix, low-volume), čo si vyžaduje časté úpravy rozvrhov (Pei et al., 2022). Tradičné nástroje majú problémy s adaptáciou na túto variabilitu, čo často vedie k vzniku úzkych miest a oneskoreniam (Dios & Framinan, 2016). Konvenčné rozvrhovacie systémy navyše často postrádajú flexibilitu potrebnú na dynamické prispôsobovanie sa zmenám a obmedzeniam, čo vedie k neefektívnosti a časovým sklzom.

Manuálne metódy rozvrhovania sú náchylné na chyby a neefektívnosti, najmä pri spracovaní veľkého objemu dát. To môže viesť k nedorozumeniam, duplicitnému plánovaniu a konfliktom v rozvrhu (Rannertshauser, Kessler, & Arlinghaus, 2022).

Nástup Industry 4.0 a inteligentnej výroby zároveň vyžaduje rozvrhovacie systémy schopné integrácie s IoT zariadeniami, umelou inteligenciou a analytikou dát v reálnom čase. Tradičné prístupy túto schopnosť nemajú, čo obmedzuje ich efektívnosť (Salatiello, Guizzi, Marchesano, & Santillo, 2022).

Rigidné rozvrhovanie môže mať negatívny vplyv aj na spokojnosť zamestnancov a nemusí byť v súlade s legislatívnymi požiadavkami na pracovný čas a podmienky. Moderné rozvrhovacie riešenia poskytujú vyššiu mieru flexibility, čím prispievajú k vyššej spokojnosti zamestnancov a lepšiemu dodržiavaniu regulácií (Fu et al., 2021).

Na záver možno konštatovať, že obmedzenia tradičných metód rozvrhovania pri riešení komplexných a dynamických podmienok moderných systémov jednoznačne poukazujú na potrebu pokročilejších, flexibilnejších a integrovaných rozvrhovacích prístupov.

3 Rozvrhovanie v digitálnej ére

Problém rozvrhovania v digitálnej ére prešiel zásadnou transformáciou, keď sa posunul od statickej, deterministickej optimalizácie k dynamickému a dátovo riadenému rozhodovaniu. Moderné výrobné a servisné systémy sú charakterizované vysokou variabilitou, častými poruchami a dostupnosťou dát v reálnom čase (Mantravadi et al., 2023; Marzia et al., 2023).

Jednou z hlavných charakteristík súčasných rozvrhovacích problémov je ich dynamický charakter. Nové úlohy môžu prichádzať nepredvídateľne, dochádza k poruchám zariadení a parametre systému sa môžu meniť počas vykonávania. Rozvrhovanie sa tak mení z jednorazového optimalizačného problému na kontinuálny proces rozhodovania vyžadujúci priebežnú aktualizáciu (Serrano-Ruiz et al., 2021; Lei et al., 2024).

Významnú úlohu zohráva viac-kriteriálna optimalizácia. Moderné rozvrhovanie musí zohľadňovať viacero cieľov, ako sú minimalizácia makespanu, znižovanie energetickej spotreby, dodržiavanie termínov a maximalizácia využitia zdrojov (Pei et al., 2022; Hu et al., 2024). Tieto požiadavky sú ďalej komplikované environmentálnymi a sociálnymi aspektmi (Rannertshauser et al., 2022).

Dostupnosť dát v reálnom čase prináša nové možnosti, ale zároveň zvyšuje komplexnosť problému. Rozhodovanie musí prebiehať rýchlo a na základe veľkého množstva heterogénnych dát, čo kladie vysoké nároky na výpočtové a analytické schopnosti systémov (K. Lei et al., 2024).

V dôsledku týchto faktorov sa rozvrhovanie transformuje na komplexnú, stochastickú a viackriteriálnu optimalizačnú úlohu, ktorá vyžaduje adaptívne, hybridné a inteligentné prístupy schopné reagovať v reálnom čase (Neumann et al., 2022; Ma et al., 2024).

3.1 Industry 4.0 a rozvrhovanie

Zatiaľ čo predchádzajúca sekcia sa zameriavala na samotnú povahu rozvrhovacieho problému, táto časť analyzuje technologické rámce, ktoré umožňujú jeho efektívne riešenie.

Industry 4.0 predstavuje technologický základ pre riešenie rastúcej komplexnosti moderných rozvrhovacích problémov a zdôrazňuje integráciu digitálnych technológií do jednotného systému (Bakon et al., 2022; Mourtzis, 2022).

Kľúčovým prvkom je prepojenie fyzických a digitálnych systémov prostredníctvom kyber-fyzických architektúr. Stroje, senzory a výrobné zdroje sú prepojené prostredníctvom IoT, čo umožňuje kontinuálne monitorovanie a výmenu dát v reálnom čase (Romero-Silva & Hernández-López, 2020). Vďaka tomu môžu rozvrhovacie systémy pracovať s aktuálnym stavom systému namiesto statických predpokladov.

Rozvrhovanie sa stáva integrálnou súčasťou širšieho digitálneho ekosystému zahŕňajúceho systémy ERP, MES a SCM, ktoré zabezpečujú prepojenie operatívneho riadenia so strategickým plánovaním (Mantravadi et al., 2023). Systémy MES zohrávajú významnú úlohu pri dynamickej aktualizácii rozvrhov na základe aktuálnych dát z výroby (Morgan et al., 2021; Mehdiyev et al., 2024).

Dôležitým aspektom je aj využitie distribuovaných výpočtových infraštruktúr. Cloud computing umožňuje centralizovanú optimalizáciu na úrovni podniku, zatiaľ čo edge computing podporuje decentralizované rozhodovanie priamo na úrovni výrobných zariadení (Pinto et al., 2024). Táto kombinácia umožňuje dosiahnuť rovnováhu medzi globálnou optimalizáciou a lokálnou flexibilitou.

Pokročilé technológie, ako digitálne dvojčatá a umelá inteligencia, poskytujú nové možnosti pre rozvrhovanie. Digitálne dvojčatá umožňujú simuláciu a testovanie rôznych scenárov (Ouahabi et al., 2024), zatiaľ čo metódy umelej inteligencie podporujú adaptívne a prediktívne rozhodovanie (Serrano-Ruiz et al., 2022; Zhang et al., 2024).

Industry 4.0 tak transformuje rozvrhovanie z izolovaného optimalizačného problému na kľúčový prvok inteligentného, prepojeného a autonómneho výrobného systému (Grassi et al., 2020).

3.2 Kľúčové technológie formujúce moderné rozvrhovanie

Moderné rozvrhovanie je čoraz viac determinované integráciou pokročilých digitálnych technológií, ktoré zásadne menia spôsob plánovania, koordinácie a optimalizácie procesov. Kým tradičné rozvrhovacie systémy boli založené prevažne na statických pravidlách a deterministických modeloch, súčasné prístupy využívajú adaptívne, dátovo riadené a inteligentné mechanizmy schopné reagovať na dynamické zmeny prostredia v reálnom čase (Mourtzis, 2022; Mantravadi et al., 2023).

Jednou z najvýznamnejších technológií je umelá inteligencia a strojové učenie, ktoré umožňujú transformáciu rozvrhovania z reaktívneho procesu na prediktívne a odporúčacie rozhodovanie. Metódy strojového učenia dokážu identifikovať vzory správania výrobných systémov, predikovať budúci vývoj a optimalizovať rozhodovanie na základe historických aj aktuálnych dát (Serrano-Ruiz et al., 2024; Zhang et al., 2024). Významný potenciál majú najmä

prístupy založené na hlbokom posilňovanom učení, ktoré umožňujú adaptívne riadenie v dynamických prostrediach pružných výrobných systémov (flexible job shop systems) (Guo et al., 2024; Wan et al., 2024). Napriek vysokému potenciálu však praktické nasadenie AI naráža na problémy interpretovateľnosti modelov, kvality dát a výpočtovej náročnosti.

Internet vecí predstavuje technologický základ pre zber a prenos dát v reálnom čase. Prostredníctvom senzorov, RFID technológií a inteligentných zariadení umožňuje kontinuálne monitorovanie stavu strojov, zásob, materiálových tokov a výrobných operácií (Romero-Silva & Hernández-López, 2020). Vďaka tomu sa rozvrhovacie systémy dokážu adaptovať na aktuálny stav systému namiesto využívania statických predpokladov. IoT zároveň podporuje implementáciu prediktívnej údržby a dynamického prideľovania zdrojov. Integrácia IoT však prináša nové výzvy v oblasti spoľahlivosti dát, latencie a kybernetickej bezpečnosti (Salatiello et al., 2022). V prostrediach s nestabilnými dátami môže IoT paradoxne znižovať robustnosť rozhodovania v dôsledku nekonzistentných alebo oneskorených dát.

Kľúčovým prvkom inteligentnej výroby sú kyber-fyzické systémy (CPS), ktoré prepájajú fyzické výrobné zariadenia s digitálnymi riadiacimi mechanizmami. CPS umožňujú decentralizované a autonómne rozhodovanie prostredníctvom kontinuálnej výmeny dát medzi fyzickou a digitálnou vrstvou systému (Seeger, Yahouni, & Alpan, 2022; Bakon et al., 2022; Mourtzis, 2022). V kontexte rozvrhovania umožňujú rýchlu reakciu na lokálne zmeny, poruchy a variabilitu výroby. Zároveň však vzniká problém koordinácie medzi jednotlivými autonómnymi rozhodovacími jednotkami, čo môže viesť ku konfliktom medzi lokálnou a globálnou optimalizáciou.

Významnú úlohu zohrávajú digitálne dvojčatá, ktoré umožňujú vytváranie virtuálnych modelov výrobných systémov a simuláciu rôznych rozvrhovacích scenárov v reálnom čase (Ouahabi et al., 2024). Digitálne dvojča umožňuje testovanie rozhodnutí pred ich implementáciou, čím znižuje riziko neefektívnych zásahov a podporuje robustnosť systému. V spojení s dátovou analytikou a AI sa digitálne dvojčatá stávajú významným nástrojom pre prediktívne a adaptívne rozvrhovanie. Ich efektívnosť je však podmienená presnosťou modelovania a schopnosťou synchronizácie s fyzickým systémom, čo môže byť v praxi náročné.

Cloud computing a edge computing vytvárajú infraštruktúrny základ moderných rozvrhovacích systémov. Cloud computing umožňuje centralizované spracovanie veľkých objemov dát a realizáciu komplexných optimalizačných algoritmov v distribuovanom prostredí (Pinto et al., 2024). Edge computing naopak podporuje rýchle lokálne rozhodovanie priamo na úrovni výrobných zariadení, čím minimalizuje latenciu a zvyšuje odozvu systému. Kombinácia týchto prístupov umožňuje vytvárať hybridné architektúry podporujúce globálnu optimalizáciu aj lokálnu flexibilitu.

Technológia blockchain nachádza uplatnenie najmä v distribuovaných a kolaboratívnych rozvrhovacích systémoch, kde je potrebné zabezpečiť transparentnosť, dôveryhodnosť a sledovateľnosť dát medzi viacerými účastníkmi procesu (Lassoued & Schwung, 2024). Význam blockchainu spočíva predovšetkým v zabezpečení integrity dát a koordinácie medzi organizáciami, nie však v samotnej optimalizácii rozvrhovania.

Robotická automatizácia procesov (RPA) zvyšuje efektívnosť administratívnych a opakujúcich sa úloh súvisiacich s rozvrhovaním. Automatizáciou rutinných operácií umožňuje zrýchlenie aktualizácie rozvrhov a integráciu heterogénnych informačných systémov (Fu et al., 2021). Hoci RPA neprináša nové optimalizačné mechanizmy, významne podporuje automatizáciu a škálovateľnosť rozvrhovacích procesov.

Dôležitú úlohu zohráva aj analýza veľkých dát (Big Data analytics), ktorá umožňuje spracovanie rozsiahlych objemov štruktúrovaných aj neštruktúrovaných dát generovaných modernými výrobnými systémami. Pokročilé analytické metódy podporujú predikciu dopytu, identifikáciu skrytých vzorov správania systému a optimalizáciu využitia zdrojov (Yin et al.,

2022; Peng et al., 2024). Rozvrhovanie sa tak transformuje z administratívnej činnosti na strategickú, dátovo orientovanú funkciu podporujúcu kontinuálne zlepšovanie procesov.

Celkovo možno konštatovať, že jednotlivé technológie prinášajú komplementárne výhody, pričom ich skutočný prínos sa prejavuje až pri ich integrácii. Budúcnosť moderného rozvrhovania preto smeruje k hybridným architektúram prepájajúcim umelú inteligenciu, simuláciu, IoT infraštruktúru a decentralizované riadenie do jednotného inteligentného ekosystému.

4 Diskusia

4.1 Porovnanie prístupov k rozvrhovaniu

Prístupy k riešeniu rozvrhovacích problémov možno rozdeliť do štyroch hlavných kategórií: exaktné metódy, heuristiky, metaheuristiky a prístupy založené na umelej inteligencii (AI-based approaches).

Exaktné metódy, ako lineárne programovanie alebo branch-and-bound algoritmy, poskytujú optimálne riešenia, avšak ich použitie je obmedzené na malé problémy z dôvodu vysokej výpočtovej náročnosti. Preto sú v reálnom čase prakticky nepoužiteľné.

Heuristické metódy, ako napríklad pravidlá Najkratší výrobný čas (SPT) alebo Najskorší termín odovzdania (EDD), umožňujú rýchle a jednoducho implementovateľné riešenia. Ich nevýhodou je nižšia kvalita riešení a obmedzená robustnosť v dynamických prostrediach.

Metaheuristiky, vrátane genetických algoritmov, simulovaného žíhania alebo algoritmov založených na kolektívnom správaní (swarm intelligence) (Lei & Liu, 2020) predstavujú kompromis medzi kvalitou riešenia a výpočtovou náročnosťou. Sú vhodné pre riešenie veľkých a komplexných problémov, avšak ich výkonnosť závisí od správneho nastavenia parametrov.

Prístupy založené na umelej inteligencii umožňujú adaptívne a dátovo riadené rozhodovanie. Sú obzvlášť vhodné pre dynamické a neisté prostredia, avšak ich implementácia je náročná a často trpí problémami s interpretovateľnosťou a generalizáciou. Nedávne prístupy založené na posilňovacom učení a hybridných metaheuristických metódach ukázali sľubné výsledky (Guo et al., 2024; Peng et al., 2024; Wan et al., 2024; Workneh et al., 2024).

V kontexte Industry 4.0 sa ako najperspektívnejšie ukazujú hybridné prístupy, ktoré kombinujú výhody viacerých metód a umožňujú dosiahnuť vyššiu flexibilitu a výkonnosť. Tabuľka 1 poskytuje komparatívny prehľad prístupov k rozvrhovaniu s ohľadom na ich aplikovateľnosť v dynamických prostrediach.

Tabuľka 1 : Porovnanie prístupov k rozvrhovaniu v dynamickom prostredí

Metóda	Optimalita	Škálovateľnosť	Schopnosť reagovať v reálnom čase	Adaptabilita
Exaktné metódy	Vysoká	Nízka	Nie	Nízka
Heuristiky	Nízka až stredná	Vysoká	Áno	Nízka
Metaheuristiky	Stredná až vysoká	Stredná	Limitovaná	Stredná
Metódy umelej inteligencie (AI)	Variabilná	Vysoká	Áno	Vysoká

Zdroj: vlastná tvorba

4.2 Kritická analýza podporných technológií

Hoci sú pokročilé technológie často prezentované ako kľúčové predpoklady moderného rozvrhovania, ich praktický prínos sa výrazne líši v závislosti od aplikačného kontextu.

Umelá inteligencia ponúka vysoký potenciál pre adaptívne rozvrhovanie, avšak jej efektívnosť je silne závislá od kvality a dostupnosti dát. V mnohých priemyselných prostrediach môžu neúplné alebo zašumené dáta výrazne znižovať výkonnosť modelov strojového učenia. Okrem toho zostáva nízka interpretovateľnosť modelov významnou prekážkou ich využitia v kritických rozhodovacích procesoch.

Internet vecí umožňuje zber dát v reálnom čase, čo je nevyhnutné pre dynamické rozvrhovanie. Integrácia IoT systémov však prináša výzvy spojené so spoľahlivosťou dát, latenciou a kybernetickou bezpečnosťou, ktoré môžu negatívne ovplyvniť stabilitu rozvrhovania.

Digitálne dvojčatá poskytujú silné simulačné možnosti, ktoré umožňujú hodnotiť rozvrhovacie rozhodnutia pred ich implementáciou. Ich praktické využitie je však limitované náročnosťou na výpočtové zdroje a potrebou kontinuálnej synchronizácie s fyzickým systémom.

Cloud computing a edge computing podporujú škálovateľné a distribuované rozvrhovanie, avšak prinášajú kompromisy medzi centralizovanou optimalizáciou a decentralizovanou odozvou. Nájsť optimálnu rovnováhu medzi týmito prístupmi zostáva otvorenou výskumnou otázkou.

Technológia blockchain zvyšuje transparentnosť a dôveryhodnosť v kolaboratívnych rozvrhovacích scenároch, najmä v dodávateľských reťazcoch. Jej úloha je však primárne infraštruktúrna a neprináša priame riešenia optimalizačných problémov.

Celkovo možno konštatovať, že tieto technológie výrazne rozširujú možnosti rozvrhovania, avšak ich integrácia zároveň prináša nové vrstvy komplexnosti, ktoré si vyžadujú systematické riadenie a architektonické riešenia.

4.3 Budúce trendy v rozvrhovaní

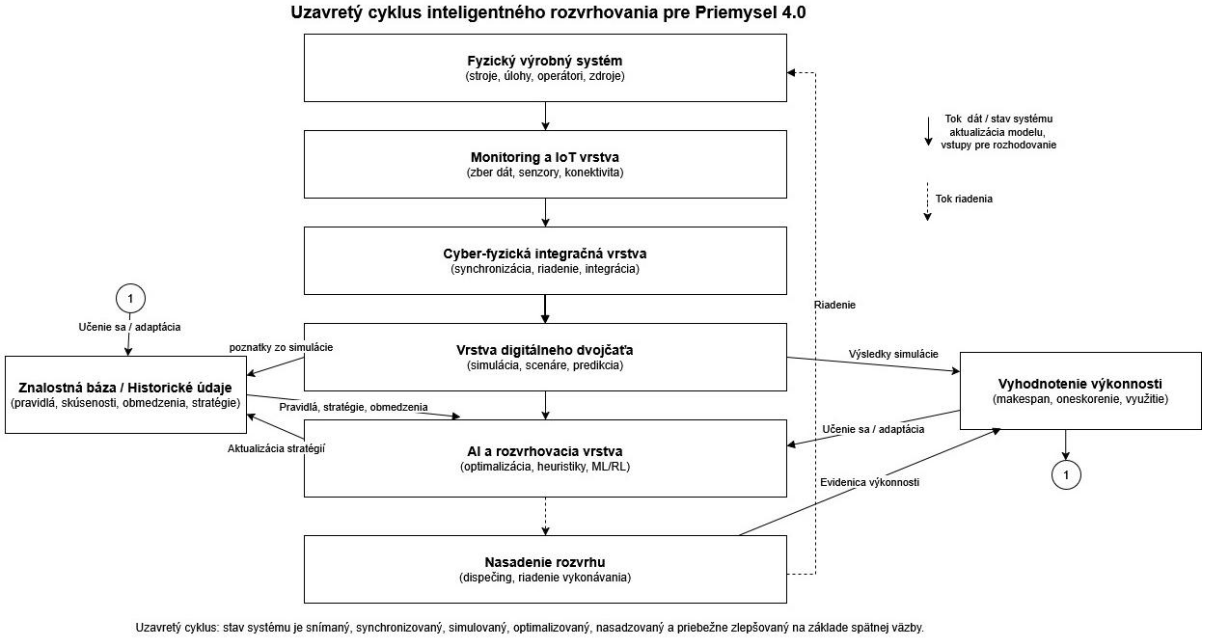
Vývoj rozvrhovania v digitálnej ére je charakterizovaný viacerými trendmi, ktoré zásadne menia jeho úlohu v moderných systémoch.

Jedným z hlavných trendov je prechod od optimalizačne orientovaného k učeniu orientovanému rozvrhovaniu. Zatiaľ čo tradičné prístupy riešia vopred definované optimalizačné úlohy, moderné systémy využívajú dátovo riadené modely, ktoré sa adaptujú na meniace sa podmienky.

Ďalším trendom je prechod od centralizovaného k decentralizovanému rozvrhovaniu. Vďaka kyber-fyzickým systémom a cloudovému computingu a edge computingu sa rozhodovanie presúva bližšie k fyzickým zdrojom, čo umožňuje rýchlejšiu reakciu na lokálne zmeny.

Významným smerom je aj rozvoj hybridných prístupov, ktoré kombinujú optimalizáciu, simuláciu a umelú inteligenciu. Tieto systémy umožňujú spojiť prediktívne schopnosti s adaptívnym riadením. Pozri obrázok 1.

Obrázok 1: Architektúra uzavretého cyklu inteligentného rozvrhovania v prostredí Industry 4.0



Zdroj: vlastná tvorba

S rastúcim dôrazom na udržateľnosť sa do rozvrhovania čoraz viac integrujú environmentálne kritériá, ako sú spotreba energie a emisie. Zároveň rastie význam prístupov orientovaných na človeka, ktoré zohľadňujú pracovné podmienky a ergonómiu.

Tieto trendy naznačujú, že rozvrhovanie sa vyvíja smerom k multidisciplinárnej oblasti, ktorá prepája technológie, optimalizáciu a ľudské faktory.

5 Syntéza

Analýza súčasného stavu výskumu ukazuje, že rozvrhovanie prechádza zásadnou transformáciou z izolovaného optimalizačného problému na komplexný, adaptívny a dátovo riadený systém. Napriek významnému pokroku však pretrváva viacero otvorených problémov.

Jedným z hlavných problémov je rozdiel medzi teoretickými modelmi a ich praktickou implementáciou. Mnohé modely predpokladajú ideálne podmienky, ktoré nezodpovedajú realite moderných výrobných systémov.

Ďalšou výzvou je integrácia rôznych technológií do jednotného systému. Kombinácia umelej inteligencie, IoT, CPS a digitálnych dvojčiat prináša vysokú komplexnosť, ktorá si vyžaduje nové architektonické prístupy.

Významným problémom zostáva aj interpretovateľnosť a spoľahlivosť rozhodovacích systémov založených na umelej inteligencii, najmä v kritických aplikáciách.

Zároveň existuje potreba vyváženia medzi centralizovaným a decentralizovaným riadením, ako aj medzi globálnou optimalizáciou a lokálnou adaptáciou.

Tieto výzvy predstavujú významné výskumné príležitosti a naznačujú smer budúceho vývoja v oblasti rozvrhovania.

6 Záver

Tento článok poskytol komplexný prehľad problematiky rozvrhovania v digitálnej ére, so zameraním na technologické faktory, metodologické prístupy a budúce trendy.

Analýza ukázala, že tradičné prístupy k rozvrhovaniu už nedokážu efektívne riešiť komplexnosť moderných systémov a je potrebné ich doplniť o adaptívne a dátovo riadené metódy.

Kľúčovú úlohu zohrávajú technológie Industry 4.0, ktoré umožňujú integráciu dát, simuláciu a inteligentné rozhodovanie. Najväčší potenciál majú hybridné prístupy, ktoré kombinujú optimalizačné metódy, simuláciu a umelú inteligenciu.

Budúci vývoj bude smerovať k autonómnym, inteligentným a udržateľným rozvrhovacím systémom, ktoré budú schopné reagovať na dynamické zmeny v reálnom čase a podporovať strategické ciele organizácií.

Rozvrhovanie sa tak stáva kľúčovým prvkom digitálnej transformácie a inteligentného riadenia moderných systémov.

Literatúra

1. Allahverdi, A., Ng, C. T., Cheng, T. C. E., & Kovalyov, M. Y. (2008). A survey of scheduling problems with setup times or costs. *European Journal of Operational Research, 187*(3), 985-1032. https://doi.org/10.1016/j.ejor.2006.06.060
2. Bakon, K., Holczinger, T., Süle, Z., Jaskó, S., & Abonyi, J. (2022). Scheduling under uncertainty for Industry 4.0 and 5.0. *IEEE Access, 10*, 74977-75017.
3. Dios, M., & Framinan, J. M. (2016). A review and classification of computer-based manufacturing scheduling tools. *Computers & Industrial Engineering, 99*, 229-249. https://doi.org/10.1016/j.cie.2016.07.020
4. Fu, Y., Hou, Y., Wang, Z., Wu, X., Gao, K., & Wang, L. (2021). Distributed scheduling problems in intelligent manufacturing systems. *Tsinghua Science and Technology, 26*(5), 625-645.
5. Grassi, A., Guizzi, G., Santillo, L. C., & Vespoli, S. (2020). On the modelling of a decentralised production control system in the Industry 4.0 environment. *IFAC-PapersOnLine, 53*(2), 10714-10719. https://doi.org/10.1016/j.ifacol.2020.12.2850
6. Guo, H., Liu, J., Wang, Y., & Zhuang, C. (2024). An improved genetic programming hyper-heuristic for the dynamic flexible job shop scheduling problem with reconfigurable manufacturing cells. *Journal of Manufacturing Systems, 74*, 252-263. https://doi.org/10.1016/j.jmsy.2024.03.009
7. Hu, Y., Zhang, L., Zhang, Z., Li, Z., & Tang, Q. (2024). Matheuristic and learning-oriented multi-objective artificial bee colony algorithm for energy-aware flexible assembly job shop scheduling problem. *Engineering Applications of Artificial Intelligence, 133*, 108634. https://doi.org/10.1016/j.engappai.2024.108634
8. Lassoued, Y., & Schwung, A. (2024). Blockchain-enabled collaborative scheduling in distributed manufacturing systems. *IEEE Access, 12*, 45521–45538.
9. Lei, D., & Liu, M. (2020). An artificial bee colony with division for distributed unrelated parallel machine scheduling with preventive maintenance. *Computers & Industrial Engineering, 141*, 106320. https://doi.org/10.1016/j.cie.2020.106320
10. Lei, K., Guo, P., Wang, Y., Zhang, J., Meng, X., & Qian, L. (2024). Large-scale dynamic scheduling for flexible job-shop with random arrivals of new jobs by hierarchical reinforcement learning. *IEEE Transactions on Industrial Informatics, 20*(1), 1007-1018. https://doi.org/10.1109/TII.2023.3272661
11. Ma, Y., Shi, J., Cai, J., Liu, J., Qiao, F., & Liao, Y. (2024). A semi-supervised production scheduling method based on co-training deep neural network for smart shop floors. *Computers & Industrial Engineering, 194*, 110383. https://doi.org/10.1016/j.cie.2024.110383

12. Mantravadi, S., Srai, J. S., & Møller, C. (2023). Application of MES/MOM for industry 4.0 supply chains: A cross-case analysis. *Computers in Industry, 148*, 103907.
13. Marzia, S., AlejandroVital, S., & Azab, A. (2023). Automated process planning and dynamic scheduling for smart manufacturing: A systematic literature review. *Manufacturing Letters, 35*, 861-872. https://doi.org/10.1016/j.mfglet.2023.07.013
14. Mehdiyev, N., Mayer, L., Lahann, J., & Fettke, P. (2024). Deep learning-based clustering of processes and their visual exploration: An industry 4.0 use case for small, medium-sized enterprises. *Expert Systems, 41*(2), e13139.
15. Morgan, J., Halton, M., Qiao, Y., & Breslin, J. G. (2021). Industry 4.0 smart reconfigurable manufacturing machines. *Journal of Manufacturing Systems, 59*, 481-506.
16. Mourtzis, D. (2022). Advances in Adaptive Scheduling in Industry 4.0. *Frontiers in Manufacturing Technology, 2*. https://doi.org/10.3389/fmtec.2022.937889
17. Neumann, A., Hajji, A., Rekik, M., & Pellerin, R. (2022). A didactic review on genetic algorithms for industrial planning and scheduling problems. *IFAC-PapersOnLine, 55*(10), 2593-2598. https://doi.org/10.1016/j.ifacol.2022.10.100
18. Ouahabi, N., Chebak, A., Kamach, O., Laayati, O., & Zegrari, M. (2024). Leveraging digital twin into dynamic production scheduling: A review. *Robotics and Computer-Integrated Manufacturing, 89*, 102778. https://doi.org/10.1016/j.rcim.2024.102778
19. Pei, F., Zhang, J., Mei, S., & Song, H. (2022). Critical review on the objective function of flexible job shop scheduling. *Mathematical Problems in Engineering, 2022*(1), 8147581. https://doi.org/10.1155/2022/8147581
20. Peng, S., Xiong, G., Yang, J., Shen, Z., Tamir, T. S., Tao, Z., Wang, F.-Y. (2024). Multi-agent reinforcement learning for extended flexible job shop scheduling. *Machines, 12*(1), 8. https://doi.org/10.3390/machines12010008
21. Pinto, M., Silva, C., Thürer, M., & Moniz, S. (2024). Nesting and scheduling optimisation of additive manufacturing systems: Mapping the territory. *Computers & Operations Research, 165*, 106592. https://doi.org/10.1016/j.cor.2024.106592
22. Priore, P., Fuente, D. D. L., Gomez, A., & Puente, J. (2001). A review of machine learning in dynamic scheduling of flexible manufacturing systems. *Artificial Intelligence for Engineering Design, Analysis and Manufacturing, 15*(3), 251–263. https://doi.org/10.1017/s0890060401153059
23. Rannertshauser, P., Kessler, M., & Arlinghaus, J. C. (2022). Human-centricity in the design of production planning and control systems: A first approach towards Industry 5.0. *IFAC-PapersOnLine, 55*(10), 2641-2646. https://doi.org/10.1016/j.ifacol.2022.10.108
24. Romero-Silva, R., & Hernández-López, G. (2020). Shop-floor scheduling as a competitive advantage: A study on the relevance of cyber-physical systems in different manufacturing contexts. *International Journal of Production Economics, 224*, 107555. https://doi.org/10.1016/j.ijpe.2019.107555
25. Salatiello, E., Guizzi, G., Marchesano, M. G., & Santillo, L. C. (2022). Assessment of performance in Industry 4.0 enabled Job-Shop with a due-date based dispatching rule. *IFAC-PapersOnLine, 55*(10), 2635-2640. https://doi.org/10.1016/j.ifacol.2022.10.107
26. Seeger, P. M., Yahouni, Z., & Alpan, G. (2022). Literature review on using data mining in production planning and scheduling within the context of cyber physical systems. *Journal of Industrial Information Integration, 28*, 100371. https://doi.org/10.1016/j.jii.2022.100371
27. Serôdio, C., Mestre, P., Cabral, J., Gomes, M., & Branco, F. (2024). Software and architecture orchestration for process control in industry 4.0 enabled by cyber-physical systems technologies. *Applied Sciences, 14*(5), 2160.

28. Serrano-Ruiz, J. C., Mula, J., & Poler, R. (2021). Smart manufacturing scheduling: A literature review. *Journal of Manufacturing Systems, 61*, 265-287. https://doi.org/10.1016/j.jmsy.2021.09.011
29. Serrano-Ruiz, J. C., Mula, J., & Poler, R. (2022). Toward smart manufacturing scheduling from an ontological approach of job-shop uncertainty sources. *IFAC-PapersOnLine, 55*(2), 150-155. https://doi.org/10.1016/j.ifacol.2022.04.185
30. Serrano-Ruiz, J. C., Mula, J., & Poler, R. (2024). Job shop smart manufacturing scheduling by deep reinforcement learning. *Journal of Industrial Information Integration, 38*, 100582. https://doi.org/10.1016/j.jii.2024.100582
31. Shakeri, Z., Benfriha, K., Varmazyar, M., Talhi, E., & Quenehen, A. (2025). Production scheduling with multi-robot task allocation in a real industry 4.0 setting. *Scientific Reports, 15*(1), 1795. https://doi.org/10.1038/s41598-024-84240-3
32. Wan, L., Fu, L., Li, C., & Li, K. (2024). Flexible job shop scheduling via deep reinforcement learning with meta-path-based heterogeneous graph neural network. *Knowledge-Based Systems, 296*, 111940. https://doi.org/10.1016/j.knosys.2024.111940
33. Workneh, A. D., El Mouhtadi, M., & El Hilali Alaoui, A. (2024). Deep reinforcement learning for adaptive flexible job shop scheduling: coping with variability and uncertainty. *Smart Science, 12*(2), 387-405. https://doi.org/10.1080/23080477.2024.2345951
34. Yin, Y., Chu, F., Dolgui, A., Cheng, T. C. E., & Zhou, M. C. (2022). Big data analytics in production and distribution management. *International Journal of Production Research, 60*(22), 6682–6690. https://doi.org/10.1080/00207543.2022.2131234
35. Zhang, F., Li, R., & Gong, W. (2024). Deep reinforcement learning-based memetic algorithm for energy-aware flexible job shop scheduling with multi-AGV. *Computers & Industrial Engineering, 189*, 109917. https://doi.org/10.1016/j.cie.2024.109917
36. Zhang, W., Bao, X., Hao, X., & Gen, M. (2025). Metaheuristics for multi-objective scheduling problems in industry 4.0 and 5.0: a state-of-the-art survey. *Frontiers in Industrial Engineering, 3*. https://doi.org/10.3389/fieng.2025.1540022
37. Zhang, W., Xiao, G., Gen, M., Geng, H., Wang, X., Deng, M., & Zhang, G. (2024). Enhancing multi-objective evolutionary algorithms with machine learning for scheduling problems: recent advances and survey. *Frontiers in Industrial Engineering, 2*. https://doi.org/10.3389/fieng.2024.1337174
38. Zhang, W., Zhao, F., Li, Y., Du, C., Feng, X., & Mei, X. (2024). A novel collaborative agent reinforcement learning framework based on an attention mechanism and disjunctive graph embedding for flexible job shop scheduling problem. *Journal of Manufacturing Systems, 74*, 329-345. https://doi.org/10.1016/j.jmsy.2024.03.012