



ŽILINSKÁ UNIVERZITA V ŽILINE
Strojnícka
fakulta

AUTOREFERÁT DIZERTAČNEJ PRÁCE

Žilina, 2026

Ing. Dávid Komačka



ŽILINSKÁ UNIVERZITA V ŽILINE
Strojnícka
fakulta

Ing. Dávid Komačka

AUTOREFERÁT DIZERTAČNEJ PRÁCE

Riadenie procesov internej logistiky v podmienkach inteligentných výrobných systémov

Na získanie akademického titulu **doktor**
(„**philosophiae doctor**“, v skratke „**PhD.**“)
v študijnom odbore Strojárstvo
v študijnom programe Priemyselné inžinierstvo

Žilina 2026

Dizertačná práca bola vypracovaná v dennej forme doktorandského štúdia na Žilinskej univerzite v Žiline, Strojníckej fakulte, Katedre priemyselného inžinierstva.

Predkladateľ: Ing. Dávid Komačka
Žilinská univerzita v Žiline
Strojnícka fakulta
Katedra Priemyselného inžinierstva

Školiteľ: prof. Ing. Martin Krajčovič, PhD.
Žilinská univerzita v Žiline
Strojnícka fakulta
Katedra Priemyselného inžinierstva

Oponenti:

1. prof. Ing. Jozef Majerčák, PhD.
Dôchodca
Trnavská 4, 010 08, Žilina
2. doc. Ing. Martin Gašo, PhD.
KPI, Strojnícka fakulta, Žilinská univerzita v Žiline
Univerzitná 8215/1, 010 26, Žilina
3. prof. Ing. Peter Trebuňa, PhD.
Katedra priemyselného a digitálneho inžinierstva, Strojnícka fakulta, Technická univerzita v Košiciach
Park Komenského 9, 042 00 Košice

Autoreferát bol rozoslaný dňa:

Obhajoba dizertačnej práce sa koná dňa o hod. v miestnosti na SjF, Univerzitná 8215/1, 010 26, Žilina, pred komisiou pre obhajobu dizertačnej práce schválenou odborovou komisiou v študijnom odbore Strojárstvo, v študijnom programe Priemyselné inžinierstvo, vymenovanou dekanom Strojníckej fakulty, Žilinskej univerzity v Žiline.

S dizertačnou prácou je možné sa oboznámiť na referáte pre vedu a výskum dekanátu Sjf, UNIZA, Univerzitná 8215/1, 010 26 Žilina.

prof. Ing. Ľuboslav Dulina, Phd.
predseda komisie pre obhajobu dizertačnej práce

Úvod

Dynamický rozvoj priemyselného sektora v posledných dekádach je poháňaný neustálym pokrokom v oblasti informačných a komunikačných technológií. Súčasné koncepty Priemyslu 4.0 a nastupujúceho Priemyslu 5.0 vytvárajú komplexný rámec pre hlboké prepojenie fyzických výrobných zariadení s digitálnymi technológiami. Tento evolučný posun umožňuje vznik inteligentných výrobných systémov, ktoré sú postavené na implementácii kyberneticko-fyzikálnych technológií, internetu vecí, analýzy veľkých dát a pokročilých metód umelej inteligencie.

Nasadenie týchto moderných technológií zásadne mení nielen samotné výrobné procesy, ale kladie úplne nové nároky na logistické a zásobovacie procesy. Interná logistika, ako neoddeliteľná súčasť každého výrobného procesu, čelí v prostredí inteligentnej výroby novým, doteraz nepoznaným výzvam. Tradične využívané štíhle logistické systémy, akými sú milk-run systémy s pevne stanovenými fixnými trasami a časovými harmonogramami, dokážu požiadavky dynamicky sa meniaceho a vysoko variabilného výrobného prostredia naplňať len obmedzene. Ich reaktívny charakter neumožňuje dostatočne rýchlu adaptáciu na náhle zmeny vo výrobnom programe či na osciláciu spotreby, čo v praxi nevyhnutne vedie buď k rizikovým výpadkom materiálu priamo na linkách, alebo k nežiaducemu hromadeniu nadmerných zásob na jednotlivých pracoviskách.

Práve neschopnosť tradičných statických prístupov flexibilne reagovať na dynamiku moderných výrobných závodov sa stala hlavnou motiváciou predloženého výskumu. Predkladaná dizertačná práca reaguje na túto výskumnú medzeru a detailne sa zaoberá problematikou dynamického krátkodobého plánovania a operatívneho riadenia vnútropodnikových zásobovacích procesov v špecifických podmienkach inteligentných výrobných systémov.

Hlavným cieľom dizertačnej práce bolo navrhnuť, implementovať a experimentálne overiť komplexný metodický postup, ktorý prekonáva obmedzenia statického prístupu. Navrhnuté riešenie umožňuje kontinuálnu adaptáciu zásobovacieho plánu v reálnom čase na základe permanentného toku reálnych dát o aktuálnej spotrebe materiálu, kapacitnom vyťažení prepravných prostriedkov, presnom stave zásob na pracoviskách a taktiež prognózovaní spotreby materiálu na základe historických dát.

Jadro dizertačnej práce reprezentuje päťblokova metodika dynamického plánovania. Tá systematicky pokrýva celý logistický cyklus: od zberu a štruktúrovania dát, cez predikciu materiálových požiadaviek pomocou Holt-Wintersovho exponenciálneho vyrovňovania a adaptívne zhlukovanie zastávok, až po samotnú optimalizáciu trás prostredníctvom pokročilých metaheuristických algoritmov s následnou simulačnou verifikáciou a manažment výstupných vrstiev a monitorovania odchýlok s inteligentným preplánovaním.

Práca prináša preukázateľné teoretické i praktické prínosy pre priemyselné inžinierstvo, nakoľko úspešne spája prediktívne modelovanie, metaheuristickú optimalizáciu a diskretnú udalostnú simuláciu do jedného robustného plánovacieho a riadiaceho celku.

1. Prehľad problematiky a analýza súčasného stavu

Východiskovým bodom predloženého výskumu je hĺbková analýza súčasného stavu vnútropodnikových logistických procesov v ére transformácie priemyslu pod vplyvom konceptov Priemysel 4.0 a Priemysel 5.0. Súčasný akademický a priemyselný trendy potvrdzujú, že zatiaľ čo Priemysel 4.0 priniesol masívnu digitalizáciu, kyberneticko-fyzikálne systémy a internet vecí s primárnym zameraním na technologickú efektívnosť. Nastupujúci Priemysel 5.0 tento rámec dopĺňa o dimenziu ľudskosti, udržateľnosti a vysokej odolnosti. V tomto dynamickom prostredí sa interná logistika stáva kritickým subsystémom, od ktorého priamo závisí flexibilita a priepustnosť celého výrobného komplexu.

Pri spracovaní tejto kapitoly sa vychádzalo z rešerše relevantných vedeckých prác publikovaných v renomovaných databázach (SCOPUS, Web of Science, Google Scholar a pod.) so zameraním najmä na obdobie rokov 2017 až 2024. Literárny prieskum ukázal, že výskum v tejto oblasti sa celosvetovo koncentruje do štyroch hlavných pilierov:

- Optimalizačné algoritmy a plánovanie trás pre vnútropodnikovú logistiku,
- Dynamické systémy riadenia procesov zásobovania s využitím real-time dát,
- Inteligentná logistika, automatizácia a integrácia autonómnych vozidiel (AGV/AMR),
- Konceptualizácia systémov Milk-Run 4.0 pre inteligentné továrne.

Tradičné vs. moderné prístupy k zásobovaniu

V klasických konceptoch štíhlej výroby zohrávajú kľúčovú úlohu milk-run systémy. Ako uvádza Krajčovič (2024), tradičný milk-run funguje na princípe fixných okružných trás, pevných časových harmonogramov a staticky definovaných bodov objednávky. Tento prístup vykazuje vysokú efektívnosť, avšak výhradne v stabilných podmienkach s nízkou variabilitou a predvídateľnou spotrebou.

S prechodom na kustomizovanú výrobu s vysokou variabilitou produktov sa však limitácie tradičných statických modelov naplno prejavujú. Reaktívna povaha týchto systémov nedokáže včas zachytiť fluktuáciu spotreby materiálu. Vo vedeckej komunite preto rezonujú snahy o prechod na dynamické plánovanie. Výskumníci ako Facchini a kol. (2022) či Droste (2021) rozpracovali modely postavené na probléme trasovania vozidiel s časovými oknami, pričom logistické ťahače vybavovali lokalizačnými technológiami s cieľom priebežne optimalizovať trasy. Významným prínosom v domácom kontexte je práve koncept Milk-Run 4.0 (Krajčovič a kol., 2023), ktorý definuje potrebu využívania reálnych dát z výroby pre flexibilnú úpravu zásobovacích cyklov.

Využitie metaheuristických metód a identifikácia výskumnej medzery

Keďže operatívne plánovanie trás a rozvrhovanie vozidiel patrí do triedy NP-ťažkých kombinatorických problémov, exaktné matematické metódy (napr. zmiešané celočíselné lineárne programovanie – MILP) zlyhávajú pri požiadavke na výpočet v reálnom čase pri rozsiahlejších úlohách. Súčasný svetový výskum sa preto orientuje na pokročilé metaheuristiky. Analýza prác (napr. Bányai a Francuz, 2022) potvrdila úspešné nasadenie algoritmov mravčích kolónií, adaptívneho prehľadávania širokého okolia, či simulovaného žihania na optimalizáciu logistických tokov.

Napriek úspechom moderných prístupov boli v existujúcom stave poznania identifikované **tri kľúčové výskumné medzery**, na ktoré táto dizertačná práca priamo reaguje:

1. **Absencia integrácie predikčných modelov spotreby materiálu:** Väčšina publikovaných dynamických modelov reaguje až na vzniknutú požiadavku (reaktívny prístup), namiesto toho, aby ju na základe historických trendov a aktuálneho taktu výroby proaktívne predikovala.
2. **Chýbajúce komplexné prepojenie optimalizácie a simulácie v jednom celku:** Existuje metodologický deficit v integrácii dátovej, optimalizačnej a simulačnej vrstvy tak, aby bolo možné vypočítaný plán okamžite overiť pred jeho samotným vykonaním vo fyzickom systéme.
3. **Absencia inteligentných mechanizmov riadeného preplánovania:** Súčasný systémy buď preplánovávajú trasy neustále, alebo nedokážu adekvátne reagovať na mikro výpadky a časové odchýlky počas zmeny.

Táto kritická analýza literatúry poslúžila ako priame teoretické a metodologické východisko pre formuláciu cieľov práce a pre návrh vlastnej päťblokovej architektúry dynamického riadenia vnútornej logistiky.

2. Definovanie cieľov doktorandskej dizertačnej práce

Nasledujúca kapitola sa zaoberá stanovením hlavného cieľa doktorskej dizertačnej práce. Pre dosiahnutie hlavného cieľa je definovaných niekoľko čiastkových cieľov, následne sú popísané metódy využívané pri plnení cieľov.

2.1 Hlavný cieľ dizertačnej práce

Hlavným cieľom dizertačnej práce bolo navrhnúť a overiť systém krátkodobého plánovania a riadenia procesov vnútro podnikovej prepravy a zásobovania pracovísk v podmienkach inteligentných výrobných systémov založený na zbere údajov v reálnom čase a ich využití pri predikcii požiadaviek výrobného systému a vývoja disponibilných kapacít systému vnútro podnikovej prepravy.

2.2 Čiastkové ciele dizertačnej práce

- návrh štruktúry údajov zbieraných z reálneho systému pre potreby predikcie požiadaviek výroby a disponibilít prepravných kapacít,
- návrh spôsobu zberu a prenosu dát z reálneho systému do virtuálneho prostredia,
- návrh algoritmu pre predikciu požiadaviek výroby a disponibilít prepravných kapacít,
- návrh kritérií pre výber optimálneho rozvrhu zásobovacích prepravných trás (čas, náklady, vyťaženie transportných prostriedkov, vyťaženie dopravných uličiek, blokovanie systému, atď.),
- návrh algoritmu pre riešenie problému plánovania dynamických prepravných trás,
- návrh spôsobu integrácie prostriedkov diskretnej simulácie do procesu verifikácie rozvrhu zásobovacích prepravných trás,
- prepojenie jednotlivých častí do komplexného systému plánovania a riadenia procesov vnútro podnikovej prepravy a zásobovania pracovísk,
- overenie navrhovaného riešenia.

2.3 Metódy využité pri riešení dizertačnej práce

V procese tvorby a validácie dizertačnej práce boli uplatnené tieto vedecké metódy:

Analýza - tento prístup spočíva v rozložení daného problému na základné časti a dôkladné jeho skúmanie. Cieľom je pochopiť príčiny ich existencie, preskúmať vzťahy medzi nimi a odlišiť hlavné informácie od vedľajších. Hlavným zámerom analýzy je zjednodušiť komplexné témy a presunúť výskum od obecného k špecifickému.

Abstrakcia - proces oddeľovania nepodstatných charakteristík a súvislostí objektu alebo javu, aby sa viac zvýraznili ich dôležité a prirodzené vlastnosti.

Dedukcia - táto myšlienková metóda vedie k logickému záveru, ktorý je založený na pravdivosti predpokladov. Je to postup, ktorým sa myšlienkový proces presúva od obecného k špecifickému.

Experiment - technika, ktorá sa používa na podporu, vyvrátenie alebo potvrdenie hypotézy alebo teórie.

Korelačná štúdia - hodnotenie vzťahu medzi dvoma alebo viacerými premennými. Jej cieľom je zistiť, či existuje spojenie medzi týmito premennými, aj keď neukazuje, čo spôsobuje tento vzťah.

Modelovanie a simulácia - modelovanie a simulácia sú nástroje, ktoré výskumníci používajú na vytvorenie abstraktných reprezentácií reálnych situácií alebo systémov. Tieto modely umožňujú experimentovanie s rôznymi faktormi a sledovanie, ako sa menia výsledky.

Kvantitatívna analýza - je výskumný prístup, ktorý využíva číselné dáta a štatistické metódy na testovanie hypotéz, určovanie vzorcov a vzťahov medzi premennými. Je široko používaná pre poskytovanie merateľných dôkazov a objektívnych výsledkov v rámci rôznych vedeckých disciplín.

Porovnávanie - táto metóda zahŕňa kvantitatívne a kvalitatívne porovnávanie rôznych charakteristík objektov alebo javov, hodnotenie, ktorý z nich je lepší v určitých aspektoch a určenie ich podobností alebo rozdielov.

Zovšeobecňovanie - vedecká metóda, ktorá spočíva v logickom prechode od špecifického k obecnému, založená na zjednocovaní informácií na základe jednej alebo viacerých spoločných vlastností.

Validácia a overovanie - validácia sa týka overenia, či nástroje alebo metódy merajú to, čo majú, a či sú presné. Overovanie sa zameriava na potvrdenie, že výskumné postupy sú správne a opakovateľné. Tieto procesy sú kritické pre dosiahnutie vedeckej presnosti a dôveryhodnosti výskumných výsledkov.

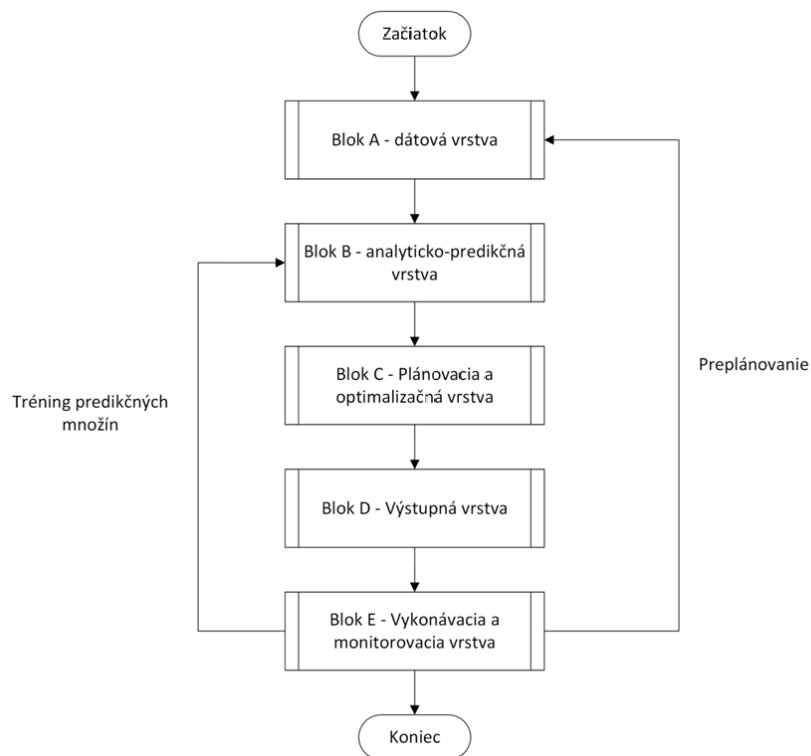
3. Návrh metodiky riadenie procesov internej logistiky v podmienkach inteligentných výrobných systémov

Základný rámec riešenia je postavený na viacvrstvovej kyberneticko-fyzikálnej architektúre, ktorá zabezpečuje obojsmerný tok informácií medzi reálnym výrobným prostredím a virtuálnym optimalizačným jadrom.

- **Fyzická vrstva:** Reprezentuje reálne výrobné linky, spotrebné miesta, logistické vlaky a operátorov internej logistiky.
- **Dátová a komunikačná vrstva:** Zabezpečuje kontinuálny zber dát v reálnom čase prostredníctvom IoT senzorov, RTLS UWB technológie a výrobných informačných systémov.
- **Rozhodovacia a optimalizačná vrstva:** Predstavuje digitálne dvojča systému. Tu prebieha predikcia spotreby, exekúcia optimalizačných algoritmov a simulačná verifikácia.

3.1 Päťbloková metodika dynamického plánovania a riadenia

Samotné funkčné jadro systému je štruktúrované do piatich logicky prepojených blokov (Blok A až Blok E), ktoré pokrývajú kompletný životný cyklus spracovania dát, predikcie, optimalizácie, simulácie a spätnoväzbového riadenia.



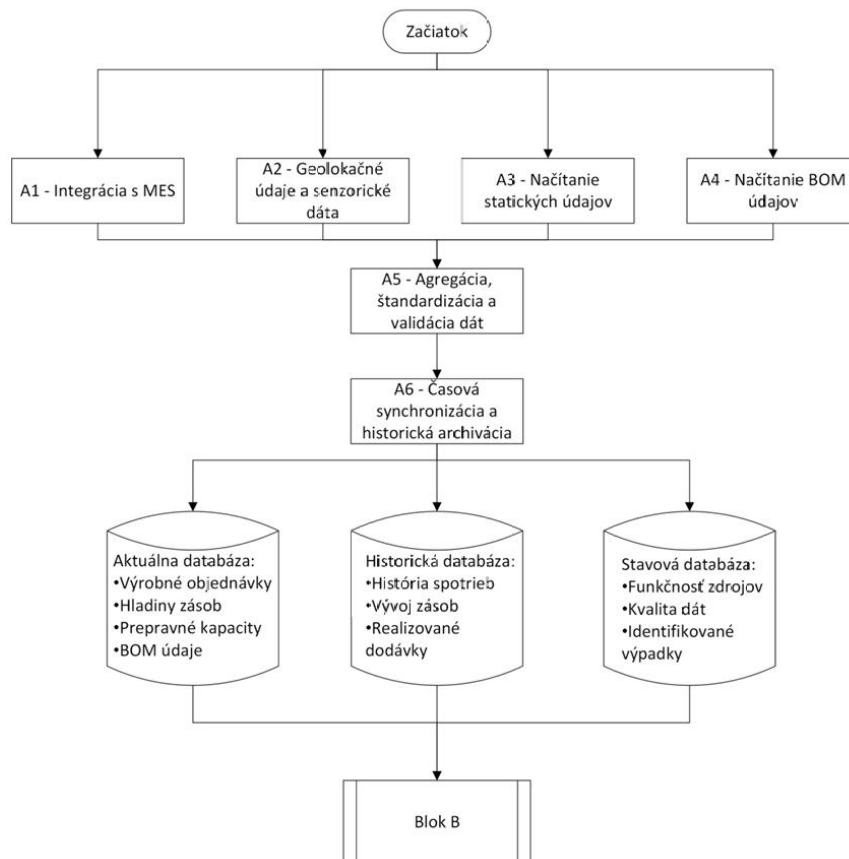
Obr. 1 Architektonická štruktúra metodického postupu

3.2 Blok A – dátová vrstva systému

Tento blok tvorí základnú dátovú vrstvu celého systému a zabezpečuje transformáciu neštruktúrovaných priemyselných dát na štruktúrované vstupy pre optimalizačné jadro. Procesy v tomto bloku sú rozdelené do dvoch kategórií:

1. **Statické vstupy:** Zahŕňajú priestorové usporiadanie výrobnéj haly, presnú polohu a súradnice spotrebných miest, maticu vzdialeností a časov prejazdov medzi nimi, ako aj fixné parametre logistickej flotily (kapacita tahačov, typy a kapacity prepravných boxov).
2. **Dynamické vstupy:** Predstavujú nepretržitý tok dát z výrobného procesu v reálnom čase. Ide najmä o aktuálne stavy zásob na jednotlivých pracoviskách a informácie o aktuálne vyrábanom produkte na linke.

Dátový manažment využíva integračné rozhrania na prepojenie s podnikovými systémami (ERP, MES) a prvkami internetu vecí (IoT senzory na linkách, RTLS). Výstupom tohto bloku je komplexná a očistená dátová matica, ktorá slúži ako vstup pre nasledujúce prediktívne a optimalizačné moduly.



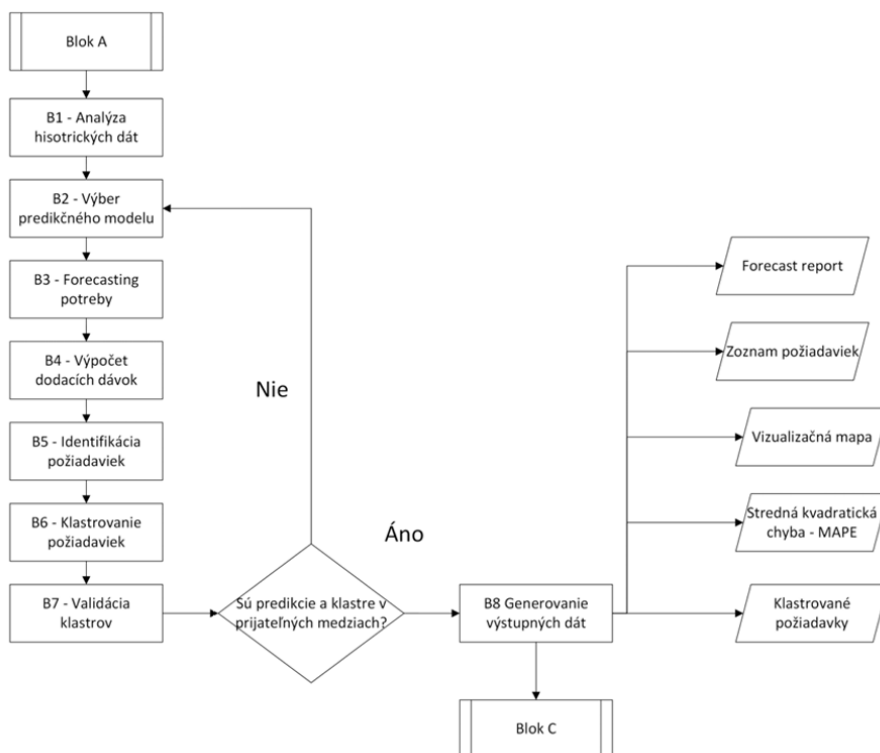
Obr. 2 Blok A - Dátová vrstva systému

3.3 Blok B – analyticko-predikčná vrstva systému

Tento blok tvorí analytické jadro navrhutej metodiky. Jeho cieľom je transformovať očistené dáta z predchádzajúceho bloku na proaktívne požiadavky na závoz s vopred definovanými časovými oknami, čím sa predchádza reaktívnemu čakaniu na kritický nedostatok zásob. Procesná logika vnútri bloku prebieha v dvoch naväzujúcich fázach.

V **prvej fáze** systém na základe aktuálneho taktu výroby a historických trendov spotreby prognózuje budúci vývoj zásob. Využíva na to algoritmus *Holt-Wintersovho trojitého exponenciálneho vyrovňovania*, ktorý priebežne prispôsobuje svoje parametre tak, aby zachytil trend aj sezónnosť spotreby spôsobenú striedaním typov produktov. Vypočítaná predpoveď sa v reálnom čase koriguje na základe aktuálnych výrobných rozvrhov z MES systému. Následne systém určí čas do úplného vyčerpania zásob, prepočíta čistú potrebu v kusoch na reálne balenia so zaokrúhľovaním nahor a priradí požiadavkám indexy priorít spolu s časovými oknami (najskorší a najneskorší možný čas doručenia).

V **druhej fáze** nastupuje priestorová a časová konsolidácia požiadaviek na princípe „*cluster first, route second*“. Systém aplikuje modifikovaný klastrovací algoritmus typu *K-means++*. Ten namiesto bežného geografického klastrovania pracuje s viackriteriálnou metrikou vzdialeností, takže do výpočtu polohy stredov zhlukov integruje nielen súradnice pracovísk, ale aj naliehavosť časových okien a priority. Zastávky s blízkou polohou a podobným časom závozu sa tak spoja do spoločného zhluku. Po vytvorení klastrov systém automaticky overí ich kapacitnú a časovú uskutočniteľnosť vzhľadom na technické limity flotily tahačov (nosnosť, objem, dĺžka cyklu) a v prípade preťaženia ich rozdelí.



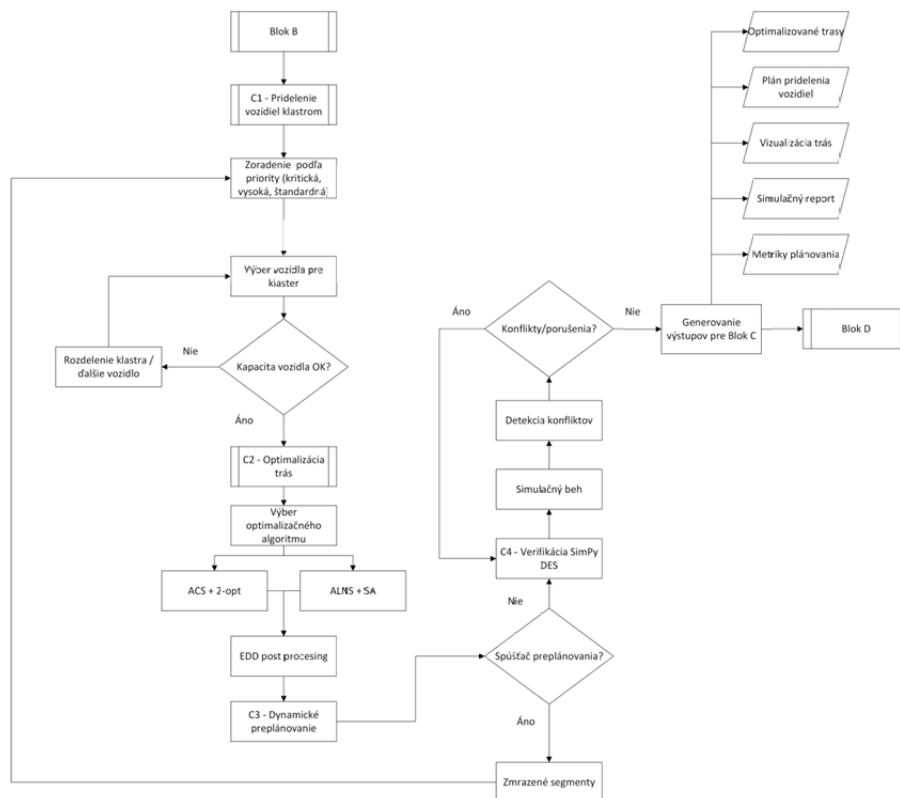
Obr. 3 Blok B - analyticko-predikčná vrstva systému

Výstupom bloku je očistené a štruktúrované zadanie pre optimalizačné algoritmy v Bloku C. Obsahuje presný zoznam materiálov v baliaciach jednotkách, ich časové okná s prioritami a ich rozdelenie do kapacitne overených zhlukov, čo garantuje, že optimalizácia pracuje iba s reálne uskutočniteľnými požiadavkami.

3.4 Blok C – plánovacia a optimalizačná vrstva systému

Tento blok predstavuje výpočtové a rozhodovacie jadro navrhutej metodiky, ktoré rieši dynamický problém trasovania vozidiel s časovými oknami. Na základe kapacitne overených zhlukov požiadaviek z predchádzajúceho bloku hľadá systém také poradie obsluhy zastávok, ktoré minimalizuje celkovú dĺžku trás, počet nasadených ťahačov a penalizácie za nedodržanie časových okien. Vzhľadom na vysokú výpočtovú zložitosť problému (NP-ťažká úloha) softvérová aplikácia ponúka používateľovi možnosť voľby medzi dvoma pokročilými optimalizačnými algoritmi podľa charakteru logistickej siete:

- **Algoritmus mravčej kolónie s lokálnym vyhľadávaním (ACS + 2-opt):** Táto voľba je navrhnutá pre rýchly výpočet riešenia v reálnom čase. Algoritmus simuluje správanie mravcov pri hľadaní najkratšej cesty pomocou ukladania a vyparovania feromónovej stopy, pričom striktno zohľadňuje časové okná a prioritizáciu požiadaviek. Na urýchlenie konvergencie a vyhladenie nájdenej trasy je integrovaný lokálny operátor 2-opt, ktorý odstraňuje neefektívne kríženia ciest.
- **Adaptívne vyhľadávanie širokého okolia so simulovaným žíhaním (ALNS-SA):** Táto voľba slúži na hĺbkovú optimalizáciu zložitejších logistických scenárov. Algoritmus ALNS flexibilne strieda rôzne deštrukčné a rekonštrukčné operátory na základe ich doterajšej úspešnosti. Prepojenie s metódou simulovaného žíhania a jej pravdepodobnostným kritériom akceptácie (vyžitie klesajúcej teploty a koeficientu chladenia) umožňuje prijímať aj matematicky horšie riešenia. Tým algoritmus nezostane uväznený v lokálnom minime a dokáže nájsť globálne optimum.



Obr. 4 Blok C - plánovacia a optimalizačná vrstva systému

V rámci bloku C bol taktiež implementovaný algoritmus, ktorý spúšťa preplánovanie. Pre tento spúšťač boli zadané udalosti, ktoré systém sleduje, a na základe ktorých systém spúšťa proces preplánovania. Typy udalostí majú priradený stupeň priority, rozsah preplánovania pri danej udalosti a taktiež zdroj dát, z ktorých si spúšťač mechanizmus čerpá dáta.

Tab. 1 Tabuľka udalostných spúšťačov

Typ udalosti	Priorita	Rozsah	Zdroj
Riziko výpadku zásob	Kritická (0)	Čiastočné	Blok E
Porucha AGV	Kritická (0)	Celkové	Fleet manžér
Presiahnutie ROP	Vysoká (1)	Čiastočné	Blok E
Manuálny zásah	Vysoká (1)	Celkové	Operátor
Zmena taktu výroby	Stredná (2)	Celkové	MES/BOM
Akumulácia odchýlok	Stredná (2)	Celkové	Blok E
Zmena výrobného mixu	Stredná (2)	Celkové	MES/BOM
Periodický spúšťač	Nízka (3)	Celkové	Časovač

Výstupom bloku C je matematicky optimalizovaný logistický plán vygenerovaný zvoleným algoritmom. Obsahuje presný časový harmonogram odchodov ťahačov, optimálne sekvencie zastávok pre jednotlivé vozidlá a priradenie materiálových balení konkrétnym trasám. Tento detailný rozvrh sa následne odovzdáva do Bloku D.

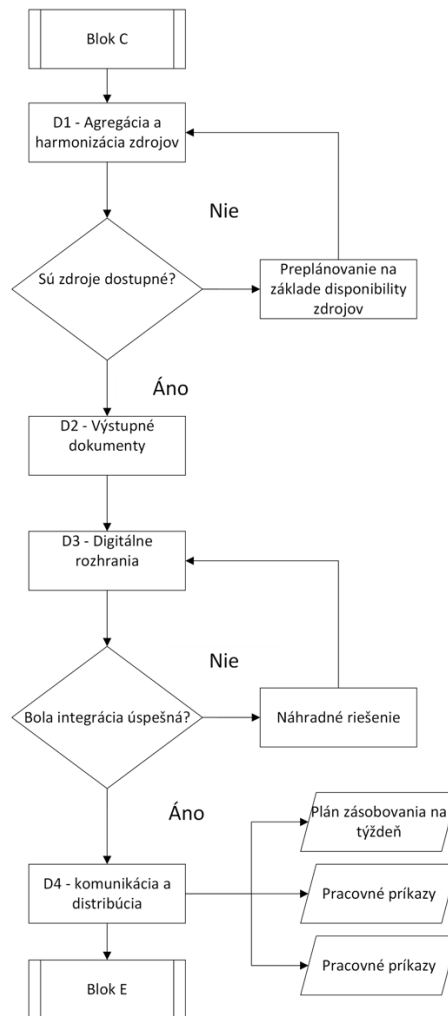
3.5 Blok D – výstupná vrstva systému

Tento blok zabezpečuje transformáciu overeného digitálneho rozvrhu do reálnych úloh vo fyzickom prostredí výrobnéj haly. Pôsobí ako exekučný medzičlánok, ktorý prekladá matematické a simulačné výsledky z Bloku C do podoby exaktných inštrukcií pre logistický personál.

Proces bloku D je nasledovný:

- **Generovanie finálnych inštrukcií:** Po získaní validovaného plánu systém automaticky skombinuje priestorové dáta trás s materiálovými požiadavkami. Prepočíta optimalizované sekvencie zastávok na konkrétne časové rozvrhy odjazdov a príjazdov pre každý milk-run samostatne.
- **Tvorba vychystávacích plánov:** V tomto kroku systém rozloží celkový objem priradeného materiálu na detailné inštrukcie pre nakládku a vykládku. Surové požiadavky pretransformuje na príkazy pre manipuláciu s konkrétnymi priemyselnými baleniami (napr. presný počet KLT boxov či paliet) prislúchajúcimi k daným zastávkam na trase.
- **Distribúcia a vizualizácia v reálnom čase:** Posledný procesný krok zabezpečuje prenos dát cez podnikové komunikačné rozhrania. Informácie sa vizualizujú a odosielajú na koncové

zariadenia operátorov. Systém v tomto kroku riadi priradenie správneho rozvrhu správne mu vodičovi na základe jeho aktuálnej dostupnosti a polohy.



Obr. 5 Blok D – Výstupná vrstva systému

Výstupom bloku D sú definované a štruktúrované riadiace dokumenty a príkazy, ktoré smerujú k logistickým operátorom a taktiež do dashboardov v rámci logistiky:

Optimalizovaný harmonogram navážania: Časový plán pre logistické centrum, ktorý určuje presné momenty vypustenia jednotlivých súprav do obehu, čím sa predchádza dopravnému preťaženiu logistických uličiek.

Sekvenčné mapy trás: Presne usporiadané zoznamy zastávok pre vodičov ťahačov. Vodič má jednoznačne určené poradie obsluhy pracovísk, ktoré minimalizuje prejazdené vzdialenosti.

Digitálne manipulačné príkazy: Pokyny zobrazené priamo na priemyselných termináloch alebo tabletoch vodičov. Tieto inštrukcie operátorovi presne definujú, aký typ materiálu, v akom počte baliacich jednotiek a na ktorej konkrétnej zastávke má v rámci zásobovacieho okruhu vyložiť, respektíve naložiť.

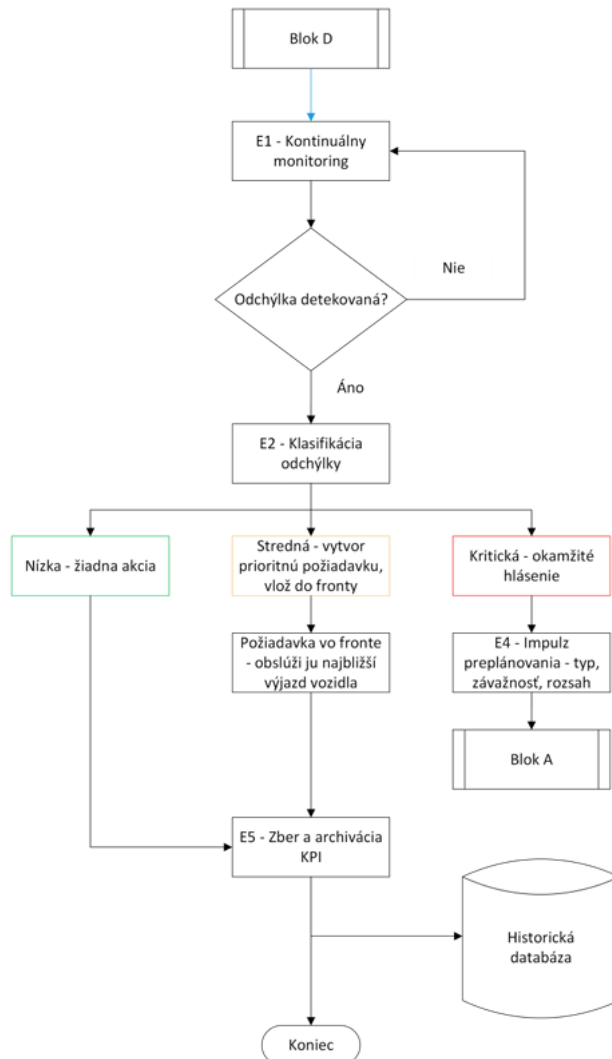
Tento systematický tok v Bloku D garantuje, že do fyzickej prevádzky vstupuje overený, prehľadný a jednoznačný plán, čím sa výrazne eliminuje chybovosť ľudského faktora a minimalizujú sa prestoje spôsobené nesprávnou manipuláciou s materiálom.

3.6 Blok E – vykonávacia a monitorovacia vrstva systému

Tento blok predstavuje finálny uzol navrhutej metodiky, ktorý uzatvára celú riadiacu slučku a transformuje ju na dynamický systém s permanentnou spätnou väzbou. Jeho hlavnou úlohou je zabezpečiť proaktívnu obranu logistického toku voči nečakaným narušeniam priamo počas realizácie plánu vo fyzickom prostredí.

Proces spracovania dát v bloku E je nasledovný:

- **Sledovanie odchýlok a IoT monitoring:** Počas toho, ako milk-runy fyzicky jazdia po dielni, systém cez IoT infraštruktúru nepretržite sníma realitu a porovnáva ju s pôvodným plánom z Bloku D. V každom okamihu zaznamenáva dva druhy odchýlok:
 - *Časová odchýlka:* Rozdiel medzi plánovaným a skutočným časom príchodu ťahača na logistickú zastávku.
 - *Materiálová odchýlka:* Rozdiel medzi očakávanou a reálnou rýchlosťou spotreby materiálu na linke.
- **Určenie kritickosti (Rozhodovanie):** Detegovaná odchýlka automaticky prechádza filtrom kritickosti. Systém nespúšťa preplánovanie hneď, aby na dielni nevznikol chaos. Podľa veľkosti odchýlky a zostávajúceho dosahu zásob priradí situácii jednu z troch zón:
 - *Zelená zóna (Nekritická):* Odchýlka je minimálna. Systém stav iba zapíše do prevádzkového logu a pokračuje sa v pôvodnom pláne.
 - *Žltá zóna (Varovná):* Odchýlka sa blíži k hranici tolerancie. Systém ad-hoc požiadavku zaregistruje pre nasledujúci bežný plánovací cyklus.
 - *Červená zóna (Kritická):* Meškanie ťahača alebo spotreba materiálu prekročili nebezpečnú hranicu a hrozí výpadok výroby. Systém okamžite vynúti nápravnú akciu.
- **Exekúcia akcií a ukladanie dát:** Tento krok rozdeľuje aktivovanú odozvu na dve línie:
 - **operatívnu** (riešenie aktuálneho problému v reálnom čase).
 - **historicko-analytickú** (zber dát pre dlhodobé učenie systému).



Obr. 6 Blok E - Monitorovacia a vykonávacia vrstva systému

Výstupy z bloku E sú nasledovné:

- Impulz pre dynamické preplánovanie: Pri dosiahnutí Červenej zóny systém zbalí aktuálne dáta o pozíciách ťahačov a stave zásob a odošle ich späť do výpočtového jadra. Pôvodný rozvrh sa ruší a algoritmy za behu prepočítajú nové trasy tak, aby včasne vyzásobili ohrozené pracovisko.
- Zber a prenos historických údajov: Bez ohľadu na to, či k odchýlke došlo alebo nie, Blok E kontinuálne ukladá všetky zozbierané prevádzkové dáta (reálne časy prejazdov, časy nakládok, reálne krivky spotreby) a posiela ich späť do dátovej základne (Blok A/B). Tieto historické dáta slúžia na tréning predikčných modelov a spresňovanie plánov pre ďalšie zmeny, čím sa systém neustále sám zdokonaľuje.
- Výstražné notifikácie: Digitálny signál na dispečerský panel a tablety vodičov, ktorý ich okamžite informuje, že ich trasa bola kvôli kritickej situácii modifikovaná.

4. Experimentálne overenie navrhnutého systému

Pre komplexnú validáciu navrhnujej päťblokovkej metodiky a vyvinutého softvérového prototypu bola definovaná prípadová štúdia reprezentujúci reálne, vysoko záťažové priemyselné prostredie.

Modelovaná výrobná hala pozostávala z **40 samostatných výrobných pracovísk**, ktoré boli zásobované flotilou 3 logistických vlakov štartujúcich z centrálného skladu. Celkový materiálový tok zahŕňal **204 unikátnych materiálových položiek** (rôzne druhy komponentov, spojovacieho materiálu a podzostáv), ktoré boli distribuované v unifikovaných priemyselných baleniach (KLT boxy a prepravné palety).

Cieľom prípadovej štúdie bolo simulovať prevádzku počas celej pracovnej zmeny, kedy na linkách dochádza k dynamickým zmenám taktov výroby, fluktuácii spotreby a stochastickým zdržaniam, a porovnať výkonnosť navrhnutého riadenia s tradičným prístupom.

Overenie prebiehalo v prostredí vyvinutej aplikácie, pričom experiment postupoval na základe logického toku navrhnujej metodiky a prebiehal nasledovne:

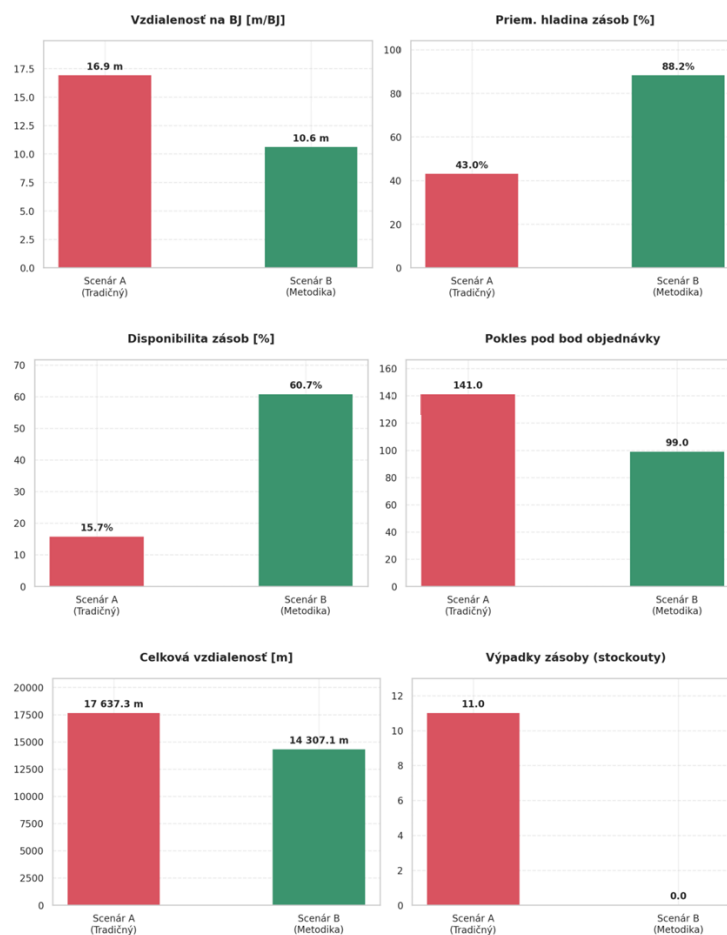
1. **Počiatkové nastavenie a simulácia tradičného stavu:** Najskôr bola prípadová štúdia spustená v režime tradičného štíhleho zásobovania. Logistické vlaky jazdili po fixne stanovených okružných trasách v pevných časových intervaloch. Tento stav slúžil ako referenčná báza pre komparatívnu analýzu.
2. **Spustenie dynamického cyklu v SimPy:** Následne bol spustený navrhnutý systém. V prostredí SimPy bol nasimulovaný nepretržitý zber dát o stave zásob na linkách. **Blok B** na základe taktu spotreby proaktívne predikoval momenty vyčerpania zásob a automaticky priradil časové okná a stupne priority (kritická, vysoká, štandardná). Následne algoritmus *K-means++* vykonal adaptívne zhlukovanie zastávok.
3. **Spustenie a testovanie optimalizačného jadra:** Pre pripravené zhľuky sa v **Bloku C** testovalo generovanie trás. V aplikácii bol využitý algoritmus adaptívneho prehľadávania širokého okolia s využitím simulovaného žihania:
 - o *Adaptívne vyhľadávanie širokého okolia (ALNS-SA)* bolo nasadené na globálnu optimalizáciu celej zmeny, kde vďaka mechanizmu simulovaného žihania dokázalo nájsť stabilnejšie minimá pri rozsiahlej sieti 40 pracovísk.
4. **Simulácia stochastických vplyvov a manažment odchýlok:** Počas simulačného behu vstupovali do systému stochastické javy. V **Bloku E** sa testovala reakcia na odchýlky. Pri prekročení kritickej tolerancie (Červená zóna – riziko prestoja linky) systém úspešne aktivoval spätnú väzbu a za behu vykonal inteligentné preplánovanie trás, zatiaľ čo nekritické odchýlky odfiltroval. Všetky prevádzkové časy boli priebežne ukladané do historickej databázy

Na základe experimentálneho overenia bol porovnaný tradičný systém milk-run zásobovania voči navrhovanej metodike. Na základe implementovaného predikčného modelu a monitorovacích mechanizmov boli minimalizované prepravné vzdialenosti, zlepšená disponibilita zásob, vyvážená logistická flotila, úplná eliminácia prestojov výroby a znížená viazanosť zásob vo výrobe. Počas 5 zmenového experimentu sa spresňoval aj predikčný model na základe zberu historických dát.

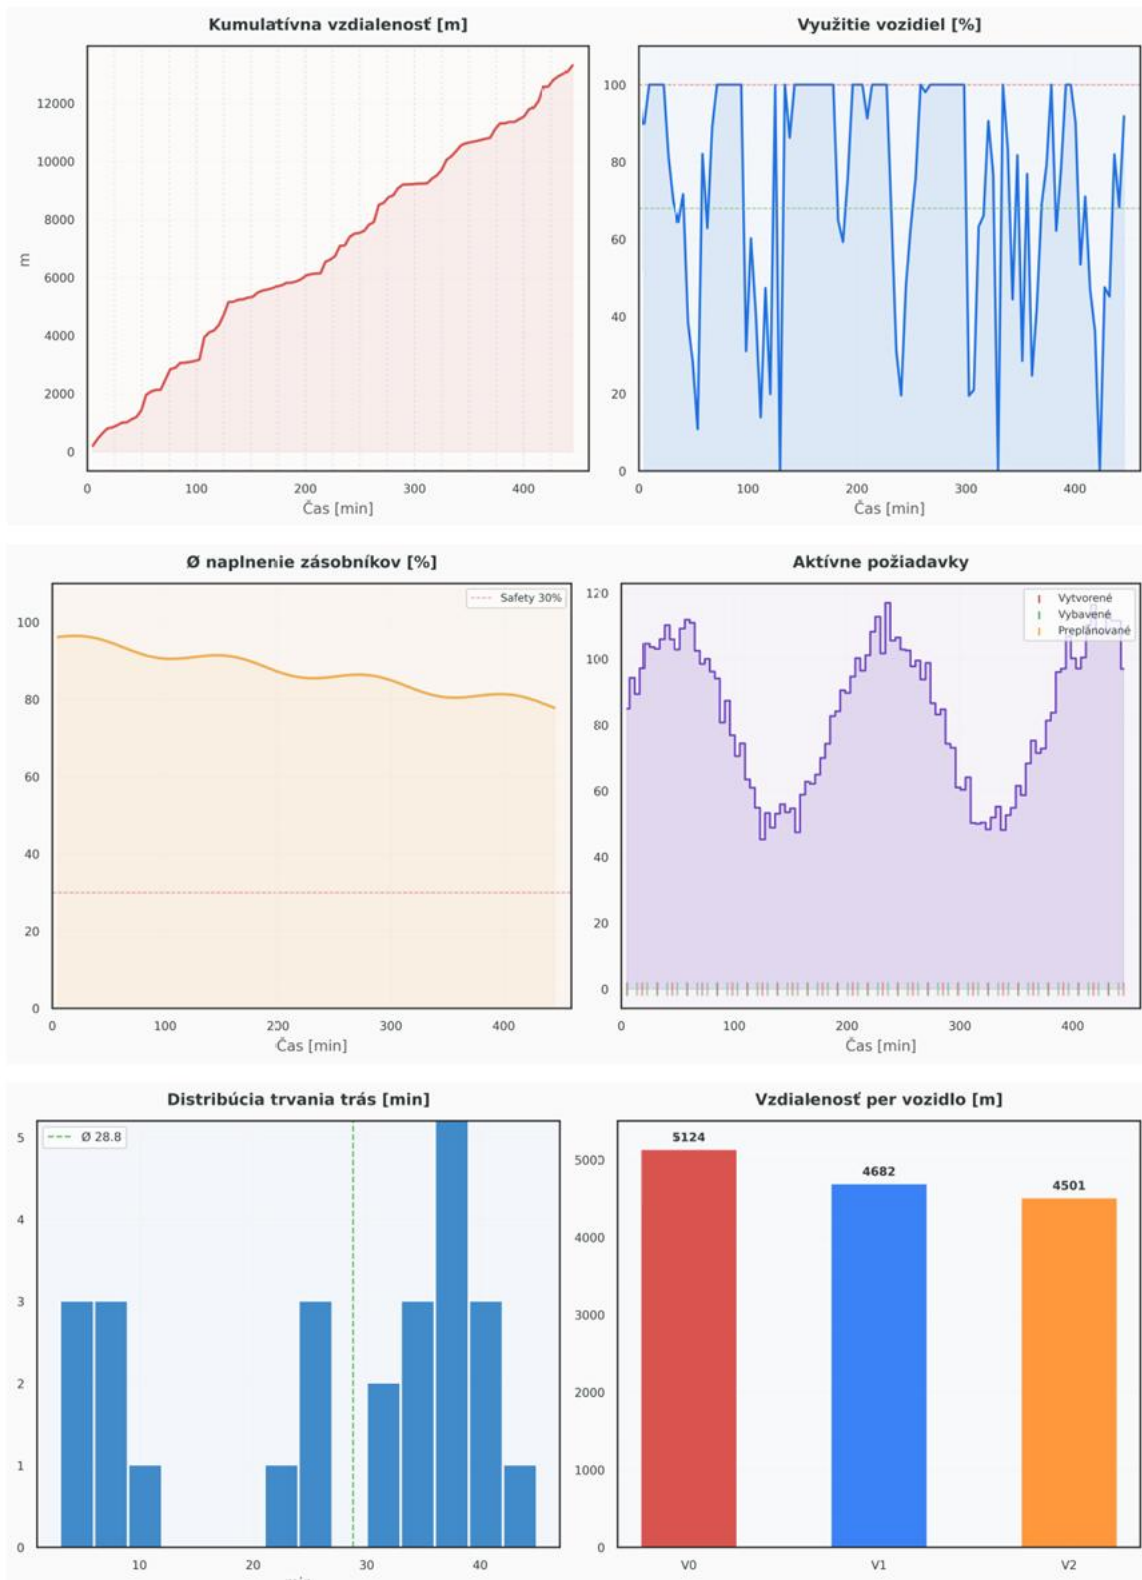
Následné grafy a tabuľka ukazujú porovnanie tradičného systému voči navrhovanej metodike, ako aj grafy distribúcie a trvania trás, priemerného naplnenia zásobníkov a tvorbe požiadaviek v čase.

Tab. 2 Porovnanie tradičného milk-run systému voči navrhovanej metodike

KPI	Scenár A – Tradičný	Scenár B – Metodika	Zmena [%]	Hodnotenie
— Zásobovacia spoľahlivosť —				
Disponibilita zásob [%]	15,7	60,7	+286.6%	✓ Metodika lepšia
Čas pod bezp. hladinou [min]	375	175	-53.3%	✓ Metodika lepšia
Min. zásoba na pracovisku [ks]	0	13	—	✓ Metodika lepšia
Výpadky zásob	11	0	-100.0%	✓ Metodika lepšia
Priem. hladina zásob [%]	43	88,2	+105.1%	✓ Metodika lepšia
Pokles pod bod objednávky	141	99	-29.8%	✓ Metodika lepšia
— Logistické náklady —				
Celková vzdialenosť [m]	17637	14307	-18.9%	✓ Metodika lepšia
Vzdialenosť / dodávka [m]	127,8	49,2	-61.5%	✓ Metodika lepšia
Počet trás	43	31	-27.9%	✓ Metodika lepšia



Obr. 7 Štatistické ukazovatele - tradičný systém vs. navrhovaná metodika



Obr. 8 Grafy sledovaného systému

5. Teoretické a praktické prínosy dizertačnej práce

Primárnym teoretickým prínosom práce je **návrh komplexnej metodiky dynamického krátkodobého plánovania a riadenia zásobovacích procesov v inteligentných výrobných systémoch**. Metodika v štruktúre piatich blokov (A–E) systematicky pokrýva celý cyklus od zberu dát z reálneho výrobného systému až po verifikáciu rozvrhu zásobovacích trás prostredníctvom diskretnej udalostnej simulácie. Tento ucelený prístup predstavuje rozšírenie existujúceho teoretického rámca, v ktorom sa problematika dynamického zásobovania rieši len čiastočne bez prediktívnych modelov. V práci bol taktiež navrhnutý **konceptný, matematický a simulačný modul** a ich vzájomné prepojenie. Ďalším prínosom je **návrh štruktúry údajov a spôsobu ich zberu a prenosu z reálneho systému do virtuálneho prostredia**. Práca konkrétne definuje, aké veličiny je potrebné monitorovať na úrovni výrobných pracovísk a zásobovacích vozidiel, akým spôsobom sa tieto dáta integrujú s MES/SAP systémami a technológiami RTLS, a v akej forme vstupujú do predikčných a optimalizačných algoritmov. Tým sa vyplní medzera medzi abstraktnými konceptmi kyberneticko-fyzických systémov a ich konkrétnou implementáciou v logistickej praxi. Práca ďalej prispieva **návrhom kritérií pre výber optimálneho rozvrhu zásobovacích prepravných trás v podmienkach dynamicky sa meniaceho výrobného prostredia**. Definované kritériá zohľadňujú viaceré dimenzie výkonnosti – úroveň obsluhy pracovísk vyjadrená metrikou OTD (On-Time Delivery), dodržanie časových okien, celkovú prejazdovú vzdialenosť a mieru výpadkov materiálu – čo umožňuje multikritériálne porovnanie scenárov zásobovania. Samostatným prínosom je **návrh hybridného algoritmu pre plánovanie dynamických prepravných trás**, integrujúceho predikciu spotrebných požiadaviek na báze Holt Wintersovho exponenciálneho vyrovnávania, adaptívne zhlukovanie zastávok, a metaheuristické optimalizačné metódy (ACS+2-opt, ALNS-SA). Tieto komponenty sú vzájomne prepojené prostredníctvom spúšťacieho mechanizmu, ktorý reaguje na udalosti v reálnom čase a iniciuje preplánovanie trás len vtedy, keď je to skutočne potrebné. Posledným teoretickým prínosom je **začlenenie diskretnej udalostnej simulácie** ako verifikačného nástroja v rámci metodického postupu. Simuláciou v prostredí SimPy sa overuje správnosť a robustnosť navrhnutých zásobovacích rozvrhov ešte pred ich nasadením do reálnej prevádzky, pričom výsledky slúžia aj ako základ pre štatistické porovnanie dynamickej metodiky s tradičným fixným milk-run systémom.

Najvýznamnejším praktickým prínosom práce je **všeobecne použiteľný metodický postup pre krátkodobé dynamické plánovanie a riadenie vnútro podnikových zásobovacích procesov**. Postup je navrhnutý tak, aby bol aplikovateľný v rôznych typoch výrobných podnikov bez ohľadu na konkrétnu konfiguráciu layoutu, počet pracovísk či použitý informačný systém. Predpokladom úspešnej aplikácie je dostupnosť dát o spotrebe materiálu v reálnom čase, čo je v prostredí Priemyslu 4.0 čoraz bežnejší predpoklad. Priamym praktickým výsledkom je **zefektívnenie procesu krátkodobého plánovania zásobovania**. Simulačné experimenty preukázali, že dynamická metodika (Scenár B) v porovnaní s tradičným fixným milk-run systémom (Scenár A) dosahuje merateľné zlepšenie vo vybraných ukazovateľoch výkonnosti, predovšetkým z hľadiska úrovne obsluhy pracovísk a redukcie výpadkov materiálu. Znižuje sa tiež zbytočná prejazdová vzdialenosť prepočítaná na jednotku skutočne obsluženého dopytu. Tretím praktickým prínosom je **rýchla adaptabilita zásobovacieho rozvrhu na aktuálne požiadavky z výroby a disponibilné logistické kapacity**. Spúšťací mechanizmus zabezpečuje, že zásobovací plán sa aktualizuje priebežne na základe skutočného stavu zásob a predikovaného vývoja spotreby, a nie podľa vopred stanoveného časového harmonogramu. Výsledkom je výrazné skrátenie reakčnej doby systému na neočakávané zmeny výrobného programu alebo výpadky kapacít. V neposlednom rade práca prispieva **vytvorenou softvérovou aplikáciou**,

ktorá slúži ako plne funkčný prototyp implementujúci všetky bloky metodiky vrátane interaktívneho používateľského rozhrania, vizualizácie výsledkov a exportu do formátu Excel. Aplikácia môže byť využitá ako základ pre ďalší výskum alebo ako referenčná implementácia pri nasadení metodiky v priemyselnom prostredí.

Záver

Predložená dizertačná práca sa zaoberala problematikou dynamického krátkodobého plánovania a riadenia procesov internej logistiky v podmienkach inteligentných výrobných systémov. Hlavnou motiváciou výskumu bola identifikovaná nedostatočnosť tradičných milk-run systémov vo variabilných výrobných prostrediach, v ktorých sa výrobný mix mení rýchlejšie, ako je statický zásobovací systém schopný zareagovať. Výstupom práce je päťbloková metodika, ktorá vytvára komplexný systém krátkodobého plánovania zásobovacích procesov. Metodika pokrýva plánovací a riadiaci cyklus od zberu dát, cez predikciu požiadaviek na spotrebu a optimalizáciu zásobovacích trás s využitím metaheuristických algoritmov, až po monitorovanie procesu, detekciu odchýlok a riadené preplánovanie s mechanizmom proti osciláciám. Táto metodika predstavuje vyplnenie medzery v rámci existujúcich teoretických rámcov, v ktorých sa problematika dynamického zásobovania doposiaľ riešila len čiastočne. Navrhovaná metodika bola overená prostredníctvom softvérovej simulačnej aplikácie implementovanej v prostredí Python, SimPy a NiceGUI. Porovnávací experiment aj záťažový test robustnosti na rozšírenej dátovej množine jednoznačne preukázali prevahu navrhovanej metodiky nad tradičným fixným systémom vo všetkých sledovaných dimenziách výkonnosti. Z hľadiska zásobovacej spoľahlivosti metodika v oboch experimentoch eliminovala výpadky zásob, ktoré v tradičnom scenári nastali štyrikrát, resp. jedenásťkrát. Navrhovaná metodika zároveň nevedie k nárastu logistických nákladov – celková prejdená vzdialenosť Scenáru B bola v oboch experimentoch nižšia oproti tradičnému systému (–13,5 % a –18,9 %), čo potvrdzuje, že konsolidácia dynamicky zostavovaných trás zvyšuje efektivitu využitia vozidiel. Viacmenový experiment navyše potvrdil, že výkonnostné zlepšenia nie sú jednorazovým javom – systém sa s pribúdajúcimi dátami stabilizuje a jeho predikčná presnosť rastie. Na teoretickej úrovni práca prináša komplexnú a formálne popísanú metodiku pokrývajúcu celý cyklus dynamického zásobovania, návrh dátových štruktúr a integračných rozhraní pre reálne výrobné systémy, definovanú sadu multikriteriálnych KPI pre porovnávanie zásobovacích scenárov a začlenenie diskkrétnej udalostnej simulácie ako verifikačného nástroja priamo do metodického postupu. Na praktickej úrovni predstavuje kľúčový príspevok plne funkčný softvérový prototyp implementujúci všetky bloky metodiky, ktorý môže slúžiť ako referenčná implementácia pri nasadení v priemyselnom prostredí, ako aj všeobecne použiteľný metodický postup aplikovateľný v rôznych typoch výrobných podnikov nezávisle od konkrétnej konfigurácie layoutu či použitých informačných systémov. Identifikované smery ďalšieho výskumu zahŕňajú obojsmerné prepojenie zásobovacieho plánovania s výrobným rozvrhovaním, uzavretie spätnoväzobnej slučky s reálnym systémom prostredníctvom priameho napojenia na RTLS a MES/ERP, aplikáciu reinforcement learning na adaptáciu konfiguračných parametrov systému a pilotné nasadenie metodiky v reálnom výrobnom prostredí ako záverečný krok jej validácie. Predložená práca nadväzuje na koncept vedecko-výskumnej línie Katedry priemyselného inžinierstva Žilinskej univerzity v Žiline v oblasti digitalizácie výrobných a logistických systémov a vyplňa identifikovanú výskumnú medzeru na úrovni operatívneho dynamického plánovania vnútro podnikového zásobovania. Tým rozširuje a uzatvára metodický rámec budovaný predchádzajúcimi prácami na katedre – od návrhu infraštruktúry digitálneho dvojčata, cez statické projektovanie logistiky, až po dynamické operatívne riadenie zásobovacích procesov v reálnom čase.

Resumé

This doctoral thesis presents an innovative methodology for the dynamic, proactive, and adaptive management of internal logistics in smart factories (Industry 4.0). Traditional static milk-run systems with fixed routes and schedules fail to respond flexibly to consumption fluctuations and operational disruptions in high-variety manufacturing. To overcome these limitations, this research proposes a comprehensive five-block cyber-physical architecture operating in a closed-loop system that transforms static planning into a live, learning environment.

The methodology continuously captures dynamic production data and uses a Holt-Winters triple exponential smoothing model to proactively predict material depletion moments. Raw requirements are converted into industrial packaging units, prioritized, assigned strict time windows, and clustered using a K-means++ algorithm into capacity-balanced groups. The optimization core then allows a flexible choice between an Ant Colony System (ACS + 2-opt) for real-time re-routing and an Adaptive Large Neighborhood Search with Simulated Annealing (ALNS-SA) for global optimization. These mathematically generated routes are immediately stress-tested within a discrete event simulation (DES) application developed in Python (SimPy, NiceGUI) to evaluate their robustness against stochastic operational noise, such as handling time fluctuations and traffic delays. Validated schedules are distributed as digital commands to operator terminals. Finally, the control loop is closed via continuous IoT monitoring that tracks time and material deviations, triggering immediate on-the-fly re-routing during disruptions, while saving operational timestamps into a historical database to continually refine the forecasting models.

The proposed solution was experimentally verified on a complex use case comprising 40 production workstations and 204 material items. A comparative analysis demonstrated that transitioning to this dynamic approach completely eliminated logistics-induced downtime due to proactive management. Furthermore, adaptive clustering significantly reduced the total distance traveled by the logistics fleet, optimized operator workload distribution, and lowered average shop-floor inventory levels, successfully freeing up valuable manufacturing space. The thesis bridges operations research with modern software engineering, providing an industrially applicable Digital Twin tool for internal logistics.

Zoznam použitej literatúry

- [1] ADELANTADO, F., VILAJOSANA, X., TUSET-PEIRO, P., MARTINEZ, B., MELIA-SEGUI, J., WATTEYNE, T. 2017. Understanding the Limits of LoRaWAN. IEEE Communications Magazine, 55(9), 34–40. <https://doi.org/10.1109/mcom.2017.1600613>
- [2] ALARIFI, A., AL-SALMAN, A., ALSALEH, M., ALNAFESSAH, A., AL HADHRAMI, S., AL-AMMAR, M. A., & AL-KHALIFA, H. S. 2016. Ultra Wideband Indoor Positioning Technologies: Analysis and Recent Advances. Sensors (Basel, Switzerland), 16(5). <https://doi.org/10.3390/s16050707>
- [3] ANASOFT, 2019. [online]. 2019 [cit. 2024-11-01]. Dostupné z: <https://www.anasoft.com/emans/sk/home/Novinky-blog/blog/digitalne-dvojca-veduca-technologiea-inteligentneho-priemyslu>
- [4] ANTONIUK, I. 2022. Krátkodobé plánovanie s podporou simulácie v inteligentnej výrobe. [Dizertačná práca]. Žilina: Žilinská univerzita v Žiline, Strojnícka fakulta, Katedra priemyselného inžinierstva.
- [5] ANTONIUK, I., SVITEK, R., KRAJČOVIČ, M., & FURMANNOVÁ, B. 2021. Methodology of design and optimization of internal logistics in the concept of Industry 4.0. Transportation Research Procedia, 55, 503–509. <https://doi.org/10.1016/j.trpro.2021.07.093>
- [6] ASSECO CEIT, 2024. [online]. 2024 [cit. 2024-11-01]. Dostupné z: <https://www.asseco-ceit.com/sk/twiserion-digital-manager/>
- [7] ATP JOURNAL, 2024. [online]. 2024 [cit. 2024-08-03]. Dostupné z: https://www.atpjournalsk.com/rubriky/prehľadove-clanky/industry-5.0-koncept-technologie-ciele-1.html?page_id=33728
- [8] BAELDUNG, 2024. [online]. 2024 [cit. 2025-01-04]. Dostupné z: <https://www.baeldung.com/cs/simulated-annealing>
- [9] BAGHERI, B., YANG, S., KAO, H.-A., LEE, J. 2015. Cyber-physical Systems Architecture for Self-Aware Machines in Industry 4.0 Environment. IFAC PapersOnLine, 48(3), 1622–1627. <https://doi.org/10.1016/j.ifacol.2015.06.318>
- [10] BAHETI, R., GILL, H. 2011 Cyber-Physical Systems. The Impact of Control Technology, 2011, 161-166.
- [11] BÁNYAI, T., FRANCUZ, Á. 2022. A New Design Approach for Milkrun Based In-Plant Supply in Manufacturing Systems. Journal of Machine Engineering. <https://doi.org/10.36897/jme/152245>
- [12] BINGHAI, Z., LINGWEI, Z. 2022. A multi-objective decomposition evolutionary algorithm based on the double-faced mirror boundary for a milk-run material feeding scheduling optimization problem. Computers & Industrial Engineering, 171, 108385. <https://doi.org/10.1016/j.cie.2022.108385>
- [13] BLUM, C., ROLI, A. 2003. Metaheuristics in combinatorial optimization. ACM Computing <https://doi.org/10.1145/937503.937505>

- [14] *Surveys*, 35(3), 268–308. BOCEWICZ, G., NIELSEN, I., BANASZAK, Z. 2019. Blockage-Free Route Planning for In-Plant Milk-Run Material Delivery Systems. *Studies in Systems, Decision and Control*, 105–132. https://doi.org/10.1007/978-3-030-27652-2_6
- [15] BOCEWICZ, G., NIELSEN, P., & ZBIGNIEW, B. 2019. Milk-run routing and scheduling subject to different pick-up/delivery profiles and congestion avoidance constraints. *IFAC-PapersOnLine*, 52(8), <https://doi.org/10.1016/j.ifacol.2019.08.089>
- [16] 313–320. BOWERSOX, D. J., CLOSS, D. J. 2011. *Logistical management : the integrated supply chain process*. New Delhi Tata Mcgraw-Hill.
- [17] BRITANNICA, 2024. [online]. 2024 [cit. 2024-08-02]. Dostupné z: <https://www.britannica.com/technology/history-of-technology>
- [18] BUYUKOZKAN, K., BAL, A., OKSUZ, K., M., KAPUKAYA, N., E. SATOGLU, I., S. 2019. A Mathematical Model and a Matheuristic for In-Plant Milk-Run Systems Design and Application in White Goods Industry. *Lecture Notes in Management and Industrial Engineering*, 99–112. https://doi.org/10.1007/978-3-030-03317-0_9
- [19] BUYUKOZKAN, K., SATOGLU, S., I. 2020. A Mathematical Model and an Artificial Bee Colony Algorithm for In-Plant Milk-Run Design. *Lecture Notes in Management and Industrial Engineering*, 106–118. https://doi.org/10.1007/978-3-030-42416-9_11
- [20] CLINE, B., NICULESCU, R. S., HUFFMAN, D., & DECKEL, B. 2017. Predictive maintenance applications for machine learning. *IEEE Xplore*. <https://doi.org/10.1109/RAM.2017.7889679>
- [21] COURSEERA, 2023. [online]. 2023 [cit. 2024-08-31]. Dostupné z: <https://www.coursera.org/articles/structured-data>
- [22] DEB, A. 2011. *Introduction to soft computing techniques: artificial neural networks, fuzzy logic and genetic algorithms*. Elsevier EBooks, 3–24. <https://doi.org/10.1533/9780857090812.1.3>
- [23] DEDIĆ, N., STANIER, C. 2017. Measuring the success of changes to Business Intelligence reporting. *Journal of solutions to Management improve Business Intelligence Analytics*, 4(2), <https://doi.org/10.1080/23270012.2017.1299048>
- [24] DER, V. 2018. *PROCESS MINING : data science in action*. 130–144.
- [25] DHL, 2023. [online]. 2023 [cit. 2024-11-30]. Dostupné z: <https://www.dhl.com/discover/sk-sk/logistics-advice/import-export-advice/what-is-logistics>
- [26] DORIGO, M., GAMBARDELLA, L. M. 1997. Ant colony system: a cooperative learning approach to the traveling salesman problem. *IEEE Transactions on Evolutionary Computation*, 1(1), 53. <https://doi.org/10.1109/4235.585892>
- [27] DORIGO, M., STÜTZLE, T. (2004) *Ant Colony Optimization*. Cambridge: MIT Press. ISBN: 978-0-262-04219-2, <https://mitpress.mit.edu/9780262042192/ant-colony-optimization/>
- [28] DROSTE, M., DEUSE J. 2011. A Planning Approach for In-plant Milk Run Processes to Optimize Material Provision in Assembly Systems. *Springer EBooks*, 604–610. https://doi.org/10.1007/978-3-642-23860-4_99
- [29] ENCYCLOPEDIA, 2024. [online]. 2024 [cit. 2024-08-02]. Dostupné z: <https://www.encyclopedia.com/history/news-wires-white-papers-and-books/second-industrial-revolution>
- [30] EUROPARL, 2020. [online.] 2020 [cit. 2024-12-01]. Dostupné z: <https://www.europarl.europa.eu/topics/sk/article/20200827STO85804/umela-inteligencia-definicija-vyuzitie>

- [31] FACCHINI, F., MOSSA, G., TULLIO, D., S. 2022. A Milk-run routing and Scheduling model for a Smart Manufacturing System. *IFAC PapersOnLine*, 55(10), 1122–1127.
<https://doi.org/10.1016/j.ifacol.2022.09.540>
- [32] FAWCETT, T., PROVOST, F. 2013. *Data Science for Business*. ResearchGate; O'Reilly Media Inc.
- [33] GENDREAU, M., JEAN-YVES POTVIN. (2010). *Handbook of Metaheuristics*. Springer Us.
- [34] GEZICI, S., TIAN, Z., GIANNAKIS, G. B., KOBAYASHI, H., MOLISCH, A. F., POOR, H. V., SAHINOGLU, Z. 2005. Localization via ultra-wideband radios: a look at positioning aspects for future sensor networks. *IEEE Signal Processing Magazine*, 22(4), 70–84.
<https://doi.org/10.1109/MSP.2005.1458289>
- [35] GLOVER, F., LAGUNA, M. 2002. *Tabu search*. Kluwer Academic.
- [36] GOTTHARDT, S., HULLA, M., EDER, M., KARRE, H., RAMSAUER, C. 2019. Digitalized milk-run system for a learning factory assembly line. *Procedia Manufacturing*, 31, 175–179.
<https://doi.org/10.1016/j.promfg.2019.03.028>
- [37] GREGOR, M., HODOŇ, R., GRZNÁR, P., MOZOL, Š. 2022. Design of a System for Verification of Automatic Guided Vehicle Routes Using Computer Emulation. *Applied Sciences*, 12(7), 3397.
<https://doi.org/10.3390/app12073397>
- [38] GREGOR, T., KRAJČOVIČ, M., & WIĘCEK, D. 2017. Smart Connected Logistics. *Procedia Engineering*, 192, <https://doi.org/10.1016/j.proeng.2017.06.046>
- [39] 265–270. GU, J., GOETSCHALCKX, M., MCGINNIS, L. F. 2010. Research on warehouse design and performance evaluation: A comprehensive review. *European Journal of Operational Research*, 203(3), 539–549. <https://doi.org/10.1016/j.ejor.2009.07.031>
- [40] GUNASEKARAN, A., NGAI, E. W. T. 2004. Information systems in supply chain integration and management. *European Journal of Operational Research*, 159(2), 269–295.
<https://doi.org/10.1016/j.ejor.2003.08.016>
- [41] HAN, J., KAMBER, M., PEI, J. 2012. *Data Mining: Concepts and Techniques*. Elsevier Inc.
<https://doi.org/10.1016/C2009-0-61819-5>
- [42] Harle, R. 2013 A Survey of Indoor Inertial Positioning Systems for Pedestrians. *Communications Surveys & Tutorials IEEE*, 15, 1281-1293. <https://doi.org/10.1109/SURV.2012.121912.00075>
- [43] HOLUBEK, R., KOSTAL, P. 2013. *The Intelligent Manufacturing Systems*. Advanced Science
<https://doi.org/10.1166/asl.2013.4816>
- [44] Letters, 19(3), 972–975. HOU, X., ARSLAN, T., ARIEF AFFENDI JURI, WANG, F. 2016. Indoor Localization for Bluetooth Low Energy Devices Using Weighted Off-set Triangulation Algorithm. *Proceedings of the Satellite Division's International Technical Meeting*.
<https://doi.org/10.33012/2016.14720>
- [45] CHEN, 2024. [online]. 2024 [cit. 2024-08-02]. Dostupné z: <https://www.investopedia.com/terms/i/industrial-revolution.asp>
- [46] CHOPRA, S., MEINDL, P. 2016. *Supply Chain Management : Strategy, Planning and Operation* (6th ed.). Pearson Education.
- [47] CHRISTOPHER, M. 2016. *Logistics & Supply Chain Management*, 5th Edition. FT Publishing International.
- [48] IBM, 2024. [online]. 2024 [cit. 2024-08-02]. Dostupné z: <https://www.ibm.com/think/topics/iaas>
- [49] IKUMAPAYI, O., M., LASEINDE, O., T., ELEWA, R. R., SAMSON, T., TITILAYO A., E. 2024. Smart Sensors for Real-time Monitoring in a Sustainable Logistics. *E3S Web of Conferences*, 552,
<https://doi.org/10.1051/e3sconf/202455201079>
- [50] 01079. IMPACT, 2024. [online]. 2024 [cit. 2024-08-31]. Dostupné z: <https://impact.com/marketing-intelligence/7-vs-big-data/>
- [51] INDUSTRY4, 2024. [online] 2024 [cit. 2024-08-03]. Dostupné z: <https://industry4.sk/o-industry-4-0/principy/>
- [52] JACOBS, F., R., BERRY, W. L., D CLAY WHYBARK, VOLLMANN, T. E. 2011. *Manufacturing planning and control for supply chain management*. New York McGraw Hill Professional.
- [53] JAFARI, N., AZARIAN, M., YU, H. 2022. Moving from Industry 4.0 to Industry 5.0: What Are the Implications for Smart Logistics? *Logistics*, 6(2), 26. <https://doi.org/10.3390/logistics6020026>

- [54] JIANG, H., XIAO, Y., LI, J., LIU, X. (2012). Prediction of the Melt Index Based on the Relevance Vector Machine with Modified Particle Swarm Optimization. *Chemical Engineering Technology*, 35(5), 819–826. <https://doi.org/10.1002/ceat.201100437>
- [55] KIRKPATRICK, S., GELATT, C.D., VECCHI, M.P. (1983) Optimization by Simulated Annealing. *Science*, 220(4598), 10.1126/science.220.4598.671 <https://www.science.org/doi/10.1126/science.220.4598.671>
- [56] 671–680. DOI: KLENK, E., GALKA, S., GÜNTNER, W. A. 2015. Operating Strategies for In-Plant Milk-Run Systems. *IFAC-PapersOnLine*, 48(3), 1882–1887. <https://doi.org/10.1016/j.ifacol.2015.06.361>
- [57] KLUSKA, K., PATRYCJA HOFFA-DABROWSKA, & ZWOLANKIEWICZ, A. 2019. Simulation Modeling of Milk-Run Internal Logistics System – Case Study. *Communications in Computer and Information Science*, 15–26. https://doi.org/10.1007/978-3-030-24299-2_2
- [58] KOSTRZEWSKI, M., VARJAN, P., GNAP, J. 2020. Solutions Dedicated to Internal Logistics 4.0. In: Grzybowska, K., Awasthi, A., Sawhney, R. (eds) *Sustainable Logistics and Production in Industry 4.0. EcoProduction*. Springer, Cham. https://doi.org/10.1007/978-3-030-33369-0_14
- [59] KRAJČOVIČ M., GRZNÁR, P., GAŠO, M., MOZOL, Š., KOMAČKA, D. 2023. MILK-RUN 4.0 – Supply system in conditions of intelligent production. *Trends and Innovative Approaches in Business Processes*, 26, 46-51
- [60] KRAJČOVIČ, M., GRZNÁR, P., GAŠO, M., MOZOL, Š., KOMAČKA, D. 2023. Milk-run 4.0 – supply system in conditions of intelligent production. *Trends and Innovative Approaches in Business Processes*, 23, 46-52.
- [61] KUMAR, R., KHANNA, R., KUMAR, S. (2021). Vehicular middleware and heuristic approaches for intelligent transportation system of smart cities. Elsevier EBooks, 163–175. <https://doi.org/10.1016/b978-0-323-85769-7.00019-7>
- [62] KUSIAK, A. 2018. Smart manufacturing. *International Journal of Production Research*, 56(1-2), <https://doi.org/10.1080/00207543.2017.1351644>
- [63] 508–517. LI, J., HAN, G., ZHU, C., SUN, G. 2016. An Indoor Ultrasonic Positioning System Based on TOA for Internet of Things. *Mobile Information Systems*, 2016, 1–10. <https://doi.org/10.1155/2016/4502867>
- [64] LIANG, S., RAJORA, M., LIU, X., YUE, C., ZOU, P., WANG, L. 2016. Intelligent Manufacturing Systems: A Review. *International Journal of Mechanical Engineering and Robotics Research*, 7(3), 324–330. <https://doi.org/10.18178/ijmerr.7.3.324-330>
- [65] Research, 7(2), 324–330. LOURENÇO, H. R., MARTIN, O. C., STÜTZLE, T. 2010. Iterated Local Search: Framework and Applications. *Handbook of Metaheuristics*, 363–397. https://doi.org/10.1007/978-1-4419-1665-5_12
- [66] MAO, Z., HUANG, D., FANG, K., WANG, C., LU, D. 2019. Milk-run routing problem with progress-lane in the collection of automobile parts. *Annals of Operations Research*, 291(1-2), 657–684. <https://doi.org/10.1007/s10479-019-03218-x>
- [67] MARIALUISA, M., MATTEO M., S., MUHAMMAD, S. 2023. Optimizing milk-run system and IT-based Kanban with artificial intelligence: an empirical study on multi-lines assembly shop floor. *Production & Manufacturing Research*, 11(1). <https://doi.org/10.1080/21693277.2023.2179123>
- [68] MARIALUISA, M., MATTEO M., S., MUHAMMAD, S. 2023. Optimizing milk-run system and IT-based Kanban with artificial intelligence: an empirical study on multi-lines assembly shop floor. *Production & Manufacturing Research*, 11(1). <https://doi.org/10.1080/21693277.2023.2179123>
- [69] MARR, B. 2015. *Big data: Using smart big data, analytics and metrics to make better decisions and improve performance*. John Wiley And Sons, Inc.
- [70] MCKINSEY, 2022. [online]. 2022 [cit. 2024-08-02]. Dostupné z: <https://www.mckinsey.com/featured-insights/mckinsey-explainers/what-are-industry-4-0-the-fourth-industrial-revolution-and-4ir>
- [71] MIQUEO, A., GRACIA-CADARSO, M., TORRALBA, M., GIL-VILDA, F., YAGÜE-FABRA, J., A. 2023. Multi-Model In-Plant Logistics Using Milkruns for Flexible Assembly Systems under Disturbances: An Industry Study Case. *Machines*, 11(1), 66–66. <https://doi.org/10.3390/machines11010066>

- [72] MONOSTORI, L., KÁDÁR, B., BAUERNHANSL, T., KONDOH, S., KUMARA, S., REINHART, G., SAUER, O., SCHUH, G., SIHN, W., UEDA, K. 2016. Cyber-physical systems in manufacturing. *CIRP Annals*, 65(2), 621–641. <https://doi.org/10.1016/j.cirp.2016.06.005>
- [73] MURATA, T. 1989 Petri nets: Properties, analysis and applications, in *Proceedings of the IEEE*, vol. 77, no. 4, pp. 541-580, April 1989, doi: 10.1109/5.24143.
- [74] NI, L. M., LIU, Y., LAU, Y. C., PATIL, A. P. 2003. LANDMARC: indoor location sensing using active <https://doi.org/10.1109/PERCOM.2003.1192765>
- [75] RFID. IEEE Xplore. PAWLEWSKI, P., KOSACKA-OLEJNIK, M., & WERNER LEWANDOWSKA, K. 2021. Digital Twin Lean Intralogistics: Research Implications. *Applied Sciences*, 11(4), <https://doi.org/10.3390/app11041495>
- [76] 1495. POLAK-SOPINSKA, A. 2019. Incorporating human factors in in-plant milk run system planning models. *Adv. Intell. Syst. Comput.* 876, 160–166 (2019). https://doi.org/10.1007/978-3-030-02053-8_26
- [77] PROVOST, F., FAWCETT, T. 2013. Data Science and Its Relationship to Big Data and Data-Driven Decision Making. *Big Data*, 1, 51-59. <https://doi.org/10.1089/big.2013.1508>
- [78] ROPKE, S., PISINGER, D. 2006. An adaptive large neighborhood search heuristic for the pickup and delivery problem with time windows. *Transportation Science*, 40(4), 455–472. <https://doi.org/10.1287/trsc.1050.0135>
- [79] ROSE, K., ELDRIDGE, S.D., & CHAPIN, L. 2015. THE INTERNET OF THINGS : AN OVERVIEW Understanding the Issues and Challenges of a More Connected World.
- [80] ROSING, V., M, SCHEER A-W, SCHEEL, V., H. 2015. The complete business process handbook. Volume 1, Body of knowledge from process modeling to BPM. Morgan Kaufmann Is An Imprint Of Elsevier. <https://www.elsevier.com/books/the-complete-business-process-handbook/von-rosing/978-0-12-799959-3>
- [81] SADIKU, M. N. O., TEMBELY, M., MUSA, S. M. 2018. Internet of Services. *International Journal of Advanced Research in Computer Science and Software Engineering*, 8(5), 91. <https://doi.org/10.23956/ijarcsse.v8i5.678>
- [82] SAEIK, F., AVGERIS, M., SPATHARAKIS, D., SANTI, N., DECHOUNIOTIS, D., VIOLOS, J., LEIVADEAS, A., ATHANASOPOULOS, N., MITTON, N., PAPAVALASSIOU, S. (2021). Task offloading in Edge and Cloud Computing: A survey on mathematical, artificial intelligence and control theory solutions. *Computer Networks*, 195, <https://doi.org/10.1016/j.comnet.2021.108177>
- [83] 108177. SEWIO, 2024. [online]. 2024 [cit. 2024-09-01] Dostupné z: <https://www.sewio.net/real-time-location-system-rtls-on-uwbl/>
- [84] SHAW, P. 1998. Using constraint programming and local search methods to solve vehicle routing problems. In: MAHER, M., PUGET, J.-F. (eds.) *Principles and Practice of Constraint Programming – CP98*. Lecture Notes in Computer Science, vol. 1520. Springer, Berlin, pp. 417–431. https://doi.org/10.1007/3-540_49481-2_30
- [85] SIPAHIOGLU, A., & ALTIN, I. 2019. A Mathematical Model for In-Plant Milk-Run Routing. *Pamukkale University Journal of Engineering Sciences*, 25(9), 1050–1055. <https://doi.org/10.5505/pajes.2019.03366>
- [86] SIPAHIOGLU, A., ACAR, I., ALTIN, I. (2024). A Metaheuristic Approach for In-Plant Milk-Run System with Autonomous Vehicles. *Networks and Spatial Economics*, 24(4), 1021–1041. <https://doi.org/10.1007/s11067-024-09650-2>
- [87] SISINNI, E., SAIFULLAH, A., HAN, S., JENNEHAG, U., & GIDLUND, M. 2018. Industrial Internet of Things: Challenges, Opportunities, and Directions. *IEEE Transactions on Industrial Informatics*, 14(11), 4724–4734. <https://doi.org/10.1109/tii.2018.2852491>
- [88] SKOKAN, M. 2020. Projektovanie výrobných systémov využívajúcich koncept digitálneho dvojčata. [Dizertačná práca]. Žilina: Žilinská univerzita v Žiline, Strojnícka fakulta, Katedra priemyselného inžinierstva.
- [89] SRIDHARAN, V., BERRY, W.L., UDAYABHANU, V. (1987) Freezing the Master Production Schedule Under Rolling Planning Horizons. *Management Science*, 33(9), 1137–1149. DOI: 10.1287/mnsc.33.9.1137

- [90] SVITEK, R. 2021. Návrh metodiky projektovania logistického systému v prostredí digitálneho dvojčaťa. [Dizertačná práca]. Žilina: Žilinská univerzita v Žiline, Strojnícka fakulta, Katedra priemyselného inžinierstva.
- [91] TAN, Y. 2016. Introduction (pp. 1–7). Morgan Kaufmann. <https://doi.org/10.1016/B978-0-12-809362-7.50001-7>
- [92] TAO, F., ZHANG, L., NEE, A. Y. C. 2011. A review of the application of grid technology in manufacturing. *International Journal of Production Research*, 49(13), 4119–4155. <https://doi.org/10.1080/00207541003801234>
- [93] TELLINI, T., SILVA, F. J. G., PEREIRA, T., MORGADO, L., CAMPILHO, R. D. S. G., & FERREIRA, L. P. 2019. Improving In-Plant Logistics Flow by Physical and Digital Pathways. *Procedia Manufacturing*, 38, 965–974. <https://doi.org/10.1016/j.promfg.2020.01.180>
- [94] TOMPKINS, J. A. 2010. *Facilities planning*. John Wiley & Sons ; Chichester.
- [95] TOTH, P., VIGO, D. 2015. *Vehicle routing : problems, methods, and applications*. Society for Industrial and Applied Mathematics (SIAM, 3600 Market Street, Floor 6, Philadelphia, PA 19104).
- [96] TREBUNA, P., PEKARCIKOVA, M., PETRIK, M. 2018. Application of Tecnomatix Process Simulate for optimisation of logistics flows. In *Acta Montanistica Slovaca*, Volume 23, Issue 4, pp. 378-389, ISSN 1335-1788
- [97] TURGAY, S., ÇOBAN, C. 2024. Heuristic-Based Hybrid Algorithm for Value Stream Design with Milk-Run Approach. *WSEAS TRANSACTIONS on BUSINESS and ECONOMICS*, 21, https://doi.org/10.37394/23207.2024.21.103_1262-1275.
- [98] VALIAUGA, 2020. [online]. 2020 [cit. 2024-08-04]. Dostupné z: https://www.atpjournals.sk/rubriky/prehľadove-clanky/cloud-computing-jehnacou-silou-vosvete-informacnych-technologii.html?page_id=30709
- [99] WIŚNIEWSKI, 2019. [online]. 2019 [cit. 2024-11-03]. Dostupné z: <https://versabox.eu/blog/model-digital-twin-in-intralogistics/>
- [100] WSCUBETECH, 2025. [online]. 2025 [cit. 2025-01-04]. Dostupné z: <https://www.wscubetech.com/resources/dsa/greedy-algorithms>
- [101] XENONSTACK, 2024. [online]. 2024. [cit. 2024-11-30]. Dostupné z: <https://www.xenonstack.com/blog/veracity-in-big-data>
- [102] ZHOU, B., WEN, M. 2024. A mutli-objective artificial electric field algorithm with reinforcement learning for milk-run assembly line feeding and scheduling problem. *Computers & Industrial* <https://doi.org/10.1016/j.cie.2024.110080>
- [103] Engineering, 190, 110080. ZÜHLKE, D., OLLINGER, L. 2011. Agile Automation Systems Based on Cyber-Physical Systems and Service-Oriented Architectures. In *Lecture notes in electrical engineering* (pp. 567–574). https://doi.org/10.1007/978-3-642-25553_3_70

Zoznam publikačnej činnosti

- [1] Komačka, D., & Furmannová, B. (2023). Cyfrowa transformacja procesów logistycznych w przemyśle motoryzacyjnym = Digital transformation of logistics processes in automotive industry. In *Technologie, procesy i systemy produkcyjne* (pp. 53–62). Bielsko-Biała, Poland: Wydawnictwo naukowe Uniwersytetu Bielsko-Bialskiego. [online]. <https://doi.org/10.53052/9788367652117.05>
- [2] Krajčovič, M., Grznár, P., Gašo, M., Mozol, Š., & Komačka, D. (2023). Milk-run 4.0 – supply system in conditions of intelligent production. In *Trendy a inovatívne prístupy v podnikových procesoch 2023* (pp. 46–51). Košice, Slovakia: Technická univerzita v Košiciach. [online].
- [3] Komačka, D., Krajčovič, M., & Gabajová, G. (2024). Digitization of value stream mapping via real time locating system. In *Invention for Enterprise 2024* (pp. 98–101). Bielsko-Biała, Poland: Fundacja Centrum Nowych Technologii. [online].
- [4] Krajčovič, M., Bastiuchenko, V., Furmannová, B., Botka, M., & Komačka, D. (2024). New approach to the analysis of manufacturing processes with the support of data science. *Processes*, 12(3), art. no. 449, pp. 1–26. <https://doi.org/10.3390/pr12030449>
- [5] Krajčovič, M., Matys, M., Gabajová, G., & Komačka, D. (2024). Utilization of immersive virtual reality as an interactive method of assignment presentation. *Electronics*, 13(8), art. no. 1430, pp. 1–13. <https://doi.org/10.3390/electronics13081430>
- [6] Komačka, D., Krajčovič, M., Gabajová, G., & Matys, M. (2024). The applications of data mining and data science in industrial engineering. In *Trends and Innovative Approaches in Business Processes 2024* (pp. 131–136). Košice, Slovakia: Technická univerzita v Košiciach. [online].
- [7] Marčan, M., Grznár, P., Papánek, L., & Komačka, D. (2025). Design and simulation of the AGV logistics system: case study. In *TRANSCOM 2025: 16th International Scientific Conference on Sustainable, Modern and Safe Transport* (Vol. 93, pp. 455–458). Amsterdam, Netherlands: Elsevier. <https://doi.org/10.1016/j.trpro.2025.11.069>
- [8] Komačka, D., Krajčovič, M., & Kasajová, M. (2025). Software support for design, simulation and optimization of production and logistics systems. In *Invention for Enterprise 2025* (pp. 38–43). Bielsko-Biała, Poland: Fundacja Centrum Nowych Technologii. [online].
- [9] Komačka, D., Krajčovič, M., Matys, M., & Marčan, M. (2025). Optimization of in-plant logistics processes in assembly systems using digital simulation tools: a case study using AGV and Twisierion Design Manager. In *TRANSCOM 2025: 16th International Scientific Conference on Sustainable, Modern and Safe Transport* (Vol. 93, pp. 328–333). Amsterdam, Netherlands: Elsevier. <https://doi.org/10.1016/j.trpro.2025.11.050>
- [10] Marčan, M., Furmann, R., & Komačka, D. (2025). Dynamic routing and real-time decision-making of AGVs. In *Invention for Enterprise 2025* (pp. 44–47). Bielsko-Biała, Poland: Fundacja Centrum Nowych Technologii. [online].