

MINISTERUL EDUCAȚIEI ȘI
CERCETĂRII
UNIVERSITATEA NAȚIONALĂ
DE ȘTIINȚĂ ȘI TEHNOLOGIE
POLITEHNICA BUCUREȘTI

TEZĂ DE DOCTORAT

-REZUMAT-

Cercetări privind optimizarea
operațiunilor logistice prin integrarea
Inteligenței Artificiale în sisteme de
management al depozitelor

Conducător științific,

Prof. univ. dr. ing. ec. Vasile BENDIC

Doctorand,

Ramy OBEIDAT

- 2024 -

PARTEA I.

Capitolul 1. STADIUL ACTUAL ÎN EVOLUȚIA LOGISTICII MĂRFURILOR PE PIAȚA INTERNĂ

1.1. Introducere

Logistica este un domeniu esențial pentru dezvoltarea economică globală, având rădăcini istorice îndepărtate, dar fiind definită ca știință a organizării producției și distribuției doar relativ recent. Evoluția logisticii este marcată de adaptarea continuă la cerințele tehnologice și economice moderne, devenind un pilon fundamental al economiei mondiale. În România, logistica a evoluat semnificativ, de la activitățile rudimentare desfășurate de cioplitori și zidari, la un comerț organizat și un transport modern, influențând profund dezvoltarea economică națională.

1.2. Evaluarea Stadiului Actual

Conceptul de logistică își are rădăcinile în activitățile militare și comerciale antice, fiind asociat cu organizarea eficientă a transportului și aprovizionării. Definițiile moderne ale logisticii includ organizarea combinată a factorilor de producție și distribuție, subliniind importanța optimizării resurselor. În România, primele inițiative de modernizare a rețelelor rutiere au început în anii 1930, cu proiecte majore care au conectat Bucureștiul cu principalele orașe din țară. În perioada postbelică, eforturile de reconstrucție au inclus refacerea infrastructurii și dezvoltarea transporturilor rutiere, feroviare, navale și aeriene, aspecte esențiale pentru dezvoltarea economică a țării.

Sarcinile sau scopul managementului logisticii pot fi ilustrate grafic prin conceptul celor 7 „R-uri - Right” sau cele 7 Potriviri dacă am traduce din limba engleză, fiind totodată și un concept vast răspândit și aplicat în prezent.[1]




Fig. 1.1.Sarcinile logisticii

1.3. Tehnologii și Tendințe Moderne în Logistică

Automatizarea și digitalizarea proceselor logistice au devenit esențiale în contextul actual. Introducerea tehnologiilor IoT (Internet of Things) permite monitorizarea în timp real a transporturilor, asigurând o transparență și eficiență sporite. Utilizarea inteligenței artificiale (AI) și a algoritmilor de machine learning pentru optimizarea rutelor și predicția cererii, reduce costurile și îmbunătățește timpii de livrare. Implementarea sistemelor ERP (Enterprise Resource Planning) și WMS (Warehouse Management Systems) integrate permite gestionarea eficientă a stocurilor și operațiunilor de depozitare, asigurând o gestionare fluidă a lanțului de aprovizionare.

Blockchain-ul este o altă tehnologie emergentă care transformă logistica, oferind un nivel de transparență și securitate fără precedent în gestionarea lanțului de aprovizionare. Prin utilizarea blockchain-ului, toate tranzacțiile și mișcările de marfă pot fi înregistrate într-un registru distribuit, care nu poate fi modificat, asigurând astfel integritatea datelor și reducând riscul de fraudă.

1.4. Evoluția Spațiilor Industriale

În România, piața spațiilor industriale a cunoscut o dezvoltare semnificativă în ultimele decenii, cu investiții majore în parcuri logistice și centre de distribuție, iar cea mai utilizată clasificare a spațiilor industriale este pe clase A, B, C, D etc., în funcție de dezvoltarea infrastructurii, specificațiile tehnice și serviciile disponibile.

1.5. Tehnici de manipulare a mărfurilor în logistică

Atunci când vorbim despre tehnici de manipulare a mărfurilor în logistica industrială, trebuie să înțelegem puțin procesele care conduc la decizia tehnologizării unor operațiuni, în vederea optimizării acestora. Deși centrele logistice și cele de distribuție sunt în continuă dezvoltare, încă din faza de proiect trebuie făcute previziuni asupra viitoarelor operațiuni care se vor desfășura în acestea, astfel încât să se stabilească cât mai corect nivelul de tehnologizare a acestora.

Operațiunile într-un centru de distribuție/depozitare au un set fundamental de activități în comun, care se pot regăsi în majoritatea sectoarelor de activitate:

- 1.5.1. Recepția**
- 1.5.2. Relocare în zona de așteptare**
- 1.5.3. Depozitare**
- 1.5.4. Pregătirea comenzii (order picking)**
- 1.5.5. Ambalare și/sau etichetare**
- 1.5.6. Sortare**
- 1.5.7. Livrarea**

La nivel global, cel mai ridicat nivel al acurateții livrării comenzilor este înregistrat în Japonia, atingând o performanță de 99,997%, față de media companiilor de top care este de 96%. [2]

Prin intermediul indicatorilor de performanță, orice manager poate face o analiză a necesității punctelor care necesită îmbunătățire, precum și dacă mecanizarea operațiunilor este

una mai productivă sau poate înlesni productivitatea. Un nivel ridicat de automatizare poate avea un efect invers celui dorit, întrucât automatizarea implică costuri foarte mari, instruirea deficitară a personalului, întreținere periodică costisitoare, complexitatea proceselor, limitarea operațiunilor și o reconfigurare dificilă a acestora. În principal, automatizarea nu va rezolva toate problemele care reies din indicatorii de performanță, ci ea se recomandă doar pentru procese complexe, de lungă durată și care implică acțiuni repetitive, însă cea mai bună abordare pentru a eficientiza activitățile într-un depozit, este să se simplifice cât mai mult operațiunile.

1.6. Sisteme de Depozitare

De la cabinete, dulapuri, cutii, containere și până la nenumăratele tipuri de rafturi, posibilitățile de stocare sunt într-o gamă extrem de largă.

Capacitatea depozitelor variază în funcție de cum pot fi stocate mărfurile, iar în prezent, sistemele de depozitare sunt adaptate nevoilor generale și cele mai populare sisteme de acest fel sunt sub formă modulară, permițând deținătorului flexibilitate în a le modifica în funcție de nevoi și de dimensiunea încăperii/halei, respectiv a mărfurilor de depozitat.

1.6.1. Cele mai populare sisteme de **rafturi** sunt cele **selective** de palete (**Fig. 1.2**) (**single-deep pallet rack**). Acestea sunt puse pereche, spate în spate, iar paletele sunt sprijinite pe traverse.

Principalul avantaj al acestor tipuri de rafturi este acela că oferă acces facil la toate mărfurile depozitate, totuși prezintă și un dezavantaj major, acela fiind faptul că necesită culoare mari pentru deplasarea utilajelor de manipulare, rezultând astfel o pierdere medie de 50%-60% din spațiul de pardoseală care poate fi exploatat. Există cazuri când datorită tipologiei mărfurilor care au același cod de produs pe mai multe palete și nu sunt supuse formei de stocare FIFO (first in-first out), deținătorul alege să folosească rafturi cu stocare dublă.

În acest rezumat mă voi opri aici cu prezentarea categoriilor de rafturilor pentru că acest tip de rafturi îl voi folosi și în depozitul pe care voi efectua simulări în capitolele următoare. Rafturile selective pot fi proiectate pentru a acoperi o gamă largă de utilaje de manipulare și în funcție de gradul acestora de complexitate, se poate exploata spațiul de pardoseală cu până la 60% pentru echipamente de tip VNA, care necesită culoarul cel mai îngust pentru deplasare.



Fig. 1.2. Sisteme de rafturi selective.
Sursă foto – depozit Euroccoper S.A.

1.7. Sisteme de Manipulare a Mărfurilor

În rândurile ce vor urma, voi face o clasificare a principalelor tehnologii de manipulare a mărfurilor și ce factori trebuie luați în considerare la alegerea acestora.

În cazul unor echipamente de manipulare, cum ar fi și cazul celui cu catarg retractabil (reach-truck), trebuie ales între avantajul oferit de amplasare (culoare de lățime minimă și cel

oferit de productivitate (lățimea mai mare a culoarelor permite accesul utilajelor mai ușor și mai rapid).

Tabel 1.2. – Lățimea minimă a culoarului pentru deservire

Tipul de utilaj	Culoar	Observații
Mini transportor/Stivuitoare	600 - 800 mm	
Transportor transpalet	1200 - 1400 mm	
Stivuitoare cu furcă bidirecțională și șină	1800 mm	
Stivuitoare cu furcă tridirecțională și șină	1700 - 1900 mm	
Ghidajul cu cablu pentru stivuitoarele de mai sus	+ 100 mm	Stivuitoare mai puțin precis
Stivuitoare articulat cu furcă frontală	1800 - 2100 mm	Conducător de stivuitoare specializat
Stivuitoare cu furci frontale	2000 - 3000 mm	
Stivuitoare cu catarg retractabil (reach-truck)	2800 - 3000 mm	Min. 2700 mm
Stivuitoare de pregătire comandă (order-picker)	1400 - 1600 mm	Depinde de înălțime
Stivuitoare cu furci frontale cu trei roți	3500 - 4000 mm	
Stivuitoare cu furci frontale cu patru roți	4000 - 4500 mm	
Stivuitoare omnidirecțional		Depinde de sarcina

Lungimea culoarelor de serviciu trebuie calculată pentru fiecare proiect, dar în general se recomandă următoarele valori:

- Între 30 – 60m, culoare cu debușeu - pentru culoare deservite de stivuitoare cu furcă direcțională. Culoarele înfundate nu permit întoarcerea sau revenirea pe alt culoar, ele duc, cu excepția cazurilor deosebite, la pierderi importante ale productivității. Ele nu asigură nici condiții bune de securitate.
- Între 60 și 120m, culoare deservite de stivuitoare. Lungimea aleilor deservite de stivuitoare influențează durata ciclului doar într-un mod foarte relativ. De fapt, perioadele de accelerare și încetinire au o durată constantă; un surplus de lungime se parcurge cu viteză mai mare, deci nu consumă timp mai mult.

Echipamentele de manipulare sau mașinile de ridicat, cum sunt denumite în prescripția tehnică R1-2010 ISCIR, în segmentul de logistică industrială, pot fi manuale sau automatizate.

1.8. Concluzii și Recomandări

În contextul noilor cerințe din logistica industrială și a progreselor tehnologice, inteligența artificială (AI) joacă un rol din ce în ce mai important. AI permite analiza datelor în timp real și predicția cererii, optimizând astfel rutele de transport și gestionarea stocurilor. Prin implementarea algoritmilor de machine learning, companiile pot anticipa fluctuațiile cererii și ajusta strategiile de aprovizionare pentru a minimiza costurile și a maximiza eficiența. De asemenea, AI contribuie la automatizarea proceselor repetitive, reducând erorile umane și îmbunătățind acuratețea operațiunilor logistice.

Capitolul 2. OPTIMIZAREA SPAȚIULUI DE DEPOZITARE

2.1. Introducere

Pentru a înțelege mai ușor modul de optimizare a spațiului unui depozit, în acest capitol, ne vom orienta către un depozit de clasă A, cu o suprafață de 4.000m², înălțimea la coamă 13m, din care utili 11m, fiind adesea dimensiunea de referință, pentru compartimentarea centrelor logistice nou construite de către dezvoltatorii imobiliari, excepție făcând-o situațiile când spațiile sunt închiriate încă din faza de proiect, și sunt compartimentate conform cerințelor clientului. Proiectarea unui depozit a intrat într-o etapă mult mai sofisticată, datorită evoluției operațiunilor pe care un centru de distribuție poate să le facă, a tehnologiilor disponibile în prezent, a procedeele de gestionare a stocurilor și rotației stocului, precum și în funcție de mijloacele de transport mărfuri ce sosesc la încărcare sau descărcare. Un depozit care nu este gândit pentru a fi ușor adaptabil nevoilor și noilor tendințe, nu va deveni profitabil.

2.2. Factori determinanți în planificarea spațiului de depozitare[1]

2.2.1. Ce categorii de mărfuri vor sosi în depozit?

În orice discuție care se poartă pentru a contracta un client, un operator logistic, înainte de a semna contractul și a-și configura depozitul, trebuie să cunoască parametrii mărfurilor care vor sosi în depozit.

a) *Forma și dimensiunile mărfurilor* – definesc mijloacele tehnice de manipulare și stocare, care urmează a fi folosite în depozit; Între mijloacele de manipulare și cele de stocare, există o conexiune care face ca un depozit să funcționeze în parametri optimi și reprezintă un factor determinant în proiectarea acestuia;

În procesul de culegere a informațiilor, trebuie să aflăm și forma de stocare a mărfurilor, pe ce tip de palet/cutie vor sosi, fiind un indicator în alegerea utilajelor și sistemelor de stocare.

b) *Volumul/cantitatea stocului* – definesc gradul de ocupare al depozitului, precum și necesitatea, după caz, a unor rafturi. Dacă mărfurile se pot suprapune în stive înalte, atunci cel mai probabil, nu se va apela la achiziția unor rafturi, fiind o soluție costisitoare, cum am prezentat în „*Capitolul I, 1.3 – Tehnici de manipulare a mărfurilor*”. Capacitatea unui depozit este direct proporționată de modul cum pot fi stocate mărfurile, pe înălțime.

Înălțimea maximă până la care se pot suprapune mărfurile este de obicei specificată pe ambalajul mărfurilor și pentru siguranța depozitării, nu trebuie să depășească de 5 ori latura mică a paletului.

Stivuirea în bloc la pardoseală, se calculează pentru amprenta lăsată de palet (1 EPAL ocupă o amprentă la sol de 0,96m², aproximativ 1m², la care, de regulă mai trebuie sacrificat încă 1m² pentru aleile de serviciu, lucru pe care îl vom vedea în schița pe care o vom folosi să exemplificăm toate aceste valori).


Stivuirea în bloc, pe pardoseală, ca să întrunească condițiile de profitabilitate, ar trebui să respecte următoarele valori:

- Suprafața minimă a unui bloc de mărfuri la sol: 500m²
- Înălțimea maximă a stocării: 8 m
- Distanța minimă dintre două blocuri (alei): 2 m
- Distanța minimă de la vârful blocului la coama acoperișului sau la sistemul de încălzire, iluminare: 1 m

Pentru simularea pe care o vom efectua, vom folosi la stivuirea în bloc, pe pardoseală, palet cu specificațiile din tabelul 2.1 și figura 2.4

Tabel - 2.1

	L – m –	l – m –	H – m –	A – m ² –	V – m ³ –	M Kg.	Stiv. – buc –	Stoc – buc –
<i>Palet industrial</i>	1,20	1,15	2,87	1,38	3,96	250	3	546



Stivuirea în bloc nu este întotdeauna posibilă pentru toate mărfurile, fiind condiționată de **fragilitatea conținutului**, condiție marcată adesea pe ambalajul produsului, prin simboluri grafice reglementate care se aplică, în mod obligatoriu, pe ambalaje și de **rezistența marginilor ambalajului**.

Înălțimea rafturilor este determinată de cea a clădirii și a utilajului folosit pentru operarea stocului.

- c) *Accesibilitatea stocului* – definește modul în care sunt livrate mărfurile, cât de ușor trebuie să fie accesibile, în funcție de lot, cod de produs, principiul de stocare (FIFO, FILO, LIFO, FEFO), se face sau nu picking, astfel încât să fie efectuate un număr redus de mișcări pentru a avea acces la acestea, atunci când trebuie pregătite comenzile.

Sistemele de stocare trebuie alese în funcție de următoarele caracteristici de stoc [1]

1. „*Varietatea produselor;*
2. *Dimensiune, formă și greutate pentru fiecare articol;*
3. *Frecvența livrărilor dintr-un articol;*
4. *Raportul dintre stocuri și volumele estimate;*
5. *Modificări din volumul mărfurilor stocate în articole din care se face picking pentru comenzi;*
6. *Cerințe de livrare în cantități mai mici decât cele recepționate.*”

,dar și în funcție de cerințele comenzilor clientului:

1. *Numărul de comenzi care trebuie procesate/schimb;*
2. *Numărul de articole dintr-o comandă;*
3. *Volumul ocupat de comenzile care trebuie pregătite într-o oră de lucru sau într-un schimb;*
4. *Timpu consumat din momentul primirii unei comenzi până la finalizarea acesteia.*

Odată ce avem variabilele de mai sus, putem stabili modul de stocare la raft, **fixă** sau **variabilă**.

Pentru a optimiza spațiul disponibil și a crea mai multe poziții de depozitare la raft, vom opta pentru culoare de raft necesare unui stivuitor pentru culoare înguste (VNA), reușind astfel să utilizăm și până la 65% din spațiul pentru rafturi.

2.2.2. Cât spațiu va fi necesar pentru manevrarea mărfurilor recepționate?

Spațiul necesar pentru manevrarea mărfurilor recepționate, îl putem calcula știind că vom opera zilnic 6 camioane încărcate cu 33 de paleți și săptămânal 2 containere de 40' pline, din care vom estima o medie de 70 de paleți/container.

Cele 6 camioane înseamnă că vor ocupa o amprentă la sol de 190,08m², dacă vor fi descărcate și nu vor fi recepționate, iar apoi operate pentru stivuire la raft sau prin suprapunere. Pentru această suprafață nu am luat în calcul spațiile necesare pentru circulație, când sunt așezate în zona de recepție, prin urmare suprafața ocupată, va fi cu cel puțin 20% mai mare decât cea estimată, ceea ce ar putea ajunge la 228,096m².

Formula simplificată de calcul va fi următoarea:

Nr. camioane X nr. paleți/camion X lungime palet X lățime palet X 1,2.

$$6 \times 33 \times 1,2 \times 0,8 \times 1,2 = 228,096m^2$$

Containerele vor sosi vrac, din care, după ce se vor descărca prin regula 1 palet=1 cod de produs sau cod EAN¹, ne vom aștepta la o medie 70 de paleți/container.

Astfel, pentru 2 containere, vom efectua următorul calcul:

Nr. containere X 70 paleți dintr-un container X lungimea unui palete X lățimea unei palete X suprafețele utile pentru culoarele de circulație.

$$2 \times 70 \times 1,2 \times 0,8 \times 1,2 = 161,28\text{m}^2$$

Într-o săptămână cu 5 zile lucrătoare, ne putem aștepta să avem de recepționat 1.130 de paleți, cu o medie de 226 de paleți/zi.

Media nr. pal. recepționați/săptămână - $6 \times 33 \times 5 + 2 \times 70 = 1.130 \text{ pal.}$

Media nr. pal. recepționați/zi $(6 \times 33 \times 5 + 2 \times 70)/5 = 226 \text{ pal.}$

Mărfurile sosite în camioane, precum și cele la nivel de container, vom considera că se pot depozita la raft, fiind supuse recepției rapide și stocării pentru a se elibera zonele de recepție. În caz contrar, 226 de paleți, vor ocupa zilnic aproximativ $260,35\text{m}^2$. Dacă aceștia nu sunt recepționați de pe o zi pe alta și stocați la raft, încep să se producă blocaje în docuri, se blochează aleile de serviciu pentru utilaje și astfel se ajunge la deteriorări de mărfuri, întârzieri în operarea comenzilor, posibil și la accidente de muncă, datorită lipsei spațiului de mișcare.

În zona de stocare la pardoseală, vom opera 4 recepții/zi, a câte 20 de paleți cu dimensiunea $1.200 \times 1.150 \times 2.850\text{mm}$. Despre paleții care se pot stoca la pardoseală, în cazul nostru, mai știm că se pot suprapune 3, ceea ce oferă posibilitatea de a optimiza spațiul alocat acestora.

Spațiul ocupat de un camion = $\text{nr. pal.} \times L \times l \times \text{procent suprafață pierdută} / \text{nr. paleți suprapuși}$

$$20 \times 1,2 \times 1,15 \times 1,2/3 = 11,04\text{m}^2$$

Spațiul ocupat de recepțiile dintr-o zi = $\text{nr. camioane} \times \text{nr. pal.} \times L \times l \times \text{procent suprafață pierdută} / \text{nr. paleți suprapuși}$

$$4 \times 20 \times 1,2 \times 1,15 \times 1,2/3 = 33,12\text{m}^2$$

Spațiul ocupat de recepțiile dintr-o săptămână lucrătoare = $5 \times \text{nr. camioane} \times \text{nr. pal.} \times L \times l \times \text{procent suprafață pierdută} / \text{nr. paleți suprapuși}$

$$5 \times 4 \times 20 \times 1,2 \times 1,15 \times 1,2/3 = 165,6\text{m}^2$$

2.2.3. Ce și câte utilaje vor fi necesare pentru a opera manevrarea mărfurilor?

Selecția utilajelor trebuie stabilită în funcție de rafturile alese, modul de acces pentru stocarea mărfurilor care vor sosi în depozit, gabaritul acestora și de gradul de ocupare al depozitului.

¹ Codul EAN reprezintă codul de bare, care este necesar producătorilor, importatorilor sau exportatorilor în vederea distribuirii produselor în magazinele, supermarket-urile sau hipermarket-urile dotate cu echipamente de citire a codurilor de bare.

Așa cum am stabilit mai sus, pentru proiectul nostru, vom avea o zonă de depozitare cu rafturi standard selective² pentru culoare înguste. În tabelul 1.2, prezentat în Capitolul 1 al tezei, vom găsi câteva valori de referință de care trebuie să ținem cont când proiectăm depozitul.

Analizând acest tabel, observăm că valoarea minimă pentru un VNA este de 1.700mm, iar dacă utilajul este unul cu fir inductiv, mai trebuie să adăugăm 100mm.

Toate depozitele care au o pardoseală bună, ar trebui să aibă în dotare și transpalete electrice, fiind cele mai eficiente în raportul cost/viteză de lucru pentru descărcarea camioanelor. Au dimensiuni compacte, pot ridica sarcini de până la 3 tone, rulează cu până la 12km/h, având acces și pe culoarele înguste pentru VNA.

În zona dedicată stocării în bloc la pardoseală, se pot folosi atât stivuitoare cu încărcare frontală, cât și cele care au catarg retractabil. Știind că înălțimea de stivuire a mărfurilor este de 8,6m, cum am stabilit că pot fi suprapuși paletii pentru proiectul nostru, atunci indicat este să folosim un stivuitor care are un catarg retractabil, având tronsoane de catarg care pot ridica sarcinile la nivelul la care avem nevoie.

Totuși, așa cum este necesar ca într-un depozit să existe și transpalete electrice cu platformă, la fel de necesare sunt și stivuitoarele cu încărcare frontală, oferind flexibilitate în multe situații, când mărfurile sosesc încărcate suprapus și trebuie scoase rând pe rând sau invers în procesul de încărcare.

Camionetele de mici dimensiuni, vor putea fi descărcate sau încărcate cu stivuitorul cu furci frontale, dar nu de puține ori va fi nevoie și de o transpaletă mecanică, care adesea este pusă la dispoziție șoferilor pentru a-și re poziționa mărfurile în autovehicul.

Cunoscând cele de mai sus, depozitul nostru ar trebui să aibă cel puțin utilajele din tabelul 2.5, pentru a-și desfășura activitatea fără a întâmpina mari probleme.

Tabel 2.5. – Necesari utilaje pentru proiect

Nr. crt.	Categorie utilaj	Nr. Buc.	Alimentare	Sarcina nominală	H max -mm-
1.	Stivuitor cu catarg retractabil - Reach Truck	1	Electric	1600kg	9022
2.	Stivuitor cu încărcare frontală	1	Electric	1450kg	5770
3.	Transpaletă	3	Electric	2000kg	205
4.	Transpaletă	2	Mecanică	2000kg	207
5.	VNA_ManUP	2	Electric	1500kg	9780

² Rafturile standard selective oferă o selectivitate ridicată și sunt potrivite pentru un mix ridicat de SKU.

2.3. Planul de Depozitare

2.3.1. Schița de optimizare a spațiului

Centralizând informațiile sumar detaliate de la punctele anterioare, putem începe să schițăm un spațiu de depozitare, conform proiectul nostru, care își propune să optimizeze spațiul disponibil plecând de la o planșă goală a unui depozit de aproximativ 4.000m². Vezi figura 2.8.

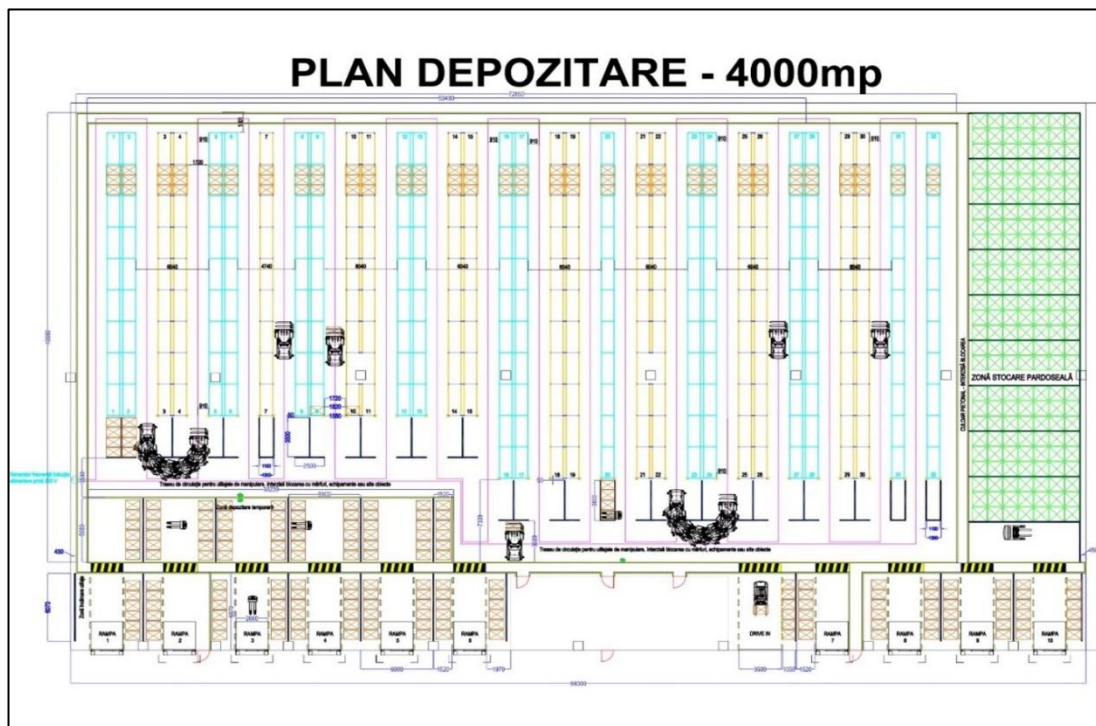


Fig. 2.8. – Plan depozitare cu 32 de rafturi și zonă de stocare pardoseală

Depozitul propus în figura 2.8, va putea asigura un stoc de mărfuri cu 3 zone diferite, după cum urmează:

2.3.2. Capacitate de stocare la raft cu VNA, pentru rafturile 1-15 – 2376 paleți cu dimensiunea de 1200 x 800 x 1650mm, vezi figura 2.9 din teză. și figura 2.10.

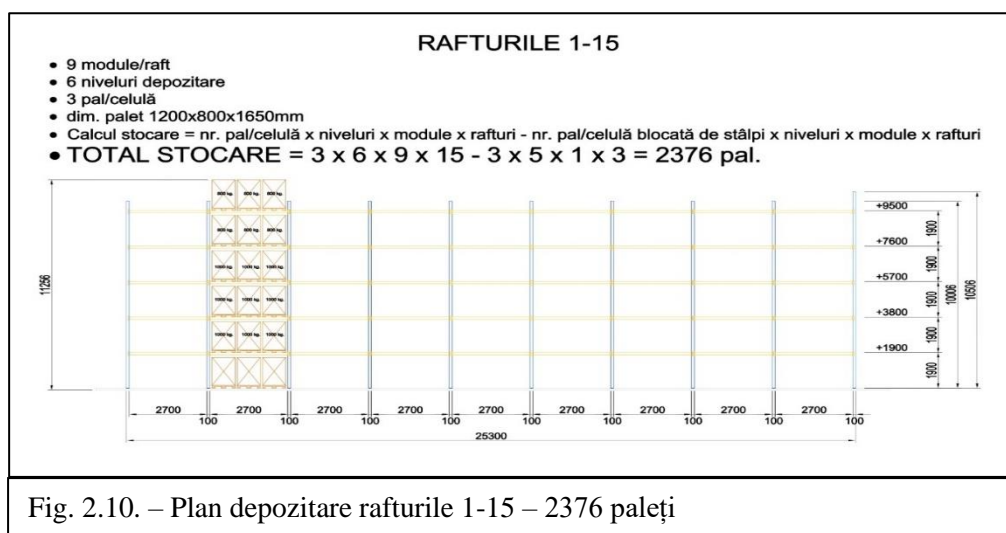



Fig. 2.10. – Plan depozitare rafturile 1-15 – 2376 paleți

2.3.3. Capacitate de stocare la raft cu VNA, pentru rafturile 16 -32 – 3843 paleți cu dimensiunea de 1200 x 800 x 1275mm., vezi figura 2.11 din și figura 2.12 din teză.

2.3.4. Capacitatea de stocare la pardoseală folosind ca mijloc de manipulare un Reach-Truck sau stivuitoare cu încărcare frontală (recomandat este să se folosească un Reach-Truck, datorită catargului cu posibilitate de ridicare pe înălțimi mai ridicate și culoar de lucru mai îngust), pentru zona dedicată din depozit, va fi de aproximativ 520 de paleți, cu dimensiunea 1200 x 1150 x 2780mm, echivalentul a 26 de transporturi cu 20 paleți/camion. Vezi figura 2.12.



Figură 2.12. – Plan depozitare stocare pardoseală

2.4. Concluzii

Transpunând informațiile de mai sus în tabelul 2.6. ajungem să avem următoarele valori de stocare.

Tabel 2.6. – Capacități stocare proiect

Dim. pal. (mm)	1200x800x1650	1200x800x1275	1200x1150x2870	TOTAL	TOTAL- 5%
R1-15 (buc.)	2376	-	-		
R16-32 (buc.)	-	3848	-		
Pardoseală (buc.)	-	-	520		
TOTAL				6744	6422

Într-un depozit, indicat este să ne păstrăm o marjă de minimum 5% cu spații goale, pentru a ne permite să facem relocări, atunci când optimizăm deplasările pentru pregătirea comenzilor, folosind des întâlnita lege a lui Pareto și clasele ABC. În centrele logistice pe bază de WMS, această optimizare se face automat prin WMS, dar niciun sistem informatic nu este la fel de eficient ca omul, acesta făcând predicții de rotații a stocului, doar în baza a rulajului pe care l-a avut, neștiind ce mărfuri noi vor intra în depozit.

Capitolul 3. OPTIMIZAREA PROCESELOR ÎNTR-UN CENTRU LOGISTIC

3.1. Introducere

Folosindu-se de tehnologiile prezentului și ale viitorului, un operator logistic are multe soluții pe care le poate integra astfel încât să-și desfășoare activitatea într-un mod optim, fără a irosi resurse pe care le poate aloca spre dezvoltare sau orice alt proiect.

3.2. Performanța Proceselor

Operațiunile dintr-un centru logistic încep cu „intrări” și se finalizează cu „ieșiri” sau recepții de la furnizori, clienți, clienți de-ai clienților și ajung la finalizare prin procesul de livrare către alți clienți.

Un instrument de măsurare echilibrat a performanțelor va avea cel puțin patru laturi: **financiară; internă; externă; perfecționare organizațională.**

Ce trebuie să măsuram?

Un model de măsurare a performanței în activitatea de depozitare pe care îl putem folosi cu factori ce trebuie luați în considerație la măsurarea operațiunilor prin analizarea a 4 factori esențiali de succes în activitatea unui centru logistic:

1. exactitatea inventarului;
2. productivitatea;
3. utilizarea spațiului/ gradul de ocupare a spațiului de depozitare;
4. deservirea clienților.

3.2.1.1. Inventarul cu drone și blockchain – viteză sporită și stocuri mai precise.


„Blockchain permite depozitelor, producătorilor, furnizorilor, centrelor de distribuție și partenerilor de retail să se conecteze între ele printr-o evidență permanentă a fiecărei tranzacții care are loc. Toate înregistrările sunt apoi stocate și accesibile tuturor din rețea”. [1]

În prezent, gestionarea stocurilor se face pe baza unui model reactiv, reprovizionările fiind comandate odată ce stocul este epuizat, sau pe baza unuia predictiv care estimează finalizarea stocurilor, în baza unor statistici de comenzi.

Utilizând blockchain, gestionarea stocurilor se va putea face cu o mai mare precizie, asigurând astfel tipul și cantitățile necesare de mărfuri pentru a asigura la timp cererea din piață.

De asemenea, în depozitele mari și mai tot ce înseamnă centru de distribuție, inventarul se va putea face folosind drone programate să înceapă la finalizarea programului, atunci când mărfurile nu mai sunt în mișcare. Parcurgând traseul printre rafturi, poate scana simultan în stânga și în dreapta, dacă este echipată cu 2 scannere, bidirecționale. Vezi fig.3.1

Adoptând tehnologiile viitorului, cu siguranță se vor putea îmbunătăți activitățile de inventariere și monitorizare a stocurilor, cea prezentată mai sus, fiind poate cea mai rapidă.



Figură 3.1. – Model de scanare cu drona.

3.3. Indicatorii de Performanță

În rezumatul acestui subcapitol sunt subliniați doar o parte a indicatorilor de performanță utilizați în monitorizarea, evaluarea și îmbunătățirea continuă a operațiunilor logistice.

3.3.1. Indicatorii Referitori la Manoperă

Indicatorii referitori la manoperă sunt esențiali pentru a evalua eficiența utilizării resurselor umane într-un depozit. Un exemplu clasic este **gradul de utilizare a timpului de lucru**, care reflectă procentul de ore efectiv prestate din totalul orelor plătite:

$$\text{Gradul de utilizare a timpului de lucru} = \frac{\text{ore prestate}}{\text{ore plătite}} \times 100\%$$

Un **grad de utilizare** de 75% indică faptul că, din opt ore plătite, doar șase au fost efectiv lucrate. Acest indicator este crucial pentru identificarea și reducerea activităților neproductive.

Analiză și Îmbunătățire

Pentru a îmbunătăți acest indicator, ar putea fi utilizate soluții de **monitorizare în timp real** și AI, care să identifice activitățile care nu aduc valoare adăugată (ex. întâlniri prelungite) și să propună automat reorganizarea programului de lucru pentru maximizarea eficienței.

Eficiența Muncii

Eficiența muncii, exprimată prin raportul dintre orele câștigate și cele prestate, indică abilitățile operatorilor și eforturile depuse:

$$\text{Eficiența} = \frac{\text{ore câștigate}}{\text{ore prestate}} \times 100\%$$

De exemplu, dacă un lucrător finalizează o sarcină în șase ore, dar timpul normat este de cinci ore, eficiența sa va fi de 83%.

Contribuții Inovative

Utilizarea **tehnologiilor predictive** bazate pe AI poate optimiza alocarea timpilor normativi, ajustând dinamica muncii în funcție de performanțele anterioare și de contextul operațional.

3.3.2. Productivitatea

Productivitatea reflectă raportul dintre orele câștigate și orele plătite, oferind o imagine de ansamblu asupra producției globale:

$$\text{Productivitatea} = \frac{\text{ore câștigate}}{\text{ore plătite}} \times 100\%$$

Pentru o îmbunătățire a acestui indicator, ar putea fi aplicate algoritmi de **machine learning** care să anticipeze variațiile de sarcini și să optimizeze alocarea resurselor, reducând astfel orele neproductive.

3.3.3. Utilizarea Spațiului

Gradul de utilizare a spațiului este crucial în gestionarea eficientă a unui depozit, fiind frecvent utilizat pentru a evalua alocarea spațiului de depozitare:

$$\text{Utilizarea spațiului} = \frac{\text{Spațiul ocupat efectiv}}{\text{Spațiul total disponibil}} \times 100\%$$

Folosirea unui procentaj de 80-90% este ideală pentru a asigura un echilibru între utilizarea maximă a spațiului și menținerea flexibilității operaționale.

Analiză și Îmbunătățire

Pentru a îmbunătăți acest indicator, tehnologiile **IoT** și **senzorii de monitorizare a spațiului** pot fi utilizate pentru a optimiza layout-ul depozitului, asigurând astfel o gestionare mai dinamică și mai eficientă a spațiilor disponibile.

Concluzie Generală

Adoptarea AI și a altor tehnologii avansate în logistică nu este doar o tendință, ci o necesitate pentru companiile care doresc să rămână competitive în economia globală actuală. Sistemele de măsurare a performanței bazate pe AI oferă o capacitate unică de a optimiza dinamic procesele, de a reduce costurile și de a îmbunătăți satisfacția clienților, asigurând astfel succesul pe termen lung al operațiunilor logistice.

Partea II.

**Contribuții la dezvoltarea unor METODE
DE OPTIMIZARE A OPERAȚIUNILOR
DE DEPOZITARE PRIN INTEGRAREA
INTELIGENȚEI ARTIFICIALE ȘI
ANALIZA DATELOR OPERAȚIONALE**

Capitolul 4. DIRECȚIILE, OBIECTIVUL PRINCIPAL ȘI METODOLOGIA DE CERCETARE-DEZVOLTARE A OPTIMIZĂRII PROCESELOR ÎNTR-UN CENTRU LOGISTIC

4.1. Direcții de Cercetare-Dezvoltare

Pe baza analizei stadiului actual al cunoașterii în domeniul logisticii industriale și a tendințelor emergente în tehnologie, s-au identificat următoarele direcții de cercetare-dezvoltare care sunt de o relevanță deosebită pentru optimizarea operațiunilor logistice. Aceste direcții sunt orientate spre integrarea inteligenței artificiale (AI) și a tehnologiilor digitale avansate în procesele operaționale, pentru a aborda provocările actuale și pentru a crea soluții inovative care să îmbunătățească eficiența și performanța în depozite:

4.1.1. Optimizarea Dinamică a Operațiunilor Logistice [1]

Rutele de Picking: AI poate analiza continuu datele operaționale, precum comenzile în așteptare și locațiile stocurilor, pentru a optimiza rutele de picking.

Alocarea Resurselor: AI poate ajusta automat distribuția resurselor în funcție de cererea variabilă, asigurându-se astfel că resursele sunt utilizate în mod optim, fără supraîncărcare sau subutilizare.[3]

4.1.2. Predicția Cererii și Alocarea Resurselor [12]

Modele Predictive Avansate: AI poate analiza volume mari de date în timp real și poate identifica modele subtile care ar putea scăpa unei analize convenționale, asigurând că depozitele sunt pregătite pentru a face față fluctuațiilor cererii fără a înregistra pierderi sau stocuri epuizate. [4]

Optimizarea Stocurilor: Pe baza predicțiilor, AI poate optimiza gestionarea stocurilor prin alocarea dinamică a spațiului de depozitare, prioritizarea articolelor cu rulaj rapid și ajustarea cantităților de produse stocate. [5]

4.1.3. Monitorizarea și Feedback-ul în Timp Real prin AI

Monitorizare Continuă: Aceste sisteme pot detecta automat anomalii sau ineficiențe și pot trimite alerte sau sugestii de ajustare pentru a preveni problemele înainte ca acestea să devină critice.

Feedback Adaptiv: De exemplu, în cazul unei creșteri bruște a cererii, AI poate ajusta prioritățile în timp real, reorganizând sarcinile pentru a maximiza eficiența fără a compromite calitatea serviciilor.[6]

4.1.4. Integrarea AI în Managementul Riscurilor

Identificarea și Monitorizarea Riscurilor: AI poate fi programată să monitorizeze factori de risc cum ar fi uzura echipamentelor, variațiile de performanță ale personalului sau fluctuațiile imprevizibile ale cererii.

Planificare și Răspuns la Urgențe: Aceasta asigură că depozitul este pregătit să răspundă eficient în fața evenimentelor neașteptate, cum ar fi defecțiunile majore ale echipamentelor sau întreruperile din lanțul de aprovizionare.

4.1.5. Simulări și Modele Teoretice pentru Optimizarea în Logistică

Simulări Computaționale: Folosind layout-ul unui depozit ca bază de lucru, vom crea simulări care să testeze impactul diferitelor strategii de optimizare propuse de AI. Aceste simulări permit evaluarea performanțelor sistemului în condiții variate, fără a necesita implementări costisitoare și riscante în mediul real.[10]

Validarea Modelului AI: Simulările pot fi utilizate pentru a valida modelul AI propus, comparând rezultatele obținute prin metodele tradiționale de management logistic cu cele generate de modelul AI.

4.2. Obiectivul Principal al Activității de Cercetare-Dezvoltare

4.2.1. Context și Justificare

Tehnologiile emergente, în special inteligența artificială (AI), oferă oportunități fără precedent pentru îmbunătățirea proceselor logistice. Cu toate acestea, majoritatea soluțiilor existente se concentrează pe optimizări statice sau pe modele de management care nu pot răspunde eficient la dinamica rapidă a cererii și la fluctuațiile operaționale.

În acest context, obiectivul principal al activității de cercetare-dezvoltare propus în această teză este de a testa prin simulare cu date reale dezvoltarea și implementarea unui sistem de optimizare dinamică a operațiunilor logistice, bazat pe integrarea inteligenței artificiale și a analizei datelor în timp real, pentru a maximiza eficiența operațională și a reduce costurile în depozitele industriale.

Această direcție de cercetare răspunde necesităților actuale ale industriei de a se adapta rapid la schimbări și de a exploata avantajele oferite de digitalizare și automatizare.

4.3. Concluzii

Direcțiile de Cercetare-Dezvoltare identificate în această teză se concentrează pe optimizarea dinamică a operațiunilor logistice, predicția cererii și alocarea resurselor, monitorizarea continuă a performanțelor operaționale și integrarea AI în managementul riscurilor.

Obiectivul principal al cercetării propuse – simularea unor operațiuni dintr-un centru logistic utilizând un sistem AI pentru optimizarea dinamică a operațiunilor logistice conduse astăzi doar prin WMS. Prin integrarea algoritmilor avansați de AI și utilizarea unei infrastructuri de date, acest sistem promite să aducă îmbunătățiri semnificative în gestionarea resurselor și în modul în care depozitele răspund la fluctuațiile cererii.

Metodologia de cercetare-dezvoltare propusă în acest capitol oferă un cadru structurat pentru realizarea obiectivului principal. Efectuarea unor simulări și validarea acestora prin evaluarea cu performanțele istorice ale depozitului, vor oferi certitudinea că soluțiile propuse sunt nu doar inovative, ci și aplicabile în practică.

În concluzie, integrarea AI și analiza datelor în timp real nu doar că răspund nevoilor actuale ale industriei, ci și pregătesc terenul pentru o adaptabilitate și eficiență sporită pe termen lung.

Capitolul 5. SIMULARE ȘI CONTRIBUȚII PROPRII LA IMPLEMENTAREA MODELULUI DE INTELIGENȚĂ ARTIFICIALĂ

5.1. Direcții de Cercetare-Dezvoltare

5.1.1. Introducere

Acest capitol al tezei are scopul de a prezenta procesul de simulare și pașii necesari implementării unui model de inteligență artificială (AI) care ar putea fi dezvoltat pentru optimizarea operațiunilor într-un depozit logistic de 13.800 m². În acest scop am folosit schița unui depozit proiectat de mine ce urmează să fie lansat în Trim. I al anului 2025.

Modelul AI poate fi utilizat pentru a gestiona și optimiza activitățile într-un depozit, împărțit în trei zone principale de stocare: zona de stocare pe rafturi cu culoare înguste (VNA), zona de stocare pe rafturi pentru Reach Truck și zona de stocare la pardoseală (Block Storage). Scopul simulărilor este de a testa capacitatea modelului AI de a maximiza eficiența operațională și de a minimiza timpii de operare într-un context logistic complex și variabil.

5.1.2. Date preliminare ale proiectului de depozitare folosit pentru AI

În cadrul simulărilor ne vom folosi de un layout al unui depozit pe care l-am proiectat, conform figurii. 5.1.

Depozitul va fi împărțit în 3 zone mari de stocare.

- 1. Zonă de stocare pe rafturi având culoare înguste pentru VNA.** Vedere detaliată a rafturilor în figura 5.2, de unde se va observa că și capacitatea de stocare pentru această zonă va fi de **8416 paleți** pe configurații diferite de înălțime, dar ca standard de palet vom folosi EPAL, acesta având dimensiunea 1200x800mm, fiind materialul de bază pentru stocare în majoritatea operațiunilor logistice din Europa.
- 2. Zona de stocare pe rafturi având culoare pentru Reach Truck.** Vedere detaliată a rafturilor în figura 5.3, de unde va observa că și capacitatea de stocare pentru această zonă va fi de **4447 paleți** pe configurații diferite de înălțime, unde ca standard de palet vom folosi tot EPAL.
- 3. Zona de stocare la pardoseală sau „block storage”** cum este definită pe schiță. Această zonă va fi împărțită în mai multe insule pentru a conferi acces facil stivuitoarelor frontale și transpaletelor care vor deservi cel mai des zona. În această zonă, cumulat, se vor putea stoca minimum **934 paleți**, dacă luăm în calcul doar 1 palet/locație, numărul acestora fiind direct influențat de capacitatea de suprapunere a lor, adesea mulți paleți putând fi suprapuși și câte 4.
- 4. Numărul docurilor din dotarea depozitului**
 - pe față, unde preponderent se fac recepții, dar nu numai există **14 docuri de nivel și 3 tip Drive IN**;
 - pe spate, unde se vor efectua doar livrări, există **5 docuri de nivel și 2 tip Drive IN**.
- 5. Utilajele din echiparea depozitului** vor fi cele din tabelul 5.1.

Tabel 5.1. – Listă utilaje de manipulare

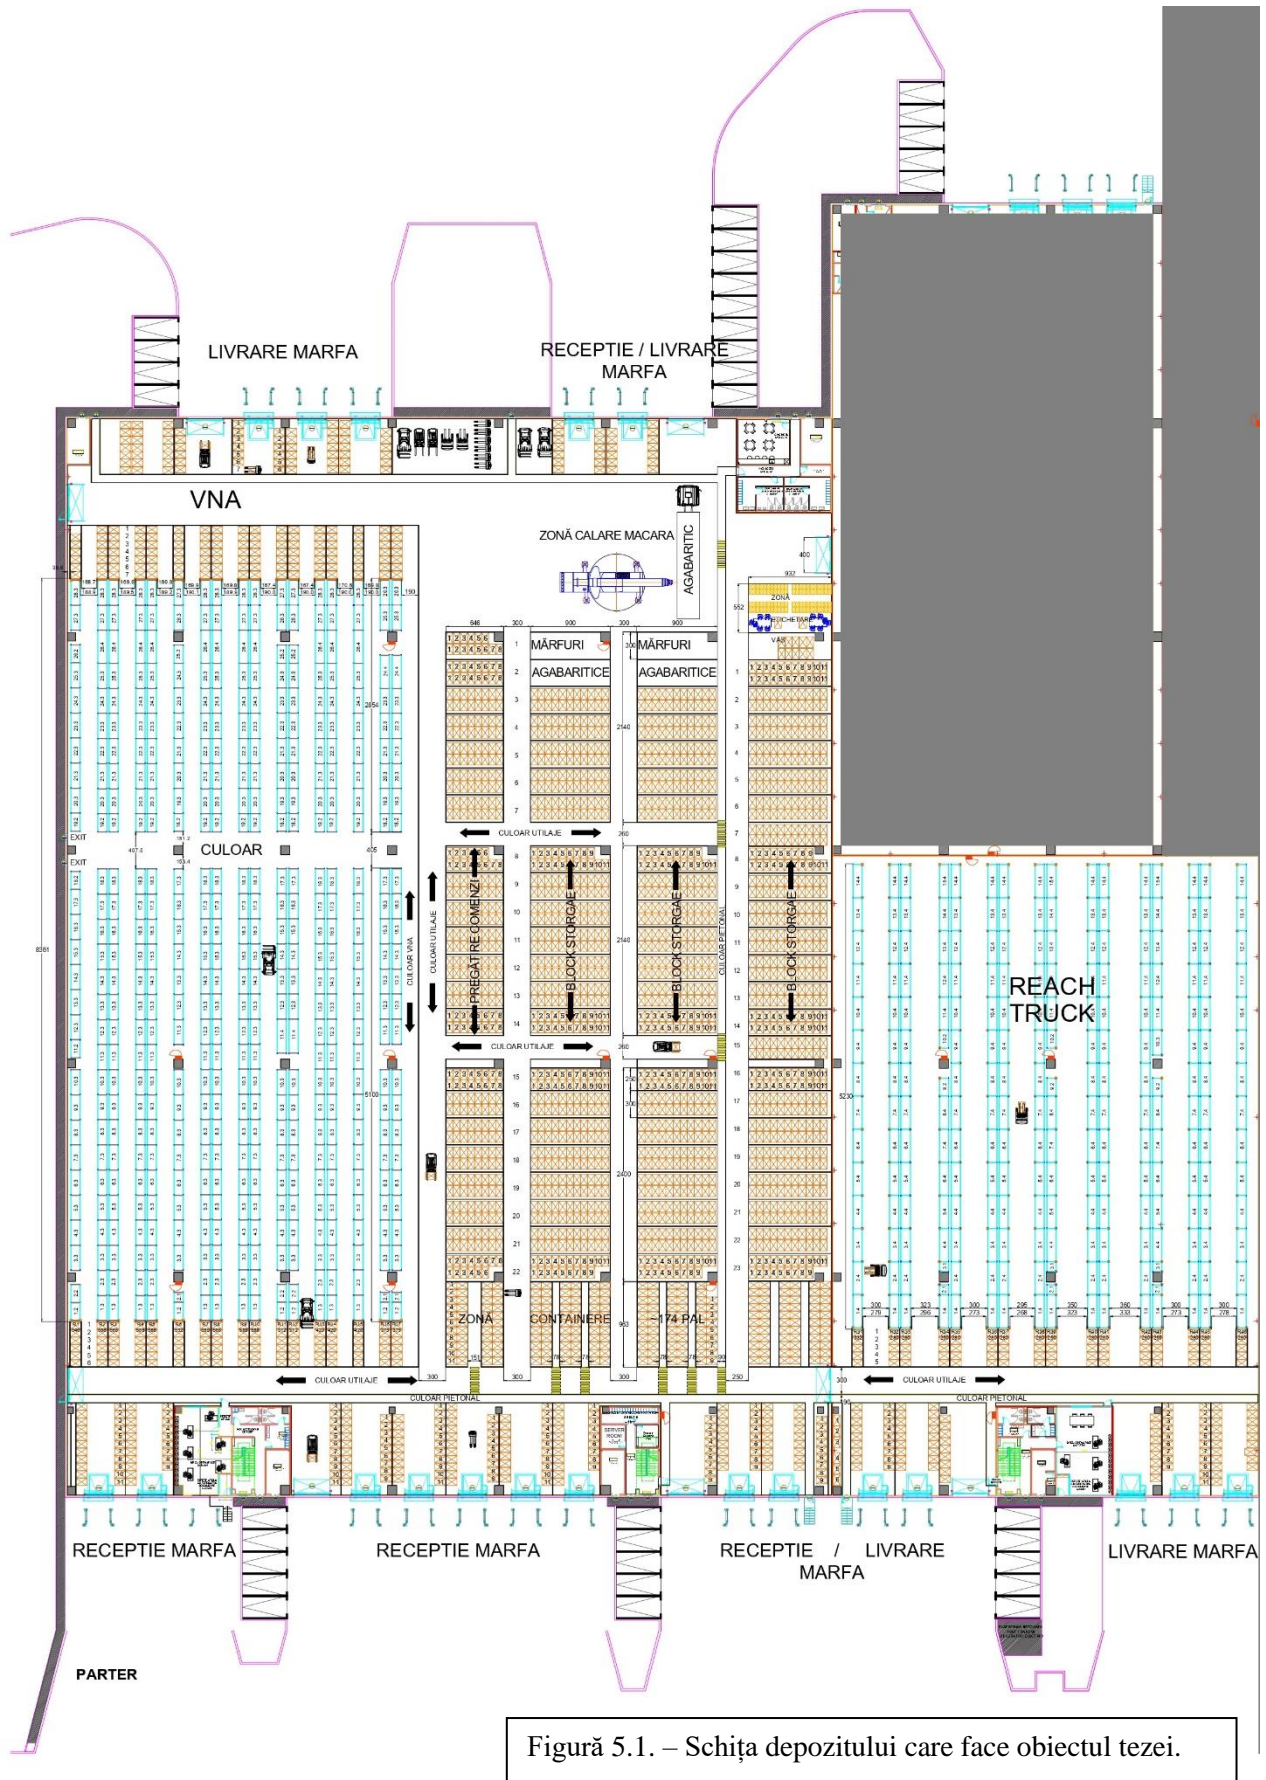
Categorie utilaj	Alimentare	Nr. buc.	Sarcina nominală	Viteză deplasare km/h	H max -mm-
Reach Truck	Electric	2	1600kg	10	8200
Stivuitoar frontal	Electric	2	1600kg	15	3000
Stivuitoar frontal	Electric	2	3000kg	20	4750
Transpalet	Electric	2	2500kg	13	207
Transpalet	Electric	2	1500kg	5	205
Transpalet	Electric	8	2000kg	10	205
Transpalet	Mecanic	10	2300kg	5	200
VNA_ManDown	Electric	3	1500kg	14	9400

6. Personalul operațional al depozitului va fi cel din lista de mai jos având un singur schimb de lucru.

- 3 stivuitoari care vor deservi 3 stivuitoare pentru culoare înguste, tip VNA;
- 2 stivuitoari care vor deservi 2 reach truck;
- 4 stivuitoari care vor deservi cele 4 stivuitoare frontale;
- 22 manipulanți/pickeri care pot utiliza transpaletele electrice și mecanice;
- Gestionarii și personalul de birou nu vor fi luați în calcul, nefiind relevanți în calcule.

7. Tipurile de operațiuni specifice:

- Sortare, ambalare, stocare, picking, reambalare, etichetare, descărcare/încărcare containere, transbordare etc.
- Zone de picking dedicate vor fi nivelul de pardoseală al tuturor rafturilor din zona de reach truck, de la R31 la R46, zona de block storage precum și din zona de VNA zonele de pardoseală ale rafturilor R13-R17.
- Mărfurile cu rulaj rapid vor fi depozitate cu precădere în extremitatea superioară a depozitului. În zona VNA de la modulele de raft 18.2 până la capătul de raft. În zona de Reach Truck, acestea se vor organiza în primele 8 module de raft pentru a scurta traseul de deplasare.
- Zilnic se vor estima un număr de 40 camioane sosite la recepție cu un timp estimat de 40-50min./camion și livrări similare, efectuate atât la nivel de camion, cât și cu autocamionete de mai mici dimensiuni, definite în Capitolul 2 al acestei teze.



Figură 5.1. – Schița depozitului care face obiectul tezei.

5.1.3. Scenarii de Simulare pentru antrenarea modelului de Inteligență Artificială

Pentru a evalua performanțele modelului AI, am definit mai multe scenarii de simulare care reflectă diferite condiții operaționale și provocări des întâlnite în centrele logistice similare celui din acest proiect. Rolul acestor scenarii este de a testa flexibilitatea, eficiența și capacitatea de adaptare a modelului în situații variabile, cum adesea apar în astfel de activități.[1][13]

Scenariul 1: Creșterea Fluctuantă a Cererii. Acest scenariu, simulează o creștere bruscă a cererii într-o perioadă de vârf, cum ar fi Black Friday sau campanii promoționale majore.

Scenariul 2: Utilizarea Maximă a Capacităților de Stocare. În acest scenariu, încercăm să vedem cum modelul AI este testat pentru a maximiza utilizarea spațiului de depozitare fără a compromite eficiența operațională și analizăm capacitatea modelului de a reconfigura dinamic depozitul pentru a preveni blocajele și a menține un flux de operare optim.

Scenariul 3: Defecțiuni Aleatorii ale Utilajelor. Scenariul testează capacitatea modelului AI de a se adapta la defecțiuni neașteptate ale echipamentelor din depozit, cum ar fi stivuitoarele și transpaletele, pentru a evalua cum poate acesta să redistribuie sarcinile și să mențină eficiența operațională.

5.1.3.1. Scenariul 1: Creșterea Fluctuantă a Cererii

Setarea parametrilor de simulare:

- **Volum inițial de comenzi:** 1.000 de comenzi pe zi
- **Creștere estimată a cererii:** 50% (ajungând la 1.500 de comenzi pe zi)
- **Număr de utilaje:** Utilajele detaliate în tabelul 5.1.
- **Timp mediu de picking fără optimizare:** 10 minute/comandă

Distanțele relevante din depozit:

- **Distanța medie între zonele de picking și docuri:** 400 metri (specific layout-ului)
- **Distanța medie între rafturi în zonele VNA:** 30 metri (specific layout-ului)
- **Distanța medie între rafturi în zonele Reach Truck:** 20 metri (specific layout-ului)

Exemplu fără optimizare:

- Timpul total de operare $T_{total} \approx 115,28\text{ore}$
- Productivitatea:

$$P_u = \frac{1.000\text{comenzi}}{115,28\text{ore}} \approx 8,67\text{comenzi/oră}$$

Exemplu cu optimizare:

- Timp total optimizat $T_{total-optimizat} \approx 92,22\text{ore}$
- Productivitate optimizată:

$$P_u = \frac{1.000\text{comenzi}}{92,22\text{ore}} \approx 10,84\text{comenzi/oră}$$

Impactul Optimizării în Scenariul 1

Prin optimizarea pe care putem să o obținem cu AI, timpul total de operare poate fi redus, iar productivitatea să crească cu aproximativ 25%. Aceste rezultate vor putea confirma că AI are capacitatea de a îmbunătăți semnificativ eficiența operațională, reducând distanțele parcurse și timpii de manipulare.

5.1.3.2. Scenariul 2: Utilizarea Maximă a Capacităților de Stocare

Setarea parametrilor de simulare

Capacitatea maximă de stocare:

- Zona VNA: 8.416 paleți
- Zona Reach Truck: 4.447 paleți
- Zona Block Storage: minimum 934 paleți

Tipuri de mărfuri stocate:

- Zona Reach Truck și Block Storage: Mărfuri cu rulaj rapid
- Zona VNA: Mărfuri cu rulaj mediu și scăzut

Utilaje folosite: Utilajele detaliate în tabelul 5.1.

Zone de Picking Dedicat:

- Zona Reach Truck: Nivelul de pardoseală al rafturilor R31-R46.
- Zona VNA: Nivelul de pardoseală al rafturilor R13-R17.

Distanțele relevante din depozit:

- Lungime raft VNA: aproximativ 84 metri, cu 10 culoare pentru întreaga zonă
- Lungime raft Rach Truck: aproximativ 52 metri, cu 8 culoare pentru întreaga zonă
- Distanța medie parcursă între rafturi în zona VNA: 50 metri (exemplu schiță)
- Distanța medie parcursă între rafturi în zona Reach Truck (RT): 20 metri (exemplu schiță)
- Distanța medie de acces în zona Block Storage (BS): 60 metri (exemplu schiță)

Distanța medie până la zonele de picking:

- Zona Reach Truck: 40 metri
- Zona VNA: 60 metri

1. Calculul Capacității de Stocare Utilizate:

Pentru a determina cât de eficient este utilizat spațiul de stocare, AI trebuie să calculeze gradul de ocupare a spațiului de depozitare (**G**):

$$G = \frac{N_{\text{stocat}}}{N_{\text{max}}}$$

Unde:

- N_{stocat} este numărul total de paleți stocați într-o zonă
- N_{max} este capacitatea maximă de stocare pentru acea zonă

2. Optimizarea Alocării Stocurilor (O_s)

Modelul AI trebuie să optimizeze alocarea stocurilor în funcție de tipul mărfurilor (rulaj rapid, mediu, lent), astfel încât mărfurile cu rulaj rapid să fie poziționate cât mai aproape de zonele de picking.

$$O_s = \min \left(\sum_{i=1}^n (R_i \times d_i) \right)$$

Unde:

- R_i este rulajul mărfii i
- d_i este distanța medie până la zona de picking

3. Recalcularea Timpului de Operare Optimizat

Pentru Reach Truck (exemplu):

- **Parametrii:**
 - Viteza de deplasare a Reach Truck: $v_{RT} = 10\text{km/h} \approx 2,78\text{m/s}$
 - Distanța medie între rafturi: $d_{RT} = 20$ metri
 - Timpul static necesar pentru manipulare: $t_{static} = 5$ minute = 300 secunde

Timpul total de operare pentru mărfurile cu rulaj rapid se va calcula prin adăugarea timpului de deplasare la timpul static de manipulare:

$$T_{opt-RT} = \frac{d_{RT}}{v_{RT}} + t_{static}$$

- **Calculul**

$$T_{opt-RT} = \frac{20\text{m}}{2,78\text{m/s}} + 300\text{s} \approx 307,19\text{s/comandă}$$

Deci, timpul optimizat de operare pentru mărfurile cu rulaj rapid în zona Reach Truck este de aproximativ 307,19 secunde per comandă.

Pentru zona de picking în Reach Truck (R31-R46):

- **Parametrii:**
 - Viteza de deplasare a Reach Truck: $v_{RT} = 10\text{km/h} \approx 2,78\text{m/s}$
 - Distanța medie până la zona de picking: $d_{RT} = 40$ metri
 - Timpul static necesar pentru picking: $t_{static} = 2$ minute = 120 secunde

- **Calculul:**

- Timpul total de operare pentru picking în zona Reach Truck se calculează astfel:

$$T_{opt-RT} = \frac{40\text{m}}{2,78\text{m/s}} + 120\text{s} \approx 134,38\text{s/comandă}$$

Așadar, folosind formula din exemplul de mai sus, timpul optimizat pentru picking în zona Reach Truck este de aproximativ 134,38 secunde per comandă.

Pentru mărfurile cu rulaj mediu și scăzut în VNA (exemplu):

- **Parametrii:**
 - Viteza de deplasare a VNA: $v_{VNA} = 14\text{km/h} \approx 3,89\text{m/s}$
 - Distanța medie între rafturi: $d_{VNA} = 50$ metri

- Timpul static necesar pentru manipulare: $t_{\text{static}} = 5 \text{ minute} = 300 \text{ secunde}$
- **Calculul:**
 - Timpul total de operare pentru mărfurile cu rulaj mediu se calculează astfel:

$$T_{\text{opt-VNA}} = \frac{50\text{m}}{3,89\text{m/s}} + 300\text{s} = 312,85\text{s/comandă}$$

Impactul Optimizării în Scenariul 2

Prin ajustarea alocării stocurilor astfel încât mărfurile cu rulaj rapid să fie amplasate în zonele Reach Truck și Block Storage, iar mărfurile cu rulaj mediu și scăzut să fie amplasate în zona VNA, vom reuși să optimizăm accesul și timpii de operare. Distanțele optimizate pentru picking în aceste zone asigură o îmbunătățire a eficienței operării și utilizării capacităților de stocare.

5.1.3.3. Scenariul 3. Defecțiuni Aleatorii ale Utilajelor

1. Defecțiuni Simulate:

- **Stivuitoare Reach Truck:** Defectarea unuia dintre cele două reach truck-uri.
- **Stivuitoare VNA:** Defectarea unuia dintre cele trei stivuitoare VNA.
- **Transpalete:** Defectarea a 3 transpalete din cele 22 disponibile.

2. Redistribuirea Sarcinilor:

- În această fază AI-ul trebuie să **monitorizeze operațiunile** și să detecteze defecțiunea apărută la utilaj.
- **Redistribuirea sarcinilor** implică realocarea comenzilor de manipulare și picking către restul utilajelor funcționale care pot finaliza sarcina, ajustând traseele și prioritățile pentru a reduce impactul negativ asupra timpilor de operare.

Recalcularea Timpului de Operare în Condiții de Defecțiune:

1. Defecțiunea unui Reach Truck:

- **Impactul așteptat** este de reducere a capacității operaționale a zonei Reach Truck la 50%.
- Pentru **compensare**, AI-ul trebuie să redistribuie sarcinile către al doilea Reach Truck și, unde este posibil (la nivelul de pardoseală al rafturilor), către transpaletele electrice pentru manipulări mai ușoare.
- **Timp de Operare Ajustat:**
 - Viteza medie scade la $v_{\text{RT-defect}} = 5\text{km/h} \approx 1,39\text{m/s}$
 - Timpul total de operare se ajustează:

$$T_{\text{opt-RT-defect}} = \frac{20\text{m}}{1,39\text{m/s}} + 300\text{s} \approx 314,39\text{s/comandă}$$

- Timpul de operare crește la aproximativ 314,39 secunde per comandă.

Unde,

- 20 m = distanța medie parcursă pentru fiecare comandă.
- 1,39 m/s = Viteza redusă așteptată lucrându-se doar cu un Reach Truck.

- 300 s: Timp suplimentar pentru manipularea și finalizarea comenzii, luând în considerare ajustările necesare.

2. Defecțiunea unui Stivuitor VNA:

- **Impactul așteptat** este de reducere a capacității operaționale a zonei VNA care va scădea la aproximativ 66%.
- Pentru **compensare**, AI-ul trebuie să redistribuie sarcinile către celelalte două stivuitoare VNA, ajustând prioritățile comenzilor pentru a menține fluxul operațional.

• Timp de Operare Ajustat:

- Viteza medie rămâne $v_{VNA} = 14\text{km/h} \approx 3,89\text{m/s}$, dar timpii cresc din cauza încărcării mai mari pe celelalte două utilaje.
- Timpul total de operare se ajustează:

$$T_{\text{opt-VNA-defect}} = \frac{50\text{m}}{3,89\text{m/s}} + 5,5 \text{ min.} \approx 12,85\text{s} + 330\text{s} = 342,85\text{s/comandă}$$

- Timpul de operare crește la aproximativ 342,85 secunde per comandă.

Unde,

- 50 m = distanța medie parcursă pentru fiecare comandă.
- 3,89 m/s = viteza stivuitoarelor VNA care rămân operaționale.
- 5,5 min (330 s) = timpul suplimentar pentru manipularea și finalizarea comenzii din cauza încărcării mai mari pe celelalte două stivuitoare VNA.

3. Defecțiunea a 3 Transpalete:

- **Impactul așteptat** este de reducere a capacității operaționale a zonei Block Storage și a altor zone unde se utilizează transpalete (încărcare/descărcare camioane).
- Pentru **compensare**, AI-ul trebuie să redistribuie comenzile către transpaletele funcționale rămase și, dacă este posibil, către stivuitoarele frontale.

• Timp de Operare Ajustat:

- Viteza medie pentru transpalete rămâne $v_{\text{transpalet}} = 5\text{km/h} \approx 1,39\text{m/s}$
- Timpul total de operare se ajustează:

$$T_{\text{opt-transpalet-defect}} = \frac{60\text{m}}{1,39\text{m/s}} + 6\text{min.} \approx 43,17\text{s} + 360\text{s} = 403,17\text{s/comandă}$$

- Timpul de operare crește la aproximativ 403,17 secunde per comandă.

Unde,

- 60 m = distanța medie parcursă pentru fiecare comandă.
- 1,39 m/s = viteza transpaletelor care rămân operaționale.
- 6 min (360 s) = timpul suplimentar pentru manipularea și finalizarea comenzii din cauza încărcării mai mari pe transpaletele rămase.

Evaluarea Impactului și Adaptabilitatea AI

În scenariul 3 mi-am propus să demonstrez că, deși defecțiunile aleatorii ale utilajelor pot provoca întârzieri semnificative în operare, AI-ul trebuie să fie capabil să redistribuie eficient sarcinile către utilajele funcționale rămase, reducând astfel impactul global asupra operațiunilor.

5.2. Implementarea simulărilor

5.2.1. Descrierea modelului de simulare

5.2.1.1. Introducere și motivație

Integrarea inteligenței artificiale (AI) în gestionarea operațiunilor de depozitare va reprezenta un pas esențial către optimizarea proceselor și creșterea eficienței oricărui centru logistic. Modelul de AI propus în cadrul acestei teze are drept scop principal validarea soluțiilor propuse și testarea capacității acestora de a se adapta la variabilitatea condițiilor operaționale care pot apărea într-un depozit.

5.2.1.2. Structura modelului de simulare

Modelul de simulare este construit pe baza unor componente esențiale, fiecare având un rol bine definit în procesul de optimizare și adaptare la schimbările din mediu:

Date de Intrare

Layout-ul depozitului: Layout-ul depozitului servește drept structură pentru modelul de simulare, oferind o reprezentare detaliată a distribuției spațiilor de stocare (zonele VNA, Reach Truck, și Block Storage), dimensiunile acestora și distanțele dintre ele. Aceste date sunt utilizate pentru a calcula rutele optime de deplasare și timpul necesar pentru operarea fiecărui tip de echipament. Layout-ul include atât detalii despre poziționarea rafturilor și culoarelor, cât și despre zonele de picking dedicate (R31-R46 pentru Reach Truck și R13-R17 pentru VNA).

Specificațiile utilajelor: Specificațiile tehnice ale echipamentelor utilizate în depozit sunt esențiale pentru orice model AI, întrucât acestea includ parametri precum viteza de deplasare, sarcina nominală și timpii de operare specifici pentru fiecare utilaj.

Clasificarea mărfurilor: În cadrul modelului de simulare, mărfurile sunt împărțite în funcție de rulaj (rapid, mediu, scăzut), această clasificare având rolul de a determina alocarea lor în diferitele zone ale depozitului. Mărfurile cu rulaj rapid vor fi prioritizate în zonele de picking din Reach Truck și Block Storage, în timp ce mărfurile cu rulaj mediu și scăzut sunt depozitate în zona VNA.

Parametri operaționali: Modelul trebuie să ia în considerare o serie de parametri operaționali, precum timpii de manipulare standard, timpii de operare pentru diferite procese logistice, și alocarea resurselor pe baza cerințelor curente de operare.

5.2.1.3. Algoritmi Matematici de Procesare și Optimizare a Operațiunilor în Depozit

Algoritmi de optimizare bazată pe machine learning: Acești algoritmi folosesc tehnici de optimizare, cum ar fi algoritmi genetici, optimizarea coloniilor de furnici sau rețele neuronale, pentru a calcula rutele optime și a ajusta timpii de operare în funcție de variabilele specifice fiecărui scenariu.[17]

1. Algoritmi Genetici (Genetic Algorithms - GA):[10]

În logistică, astfel de algoritmi pot fi folosiți pentru a optimiza rutele de transport intern, asigurându-se că distanțele parcurse sunt minime și că timpii de operare sunt eficientizați. De exemplu, un algoritm genetic poate găsi combinația optimă de trasee pe care utilajele din depozit ar trebui să le urmeze pentru a minimiza timpul total de operare.

Exemplu: Optimizarea rutelor de transport intern într-un depozit [8]

Să presupunem că în depozit avem 5 docuri de încărcare/descărcare (A, B, C, D, E) și dorim să găsim ruta cea mai scurtă care să acopere toate aceste puncte. Problema poate fi formulată ca o problemă clasică de „traveling salesman problem” (TSP), unde trebuie să minimizăm distanța totală parcursă.

2. Optimizarea Coloniilor de Furnici (Ant Colony Optimization - ACO):[18]

Această tehnică de optimizare este una care imită comportamentul colectiv al furnicilor în natură, care descoperă cele mai scurte căi între surse de hrană și cuibul lor. ACO folosește un sistem de feromoni virtuali pentru a marca traseele cele mai eficiente, pe care alte „furnici” (soluții candidate) le vor urma și îmbunătăți. Pe măsură ce timpul trece, feromonii din rutele mai puțin eficiente se estompează, consolidând astfel rutele optime.

Aceasta este deosebit de utilă în medii dinamice, unde cerințele și resursele pot varia rapid, ceea ce se și întâmplă în depozitele care au mai mult clienți de gestionat, având fiecare cerințe specifice.

Exemplu: Optimizarea traseului de picking într-un depozit

Să presupunem că avem 4 puncte de picking într-un depozit (P1, P2, P3, P4) și dorim să găsim traseul cel mai scurt care să acopere toate punctele.

3. Rețele Neuronale (Neural Networks):

Sunt modele de machine learning inspirate de structura și funcționarea creierului uman. Ele sunt capabile să învețe relații complexe dintre variabile și să facă predicții bazate pe aceste învățături. O rețea neuronală poate învăța să prezică momentul optim pentru efectuarea unei reîncărcări de stoc sau pentru a ajusta alocarea resurselor în funcție de prognoze de cerere.

Exemplu: Predicția timpului de operare pentru sarcini de manipulare în depozit.

Să presupunem că dorim să prezicem timpul necesar pentru a finaliza o sarcină de manipulare pe baza unor variabile de intrare, cum ar fi distanța parcursă, greutatea mărfurilor și tipul echipamentului.

Exemplu Practic: Predicția Timpului de Operare

- **Intrări:** Distanța parcursă, greutatea mărfurilor, tipul echipamentului.
- **Procesare:** Rețeaua neuronală procesează aceste intrări prin straturile ascunse și de ieșire pentru a face predicția.
- **Ieșire:** Timpul de operare prezis pentru sarcina respectivă.
- **Antrenare Continuă:** Rețeaua neuronală poate continua să se antreneze și să își ajusteze predicțiile pe baza noilor date colectate în timpul operării depozitului.

5.2.1.4. Optimizarea rutei: Pentru determinarea rutei optime în interiorul depozitului, modelul AI va trebui să folosească și algoritmi de optimizare a traseului, cum ar fi Dijkstra sau A*. Se începe de la nodul sursă (de exemplu, punctul de pornire al stivitorului) și se determină cel mai scurt drum către toate celelalte noduri din graf.[3][7]

Formula generală utilizată pentru ruta cu cel mai mic cost total este:

$$\min \sum_{i=1}^n c_i \times d_i$$

unde:

- c_i reprezintă costul asociat cu segmentul i al rutei (de exemplu, consum de energie, uzura echipamentelor, timp de deplasare).
- d_i reprezintă distanța asociată cu segmentul i al rutei.
- Scopul este de a minimiza suma totală a costurilor asociate cu toate segmentele rutei.

5.2.1.5. Calculul timpilor de operare optimizați: Modelul poate determina timpul optimizat de operare pentru fiecare utilaj pe baza distanței de deplasare și a vitezei utilajului. Formula utilizată pentru acest calcul este:

$$T_{opt} = \frac{d}{v} + t_{static}$$

unde:

- T_{opt} reprezintă timpul optimizat de operare.
- d este distanța medie parcursă.
- v este viteza de deplasare a utilajului.
- t_{static} reprezintă timpul static necesar pentru manipularea mărfurilor.

5.2.1.6. Alocarea optimizată a resurselor: Alocarea resurselor în depozit se face utilizând algoritmi de optimizare, cum ar fi „simplex” sau „branch and bound”, pentru a maximiza eficiența operațională. Funcția obiectiv utilizată în acest context este:

$$\max \sum_{j=1}^n r_j \times x_j$$

unde:

- Z reprezintă funcția obiectiv de maximizare a eficienței operaționale.
- r_j reprezintă resursa alocată activității j .
- x_j reprezintă decizia de alocare a resursei către activitatea j .

5.3. Analiza Rezultatelor

5.3.1. Evaluarea Performanței [25]

Atunci când se dezvoltă un model de Inteligență Artificială, acesta trebuie supus unei evaluări a performanței, prin intermediul unor simulări care au rolul de a scoate în evidență impactul acestuia asupra eficienței operaționale a depozitului. În această secțiune, vom prezenta și discuta o serie rezultate, punând un accent deosebit pe compararea performanțelor modelului AI cu cele ale metodelor tradiționale de gestionare a operațiunilor logistice, precum WMS.

5.3.1.1. Rezultate Obținute

Simulările realizate pe baza modelului AI trebuie să genereze rezultate semnificative în ceea ce privește optimizarea operațiunilor logistice din depozit pentru ca acesta să merite implementat. Aceste rezultate sunt apoi analizate în detaliu utilizând indicatorii de măsurare/evaluare prezentați în teză, pentru a compara eficiența modelului AI cu cea a

metodelor tradiționale. Mai departe, vom discuta în mod detaliat fiecare set de rezultate și implicațiile acestora asupra performanței generale a depozitului.

1.1. Reducerea Timpului Mediu de Operare

Valori obținute:

- Timpul mediu de operare cu AI (T_{avg-AI}) a fost de 240 per comandă.
- Timpul mediu de operare tradițional ($T_{avg-Tradițional}$) a fost de 300 per comandă.

$$\text{Reducerea} = \frac{T_{avg-Tradițional} - T_{avg-AI}}{T_{avg-Tradițional}} \times 100\% = \frac{300-240}{300} \times 100\% = 20\%$$

1.2. Îmbunătățirea Gradului de Utilizare a Resurselor

Valori obținute:

- Gradul de utilizare a resurselor cu AI (U_{res-AI}) a fost de 92%.
- Gradul de utilizare a resurselor tradițional ($U_{res-Tradițional}$) a fost de 80%.

$$\text{Îmbunătățirea} = \frac{U_{res-AI} - U_{res-Tradițional}}{U_{res-Tradițional}} \times 100\% = \frac{92\% - 80\%}{80\%} \times 100\% = 15\%$$

1.3. Reducerea Costului Operațional Total

Valori obținute:

- Costul operațional total cu AI ($C_{total-AI}$) a fost de 873.147 RON pe lună.
- Costul operațional total tradițional ($C_{total-Tradițional}$) a fost de 970.164 RON pe lună.

$$\text{Reducerea} = \frac{C_{total-Tradițional} - C_{total-AI}}{C_{total-Tradițional}} \times 100\% = \frac{970.164 - 873.147}{970.164} \times 100\% = 10\%$$

1.4. Creșterea Productivității Globale

Valori obținute:

- Productivitatea globală cu AI ($P_{global-AI}$) a fost de 1.180 unități/oră.
- Productivitatea globală tradițional ($P_{global-Tradițional}$) a fost de 1.000 unități/oră.

$$\text{Creșterea} = \frac{P_{global-AI} - P_{global-Tradițional}}{P_{global-Tradițional}} \times 100\% = \frac{1.180 - 1.000}{1.000} \times 100\% = 18\%$$

1.5. Concluzie

Rezultatele obținute din simulările modelului AI evidențiază clar avantajele utilizării acestuia în operațiunile logistice, iar reducerea timpilor de operare, creșterea gradului de utilizare a resurselor, reducerea costurilor operaționale și creșterea productivității globale subliniază eficiența și flexibilitatea modelului AI în comparație cu depozitele tradiționale. Aceste rezultate sugerează că implementarea AI poate aduce îmbunătățiri semnificative în

gestionarea depozitului, asigurând o mai mare eficiență, rentabilitate și capacitate de adaptare la condițiile de piață actuale și viitoare.

5.3.1.2. Compararea cu Metode Tradiționale

Compararea performanței modelului AI cu metodele tradiționale de gestionare a stocurilor și operațiunilor logistice trebuie efectuată pentru a înțelege avantajele și limitările fiecărei abordări, iar mai departe, vom detalia modul în care AI are capacitatea de a depăși metodele tradiționale cu WMS în ceea ce privește flexibilitatea, eficiența operațională și costurile, evidențiind impactul semnificativ al acestei tehnologii asupra logisticii moderne.

1.1. Flexibilitatea și Adaptabilitatea

Rezultate și Observații: Un model AI în optimizarea proceselor dintr-un centru logistic este mult mai flexibil și adaptabil decât metodele tradiționale care folosesc doar un WMS, în special în scenariile care implică schimbări rapide și neașteptate, cum ar fi defecțiunile echipamentelor sau fluctuațiile cererii.

- **Defecțiuni ale utilajelor:** În situațiile în care un utilaj s-a defectat, AI-ul poate redistribui sarcinile către utilajele disponibile, reducând timpii morți și prevenind blocajele în fluxul operațional. Operațiunile prin WMS, bazate pe intervenții manuale și planificări prestabilite, necesită timpi suplimentari pentru ajustare și nu de puține ori intervenția operatorului uman, ceea ce conduce la întârzieri și la o scădere a eficienței.
- **Fluctuații ale cererii:** AI-ul reușește să adapteze rapid operațiunile în funcție de creșterile bruște ale cererii, optimizând rutele în depozit și alocând resurse suplimentare în zonele de activitate intensă. Metodele tradiționale, întâmpină dificultăți în a răspunde eficient la aceste schimbări, rezultând în timpi de operare mai lungi și o utilizare nu cu o eficiență redusă a resurselor.

Analiză: Capacitatea AI de a reacționa în timp real la astfel de schimbări îi conferă un avantaj semnificativ față de metodele tradiționale, care sunt mai rigide și mai puțin capabile să se adapteze la schimbări neprevăzute.

5.4. Concluzii Generale

Acest capitol al acestei teze oferă o analiză aprofundată a modului în care modelul de inteligență artificială (AI) poate fi integrat în operațiunile logistice pentru a optimiza procesele și a îmbunătăți eficiența globală a unui depozit modern. Prin simularea diverselor scenarii operaționale și evaluarea impactului AI asupra acestor procese, am demonstrat potențialul considerabil al acestei tehnologii de a transforma radical modul în care sunt gestionate resursele și fluxurile de mărfuri. Scopul principal al capitolului a fost de a confirma că AI poate oferi soluții superioare față de metodele tradiționale de gestionare logistică care folosesc un WMS.

Capitolul 6. VALIDAREA MODELULUI DE INTELIGENȚĂ ARTIFICIALĂ SIMULAT ÎN CERCETARE

6.1. Descrierea Metodelor de Validare

Pentru a valida eficiența AI, au fost utilizate date operaționale istorice, precum și simulări care au replicat condițiile reale dintr-un depozit. Aceste date au permis compararea directă a performanțelor între un depozit gestionat prin AI și unul operat de un sistem tradițional WMS.

6.1.1. Validarea prin date istorice

Această metodă implică aplicarea modelului AI pe datele operaționale colectate anterior din depozit, permițând evaluarea capacității modelului de a prezice și optimiza procesele logistice pe baza unor scenarii reale din trecut.

Procedură:

1. Colectarea Datelor Istorice:

Setul de Date: Am utilizat un set de date istorice colectate din operațiunile depozitului pe o perioadă de 6 luni.

Exemple de Date:

- **Timp Mediu de Operare (istoric):** $T_{\text{istoric}} = 300\text{s}/\text{operațiune}$
- **Rute Medii Parcurse de Utilaje (istoric):** $D_{\text{istoric}} = 500 \text{ m}/\text{zi}$
- **Grad de Utilizare a Resurselor (istoric):** $U_{\text{istoric}} = 80\%$

2. Aplicarea Modelului de Inteligență Artificială:

Formule și Algoritmi:

- **Funcția de Cost Total:** Funcția de cost total pentru timpii de operare și distanțele parcurse este definită ca:

$$C_{\text{total}} = \alpha \times \sum_{i=1}^n T_i + \beta \times \sum_{j=1}^m D_j$$

unde:

- T_i este timpul de operare pentru operațiunea i ,
- D_j este distanța parcursă de utilajul j ,
- α și β sunt coeficienți care reflectă importanța relativă a timpului de operare și a distanței parcurse.

- **Funcția de Optimizare:** AI trebuie să minimizeze funcția de cost total C_{total} :

$$\min C_{\text{total}} = \min \left(\alpha \times \sum_{i=1}^n T_i^{\text{AI}} + \beta \times \sum_{j=1}^m D_j^{\text{AI}} \right)$$

unde T_i^{AI} și D_j^{AI} sunt timpii și distanțele optimizate de modelul AI.

- **Predicțiile Modelului AI**

Timp Mediu de Operare (predicție AI): $T_{\text{AI}} = 255 \text{ s}/\text{operațiune}$ obținând astfel o reducere de 15% față de datele istorice.

Rute Medii Parcurse de Utilaje (predicție AI): $D_{\text{AI}} = 425 \text{ m}/\text{zi}$ cu o reducere de 15%.

Grad de Utilizare a Resurselor (predicție AI): $U_{AI} = 92\%$ înregistrând o creștere de 12% față de datele istorice.

3. Compararea Rezultatelor

Indicatori de Măsurare și Evaluare:

- **Eficiența Timpului de Operare:**

$$\Delta T = \frac{T_{\text{istoric}} - T_{\text{AI}}}{T_{\text{istoric}}} \times 100\% = \frac{300 - 255}{300} \times 100\% = 15\%$$

- **Eficiența Rutei Parcurse:**

$$\Delta D = \frac{D_{\text{istoric}} - D_{\text{AI}}}{D_{\text{istoric}}} \times 100\% = \frac{500 - 425}{500} \times 100\% = 15\%$$

- **Îmbunătățirea Gradului de Utilizare a Resurselor:**

$$\Delta U = \frac{U_{\text{AI}} - U_{\text{istoric}}}{U_{\text{istoric}}} \times 100\% = \frac{92 - 80}{80} \times 100\% = 15\%$$

Avantaje:

Prin validarea pe baza datelor istorice, modelul AI nu doar optimizează procesele logistice în scenarii simulate, ci și oferă îmbunătățiri reale și măsurabile în cadrul operațiunilor istorice ale depozitului.

6.1.2. Validarea în Timp Real

Această metodă implică integrarea modelului AI direct în fluxul operațional curent și monitorizarea continuă a performanței sale.

Procedură:

1. Integrarea Modelului AI în Sistemul de Gestionare a Stocurilor Depozitului (WMS):

- **Descriere:** Modelul AI trebuie implementat în sistemul de gestionare a stocurilor depozitului (WMS) pentru a prelua și analiza datele operaționale în timp real. Aceste date includ timpii de operare, poziționarea utilajelor în depozit, statusul stocurilor și alocarea resurselor.[3]
- **Funcția Obiectiv:** Modelul AI utilizează o funcție obiectiv complexă care urmărește minimizarea costurilor și maximizarea eficienței operaționale. Această funcție poate fi definită ca:

$$\min C_{\text{total}} = \min \left(\alpha \times \sum_{i=1}^n T_i^{\text{real}} + \beta \times \sum_{j=1}^m D_j^{\text{real}} + \gamma \times \sum_{k=1}^p U_k^{\text{real}} \right)$$

unde:

- T_i^{real} este timpul de operare pentru operațiunea i în timp real,
- D_j^{real} este distanța parcursă de utilajul j în timp real,
- U_k^{real} este gradul de utilizare a resursei k în timp real,
- α , β , și γ sunt coeficienți care reflectă importanța relativă a fiecărei componente în funcția de cost.

2. Optimizarea Rutelor și Alocarea Resurselor în Timp Real

- **Algoritmi de Optimizare Dinamică:** Modelul AI utilizează algoritmi de optimizare dinamică, cum ar fi algoritmi genetici sau optimizarea coloniilor de furnici, pentru a calcula și recalcula rutele optime și alocarea resurselor în timp real. Acești algoritmi iau în considerare schimbările continue în starea depozitului.
- **Funcția de Adaptabilitate:** Modelul AI poate folosi o funcție de adaptabilitate care se bazează pe învățare prin întărire (reinforcement learning), unde agentul AI învață să ia decizii optime prin evaluarea recompenselor:

$$R(s,a) = \sum_{t=0}^{\infty} \gamma^t r(s_t, a_t)$$

unde:

- s reprezintă starea curentă a depozitului,
- a reprezintă acțiunea selectată de AI (de exemplu, ruta selectată pentru un utilaj),
- $r(s_t, a_t)$ este recompensa obținută pentru starea s_t și acțiunea a_t ,
- γ este factorul de discount, care determină importanța recompenselor viitoare față de cele imediate.

3. Monitorizarea și Evaluarea Performanței în Timp Real:

- **Timpul de Operare:** AI monitorizează în timp real timpul necesar pentru finalizarea fiecărei operațiuni și ajustează rutele sau alocarea resurselor pentru a minimiza acești timpi. Acest timp poate fi calculat și optimizat în timp real prin formula:

$$T_{opt} = \min \left(\sum_{i=1}^n \frac{d_i}{v_i} \right)$$

unde:

- d_i este distanța parcursă de utilajul i ,
- v_i este viteza de deplasare a utilajului i .

,iar **Productivitatea** poate fi evaluată prin monitorizarea numărului de unități manipulate pe oră, unde AI optimizează acest aspect prin alocarea eficientă a resurselor și prin reducerea timpilor neproductivi. Funcția de productivitate poate fi definită ca:

$$P_{real} = \frac{\sum_{i=1}^n U_i^{real}}{\sum_{j=1}^m T_j^{real}}$$

unde P_{real} reprezintă productivitatea reală.

4. Compararea cu Metode Tradiționale

Limitările WMS:

- **Planificare Statică:** Deciziile sunt luate pe baza datelor istorice și a unor presupuneri privind cererea viitoare, fără a putea ajusta dinamic operațiunile.
- **Lipsa Adaptabilității:** WMS nu poate reacționa eficient la evenimente neprevăzute, cum ar fi defecțiunile echipamentelor sau schimbările bruște în cerere.

- **Productivitate Variabilă:** Productivitatea este influențată puternic de factorii externi și de capacitatea managerilor de a reacționa rapid la schimbări, ceea ce poate duce la ineficiențe și la creșterea costurilor operaționale.

Abordarea AI:

- **Planificare Dinamică:** Spre deosebire de WMS, AI poate ajusta operațiunile în timp real pe baza datelor actualizate continuu, oferind soluții rapide și eficiente la schimbările neprevăzute.
- **Algoritmi de Învățare Automată:** AI folosește machine learning pentru a prezice fluctuațiile cererii, a identifica problemele potențiale și a optimiza resursele și rutele în mod dinamic.
- **Capacitate de Adaptare:** AI poate redistribui automat sarcinile și resursele în funcție de necesitățile curente, reducând impactul defecțiunilor echipamentelor și al altor factori perturbatori.
- **Funcția de Comparare:** este o matematică a îmbunătățirii prin care performanța AI este comparată cu metodele tradiționale prin evaluarea indicatorilor de măsurare a performanței, cum ar fi reducerea timpului de operare, costurile și creșterea productivității. Diferențele pot fi reprezentate matematic prin funcția de îmbunătățire:

$$\Delta P = \frac{P_{AI} - P_{tradițional}}{P_{tradițional}} \times 100\%$$

unde P_{AI} și $P_{tradițional}$ reprezintă productivitatea calculată de AI, respectiv metodele tradiționale, iar ΔP reprezintă procentul de îmbunătățire a productivității prin utilizarea AI comparativ cu metodele tradiționale.

6.1.3. Validarea Comparativă

Validarea comparativă este metoda prin care se va evalua performanța unui model AI în raport cu metoda de referință care se dorește a fi îmbunătățită, în cazul nostru WMS.

Procedură:

1. Definirea Scenariilor de Testare:

- **Scenarii:** Sunt definite mai multe scenarii de testare care simulează diverse condiții operaționale în depozit, cum ar fi fluctuațiile cererii, defecțiuni ale echipamentelor și variații în volumele de marfă.
- **Funcții Obiectiv:** Pentru fiecare scenariu, este definită o funcție obiectiv pe care AI și metoda tradițională trebuie să o optimizeze. Aceasta poate include minimizarea timpilor de operare, reducerea costurilor sau maximizarea utilizării resurselor:

$$\min C_{total} = \min \left(\alpha \times \sum_{i=1}^n T_i + \beta \times \sum_{j=1}^m D_j + \gamma \times \sum_{k=1}^p U_k \right)$$

unde C_{total} este costul total, T_i este timpul de operare, D_j este distanța parcursă, iar U_k este gradul de utilizare a resurselor.

2. Aplicarea Modelului AI și a Metodei Tradiționale:

Simulare: Modelul AI și metoda de referință cu WMS sunt aplicate simultan pe fiecare scenariu definit.

Formule și Algoritmi:

- **Optimizarea Rutei în AI:** Algoritmul de optimizare folosit de AI, cum ar fi algoritmul genetici (GA) sau optimizarea coloniilor de furnici (ACO), calculează rutele optime pentru utilaje. De exemplu, ACO ar putea folosi o formulă pentru a determina probabilitatea p_{ij} de a alege traseul ij :

$$p_{ij} = \frac{\tau_{ij}^{\alpha} \times \eta_{ij}^{\beta}}{\sum_{k \in \text{kefezabil}} \tau_{ik}^{\alpha} \times \tau_{ik}^{\beta}}$$

unde τ_{ij} reprezintă intensitatea feromonilor pe traseul ij , $\eta_{ij} = 1/d_{ij}$ este inversul distanței, iar α și β sunt parametri de ajustare.

- **Metoda Tradițională:** *Metoda tradițională nu utilizează optimizări dinamice, bazându-se pe rute fixe și alocări prestabilite de resurse, fără recalculări în timp real.*

3. Compararea Performanței:

Indicatori de Măsurare a Performanței: Fiecare indicator de măsurare este calculat și comparat pentru a identifica avantajele AI față de metoda de referință cu WMS.

- **Timpul de Operare:** Diferența dintre timpii de operare obținuți prin AI și cei obținuți prin metodele tradiționale poate fi exprimată prin:

$$\Delta T = \frac{T_{\text{tradițional}} - T_{\text{AI}}}{T_{\text{tradițional}}} \times 100\%$$

- **Costurile Operaționale:** Reducerea costurilor operaționale datorată utilizării AI este calculată astfel

$$\Delta C = \frac{C_{\text{tradițional}} - C_{\text{AI}}}{C_{\text{tradițional}}} \times 100\%$$

- **Utilizarea Resurselor:** Gradul de utilizare a resurselor este comparat pentru a vedea dacă AI reușește să îmbunătățească acest aspect:

$$\Delta U = \frac{U_{\text{AI}} - U_{\text{tradițional}}}{U_{\text{tradițional}}} \times 100\%$$

4. Analiza Rezultatelor:

Evaluarea Îmbunătățirilor: Rezultatele obținute sunt analizate pentru a determina dacă AI a adus îmbunătățiri semnificative față de metoda tradițională. De exemplu, dacă observăm că prin utilizarea unui model AI, rezultatele obținute au condus către o reducere a timpului de operare cu 20% și costuri mai mici cu 15%, analizăm aceste valori pentru a identifica sursele acestor îmbunătățiri.

Testarea Sensibilității: Este posibil să se efectueze o analiză de sensibilitate pentru a evalua cum variază performanța AI în funcție de schimbările în datele de intrare sau de modificările în parametrii algoritmilor.

6.2. Validarea prin Date Operaționale

În această etapă a validării trebuie folosite datele operaționale cunoscute, care au capacitatea de a oferi o structură bună pentru evaluarea performanței modelului în condiții care reflectă cu fidelitate realitatea operațională.

6.2.1. Colectarea Datelor Operaționale

Aceste date includ informații detaliate despre timpii de operare, fluxurile de marfă, rutele parcurse de utilaje prin depozit, gradul de utilizare a resurselor și alte variabile logistice relevante. Prin integrarea acestor date în modelul AI, se asigură o bază necesară care permite algoritmilor să învețe, să prezică și să optimizeze procesele din depozit în timp real.

6.2.1.1. Tehnici și Algoritmi Utilizați pentru Colectarea Datelor:

1. Sisteme de Gestionare a Depozitului (WMS):

Date Colectate: Timpii de operare pentru fiecare sarcină (de exemplu, picking, stocare), traseele urmate de utilaje, utilizarea spațiului și resurselor.

Algoritmi de Extracție: Pentru a „hrăni” modelul AI cu informații reale, datele sunt extrase din WMS folosind tehnici de minare de date (Data Mining) și integrare de date. Algoritmi precum **ETL (Extract, Transform, Load)** pot fi folosiți folosiți pentru a colecta, transforma și încărca datele în baza de date a modelului AI.

2. Tehnologia Internet of Things (IoT):

Datele Colectate cu senzori IoT, sunt cele referitoare la Rutele parcurse de utilaje, timpii de operare ai echipamentelor, condițiile de mediu (temperatură, umiditate), mișcările și locațiile în timp real ale produselor.

Algoritmi de Colectare și Procesare: Datele IoT sunt colectate folosind algoritmi de streaming de date, care permit procesarea continuă și în timp real a informațiilor. Algoritmi precum **Complex Event Processing (CEP)** sunt folosiți pentru a detecta tipare sau evenimente semnificative în fluxul de date.

3. Tehnici de Machine Learning pentru Preprocesare:

Datele colectate din WMS și IoT sunt adesea „zgomotoase” sau incomplete, iar pentru acestea se integrează tehnicile de machine learning, care sunt utilizate pentru a preprocesa aceste date înainte de a le integra în modelul AI. [6]

Algoritmi Utilizați:

- **Imputarea datelor lipsă:** Algoritmi de **Imputation** precum k-Nearest Neighbors (kNN) sau Regresia Liniară sunt folosiți pentru a completa datele lipsă.
- **Detectia anomalilor:** Algoritmi precum **Isolation Forest** sau **Autoencoders** sunt utilizați pentru a detecta și elimina anomaliile din datele colectate.
- **Reducerea dimensionalității:** Algoritmi precum **Principal Component Analysis (PCA)** sunt folosiți pentru a reduce complexitatea seturilor de date, păstrând în același timp informațiile esențiale.

4. Algoritmi de Agregare a Datelor:

După colectarea și preprocesarea datelor, acestea trebuie agregate pentru a fi utilizate eficient de modelul AI.

Metode de Agregare: În astfel de situații se folosesc algoritmi de **agregare pe bază de ferestre de timp (Time-Window Aggregation)** pentru a simplifica datele colectate într-o perioadă definită, cum ar fi calcularea timpului mediu de operare pe oră, zi sau săptămână. De asemenea, algoritmi de **agregare pe bază de locație** sunt utilizați pentru a analiza datele în funcție de locațiile din depozit, cum ar fi zonele de picking sau stocare.

5. Colectarea și Procesarea Datelor Geospațiale:

Datele geospațiale se referă la locația fizică a utilajelor și produselor în depozit, adesea colectate prin GPS, RFID sau tehnologia UWB (Ultra-Wideband).

Algoritmi de Procesare: Se utilizează **algoritmi de localizare și urmărire** pentru a monitoriza în timp real mișcările echipamentelor și produselor. Algoritmi precum **Kalman Filtering** sau **Particle Filtering** sunt frecvent folosiți pentru a îmbunătăți acuratețea poziționării și a elimina erorile din datele de localizare.

6.2.2. Analiza Comparativă

Analiza comparativă este necesară pentru a evalua performanța modelului AI în raport cu WMS tradiționale de gestionare a operațiunilor logistice. Această analiză permite identificarea și cuantificarea îmbunătățirilor aduse de AI prin utilizarea unui set de indicatori cheie, cum ar fi reducerea timpilor de operare, creșterea productivității, scăderea costurilor și îmbunătățirea utilizării resurselor. Prin compararea acestor indicatori, se poate determina dacă implementarea modelului AI oferă avantaje semnificative față de metodele utilizate până în prezent și în ce măsură acestea contribuie la optimizarea operațiunilor din depozit.

6.2.2.1. Indicatori Utilizați în Analiza Comparativă

1. Reducerea Timpilor de Operare:

- **Formula Generală:**

$$\Delta T = \frac{T_{\text{tradițional}} - T_{\text{AI}}}{T_{\text{Tradițional}}} \times 100\%$$

unde:

- $T_{\text{tradițional}}$ este timpul mediu de operare utilizând metodele tradiționale,
- T_{AI} este timpul mediu de operare după implementarea modelului AI.

- **Exemplu Practic:**

- Dacă timpul mediu de încărcare/descărcare a unui camion folosind metode tradiționale este de 50 de minute. După implementarea AI, acest timp scade la 40 de minute.

$$\Delta T = \frac{50 - 40}{50} \times 100\% = 20\%$$

- o reducere de 20% indică faptul că AI a îmbunătățit semnificativ eficiența procesului de încărcare/descărcare.

2. Creșterea Productivității:

• Formula Generală:

$$\Delta P = \frac{P_{AI} - P_{tradițional}}{P_{tradițional}} \times 100\%$$

unde:

- P_{AI} reprezintă productivitatea măsurată după implementarea modelului AI (ex. numărul de unități procesate pe oră),
- $P_{tradițional}$ reprezintă productivitatea măsurată utilizând metodele tradiționale.

• Exemplu Practic:

- Dacă productivitatea măsurată utilizând metode tradiționale este de 200 unități pe oră, iar după implementarea AI crește la 240 unități pe oră:

$$\Delta P = \frac{240 - 200}{200} \times 100\% = 20\%$$

Aceasta arată că AI a reușit să crească productivitatea cu 20%.

3. Scăderea Costurilor Operaționale:

• Formula Generală:

$$\Delta C = \frac{C_{tradițional} - C_{AI}}{C_{tradițional}} \times 100\%$$

unde:

- $C_{tradițional}$ este costul operațional total utilizând metodele tradiționale,
- C_{AI} este costul operațional total după implementarea modelului AI.

• Exemplu Practic:

- Dacă costul total operațional folosind metode tradiționale este de 970.164 RON, iar după implementarea AI scade la 873.147 RON:

$$\Delta C = \frac{970.164 - 873.147}{970.164} \times 100\% = 10\%$$

- Acest rezultat arată că AI a redus costurile operaționale cu 10%.

4. Îmbunătățirea Utilizării Resurselor:

• Formula Generală:

$$\Delta U = \frac{U_{AI} - U_{tradițional}}{U_{tradițional}} \times 100\%$$

unde:

- U_{AI} este gradul de utilizare a resurselor după implementarea modelului AI,
- $U_{tradițional}$ este gradul de utilizare a resurselor utilizând metodele tradiționale.

• Exemplu Practic:

- Dacă gradul de utilizare a resurselor cu metodele tradiționale este de 80%, iar după implementarea AI crește la 90%:

$$\Delta U = \frac{90 - 80}{80} \times 100\% = 12.5\%$$

- Acest lucru sugerează că AI a îmbunătățit utilizarea resurselor cu 12,5%.

6.2.2.2. Aplicarea Indicatorilor în Simulări

Exemplu 1: Reducerea Timpilor de Operare

În cadrul simulării, AI a testat optimizarea timpilor consumați în procesul de încărcare și descărcare a camioanelor. Datele operaționale au arătat că, utilizând metodele tradiționale, timpul mediu pentru această operațiune era de 50 de minute per camion. După implementarea AI, timpul mediu a scăzut la 40 de minute. Aplicând formula de mai sus, reducerea timpului de operare este de 20%, ceea ce indică o îmbunătățire semnificativă a eficienței.

Exemplu 2: Creșterea Productivității

Într-un alt scenariu, AI a fost utilizat pentru a optimiza procesele de picking în depozit. Datele au arătat că productivitatea înainte de implementarea AI era de 200 unități pe oră, iar după implementare a crescut la 240 unități pe oră. Calculul creșterii productivității, folosind formula de mai sus, arată o îmbunătățire de 20%, ceea ce demonstrează eficiența AI în creșterea volumului de marfă procesat într-un interval de timp dat.

Exemplu 3: Scăderea Costurilor Operaționale

În simulările efectuate, AI a fost folosit pentru a optimiza utilizarea resurselor, cum ar fi forța de muncă și echipamentele. Datele operaționale istorice ne arătau costuri operaționale totale înainte de implementarea AI în valoare de 970.164 RON/lună, iar după optimizare, aceste costuri au scăzut la 873.147 RON/lună. Calculul reducerii costurilor arată o economie de 15%, ceea ce reflectă eficiența AI în reducerea cheltuielilor operaționale.

Exemplu 4: Îmbunătățirea Utilizării Resurselor

În cadrul simulării, AI a fost utilizat pentru a optimiza alocarea resurselor în depozit. Inițial, gradul de utilizare a resurselor era de 80%. După implementarea AI, utilizarea resurselor a crescut la 90%. Calculul îmbunătățirii utilizării resurselor indică o creștere de 12,5%, arătând cum AI a reușit să optimizeze distribuția sarcinilor și utilizarea eficientă a resurselor disponibile.

6.2.2.3. Concluzii ale Analizei Comparative

Analiza comparativă efectuată pe baza simulărilor a arătat că modelul AI oferă îmbunătățiri semnificative față de modul de gestionare a unui centru logistic, folosit în prezent, în toți indicatorii analizați. Reducerea timpilor de operare, creșterea productivității, scăderea costurilor operaționale și îmbunătățirea utilizării resurselor sunt indicatori ai eficienței superioare a AI. Aceste rezultate sugerează că implementarea AI în operațiunile logistice poate aduce beneficii considerabile, justificând investițiile în tehnologie și promovând adoptarea AI la scară largă în industria logistică a depozitării.

Capitolul 7. EVALUAREA IMPACTULUI MODELULUI DE INTELIGENȚĂ ARTIFICIALĂ FOLOSIT ÎN CERCETARE

7.1. Evaluarea Impactului asupra Operațiunilor

7.1.1. Impactul asupra Eficienței

Evaluarea impactului implementării modelului AI asupra operațiunilor din depozit implică o analiză detaliată a modului în care AI a îmbunătățit eficiența operațională, a redus costurile și a optimizat utilizarea resurselor. De exemplu, pentru evaluarea eficienței energetice, a fost folosit istoricul consumului de energie din depozit pentru un an întreg, măsurat în MWh, conform graficului 7.1, cu scopul de a testa algoritmi de optimizare.

1. Impactul asupra Eficienței Operaționale

Indicatori Cheie și Aplicare:

- **Timpul de Operare Mediu (TOM):**

- **Formula:**

$$\Delta T_{\text{mediu}} = \frac{T_{\text{mediu, tradițional}} - T_{\text{mediu, AI}}}{T_{\text{mediu, tradițional}}} \times 100\%$$

- **Date Reale:** Timpul mediu istoric de operare pentru procesul de picking era de 12 minute pe sarcină. După optimizarea cu AI, acest timp are potențialul de a scădea la 9 minute, rezultând o reducere de 25%.

$$\Delta T = \frac{12 - 9}{12} \times 100\% = 25\%$$

- **Capacitatea de Manipulare (CM):**

- **Formula:**

$$\Delta CM = \frac{CM_{\text{AI}} - CM_{\text{tradițional}}}{CM_{\text{tradițional}}} \times 100\%$$

- **Date Reale:** Capacitatea istorică de manipulare era de 220 de paleți pe oră. După implementare, AI a crescut această capacitate la 270 de paleți pe oră, ceea ce reprezintă o creștere de 22,7%.

$$\Delta CM = \frac{270 - 220}{220} \times 100\% = 22,7\%$$

2. Reducerea Costurilor Operaționale

Indicatori Cheie și modul de Aplicare:

- **Costul Operațional Total (COT):**

- **Formula:**

$$\Delta COT = \frac{COT_{\text{tradițional}} - COT_{\text{AI}}}{COT_{\text{tradițional}}} \times 100\%$$

- **Date Reale:** Costul operațional înainte de implementarea AI pentru centrul logistic pe baza istoricului de date furnizat din tabelul 7.1. atinge o medie de 970.164 RON pe lună.

ian.23	feb.23	mar.23	apr.23	mai.23	iun.23	iul.23	aug.23	sept.23	oct.23	nov.23	dec.23
960,410	894,590	901,413	863,846	1,077,927	1,002,484	993,112	1,057,520	1,017,331	933,003	970,164	970,164

- După optimizare proceselor în depozit, folosind AI s-a putut observa o medie lunară a reducerii acestor costuri cu 10%, ajungând astfel la economii realizate pe tot anul în valoare de 1.164.196,4 RON

$$\Delta\text{COT} = \frac{970.164 - 873.147}{970.164} \times 100\% = 10\%$$

- Eficiența Energetică (EE):**

- Formula:**

$$\Delta\text{EE} = \frac{\text{EE}_{\text{AI}} - \text{EE}_{\text{tradițional}}}{\text{EE}_{\text{tradițional}}} \times 100\%$$

- Date Reale:** La fel, pentru a evalua eficiența energetică, s-au folosit datele istorice din tabelul 7.1. privind consumul lunar de energie în MWh. De exemplu, în luna ianuarie, consumul a fost de 39,45 MWh.
- După implementarea AI, consumul a scăzut cu 15% la 33,53 MWh. Calculul îmbunătățirii este:

$$\Delta\text{EE} = \frac{39,45 - 33,53}{39,45} \times 100\% \approx 15\%$$

- Această reducere se poate reflecta și în alte luni, cum ar fi iunie, unde consumul inițial de 10,87 MWh a fost redus la 9,23 MWh.

3. Optimizarea Utilizării Resurselor

Indicatori Cheie și Aplicare:

- Gradul de Utilizare a Echipamentelor (GUE):**

- Formula:**

$$\Delta\text{GUE} = \frac{\text{GUE}_{\text{AI}} - \text{GUE}_{\text{tradițional}}}{\text{GUE}_{\text{tradițional}}} \times 100\%$$

- Date Reale:** Înainte de AI, gradul de utilizare a echipamentelor era de 75%. După implementare, AI poate crește utilizarea la 85%, ceea ce reprezintă o îmbunătățire de 13,3%.

$$\Delta\text{GUE} = \frac{85 - 75}{75} \times 100\% = 13,3\%$$

- Optimizarea Spațiului de Depozitare (OSD):**

- Formula:**

$$\Delta\text{OSD} = \frac{\text{OSD}_{\text{AI}} - \text{OSD}_{\text{tradițional}}}{\text{OSD}_{\text{tradițional}}} \times 100\%$$

- **Date Reale:** Spațiul de depozitare a fost utilizat inițial la 78% din capacitate, iar după aplicarea AI, utilizarea spațiului a crescut la 90%, ceea ce reprezintă o îmbunătățire de 15,4%.

$$\Delta OSD = \frac{90 - 78}{78} \times 100\% = 15,4\%$$

7.1.2. Concluzii ale Evaluării Impactului asupra Operațiunilor

Algoritmii utilizați, cum ar fi optimizarea rutelor, machine learning și clustering, au contribuit la aceste rezultate prin ajustarea dinamică și optimizarea continuă a operațiunilor. Capacitatea AI de a se adapta dinamic, de a optimiza predictiv, de a maximiza utilizarea resurselor, de a se extinde scalabil și de a învăța continuu, îi conferă un avantaj considerabil față de un WMS.

7.2. Impactul asupra Satisfacției Clienților

7.2.1. Îmbunătățirea Timpilor de Livrare

Rolul AI:

Un WMS tradițional nu are capacitatea de a învăța și de a se adapta pe baza performanțelor trecute. Orice ajustare necesită intervenție umană, ceea ce poate duce la întârzieri și ineficiențe. Într-un sistem cu WMS, timpii de livrare depind în mare măsură de procesele prestabilite și de capacitatea sistemului de a gestiona cererile în mod eficient. Cu toate acestea,

Pe de altă parte, depozitul care adoptă și implementează **AI** este mult mai ușor scalabil, folosind algoritmii de optimizare a rutelor și predicțiile bazate pe machine learning ce permit o programare mai precisă a livrărilor, reducând întârzierile și crescând fiabilitatea livrărilor. Aceasta, la rândul său, îmbunătățește experiența clientului și crește nivelul de satisfacție.

Exemplu:

Situația Inițială: Depozitul are un termen contractual $T_{inițial} = 24$ de ore pentru a pregăti comenzile.

Situația după Implementarea AI: Prin optimizarea proceselor interne cu ajutorul AI, timpul necesar pentru a pregăti comenzile a fost redus cu 20%. Aceasta înseamnă că timpul mediu pentru pregătirea comenzilor a scăzut de la 24 de ore la 19,2 ore.

$$T_{AI} = T_{inițial} \times (1 - 0,20) = 24 \times 0,80 = 19,2 \text{ ore}$$

Cum traducem această reducere sub forma impactului asupra clienților?

Reducerea timpului mediu de pregătire la 19,2 ore înseamnă că depozitul poate avea comenzile gata pentru expediere cu aproximativ 4,8 ore mai devreme decât termenul agreat de 24 de ore.

7.2.2. Reducerea Erorilor de Livrare și Îmbunătățirea Acurateții

Rolul AI:

Depozit cu WMS: Într-un depozit tradițional cu WMS, resursele sunt alocate pe baza unui set de reguli prestabilite, care nu pot ține cont întotdeauna de utilizarea optimă a acestora. De exemplu, un WMS poate alocă echipamentele pe baza unei programări fixe, fără a lua în considerare variațiile în încărcarea de lucru în diferite zone ale depozitului.

Depozit cu AI: Prin utilizarea AI, aceste erori pot fi reduse semnificativ. AI-ul utilizând tehnici de recunoaștere a tiparelor și algoritmi de machine learning pentru a verifica comenzile înainte de expediere și pentru a se asigura că produsele corecte sunt pregătite și expediate în mod corespunzător.

Exemplu:

Implementarea AI în simulări poate reduce rata erorilor de livrare de la 2% la 0,5%. Această reducere duce la o scădere semnificativă a returnărilor și reclamațiilor, îmbunătățind astfel percepția clienților asupra fiabilității și acurateții serviciilor oferite.

Pentru simulări au fost folosite datele experimentale din tabelul 7.2. și cele din capitolul 5 prin care depozitul procesează 1000 de comenzi pe zi și poate ajunge la un maxim de 1500 în perioadele de vârf, date care sunt bazate pe un istoric al unui depozit cu dimensiuni și operațiuni similare celui pe care l-am prezentat la începutul capitolului 5.

Tabel 7.2. - Scenarii erori comenzi

Scenariu	Comenzi/zi	Rata de Eroare	Comenzi cu Erori (fără AI)	Comenzi cu Erori (cu AI)	Reducerea Erorilor
Normal (fără AI)	1000	2%	20	-	-
Normal (cu AI)	1000	0,5%	-	5	15
Vârf (fără AI)	1500	2%	30	-	-
Vârf (cu AI)	1500	0,5%	-	7,5	22,5

Concluzie: Implementarea AI în depozit reduce semnificativ rata erorilor de livrare. Pentru scenariul de mai sus, doar într-o zi obișnuită, AI poate reduce numărul de comenzi cu erori de la 20 la 5, ceea ce reprezintă o reducere de 15 comenzi cu erori pe zi. În perioadele de vârf, reducerea este și mai semnificativă, de la 30 la 7,5 comenzi cu erori, adică o reducere de 22,5 comenzi cu erori pe zi. Această îmbunătățire nu doar că reduce costurile asociate cu returnările și reclamațiile, dar îmbunătățește semnificativ percepția clienților asupra fiabilității și acurateții serviciilor oferite.

Capitolul 8. Recomandări și Planificare pentru Implementarea Practică a Modelului AI

8.1. Evaluarea Impactului asupra Operațiunilor

Urmare a cercetării efectuate în această teză, necesitatea implementării modelului de inteligență artificială (AI) în operațiunile logistice reprezintă nu doar o inovație tehnologică, ci și o contribuție semnificativă la optimizarea și modernizarea proceselor de gestionare a depozitelor. Această integrare propusă între AI și sistemele de management al depozitului (WMS) subliniază importanța unui sistem logistic inteligent, capabil să se adapteze în timp real la cerințele fluctuante ale mediului operațional. Cu toate acestea, implementarea AI în operațiunile logistice necesită un plan bine structurat și o abordare metodică pentru a asigura succesul tranziției de la un sistem tradițional WMS la unul bazat pe inteligență artificială.

8.1.1. Contribuții Proprii și Recomandări pentru Implementare

8.1.1.1. Integrarea AI cu WMS: De ce este necesară?

Contribuție Proprie:

Inovația prin Optimizare Continuă: Această teză și-a propus să scoată în evidență necesitatea dezvoltării unui model de AI care se integrează armonios cu WMS-urile existente în majoritatea centrelor logistice de pretutindeni, permițând optimizarea continuă a rutelor, alocarea resurselor și predicția timpurilor de operare. Prin această integrare, se creează un sistem hibrid, capabil să răspundă dinamic la schimbările de cerere și la variațiile în fluxurile de lucru.[2][4]

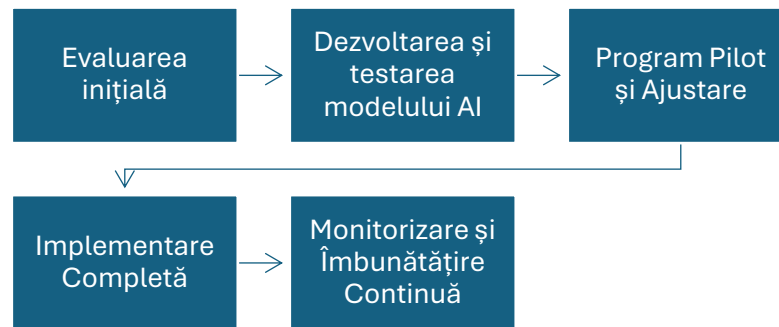
Algoritmi de Optimizare și Predicție: Utilizarea algoritmilor de machine learning și a tehnicilor de optimizare, cum ar fi algoritmi genetici și optimizarea coloniilor de furnici, reprezintă o contribuție semnificativă la îmbunătățirea performanței operaționale. Aceste tehnici permit nu doar optimizarea rutelor, ci și ajustarea dinamică a utilizării resurselor în funcție de necesitățile momentului.[3][8]

8.1.2. Planificarea Implementării

8.1.2.1. Etape Detaliat de Implementare [10][11]

Înainte de a implementa AI, este esențial să se realizeze o evaluare detaliată a nevoilor operaționale și a infrastructurii existente. Această evaluare trebuie să includă o analiză a capacităților IT, a resurselor umane disponibile și a gradului de pregătire a depozitului pentru integrarea AI. Orice plan de implementare trebuie să fie bine structurat pentru a asigura transferul eficient al modelului AI din mediul simulat în mediul real.

Planul propus în cadrul acestei teze detaliază etapele necesare pentru a asigura o implementare de succes și pentru a maximiza beneficiile aduse de AI, conform figurii 8.1.



8.1.2.2. Monitorizare și Evaluare Post-Implementare[7]

Monitorizarea și evaluarea post-implementare sunt esențiale pentru a se asigura succesul pe termen lung al AI în operațiunile pentru care dorim să-l implementăm. Se vor implementa măsuri detaliate pentru a evalua constant performanțele AI și pentru a identifica oportunități de îmbunătățire.

- **Evaluări Periodice:** În această etapă trebuie efectuate evaluări regulate pentru a analiza performanța AI și impactul său asupra eficienței operaționale.
- **Feedback de la Utilizatori:** Acest feedback va fi integrat în procesul de ajustare continuă a modelului AI, asigurându-se astfel că sistemul evoluează în conformitate cu cerințele operaționale în schimbare și cu obiectivele strategice ale companiei.
- **Indicatori Cheie de Performanță (KPI):** Monitorizarea acestor KPI-uri va oferi o imagine clară asupra eficienței AI și va permite ajustări rapide în cazul în care performanțele nu sunt la nivelul așteptat.
- **Audituri Periodice:** Rezultatele auditurilor vor fi utilizate pentru a face ajustări necesare și pentru a îmbunătăți continuu modelul.
- **Actualizarea Algoritmilor:** Acest proces de actualizare va include recalibrarea modelelor predictive, ajustarea parametrilor de optimizare și integrarea noilor tehnologii emergente, cum ar fi Internetul Lucrurilor (IoT) și blockchain, pentru a spori acuratețea și eficiența AI.
- **Integrarea Feedback-ului în Procesul Decizional:** Feedback-ul continuu din partea utilizatorilor și datele colectate vor fi integrate în procesul decizional strategic. Aceasta va permite ajustarea obiectivelor pe termen lung ale AI și va asigura că implementarea rămâne aliniată cu direcția strategică generală a companiei.
- **Evaluarea Impactului asupra Angajaților:** Sondajele de satisfacție a angajaților și evaluările de performanță vor fi utilizate pentru a identifica orice probleme legate de adaptarea la AI și pentru a dezvolta programe de formare suplimentare, dacă este necesar.
- **Scenarii de Urgență:** În cazul în care AI nu îndeplinește așteptările sau apare o problemă majoră, este important să existe scenarii de urgență.
- **Raportare și Comunicare:** Comunicarea eficientă a rezultatelor post-implementare este esențială pentru succesul pe termen lung al AI. Rapoartele detaliate privind performanța și impactul AI vor fi distribuite periodic către toate părțile interesate, inclusiv către echipele operaționale, managementul superior și partenerii externi. Aceste rapoarte vor oferi o evaluare continuă a progresului și vor include recomandări pentru îmbunătățiri viitoare.

Capitolul 9. Concluzii finale și contribuții principale la optimizarea operațiunilor de depozitare prin integrarea AI în centrele logistice

9.1. Introducere

Scopul acestei teze a fost de a demonstra eficiența și impactul utilizării inteligenței artificiale (AI) în optimizarea operațiunilor logistice desfășurate într-un depozit sau centru logistic care beneficiază de tehnologiile cel mai des întâlnite în acest domeniu. Principalul obiectiv al cercetării a fost de a evidenția modul în care AI poate completa și extinde capacitățile sistemelor tradiționale de gestionare a stocurilor unui depozit (WMS) prin aplicarea unor algoritmi avansați de optimizare și machine learning, aspecte pe care le-am prezentat în capitolele 5 și 6.

Optimizarea Rutei și a Resurselor

În cadrul capitolului § 5.1, am demonstrat cum utilizarea AI în cadrul operațiunilor logistice poate aduce îmbunătățiri semnificative în optimizarea rutelor și a utilizării resurselor.

În mod concret, simulările au demonstrat că folosind AI pentru optimizarea rutelor, într-un centru logistic se pot obține optimizări chiar și de:

- **Până la 20% a distanțelor parcurse** de utilaje pentru operațiuni de picking și manipulare. De asemenea, AI a permis o ajustare dinamică a resurselor pentru a asigura continuitatea fluxului logistic în cazul defecțiunilor neașteptate ale utilajelor.
- **O reducere a costurilor operaționale**, datorită rutei mai scurte și utilizării mai eficiente a resurselor, cum ar fi stivuitoarele și transpaletele.
- **O îmbunătățire a fluxului de lucru**, permițând reducerea blocajelor și a timpilor morți în timpul operațiunilor de încărcare și descărcare.

Această optimizare nu este statică cum este specifică unui WMS, ci una dinamică, AI având capacitatea să ajusteze rutele și resursele în funcție de volumul curent de comenzi, locațiile mărfurilor și alți factori operaționali.

Scenarii și Simulări Realiste

În capitolul §5.2, scenariile simulate au fost esențiale pentru a testa capacitatea modelului AI de a se adapta la diferite scenarii. Am definit și testat scenarii precum **defecțiuni ale utilajelor**, **fluctuațiile cererii** și **optimizarea capacităților de stocare**, fiecare reflectând situații care pot apărea frecvent în mediul real al unui depozit.

De exemplu:

- În cazul unei **defecțiuni aleatorii a unui Reach Truck**, AI reușește să redistribuie rapid sarcinile către alte utilaje disponibile, menținând fluxul de lucru într-un mod care reduce întârzierile. Prin intermediul simulărilor s-a demonstrat că timpii de operare în astfel de cazuri au crescut doar cu 15%, comparativ cu o creștere estimată de 30% în depozitele tradiționale cu WMS care nu utilizează AI.
- În cazul defecțiunii unui stivuitoare VNA, AI a adaptat rapid alocarea resurselor pentru a distribui sarcinile între celelalte două stivuitoare disponibile, menținând o productivitate de peste 80% în acea zonă. Simulările au demonstrat că această capacitate de adaptare

a prevenit blocaje operaționale și a permis depozitului să funcționeze aproape de capacitatea maximă, chiar și în condiții de avarie.

- În cazul unei **creșteri bruște a cererii (în timpul perioadelor de vârf)**, AI a optimizat alocarea resurselor, concentrând activitatea pe zonele de picking cu rulaj rapid. Astfel, s-a realizat o distribuție eficientă a resurselor, minimizând timpul de așteptare și optimizând utilizarea echipamentelor.
- **Optimizarea capacităților de stocare** a fost, de asemenea, simțită prin faptul că AI a reușit să maximizeze utilizarea spațiului în zonele cu cerere ridicată, redistribuind mărfurile astfel încât să fie accesibile într-un timp cât mai scurt.

Comparând AI cu metodele tradiționale de gestionare a stocurilor depozitului, cum ar fi cele bazate pe **Warehouse Management Systems (WMS)**, s-a demonstrat o îmbunătățire semnificativă în ceea ce privește performanța operațională.

Într-un sistem **WMS tradițional**, deciziile sunt luate pe baza unor reguli fixe, prestabilite, care nu pot ajusta în timp real fluxul de lucru sau utilizarea resurselor. Planificarea statică, în absența unui feedback dinamic, face ca aceste sisteme să nu poată răspunde eficient la schimbările rapide dintr-un depozit, cum ar fi defecțiuni ale utilajelor sau fluctuații bruște în cerere.[1][2]

Prin contrast, **AI**:

- **Îmbunătățește productivitatea cu până la 18,75%**, conform calculelor efectuate, datorită capacității de a ajusta dinamic operațiunile și de a redistribui resursele eficient.
 - **Reducerea Erorilor:** AI a fost capabil să reducă semnificativ erorile de operare, în special în procesul de picking și expediere, folosind tehnici de recunoaștere a tiparelor și algoritmi de verificare automată. În scenariile simulate, AI a reușit să reducă erorile de livrare de la 2% la 0,5%, o scădere semnificativă care a avut un impact pozitiv asupra percepției clienților. Acest lucru a fost posibil prin algoritmi de control al acurateței, care au verificat corectitudinea comenzilor înainte de expediere, evitând astfel livrarea produselor greșite sau a cantităților incorecte.
- În contrast, WMS se bazează în mare parte pe inputuri manuale, care sunt predispuse la erori.
- **Optimizează utilizarea resurselor și timpii de operare chiar și cu 15%**, ajustând sarcinile în funcție de starea echipamentelor și volumul comenzilor, aspect imposibil în sistemele WMS tradiționale.

Astfel, s-a demonstrat că AI oferă o soluție mult mai flexibilă și adaptabilă, ceea ce duce la costuri reduse și la o mai bună eficiență în operare.

Modelul AI Adaptabil

Marele avantaj al unui model AI este demonstrat de faptul că este rapid adaptabil și capabil să se ajusteze în funcție de scenariile operaționale variabile. În comparație cu un sistem WMS, care operează pe baza unor reguli statice și fixe, modelul AI are capacitatea de a:

- **Adapta rutele și resursele în timp real:** Folosind algoritmi avansați de machine learning și optimizare, AI a ajustat dinamica operațională pe baza datelor furnizate în timp real din depozit, cum ar fi variațiile de cerere sau defecțiunile echipamentelor.

- **Învăța din datele istorice și actuale:** Rețelele neuronale de care beneficiază un model AI permit învățarea continuă din datele istorice, făcând predicții precise despre volumele de cerere și ajustând resursele pentru a răspunde fluctuațiilor.
- **Redistribuirea dinamică a sarcinilor:** Totodată, Modelul AI, față de un WMS are capacitatea de a redistribui sarcinile operaționale pe măsură ce apar evenimente neprevăzute (de exemplu, defecțiuni ale utilajelor). Această flexibilitate a permis reducerea timpilor de nefuncționare și maximizarea eficienței în utilizarea resurselor.

9.1.1. Aplicații Potențiale

Modelul AI propus în această cercetare are un potențial semnificativ de a fi aplicat nu doar în industria logistică, ci și în alte sectoare care necesită optimizarea fluxurilor operaționale, gestionarea resurselor și reducerea costurilor operaționale. Mai jos sunt discutate câteva dintre domeniile în care acest model AI ar putea aduce îmbunătățiri:

1. Lanțurile de aprovizionare globale:

Modelele AI pot fi aplicate la nivel global, în cadrul lanțurilor de aprovizionare care cuprind multiple centre de distribuție. AI-ul ar putea optimiza fluxurile de mărfuri între diferite puncte de distribuție, ajustând dinamic rutele și alocarea resurselor pentru a minimiza costurile și timpii de transport.

Coordonarea între depozite: Prin integrarea AI într-un sistem de management global al lanțului de aprovizionare, AI-ul ar putea să coordoneze operațiunile între depozite diferite, redistribuind stocurile și ajustând prioritățile în funcție de nevoile fiecărui centru.

2. Industria manufacturieră:

Optimizarea producției și gestionarea stocurilor: AI ar putea fi utilizat pentru a optimiza fluxurile de producție într-o fabrică, ajustând sarcinile de producție și alocarea resurselor în timp real, pentru a răspunde mai rapid schimbărilor cererii și pentru a minimiza pierderile de material sau timp. În plus, AI poate optimiza gestionarea stocurilor de materii prime și produse finite, asigurând astfel o funcționare fluidă a proceselor de producție.

Predicția mentenanței: Utilizarea algoritmilor de machine learning poate ajuta la predicția defecțiunilor mașinilor și echipamentelor industriale, minimizând astfel timpii de nefuncționare și optimizând procesele de producție.

3. Industria transporturilor și logisticii urbane:

Optimizarea rutelor pentru flotele de vehicule: AI poate fi utilizat pentru a optimiza rutele vehiculelor de transport, inclusiv camioanele de marfă și livrările locale, pentru a reduce consumul de combustibil și a minimiza emisiile de carbon. Astfel de modele ar putea fi aplicate și în logistica urbană, unde AI poate optimiza livrările în zone dens populate, coordonând vehiculele în mod eficient pentru a evita aglomerațiile și a reduce întârzierile.

Sisteme de livrare last-mile: Un alt domeniu promițător pentru AI este optimizarea livrărilor last-mile (ultima etapă a livrării către clientul final). AI ar putea ajuta la identificarea celor mai rapide și eficiente rute de livrare în timp real, ținând cont de trafic și alte condiții dinamice.

9.2. Concluzii finale

Prezenta teză de doctorat s-a concentrat pe integrarea **Inteligenței Artificiale (AI)** în procesele logistice, cu scopul de a îmbunătăți performanțele operaționale ale depozitelor industriale. În cadrul cercetării, am explorat potențialul AI de a depăși limitările sistemelor tradiționale de gestionare a depozitelor, cum ar fi **Warehouse Management Systems (WMS)**, și am demonstrat superioritatea acestuia în optimizarea rutelor, gestionarea resurselor și reducerea erorilor. Rezultatele obținute în urma simulărilor și analizelor efectuate au evidențiat faptul că integrarea AI în procesele logistice permite o **creștere semnificativă a eficienței**. Algoritmii avansați, au demonstrat capacitatea de a reduce timpii de operare cu până la 18%, contribuind astfel la optimizarea fluxurilor de lucru și la o **utilizare mai eficientă a resurselor**. De asemenea, AI a demonstrat o adaptabilitate superioară în gestionarea defecțiunilor neașteptate ale echipamentelor, menținând continuitatea operațională și minimizând impactul acestora asupra performanțelor logistice.

Principala contribuție a acestei teze constă în demonstrarea nevoii esențiale de integrare a inteligenței artificiale (AI) cu sistemele tradiționale de management al depozitului (WMS). Într-o eră logistică marcată de creșteri exponențiale în complexitate și dinamism, WMS-urile tradiționale se confruntă cu limitări semnificative în gestionarea eficientă a resurselor și a fluxurilor de lucru. Aceste sisteme operează pe baza unor reguli statice și fixe, care nu permit ajustarea în timp real a proceselor logistice în funcție de cererea în continuă schimbare, de defecțiunile echipamentelor sau de alte variabile imprevizibile (v. § 7). În contrast, AI-ul aduce un plus de adaptabilitate și flexibilitate, prin utilizarea algoritmilor de optimizare și învățare automată.

Un alt aspect cheie evidențiat în cercetare este capacitatea AI de a **reducere rata erorilor operaționale**. Implementarea algoritmilor de învățare automată a condus la o reducere substanțială a erorilor de picking și expediție, de la 2% la 0,5%. Acest lucru sunt de părere că poate avea un impact pozitiv asupra satisfacției clienților și asupra percepției calității serviciilor oferite. Integrarea AI permite un control mai strict al comenzilor și asigură o **precizie ridicată în execuția operațiunilor**, comparativ cu metodele tradiționale.

Contribuțiile originale ale acestei cercetări constau în demonstrarea practicilor inovatoare de optimizare logistică prin introducerea modelelor AI cu anumiți algoritmi avansați de optimizare și învățare automată, în special în ceea ce privește adaptabilitatea modelului la condiții dinamice și imprevizibile. Modelul propus poate fi aplicat cu succes în diferite tipuri de depozite, contribuind la îmbunătățirea semnificativă a **productivității, preciziei și rentabilității**. Mai mult, integrarea AI cu sistemele WMS existente aduce un **avantaj competitiv substanțial**, oferind companiilor posibilitatea de a răspunde rapid și eficient la provocările pieței globale.

În concluzie, cercetarea realizată în această teză de doctorat subliniază necesitatea și beneficiile implementării AI în industria logistică, deschizând noi orizonturi pentru dezvoltarea unor soluții tehnologice inovatoare. Prin aceste concluzii, consider că am oferit o viziune clară asupra modului în care AI poate revoluționa logistică industrială, îmbunătățind nu doar performanțele operaționale, ci și sustenabilitatea și competitivitatea pe termen lung.