



Domeniul Inginerie și Management

TEZĂ DE DOCTORAT

- REZUMAT -

STUDII ȘI CERCETĂRI CU PRIVIRE LA MANAGEMENTUL PRODUȚIEI DE SERIE

Student-doctorand:
Mircea TEODORESCU

Conducător științific:
Prof. Dr. Ing. Florin LUNGU

Comisia de evaluare a tezei de doctorat:

Președinte: Prof. Dr. Inf, Ec. **Emilia Ciupan** - Universitatea Tehnică din Cluj-Napoca;

Conducător științific: Prof. Dr. Ing. **Florin Lungu** - Universitatea Tehnică din Cluj-Napoca;

Referenți:

- Prof. Dr. Ing. **Liviu Moldovan** - Universitatea de Medicină, Farmacie, Știință și Tehnologie "G.E. Palade" Târgu-Mureș;
- Prof. Dr. Ing. **Gabriela Proștean** - Universitatea Politehnică din Timișoara;
- Prof. Dr. Ing. **Nicolae Ungureanu** - Universitatea Tehnică din Cluj-Napoca.

**- Cluj-Napoca -
2024**

INTRODUCERE, STRUCTURĂ ȘI METODOLOGIE

Motivația și necesitatea demersului (Argument)

În contextul actual al pieței globalizate, optimizarea programării producției nu este doar o necesitate, ci și un imperativ pentru companiile care doresc să rămână competitive. Creșterea complexității lanțurilor de aprovizionare, diversificarea cerințelor clienților și presiunea constantă pentru reducerea costurilor impun adoptarea unor soluții tehnologice avansate. În acest sens, inteligența artificială (IA) și algoritmi de optimizare oferă un potențial imens pentru îmbunătățirea eficienței operaționale. Utilizarea acestor tehnologii permite companiilor să planifice mai precis, să reducă ciclurile de producție și să minimizeze erorile, contribuind astfel la îmbunătățirea calității produselor și la creșterea profitabilității. În plus, în era digitalizării, adoptarea IA în managementul producției devine un factor diferențiator esențial. Companiile care întârzie să implementeze astfel de soluții riscă să rămână în urmă, pierzându-și avantajul competitiv. Prin urmare, demersul de cercetare și aplicare a algoritmilor de optimizare în programarea producției nu este doar relevant, ci și esențial pentru asigurarea sustenabilității și succesului pe termen lung. Aceasta nu doar că sprijină îmbunătățirea performanței interne, dar și contribuie la schimbările rapide ale pieței, asigurând astfel viitorul organizațiilor în mediul de afaceri dinamic de astăzi.

Actualitatea și importanța temei

Tema optimizării programării producției prin utilizarea algoritmilor de IA este de o actualitate incontestabilă în contextul transformării digitale care domină industria contemporană. Într-o perioadă în care inovația tehnologică redefineste procesele de producție, adoptarea acestor metode devine esențială pentru a face față provocărilor economice și operaționale. Algoritmi de optimizare, inclusiv cei genetici și hibridi, oferă soluții eficiente pentru gestionarea complexității proceselor de producție, reducând timpii de execuție, minimalizând resursele utilizate și îmbunătățind calitatea produselor. Importanța acestei teme rezidă nu doar în capacitatea de a spori competitivitatea companiilor, ci și în potențialul de a revoluționa managementul producției la nivel global. Pe măsură ce companiile adoptă tot mai mult IA pentru a-și optimiza procesele, capacitatea de a implementa și integra aceste tehnologii devine un criteriu crucial pentru succesul pe termen lung. Astfel, cercetarea în acest domeniu contribuie semnificativ la dezvoltarea unei economii bazate pe eficiență și inovație, consolidând importanța acestei teme în peisajul actual al industriei.

Obiectivele tezei

Cercetarea întreprinsă în cadrul tezei are ca scop principal investigarea și evaluarea aplicării algoritmilor de inteligență artificială (IA), în special a celor genetici și hibridi, în optimizarea programării producției de serie. Având în vedere complexitatea și dinamismul mediului industrial actual, teza își propune să atingă următoarele obiective:

1. Identificarea elementelor inovative care contribuie la îmbunătățirea procesului de planificare și programare a producției de serie. Acest obiectiv vizează descoperirea și analiza metodelor noi, emergente în domeniul programării producției, cu accent pe aplicațiile IA.
2. Optimizarea proceselor de producție prin implementarea tehnicilor avansate de inteligență artificială, în special algoritmi genetici și hibridi. Se urmărește investigarea modului în care aceste tehnici pot aduce îmbunătățiri în eficiența și exactitatea programării producției.

3. Evaluarea aplicabilității IA în managementul producției prin analizarea modului în care diverse tipuri de algoritmi IA pot fi aplicate pentru a crește eficiența și adaptabilitatea proceselor de producție.
4. Identificarea principalelor tendințe în managementul programării producției de serie. Acest obiectiv vizează studierea și înțelegerea evoluției recente și a direcțiilor viitoare în acest domeniu, pentru a propune soluții relevante și actuale.

Aceste obiective sunt esențiale pentru a oferi o imagine clară asupra impactului și potențialului tehnologiilor IA în optimizarea proceselor de producție, asigurând astfel o contribuție semnificativă la dezvoltarea și eficientizarea managementului producției.

Teza este structurată în trei părți principale, fiecare organizată în capitole care urmăresc să atingă obiectivele cercetării.

Partea generală începe cu Capitolul 1, care oferă o privire de ansamblu asupra fundamentelor managementului producției, incluzând aspecte esențiale precum planificarea și programarea producției, diversitatea tipurilor de producție și inovațiile recente, precum impactul tehnologiei IoT și abordarea problemelor de tip Job Shop Schedule.

Capitolul 2 continuă cu un studiu comparativ al metodelor de programare a producției bazate pe algoritmi de inteligență artificială, analizând strategiile de planificare, tehnicile de ordonanțare și bazele teoretice ale IA.

Partea specifică se deschide cu Capitolul 3, care prezintă metodologia de cercetare aplicată și discută în detaliu modelarea programării producției de serie. Acest capitol include analiza interviurilor ghidate și un studiu de caz asupra companiei ABC, explorând integrarea și implementarea tehnologiilor IA, precum și comparația între metodele exacte și cele euristice.

Partea experimentală este abordată în Capitolul 4, care se concentrează pe comprimarea rezultatelor aplicării funcției obiectiv, discutând rezultatele obținute, analiza cauză-efect și evaluarea SWOT a acestora. Teza se încheie cu concluzii ce sintetizează principalele contribuții și impactul cercetării asupra domeniului.

Metodologia (întrebarea de bază a cercetării, ipotezele de cercetare și metodele de cercetare utilizate)

Metodologia acestei teze se bazează pe o abordare integrată care combină analiza teoretică cu cercetarea aplicată pentru a răspunde întrebării principale a cercetării: **„În ce măsură contribuie aplicarea algoritmilor de inteligență artificială (genetici și hibridi) și a altor tehnici de optimizare la îmbunătățirea procesului de programare a producției de serie?”**

Pentru a aborda această întrebare, au fost formulate următoarele ipoteze de cercetare:

Ipoteza 1. Metodele exacte oferă rezultate superioare celor euristice în programarea producției de serie.

Ipoteza 2. Algoritmii genetici hibridi oferă rezultate superioare celor genetici clasici în ceea ce privește exactitatea soluțiilor oferite în programarea producției de serie.

Ipoteza 3. Algoritmii genetici clasici oferă rezultate diferite și neconcludente în rulările succesive în programarea producției de serie.

Ipoteza 4. Aplicarea modelului Guinet în programarea producției va conduce la îmbunătățiri semnificative în reducerea ciclurilor de producție.

Ipoteza 5. Rezultatele aplicării algoritmilor hibridi au șanse ca pe viitor să se apropie de rezultatele aplicării metodelor exacte în programarea producției de serie.

Metodele de cercetare cantitative și calitative utilizate vor fi:

- **analiza literaturii de specialitate** - analiza datelor statistice obținute din surse secundare, inclusiv articole științifice, rapoarte industriale și studii de caz existente, pentru a identifica tendințele și evoluțiile recente în aplicarea algoritmilor IA și tehnicilor de optimizare în producția de serie.

- **interviul ghidat** - realizarea de interviuri cu experți din industrie și cercetători pentru a obține perspective aprofundate asupra aplicabilității și eficienței tehnicilor de optimizare și algoritmilor IA în programarea producției.

- **analiza cauză - efect** pentru a identifica și analiza factorii care contribuie la provocările și oportunitățile în programarea producției de serie, facilitând înțelegerea relațiilor complexe dintre diferitele elemente implicate.

- **importanța studiului de caz**- Identificarea și analiza unor studii de caz relevante pentru a demonstra aplicabilitatea practică a tehnicilor de optimizare și algoritmilor IA în diverse contexte industriale. Studiile de caz vor oferi o înțelegere practică a modului în care aceste tehnici pot fi implementate și adaptate în funcție de cerințele specifice ale fiecărei industrii.

- **rezolvarea matematică a soluției problemei funcției obiectiv** - Aplicarea metodelor exacte (CPLEX/OPL Mixt Integer Linear Programming și CPLEX Constraint Programming) și a metodelor euristice (algoritmul genetic AG și algoritmul hibrid AG + PSO) pentru a rezolva problemele de optimizare în programarea producției de serie. Aceasta implică formularea funcției obiectiv și a setului de constrângeri, urmată de analiza și compararea soluțiilor obținute.

- **analiza SWOT** - asociată aplicării algoritmilor IA și a tehnicilor de optimizare în programarea producției de serie. Aceasta va ajuta la dezvoltarea unor strategii informate și la luarea deciziilor strategice pentru îmbunătățirea performanței operaționale.

CONFIRMAREA IPOTEZELOR DE CERCETARE PE BAZA INTERVIURILOR

Ipoteza 1. Metodele exacte oferă rezultate superioare celor euristice în programarea producției de serie. Interviuurile realizate sugerează un interes variabil în utilizarea algoritmilor IA pentru optimizarea producției, majoritatea companiilor neutilizând încă aceste tehnologii. Cu toate acestea, cei care au început să exploreze utilizarea IA remarcă beneficiile clare în reducerea erorilor și creșterea eficienței. O parte semnificativă a intervievaților subliniază necesitatea unei analize cost-beneficiu detaliate înainte de implementare, ceea ce susține faptul că metodele exacte, deși superioare în rezultate, pot implica costuri semnificative și provocări de integrare. Aceasta sugerează că, în ciuda eficienței metodelor exacte, companiile ezită în adoptarea lor fără o asigurare clară a rentabilității, confirmând astfel ipoteza că metodele exacte oferă rezultate superioare, dar sunt mai greu de implementat fără un angajament ferm din partea managementului și resurse dedicate. Ipoteza este confirmată/

Ipoteza 2. Algoritmii genetici hibridi oferă rezultate superioare celor genetici clasici în ceea ce privește exactitatea soluțiilor oferite în programarea producției de serie. Din interviuri reiese o percepție generală că algoritmii genetici hibridi, deși neexplorați pe larg în practică, au potențialul de a oferi soluții mai precise în programarea producției de serie, comparativ cu metodele tradiționale. Totuși, acceptarea acestor tehnologii depinde de modul în care sunt prezentate beneficiile și de pregătirea angajaților pentru a le utiliza eficient. Companiile care au început să testeze sau să se gândească la implementarea acestor tehnologii recunosc necesitatea unui sprijin managerial puternic și a unei colaborări interdepartamentale pentru a asigura succesul acestora. Acest lucru confirmă ipoteza că algoritmii genetici hibridi pot oferi avantaje considerabile în programarea producției, dar necesită o pregătire riguroasă și o înțelegere aprofundată a tehnologiei. Ipoteza se confirmă.

Ipoteza 3: Algoritmii genetici clasici oferă rezultate diferite și neconcludente în rulările succesive în programarea producției de serie mare. Interviuurile indică faptul că majoritatea companiilor încă nu utilizează algoritmi genetici, fie clasici, fie hibridi, în programarea producției. Printre cei care au experimentat cu tehnologiile IA, există o recunoaștere a limitărilor acestora, în special în privința consistenței rezultatelor. Mai multe companii au subliniat că lipsa unor date concrete și fiabile face ca implementarea acestor algoritmi să fie provocatoare, ceea ce sugerează că rezultatele obținute prin metode genetice clasice pot fi inegale și dificil de replicat. Aceasta confirmă ipoteza că algoritmii genetici clasici nu oferă întotdeauna rezultate concludente, ceea ce poate descuraja utilizarea lor pe scară largă în programarea producției de serie mare. Ipoteza se confirmă.

Ipoteza 4. Aplicarea modelului Guinet în programarea producției va conduce la îmbunătățiri semnificative în reducerea ciclurilor de producție. Din analiza interviurilor, reiese că sprijinul managerial și infrastructura tehnologică sunt factori esențiali pentru succesul implementării IA, ceea ce ar sugera că modele complexe, precum cel al lui Guinet, ar avea nevoie de un angajament și resurse substanțiale pentru a fi implementate eficient. Companiile au subliniat importanța unei modelări adecvate și a adaptării tehnologiei la nevoile lor specifice pentru a obține o reducere semnificativă a timpilor de producție. Aceasta confirmă ipoteza că aplicarea modelului Guinet poate aduce îmbunătățiri semnificative, dar necesită o planificare și o execuție riguroasă, precum și o infrastructură solidă și un sprijin continuu din partea tuturor părților implicate. Ipoteza este confirmată.

Ipoteza 5. Rezultatele aplicării algoritmilor hibridi au șanse ca pe viitor să se apropie de rezultatele aplicării metodelor exacte în ceea ce privește programarea producției de serie mare. Interviuurile sugerează o percepție pozitivă asupra potențialului

algoritmilor hibridi, deși aceștia nu sunt încă larg adoptați. Multe companii sunt deschise la ideea de a investi în IA, recunoscând că în viitor aceste tehnologii ar putea deveni la fel de eficiente ca metodele exacte. Acceptarea graduală a acestor tehnologii, susținută de investiții și instruire adecvată, ar putea conduce la o creștere a preciziei și eficienței în programarea producției de serie mare. Aceasta susține ipoteza că, pe măsură ce tehnologia avansează și este mai bine înțeleasă, algoritmi hibridi ar putea să ofere soluții comparabile cu cele ale metodelor exacte, făcându-i astfel o alternativă viabilă în viitorul apropiat. Ipoteza se confirmă.

PARTEA EXPERIMENTALĂ

Partenerul nostru în această cercetare este firma ABC din Cluj-Napoca, subsidiară a DEF și membră a grupului XYZ cu o cifră de afaceri de peste 14 milioane euro. Firma deține 8000 mp de hale, produce peste 350 de produse lunar, exportă în 8 țări și investește anual 0,5 milioane euro.

Domenii de activitate:

- Producția de subansamble metalice pentru industria aparaturii electrice casnice.
- Asamblare și testare electromecanică.

Organizatoric, firma are 17 centre de producție, mașinile fiind grupate în centre specifice anumitor operații. Importanța în general a domeniului de studiu a cercetării este crucială pentru optimizarea și eficientizarea întregului proces de producție, contribuind direct la reducerea timpilor de livrare și la creșterea competitivității firmei pe piață.

Îmbunătățirea programării producției. Procesele tehnologice din cadrul firmei ABC necesită îmbunătățirea programării producției, așa cum este descris în tabelul următor.

Utilizarea sistemului Pegasus duce la situații în care în centrele de producție echipate cu mașini de debitare și îndoire se evidențiază apariția "locurilor înguste", care reprezintă puncte critice în fluxul de producție (a se vedea în Tabelul Nr 3.1.). Aceste locuri înguste limitează capacitatea centrelor de producție de a finaliza toate comenzile programate în intervalul de timp prevăzut, conducând la întârzieri și la o eficiență operațională redusă. Această problemă subliniază necesitatea optimizării fluxurilor de producție și a gestionării adecvate a resurselor pentru a minimiza impactul acestor constrângeri și pentru a asigura respectarea termenelor de livrare fără a crește semnificativ impactul asupra costurilor.

Setul de date inițiale utilizat pentru analiza de față include o perioadă de programare a producției de 3 săptămâni, corespunzătoare unui număr de 280 de comenzi pentru 353 de produse fabricate de compania ABC. Fiecare dintre aceste produse este asociat unui itinerar tehnologic specific, detaliat în figura următoare.

Setul de date inițiale utilizat pentru analiza de față include o perioadă de programare a producției de 3 săptămâni, corespunzătoare unui număr de 280 de comenzi pentru 353 de produse fabricate de compania ABC. Fiecare dintre aceste produse este asociat unui itinerar tehnologic specific, detaliat.

Aplicarea modelului Guinet în cadrul procesului de producție a condus la eliminarea locurilor înguste, optimizând astfel fluxul de producție. Această intervenție a permis ordonarea eficientă a producției, asigurând un flux continuu și reducând la minimum timpii de așteptare. Ca rezultat, s-a reușit eliminarea întârzierilor în livrarea produselor, îmbunătățind considerabil performanța operațională și capacitatea de a respecta termenele de livrare.

Ca atare, am ajuns la următoarea funcție obiectiv:

$$f = \min \sum_{i=1}^I T_{i,M_p} \quad (1)$$

Constrângerile aferente acestei funcții obiectiv sunt :

$$T_{i,m_p} - T_{j,m_p} + KZ_{i,j,m_p} \geq d_{j,m_p} \quad \forall i,j \in [1,I] \quad i \neq j \quad \forall m_p \in [1,M_p] \quad (2)$$

$$T_{j,M_p} - T_{i,M_p} + K(1 - Z_{i,j,m_p}) \geq d_{i,m_p} \quad \forall i,j \in [1,I] \quad i \neq j \quad \forall m_p \in [1,M_p] \quad (3)$$

$$T_{i,m_p+1} - T_{i,m_p} \geq d_{i,m_p} \quad \forall i \in [1,I] \quad \forall m_p \in [1,M_p - 1] \quad (4)$$

$$T_{i,1} \geq dint_i \quad \forall i \in [1,I] \quad (5)$$

$$T_{i,M_p} \leq dl_i - d_{i,M_p} \quad \forall i \in [1,I] \quad (6)$$

unde:

T_{i,M_p} – Timpul necesar operației i, pe centru de producție m și mașină p

T_{j,M_p} – Timpul necesar operației j, pe centru de producție m și mașina p

$Z_{i,j,m}$ – Variabila cu val 1 când operația i e programată înaintea operației j pe centrul m

$Z_{i,j,m}$ – Variabila cu val 0 când operația j e programată înaintea operației i pe centrul m

d_{i,M_p} – Timpul de procesarea operației i pe centru de producție m și mașina p

d_{j,M_p} – Timpul de procesarea operației j pe centru de producție m și mașina p

$dint_i$ – Momentul de la care poate fi programată comanda i

dl_i – Momentul la care comanda i trebuie livrată

K – constanta ce are o valoare mare

M – Numărul centrelor de producție

I, J – numărul de comenzi

P – numărul de mașini din fiecare centru de producție

Cu limitele valorice:


$i, j \in [1, 5000]$

$m \in [1, 17]$

$p \in [1, 51]$

$p \in [1, 353]$

Funcția obiectiv a avut ca scop principal minimizarea timpului total necesar pentru finalizarea comenzilor, un aspect esențial în contextul unei industrii în care livrarea la timp este un factor determinant pentru satisfacția clienților și pentru menținerea relațiilor comerciale pe termen lung. O prezentare sistematică a prezentei analize ar putea arăta astfel:



Rezolvarea soluției oferite de funcția Guinet adaptată a fost realizată prin 4 metode

I. Metodele exacte:

1.1) CPLEX/OPL Mixt Integer Linear Programming (MILP)

Metodele exacte, cum ar fi programarea liniară (MILP) utilizată în CPLEX/OPL, se bazează pe modele matematice riguroase pentru a găsi soluții optime. Aceste metode sunt deterministe, ceea ce înseamnă că pentru o anumită problemă și un set de parametri, soluția va fi întotdeauna aceeași. Programarea liniară implică formularea unei funcții obiectiv și a unui set de constrângeri, care sunt rezolvate pentru a găsi valorile optime ale variabilelor de decizie.

În varianta dezvoltată cu tehnica MILP, software-ul a rulat timp de peste 29 ore fără a genera o soluție din cauza complexității matricei implicate.- trimitere la Anexele noi. Matricea era compusă din numărul de comenzi (280), numărul de produse (353) și numărul de mașini pe care acestea trebuiau procesate (51), rezultând într-un număr imens de variante de soluții (5040840). Acest lucru evidențiază limitările metodelor exacte pentru probleme de mari dimensiuni și complexitate.

1.2) CPLEX Constraint Programming (CP)

Programarea cu constrângeri (CP) este o metodă exactă utilizată pentru a rezolva probleme complexe care nu pot fi formulate ușor în termenii programării liniare. CP utilizează un set de variabile, domenii și constrângeri pentru a modela problema, iar soluția este găsită prin explorarea sistematică a spațiului soluțiilor posibile. Metodele de CP sunt deosebit de utile pentru problemele combinatorii complexe, cum ar fi planificarea și alocarea resurselor.

Prin utilizarea metodei de rezolvare oferite de CPLEX Constraint Programming, funcția obiectiv a fost optimizată astfel încât să genereze o valoare inferioară timpului maxim permis pentru livrarea produselor. Această performanță indică nu doar eficiența modelului Guinet, ci și capacitatea superioară a CPLEX Constraint Programming de a gestiona probleme complexe de programare a producției. Conform datelor prezentate în tabelul nr. 3.7. de mai sus, timpul de rulare pentru găsirea soluției optime a fost redus semnificativ, ajungând la doar 12,55 secunde. Acest timp de procesare extrem de scurt demonstrează eficiența computațională a metodei CPLEX Constraint Programming în comparație cu alte metode tradiționale.

II. Metodele Euristice :

2.1) Algoritm Genetic (AG)

Algoritm Genetic (AG) este o tehnică de optimizare evoluționistă care utilizează procese inspirate din biologia naturală, cum ar fi selecția, crossover-ul și mutația, pentru a evolua soluții la probleme complexe. AG începe cu o populație de soluții posibile (cromozomi), fiecare reprezentând o soluție potențială a problemei. Soluțiile sunt evaluate pe baza unei funcții obiectiv, iar cele mai bune soluții sunt selectate pentru a genera noi soluții prin crossover și mutație.

Algoritmii Genetici, implementați în Matlab [123], au oferit rezultate mixte. Deși aceștia au rulat într-un timp relativ scurt, nu au reușit să livreze o soluție care să se încadreze în timpul contractual de șase săptămâni. Cea mai mică valoare a funcției obiectiv obținută prin rularea acestui tip de Algoritm Genetic a fost de 516 ore de producție, mult peste termenul de livrare contractual. În concluzie, deși Algoritmii Genetici sunt puternici în explorarea spațiului de căutare și pot găsi soluții bune în probleme complexe, performanța lor poate fi limitată de natura funcției obiectiv sau de modul în care sunt setate constrângerile. În acest context, ajustarea fină a parametrilor algoritmului, cum ar fi rata de mutație și rata de crossover, ar putea îmbunătăți performanța, dar ar putea fi necesar și un model combinat pentru a atinge obiectivele impuse.

2.2) Algoritm Hibrid (AG + PSO)

Algoritm hibrid combină Algoritm Genetic (AG) cu Optimizarea prin Roiurile de Particule (PSO) pentru a îmbunătăți performanța și diversitatea soluțiilor. PSO este inspirat de comportamentul colectiv al roiurilor de păsări sau al bancurilor de pești, unde fiecare particulă din populație se mișcă în spațiul soluțiilor, ghidată de propria experiență și de cea a vecinilor săi. Combinarea AG și PSO permite algoritmului hibrid să beneficieze atât de diversitatea genetică oferită de AG, cât și de convergența rapidă oferită de PSO.

Abordarea hibridă, care combină Algoritmii Genetici cu Optimizarea prin Roiuri de Particule (PSO), a demonstrat o performanță îmbunătățită față de utilizarea Algoritmilor Genetici în mod izolat. În cadrul experimentelor, în trei cazuri din șaiszeci, algoritmi hibridi au reușit să furnizeze soluții care respectă condiția de încadrare în intervalul de timp pentru livrarea produselor oferind cicluri de producție de 352, 446 și 480 ore de producție.

Aceste rezultate sugerează că integrarea a două metode de optimizare poate oferi beneficii semnificative, exploatând punctele forte ale fiecărei metode pentru a depăși limitările individuale. În acest caz, PSO a contribuit la îmbunătățirea exploatării în spațiul de căutare, însă nu a fost suficient pentru a respecta complet termenii contractuali de timp, indicând faptul că, deși abordările hibride pot oferi soluții mai bune, acestea necesită încă o ajustare fină și o analiză aprofundată a interacțiunii dintre metode pentru a maximiza eficiența.

Centralizator rezultate:

CPLEX OPL - MILP	Timp de productie contractual					Timp de productie obtinut		
	Sapt.	Zile	Ore 2*16	Minute	Secunde	Ore	Secunde	Timp rulare
	6	30	480	28800	1728000	necunoscut	necunoscut	>14400
CPLEX CP - Programare cu constrangeri	Timp de productie contractual					Timp de productie obtinut		
	Sapt.	Zile	Ore 2*16	Minute	Secunde	Ore	Secunde	Timp rulare
	6	30	480	28800	1728000	303.3	1091828	12.55
Matlab AG	Timp de productie contractual					Timp de productie obtinut		
	Sapt.	Zile	Ore 2*16	Minute	Secunde	Ore	Secunde	Timp rulare
	6	30	480	28800	1728000	516	1857600	21
Matlab Hybrid(Ag+PSO)	Timp de productie contractual					Timp de productie obtinut		
	Sapt.	Zile	Ore 2*16	Minute	Secunde	Ore	Secunde	Timp rulare
	6	30	480	28800	1728000	352	1267200	111

REZULTATE, DISCUȚII

Compararea metodelor exacte și a celor euristice:

A) În privința preciziei și optimizării:

- Metodele exacte, cum ar fi MILP și CP, sunt capabile să găsească soluții optime pentru probleme bine definite și cu constrângeri clare. Aceste metode sunt foarte precise și garantează găsirea celei mai bune soluții posibile. Cu toate acestea, ele pot fi ineficiente pentru probleme foarte mari sau foarte complexe din punct de vedere computațional.
- Pe de altă parte, metodele euristice, cum ar fi AG și algoritmi hibrizi, nu garantează găsirea soluției optime, dar pot găsi soluții foarte bune într-un timp rezonabil. Aceste metode sunt mai flexibile și pot aborda probleme pentru care metodele exacte ar fi impracticabile din cauza complexității sau dimensiunii mari a spațiului soluțiilor.

B) În privința flexibilității și adaptabilității:

- Metodele exacte sunt mai puțin flexibile deoarece necesită o formulare matematică strictă a problemei. Orice schimbare în problemă necesită o reformulare completă a modelului matematic. În contrast, metodele euristice sunt mult mai flexibile și pot adapta ușor la schimbările din parametrii problemei sau din mediul de operare.

C) În privința complexității implementării:

- Metodele exacte pot fi complexe de implementat și necesită cunoștințe avansate de matematică și programare. Formularea corectă a problemei și setarea corespunzătoare a parametrilor sunt esențiale pentru succesul acestor metode. Pe de altă parte, metodele euristice sunt, în general, mai ușor de implementat și de adaptat la diferite probleme. Algoritmi genetici și hibrizi pot fi implementați folosind librării de cod existente și pot fi ajustați ușor pentru a îmbunătăți performanța.

D) În privința performanței computaționale:

- Metodele exacte pot deveni foarte lente pentru problemele de dimensiuni mari din cauza necesității de a explora exhaustiv spațiul soluțiilor. Aceasta poate duce la timpi de calcul foarte mari și la necesitatea de resurse computaționale semnificative. Metodele euristice, deși

pot fi mai rapide, necesită adesea multiple iterații și pot consuma, de asemenea, resurse computaționale considerabile, dar într-un mod mai gestionabil și scalabil.

E) În privința capacității de a oferi soluții:

- Metodele exacte oferă soluții foarte precise și deterministe, dar pot fi sensibile la schimbări minore în datele de intrare sau în formularea problemei. Metodele euristice sunt mai robuste la variațiile din date și pot găsi soluții bune chiar și atunci când datele sunt incomplete sau incorecte.

Atât metodele exacte cât și cele euristice au punctele lor forte și slabe în contextul planificării producției. Alegerea metodei potrivite depinde de natura specifică a problemei, de resursele disponibile și de cerințele de precizie și eficiență. Metodele exacte sunt ideale pentru probleme bine definite și unde se cere precizie maximă, în timp ce metodele euristice sunt mai potrivite pentru probleme complexe, unde flexibilitatea și adaptabilitatea sunt esențiale. Utilizarea combinată a ambelor tipuri de metode, în funcție de context, poate oferi soluțiile cele mai bune pentru optimizarea planificării producției.

Procesul de rezolvare a funcției obiectiv, care a fost formulată prin metoda Guinet, a inclus implementarea a patru abordări distincte. Fiecare dintre aceste abordări a fost aleasă în funcție de capacitatea sa de a aborda complexitatea problemei și de a livra rezultate optime în cadrul constrângerilor impuse. Prima abordare a fost utilizarea Programării Liniare, implementată prin CPLEX OPL, o metodă tradițională, dar eficientă în probleme de optimizare, cu toate că prezintă limitări în contextul unor funcții obiectiv cu multiple constrângeri. A doua abordare, Programarea cu Constrângeri, tot prin intermediul CPLEX OPL, a oferit o flexibilitate sporită în modelarea problemelor și a permis integrarea mai ușoară a constrângerilor complexe. Rezolvarea modelului Guinet adaptat, prin metoda CP, reprezentată de funcția obiectiv însoțită de constrângerile și condițiile aferente, precum și ordonarea eficientă a activităților de producție a rezolvat problema studiului de caz, prin eliminarea locurilor înguste prezentate în Tabelul 3.1

În continuare, a fost evaluată utilizarea Algoritmilor Genetici (AG), implementați în Matlab, cunoscuți pentru capacitatea lor de a explora eficient spațiul de căutare și de a găsi soluții apropiate de optim în probleme complexe, însă cu provocări în ceea ce privește convergența rapidă către soluții optime într-un interval de timp restrâns. În final, o abordare hibridă între Algoritmii Genetici și Optimizarea prin Roiuri de Particule (PSO), de asemenea implementată în Matlab, a fost testată pentru a evalua potențialul acestei combinații de a îmbunătăți atât explorarea, cât și exploatarea spațiului de soluții, maximizând astfel șansele de a găsi soluția optimă în limitele stabilite.

Fiecare dintre aceste abordări a fost evaluată riguros în funcție de capacitatea sa de a satisface constrângerile impuse și de a minimiza timpul de producție în limitele stabilite. În urma acestor analize, s-a evidențiat faptul că alegerea metodei optime depinde de specificul problemei și de capacitatea fiecărei metode de a integra și rezolva constrângerile complexe ale procesului de producție. Aceasta subliniază necesitatea unei abordări flexibile și adaptabile în procesul de optimizare a producției, în special în contextul unor industrii dinamice și competitive.

CONCLUZII, CONTRIBUȚII, LIMITE ȘI DIRECȚII VIITOARE DE CERCETARE

Într-o lume industrială în continuă schimbare și creștere a competitivității, optimizarea proceselor de producție de serie devine esențială. Inteligența artificială (IA) oferă un set de instrumente și tehnici puternice pentru a aborda provocările complexe și variate ale acestui domeniu. Această lucrare a explorat diverse abordări și algoritmi de optimizare, evidențiind cum pot fi aplicați pentru a îmbunătăți eficiența și productivitatea proceselor industriale.

Programarea producției este una dintre cele mai complexe funcții în gestionarea proceselor de producție. Alegerea tehnologiei și a itinerariului tehnologic, împreună cu definirea procesului de fabricație, sunt esențiale pentru atingerea obiectivelor de producție. Aceste decizii depind de caracteristicile piesei de prelucrat, cum ar fi forma, dimensiunile, materialul, toleranțele și funcționalitatea. Prin utilizarea IA, aceste variabile pot fi analizate și optimizate în mod eficient, contribuind la îmbunătățirea globală a procesului de producție.

Funcția obiectiv optimizează performanța unui sistem prin minimizarea unei combinații între costul maxim și timpul ponderat, reflectă abordările inovative ale lui René Guinet în domeniul cercetării operaționale. Guinet a jucat un rol esențial în dezvoltarea acestor modele matematice, influențând profund metodele de optimizare și gestionare eficientă a resurselor, contribuind astfel la progresul industriei prin tehnici avansate de planificare și control al producției.

În contextul producției de serie, funcția obiectiv poate include minimizarea costurilor, maximizarea eficienței utilizării resurselor sau reducerea timpului de producție. Alegerea funcției obiectiv și a metodei de optimizare adecvate este crucială pentru obținerea celor mai bune rezultate.

Algoritmii genetici (AG), inspirați de procesele naturale de evoluție și selecție, sunt un exemplu de tehnică de optimizare euristică care poate fi aplicată cu succes în producția de serie. AG începe cu o populație de soluții posibile, fiecare reprezentând o potențială soluție a problemei. Soluțiile sunt evaluate pe baza unei funcții obiectiv, iar cele mai bune soluții sunt selectate pentru a genera noi soluții prin procese de crossover și mutație. Această metodă permite explorarea unui spațiu vast de soluții și găsirea unor configurații eficiente pentru linii de producție.

Optimizarea prin roiuri de particule (PSO) este o altă tehnică euristică eficientă. Inspirat de comportamentul social al roiurilor de păsări sau bancurilor de pești, PSO implică mișcarea particulelor în spațiul soluțiilor, ghidate de propria experiență și de cea a vecinilor. Aceasta permite o convergență rapidă către soluții optime, fiind deosebit de utilă în problemele unde dinamica procesului de producție este complexă și variabilă.

Combinația acestor două metode, algoritmii hibridi (AG + PSO), aduce beneficii semnificative. Prin combinarea diversității genetice oferite de AG cu convergența rapidă a PSO, algoritmii hibridi pot îmbunătăți atât viteza, cât și calitatea soluțiilor finale. De exemplu, în optimizarea liniilor de asamblare, AG poate genera diverse configurații inițiale, iar PSO poate rafina aceste configurații pentru a considera factorii dinamici precum cererea de produse sau disponibilitatea echipamentelor. Această abordare combinată permite găsirea rapidă a soluțiilor eficiente și adaptabile.

Metodele exacte, cum ar fi programarea liniară mixtă (MILP) utilizată în CPLEX/OPL, sunt fundamentale pentru problemele bine definite și liniarizabile. MILP implică formularea unei funcții obiectiv și a unui set de constrângeri, rezolvate pentru a găsi valorile optime ale variabilelor de decizie. În producția de serie, MILP este vitală pentru optimizarea resurselor și minimizarea costurilor, asigurând soluții precise și eficiente. În cazul de față având în vedere

complexitatea matricii tridimensionale care a stă la baza implementării funcției obiectiv timpiei de rulare au fost prea mari pentru a putea continua rulare algoritmului.

Pe de altă parte, programarea cu constrângeri (CP), o altă metodă exactă, este ideală pentru problemele combinatorii complexe, cum ar fi planificarea și alocarea resurselor. CP folosește un set de variabile, domenii și constrângeri pentru a modela problema, explorând sistematic spațiul soluțiilor posibile. În producția de serie, CP poate optimiza programarea și ordonanțarea sarcinilor, asigurând soluții fezabile care îndeplinesc toate cerințele.

În concluzie, tehnicile și algoritmi de optimizare, fie ei exacti sau euristici, joacă un rol crucial în îmbunătățirea eficienței și productivității proceselor de producție de serie. Metodele exacte oferă soluții precise și fiabile pentru probleme bine definite, în timp ce metodele euristice oferă flexibilitate și adaptabilitate în abordarea problemelor complexe și dinamice. Integrarea acestor tehnici în strategiile de planificare și programare a producției este esențială pentru menținerea competitivității și performanței operaționale în industria modernă.

Analiza detaliată a celor patru metode de rezolvare a problemei de programare a producției a oferit perspective valoroase asupra eficienței și aplicabilității fiecăreia în contextul specific al acestei probleme. Fiecare metodă a fost evaluată în funcție de capacitatea sa de a respecta constrângerile impuse de timp și de a livra o soluție optimă într-un interval de timp rezonabil.

Rezultatele obținute au variat considerabil între metode. CPLEX OPL, utilizând Programarea Liniară Mixtă, nu a reușit să furnizeze o soluție într-un timp rezonabil, sugerând că complexitatea problemei depășește capacitatea acestui model de a găsi o soluție optimă în cadrul unui timp de calcul practic. În contrast, utilizarea Programării cu Constrângeri în CPLEX OPL a produs rezultate mult mai favorabile, respectând termenul limită de șase săptămâni și oferind o soluție optimă în termenii specificați.

Metodele implementate în Matlab au evidențiat și ele diferențe notabile. Algoritmi Genetici, deși au rulat eficient, nu au reușit să respecte constrângerile de timp impuse, indicând necesitatea unei explorări suplimentare a parametrilor algoritmici sau a unei potențiale combinații cu alte metode pentru a îmbunătăți performanța.

În cadrul experimentelor realizate, s-a observat că algoritmi hibridi (AG+PSO) au demonstrat o capacitate limitată de a respecta condițiile stricte impuse privind intervalul de timp necesar pentru livrarea produselor. Astfel, dintr-un total de șaizeci de rulări efectuate, doar în 3 cazuri algoritmi hibridi au reușit să genereze soluții viabile care s-au încadrat în limitele temporale stabilite. Aceste soluții au rezultat în cicluri de producție de 352 ore, 446 de ore și, respectiv, 480 de ore, evidențiind astfel o inconstanță în performanța algoritmului.

Este important de menționat că, deși aceste rezultate sunt în concordanță cu obiectivele stabilite, frecvența scăzută a succesului sugerează necesitatea unei optimizări suplimentare a parametrilor algoritmilor hibridi. Această constatare subliniază importanța unei abordări continue în cercetare pentru a îmbunătăți consistența și fiabilitatea algoritmilor, astfel încât aceștia să poată furniza în mod constant soluții eficiente în cadrul cerințelor de producție. Rezultatele obținute indică un potențial promițător al metodei hibride, dar și necesitatea unei analize mai aprofundate pentru a înțelege factorii care contribuie la variabilitatea performanței.

Prin urmare, aceste observații subliniază importanța alegerii metodei de optimizare în funcție de caracteristicile specifice ale problemei. De asemenea, ele sugerează că, în situațiile în care constrângerile de timp sunt critice, tehnicile avansate de optimizare cu constrângeri pot oferi soluții mai eficiente decât modelele liniare tradiționale. În plus, rezultatele sugerează necesitatea unei ajustări fine a parametrilor algoritmici și, posibil, a unei reevaluări a

modelului de problemă pentru a îmbunătăți șansele de succes în utilizarea metodelor de optimizare.

În concluzie, studiul de față subliniază importanța alegerii metodei de optimizare în funcție de specificul problemei și de constrângerile impuse. Metodele tradiționale, cum ar fi Programarea Liniară, pot deveni ineficiente în fața unor probleme complexe cu multiple constrângeri, în timp ce abordările avansate, cum ar fi Programarea cu Constrângeri oferă alternative viabile, dar care necesită o setare atentă a parametrilor pentru a obține rezultate optime.

Abordările hibride, cum ar fi combinația dintre Algoritmii Genetici și PSO, prezintă un potențial semnificativ în optimizarea problemelor complexe, oferind un echilibru între explorare și exploatare. Cu toate acestea, succesul acestor metode este limitat și inconstant și depinde în mare măsură de modul în care sunt integrate și de capacitatea lor de a se adapta la specificul problemei.

Contribuții proprii. Una dintre cele mai importante contribuții ale tezei constă în integrarea și analiza comparativă a metodologiilor exacte și euristice în programarea producției. Studiul aduce o perspectivă valoroasă asupra modului în care aceste două abordări, fiecare cu avantajele și limitările proprii, pot fi utilizate pentru optimizarea producției în diverse contexte industriale. Prin utilizarea algoritmilor genetici și hibrizi, s-a demonstrat eficiența acestor metode în reducerea timpilor de procesare și optimizarea resurselor, oferind în același timp un cadru flexibil, adaptabil la nevoile specifice ale fiecărei industrii.

O altă contribuție deosebită a tezei este dezvoltarea unui cadru analitic detaliat pentru aplicarea modelului Guinet. S-a demonstrat cum acest model poate aduce îmbunătățiri semnificative în reducerea ciclurilor de producție, oferind soluții clare și aplicabile pentru companiile care urmăresc optimizarea proceselor prin intermediul tehnologiilor avansate, cum ar fi algoritmii de IA. Această contribuție susține nu doar eficiența proceselor de producție, ci și adaptabilitatea lor la diverse industrii.

O a treia contribuție deosebită o reprezintă găsirea unei metode de rezolvare a modelului Guinet, prin intermediul CPLEX OPL Constrain Programming, care a furnizat minimizarea valorii funcției obiectiv, rezolvarea problemei ordonanțării comenzilor în detaliu, reușind cel mai mic timp de rulare.

A. Contributii teoretice

1. Integrarea metodologiilor exacte și euristice. Teza explorează modul în care metodologiile exacte și euristice pot fi integrate pentru optimizarea producției. Printr-o analiză comparativă, se demonstrează avantajele fiecărei abordări, precum reducerea timpilor de procesare și optimizarea resurselor. Algoritmii genetici și hibrizi se dovedesc eficienți în acest context, oferind un cadru flexibil și adaptabil pentru diverse industrii. Această integrare permite companiilor să utilizeze metode personalizate pentru nevoile lor specifice, asigurând o producție mai eficientă și competitivă în mediul industrial actual.

2. Dezvoltarea unui cadru analitic pentru modelul Guinet. Teza oferă un cadru analitic detaliat pentru aplicarea modelului Guinet în optimizarea producției. S-a demonstrat că modelul aduce îmbunătățiri semnificative în reducerea ciclurilor de producție, oferind soluții clare pentru companiile care doresc să îmbunătățească eficiența proceselor lor. Prin utilizarea tehnologiilor avansate, precum algoritmii de inteligență artificială, acest model susține nu doar eficiența producției, ci și adaptabilitatea sa la diverse industrii, contribuind astfel la dezvoltarea unui cadru operațional modern și competitiv.

3. Compararea metodelor exacte și euristice. Teza prezintă o analiză comparativă între metodele exacte și cele euristice, evidențiind avantajele și dezavantajele fiecăreia în

optimizarea producției. Algoritmi precum CPLEX/OPL Constrain Programming și Algoritmul Genetic Hybrid (AG + PSO) sunt utilizați pentru a demonstra flexibilitatea și eficiența acestor metode în diverse contexte industriale. Această comparație subliniază importanța alegerii metodologiei adecvate pentru a obține rezultate optime în programarea producției și pentru a crește eficiența operațională.

4. Abordarea integrată a cercetării teoretice și aplicate. Lucrarea se distinge prin abordarea integrată a cercetării teoretice și aplicate, contribuind la avansul cunoștințelor în domeniul optimizării producției. Validarea utilității algoritmilor de IA în sectorul industrial se bazează pe un echilibru între teorie și practică. Această abordare holistică oferă un cadru solid pentru cercetători și practicieni în înțelegerea și aplicarea IA în producție.

5. Analiza tendințelor și provocărilor în adoptarea IA. Teza analizează principalele tendințe și provocări cu care se confruntă companiile în adoptarea tehnologiilor IA. Această analiză oferă un ghid valoros pentru manageri și decidenți, facilitând înțelegerea complexității implementării IA în procesele operaționale și strategice. Prin abordarea acestor provocări, companiile pot rămâne competitive pe piața globală, înțelegând mai bine cum să îmbine resursele umane și tehnologice pentru a maximiza eficiența și a îmbunătăți procesele de producție.

6. Modelarea programării producției de serie. Capitolul 3 reprezintă contribuția centrală a tezei, concentrându-se pe modelarea programării producției de serie prin algoritmi de inteligență artificială. Printr-o analiză detaliată, se oferă soluții practice pentru optimizarea producției de serie. Se abordează aspecte precum reducerea timpilor de așteptare și îmbunătățirea fluxurilor de producție, demonstrând modul în care IA poate contribui la eficientizarea operațiunilor în mediul industrial, oferind o bază solidă pentru implementarea acestor tehnologii în companii.

7. Utilizarea algoritmilor genetici și hibridi. Lucrarea explorează utilizarea algoritmilor genetici și hibridi pentru optimizarea producției. Acești algoritmi s-au dovedit a fi eficienți în reducerea timpilor de procesare și optimizarea resurselor, oferind un cadru flexibil care se poate adapta la nevoile specifice ale fiecărei industrii. Aceasta permite companiilor să-și optimizeze procesele, să reducă costurile și să îmbunătățească eficiența operațională, contribuind astfel la creșterea competitivității în mediul industrial actual. Metodologia de cercetare aplicată: Prezentarea unei metodologii riguroase pentru analiza aplicării IA în producție, bazată pe interviuri ghidate cu experți din industrie.

8. Adaptabilitatea la diverse industrii. Teza subliniază adaptabilitatea algoritmilor de IA și a modelului Guinet la diverse industrii. Prin oferirea unui cadru flexibil și personalizabil, companiile pot implementa aceste tehnologii în funcție de nevoile lor specifice, asigurând o optimizare eficientă a proceselor de producție. Aceasta permite companiilor să se adapteze mai rapid la schimbările din mediul de afaceri și să rămână competitive pe o piață dinamică.

9. Metodologia de cercetare aplicată. Teza prezintă o metodologie riguroasă pentru analizarea aplicării IA în programarea producției de serie. Prin interviuri ghidate cu experți din industrie, s-a obținut o înțelegere profundă a modului în care aceste tehnologii pot fi integrate în industriile locale. Această abordare metodologică a permis evidențierea legăturii dintre cercetarea teoretică și aplicațiile practice, oferind o bază solidă pentru implementarea IA în procesele de producție.

10. Ghid pentru manageri și decidenți. Teza oferă un ghid valoros pentru manageri și decidenți în procesul de implementare a tehnologiilor IA în producție. Prin evidențierea provocărilor, beneficiilor și a soluțiilor practice, lucrarea facilitează înțelegerea complexității și a oportunităților asociate cu utilizarea IA în procesele operaționale. Aceasta ajută companiile să ia decizii informate pentru a rămâne competitive și pentru a-și îmbunătăți eficiența și flexibilitatea operațională.

B. Contributii practice

1. Rezolvarea modelului Guinet cu CPLEX OPL. Teza prezintă o metodă de rezolvare a modelului Guinet folosind CPLEX OPL Constrain Programming. Această abordare a permis minimizarea valorii funcției obiectiv și optimizarea ordonării comenzilor, obținând cel mai scurt timp de rulare. Aceasta este o contribuție majoră în domeniul producției, demonstrând cum instrumentele avansate de programare pot rezolva probleme complexe, permițând astfel companiilor să optimizeze procesul de producție, să reducă costurile și să îmbunătățească eficiența operațională.

2. Validarea algoritmilor IA în producția industrială. Studiul de caz asupra companiei ABC validează eficiența algoritmilor de inteligență artificială în producția industrială românească. Această validare merge dincolo de teorie, demonstrând aplicarea practică a acestor tehnologii și evidențiind beneficiile lor în contextul actual al industriei. Prin interviuri ghidate și aplicații practice, se oferă o perspectivă relevantă pentru companiile care intenționează să implementeze tehnologiile IA, contribuind astfel la creșterea competitivității și la îmbunătățirea proceselor operaționale.

3. Soluții practice pentru implementarea IA. Pe lângă aportul academic, teza oferă soluții practice pentru implementarea IA în managementul producției. Aceste soluții sunt aplicabile și adaptabile pentru diverse tipuri de companii, permițând optimizarea proceselor, reducerea costurilor și îmbunătățirea flexibilității operaționale. Astfel, lucrarea devine un ghid util atât pentru cercetători, cât și pentru practicieni, arătând cum tehnologiile IA pot fi integrate eficient în procesele de producție pentru a obține avantaje competitive semnificative.

4. Studiu de caz: compania ABC. Studiul de caz al companiei ABC oferă un exemplu practic al implementării metodelor exacte în producția de serie. Prin interviuri ghidate și analiza datelor de producție, cercetarea demonstrează aplicabilitatea algoritmilor de IA în procesele de producție. Aceasta evidențiază modul în care aceste tehnologii pot fi adaptate și aplicate în contextul specific al unei companii, oferind perspective valoroase pentru alte organizații care doresc să își îmbunătățească eficiența producției.

5. Integrarea tehnologiilor avansate. Teza analizează integrarea tehnologiilor avansate în procesele operaționale, subliniind atât avantajele, cât și provocările întâlnite în adoptarea acestor soluții inovatoare. Această analiză oferă un ghid valoros pentru manageri, ajutându-i să înțeleagă riscurile și oportunitățile asociate cu utilizarea IA în producție. Prin adoptarea acestor tehnologii, companiile pot îmbunătăți eficiența și flexibilitatea operațională, devenind astfel mai competitive pe piața globală.

6. Reducerea timpilor de așteptare. Prin aplicarea modelului Guinet, teza demonstrează cum companiile pot reduce timpii de așteptare în producție. Modelul oferă soluții avansate pentru optimizarea ciclurilor de producție, permițând companiilor să-și îmbunătățească fluxurile de producție și să utilizeze mai eficient resursele. Aceasta contribuie la creșterea eficienței operaționale, reducerea costurilor și îmbunătățirea competitivității pe piața globală.

7. Reducerea costurilor prin IA. Teza demonstrează cum algoritmi de IA pot contribui la reducerea costurilor în producție. Prin optimizarea proceselor și îmbunătățirea utilizării resurselor, companiile pot reduce cheltuielile operaționale și pot crește profitabilitatea. Această abordare oferă un avantaj competitiv semnificativ, permițând companiilor să își adapteze strategiile de producție pentru a răspunde mai bine cerințelor pieței și pentru a îmbunătăți eficiența operațională.

8. Minimizarea valorii funcției obiectiv. Prin utilizarea CPLEX OPL Constrain Programming, teza reușește să minimizeze valoarea funcției obiectiv în contextul ordonării comenzilor. Această minimizare este esențială pentru îmbunătățirea eficienței proceselor de producție, permițând companiilor să își optimizeze programarea producției, să reducă timpii de

așteptare și să îmbunătățească fluxurile de lucru. Acest lucru conduce la o producție mai eficientă și la o mai bună utilizare a resurselor disponibile.

9. Flexibilizarea operațională. Prin implementarea tehnologiilor IA, companiile pot crește flexibilitatea operațională. Aceasta permite ajustarea rapidă a proceselor de producție în funcție de cerințele pieței și de schimbările în mediul de afaceri. Lucrarea demonstrează cum companiile pot utiliza aceste tehnologii pentru a îmbunătăți capacitatea de reacție la cerințele clienților, optimizând astfel producția și maximizând eficiența.

10. Eficientizarea proceselor de producție. Lucrarea contribuie la creșterea eficienței proceselor de producție prin rezolvarea în CPLEX a modelului Guinet. Prin reducerea timpilor de așteptare, optimizarea fluxurilor de producție și utilizarea eficientă a resurselor, companiile pot îmbunătăți semnificativ eficiența operațională. Aceasta are un impact direct asupra competitivității pe piața globală, permițând companiilor să livreze produse mai rapid și mai eficient.

Așadar, prin studiul de caz asupra companiei ABC, teza validează eficiența modelului Guinet adaptat în producția industrială românească. Această validare nu se limitează la o abordare teoretică, ci este susținută de aplicări practice și interviuri ghidate, oferind o perspectivă relevantă pentru companiile care doresc să implementeze tehnologii de ultimă generație.

Cercetarea evidențiază principalele tendințe și provocări cu care se confruntă companiile în adoptarea tehnologiilor IA. Această analiză oferă un ghid valoros pentru manageri și decidenți, facilitând înțelegerea complexității implementării IA în cadrul proceselor operaționale și strategice, cu scopul de a rămâne competitivi pe piața globală.

Pe lângă îmbogățirea literaturii de specialitate, teza oferă soluții practice pentru implementarea IA în managementul producției. Aceste soluții sunt aplicabile și adaptabile, permițând companiilor să optimizeze procesele și să îmbunătățească eficiența și flexibilitatea operațională. Astfel, teza devine un ghid util atât pentru cercetători, cât și pentru practicieni.

Direcții viitoare de cercetare

În contextul actual, unde cerințele pieței sunt în continuă schimbare, iar eficiența și optimizarea proceselor de producție devin priorități critice, se impune o aprofundare a cercetării în domeniul optimizării parametrilor algoritmilor de programare a producției. Recomandăm continuarea investigațiilor în direcția ajustării și optimizării parametrilor care guvernează comportamentul algoritmilor Genetici (AG) și a metodelor hibride avansate, cum ar fi combinația dintre Algoritmii Genetici și Optimizarea prin Roiuri de Particule (PSO).

În privința optimizării parametrilor în Algoritmii Genetici (AG):

Unul dintre aspectele esențiale care influențează performanța Algoritmilor Genetici este alegerea corectă a parametrilor de bază, cum ar fi mărimea populației, rata de încrucișare și rata de mutație.

- **Mărimea populației:** Acest parametru determină numărul total de soluții potențiale (cromozomi) evaluate la fiecare iterație. O populație mai mare poate duce la o explorare mai eficientă a spațiului de căutare, reducând riscul de a se bloca în optime locale. Cu toate acestea, o populație mai mare necesită și resurse computaționale suplimentare și poate duce la o creștere a timpului de execuție al algoritmului. Cercetările viitoare ar trebui să se concentreze pe identificarea unei mărimi optime a populației care să maximizeze performanța algoritmului fără a crește excesiv cerințele de calcul.

- **Rata de încrucișare:** Rata de încrucișare, care controlează frecvența cu care sunt combinate perechi de cromozomi pentru a genera noi soluții, joacă un rol crucial în asigurarea diversității populației. O rată de încrucișare prea mare poate perturba structurile bune de soluții, în timp ce o rată prea mică poate duce la convergență prematură. Direcțiile viitoare de

cercetare ar trebui să exploreze modul în care variația dinamică a ratei de încrucișare în funcție de stadiul algoritmului ar putea îmbunătăți eficiența și eficacitatea acestuia.

- **Rata de mutație:** Mutația introduce variații suplimentare în populație, permițând algoritmului să exploreze noi zone ale spațiului de soluții. În mod similar cu rata de încrucișare, rata de mutație trebuie ajustată cu atenție. O rată de mutație prea mare poate transforma algoritmul într-un proces aleatoriu, în timp ce o rată prea mică poate limita capacitatea algoritmului de a evita optimele locale. Cercetarea ar trebui să se concentreze pe dezvoltarea unor scheme adaptative de mutație, care să ajusteze rata în funcție de dinamica procesului evolutiv.

În privința optimizării parametrilor în algoritmi hibrizi (AG + PSO):

Pentru algoritmi hibrizi, care combină Algoritmi Genetici cu Optimizarea prin Roiuri de Particule, există alți parametri cheie care necesită ajustare și optimizare.

- **Mărimea roiului:** La fel ca în cazul mărimii populației din AG, mărimea roiului în PSO influențează echilibrul între explorare și exploatare. Un roi mai mare poate oferi o explorare mai completă a spațiului de soluții, dar crește și complexitatea calculului. Cercetările viitoare ar trebui să analizeze impactul mărimii roiului asupra performanței generale a algoritmului hibrid și să identifice dimensiunile optime pentru diverse tipuri de probleme de producție.

- **Factorul inerției (w):** Factorul de inerție controlează influența vitezei anterioare a particulelor asupra vitezei actuale. Un factor de inerție mare favorizează explorarea, în timp ce un factor mic favorizează exploatarea. Studii viitoare ar trebui să investigheze utilizarea unui factor de inerție variabil, care să scadă treptat pe măsură ce algoritmul se apropie de convergență, pentru a asigura un echilibru optim între explorare și exploatare.

- **Coeficienții cognitivi și sociali (c_1 și c_2):** Acești coeficienți determină cât de mult sunt particulele atrase de pozițiile lor anterioare de succes și de poziția globală de succes a roiului. Cercetarea ar trebui să se concentreze pe optimizarea acestor coeficienți pentru a maximiza performanța algoritmului hibrid. De exemplu, se poate investiga impactul ajustării dinamice a coeficienților cognitivi și sociali în funcție de evoluția procesului de căutare.

- **Viteza particulelor:** Controlul vitezei este esențial pentru a evita ca particulele să depășească regiuni de interes din spațiul de căutare. Limitarea vitezei particulelor, cunoscută sub numele de velocity clamping, poate îmbunătăți stabilitatea și eficiența algoritmului. Cercetările viitoare ar trebui să exploreze impactul diferitelor strategii de velocity clamping asupra performanței algoritmului hibrid.

Influența constrângerilor asupra performanței algoritmilor. Un alt aspect critic care necesită o atenție deosebită este modul în care constrângerile impuse problemelor de producție influențează performanța algoritmilor. Este esențial să se realizeze o analiză detaliată a modului în care diverse tipuri de constrângeri (de timp, de resurse, de calitate etc.) afectează capacitatea algoritmilor de a găsi soluții optime. Acest lucru ar putea implica dezvoltarea unor modele de optimizare mai robuste, capabile să se adapteze la diverse scenarii de producție.

De asemenea, ar putea fi benefică explorarea altor tehnici de optimizare avansate, cum ar fi algoritmi evolutivi sau alte metode metaeuristice. Aceste metode au demonstrat rezultate promițătoare în alte domenii și ar putea oferi soluții inovatoare și eficiente pentru problemele complexe de programare a producției.

Importanța unui proces iterativ de testare și ajustare. În final, este esențial ca orice metodă de optimizare utilizată să fie susținută de un proces iterativ de testare și ajustare. Acest proces permite rafinarea continuă a modelului și îmbunătățirea performanței în raport cu obiectivele stabilite. O abordare iterativă asigură că algoritmi pot fi ajustați în funcție de rezultatele obținute, permițând astfel dezvoltarea unor soluții optimizate, capabile să

răspundă eficient cerințelor pieței și să asigure succesul pe termen lung al organizației. În acest sens, colaborarea strânsă între cercetători și practicieni va juca un rol esențial în realizarea unor progrese semnificative în domeniul optimizării programării producției.

Limitele cercetării. În cadrul acestei cercetări, am identificat o serie de limitări care au influențat atât procesul de obținere a rezultatelor, cât și calitatea acestora. Aceste limitări sunt esențiale pentru o înțelegere completă a contextului în care au fost realizate experimentele și pentru o interpretare corectă a rezultatelor obținute. De asemenea, ele oferă o direcție clară pentru cercetările viitoare, care ar trebui să abordeze aceste provocări pentru a îmbunătăți performanța algoritmilor și relevanța soluțiilor propuse:

a) Mărimea matricei tridimensionale. Prima limitare majoră a cercetării a fost impusă de mărimea considerabilă a matricei tridimensionale utilizate în implementarea funcției obiectiv. Această matrice este esențială pentru modelarea complexă a spațiului de căutare și pentru asigurarea că toate constrângerile sunt luate în considerare în procesul de optimizare. Cu toate acestea, dimensiunea sa mare a condus la un timp de rulare excesiv de lung pentru găsirea unei soluții viabile prin CPLE OPL Mixt Integer Linear Programming.

În mod specific, complexitatea calculului asociat cu această matrice a necesitat resurse computaționale semnificative, ceea ce a făcut ca timpul de execuție să devină nefezabil în contextul aplicabilității practice. Această situație este problematică, mai ales într-un mediu industrial unde rapiditatea și eficiența sunt critice. Astfel, această limitare a subliniat necesitatea unor metode mai eficiente de reducere a dimensiunii problemei, fie prin simplificarea modelului matematic, fie prin implementarea unor tehnici avansate de calcul paralel sau distribuirea sarcinilor pe mai multe resurse computaționale. Abordarea acestor aspecte ar putea conduce la o îmbunătățire semnificativă a timpului de răspuns și, implicit, la o mai bună aplicabilitate a soluției în contexte reale.

b) Variația rezultatelor în cazul Algoritmilor Genetici (AG). A doua limitare semnificativă a fost observată în cazul utilizării AG. Deși acești algoritmi sunt cunoscuți pentru capacitatea lor de a explora eficient spații de căutare mari și complexe, rezultatele obținute au prezentat o variație considerabilă de la o rulare la alta. Această variație este problematică, deoarece reduce predictibilitatea și fiabilitatea soluțiilor obținute, făcând dificilă încadrarea în intervalul de timp stabilit pentru livrarea produselor.

Mai mult, AG nu au reușit să respecte în mod consistent condițiile de timp impuse, ceea ce pune sub semnul întrebării acuratețea și relevanța datelor de ieșire. Acest aspect indică o posibilă nevoie de ajustare a parametrilor algoritmici, cum ar fi mărimea populației, rata de mutație sau rata de încrucișare, pentru a îmbunătăți performanța algoritmului. De asemenea, ar putea fi necesară integrarea unor metode suplimentare de optimizare sau hibridizarea AG cu alte tehnici pentru a stabiliza rezultatele și a asigura conformitatea cu cerințele de timp. Această limitare evidențiază, de asemenea, importanța unei calibrări adecvate a algoritmului în funcție de specificul problemei de optimizare abordate.

c) Inconsistența rezultatelor în cazul algoritmilor hibridi

Deși utilizarea algoritmilor hibridi, care combină Algoritmii Genetici cu Optimizarea prin Roiuri de Particule (PSO), a arătat un potențial promițător în abordarea problemelor complexe, rezultatele au fost, din păcate, inconstante. În cadrul experimentelor, doar în trei cazuri din șaiszeci, algoritmii hibridi au reușit să furnizeze soluții care respectă condiția de încadrare în intervalul de timp pentru livrarea produselor. Acest fapt subliniază un alt nivel de variabilitate care ridică întrebări cu privire la robustețea și fiabilitatea acestor metode.

Inconsistența rezultatelor în funcție de rulare sugerează că algoritmii hibridi sunt sensibili la setările inițiale ale parametrilor, cum ar fi mărimea roiului, factorul de inerție și

coeficienții cognitivi și sociali. Aceasta implică necesitatea unei cercetări mai aprofundate pentru a înțelege mai bine dinamica acestor algoritmi și pentru a dezvolta strategii de ajustare automată a parametrilor în timpul rulării, în funcție de performanțele observate. În plus, acuratețea datelor de ieșire obținute de algoritmi hibridi a fost considerată nesatisfăcătoare în anumite cazuri, ceea ce indică nevoia de rafinare a metodei de evaluare a soluțiilor generate.

Această limitare subliniază, de asemenea, necesitatea unor metode mai avansate de testare și validare a algoritmilor hibridi, pentru a se asigura că rezultatele sunt consistente și fiabile, independent de variațiile minore ale condițiilor inițiale. Posibile soluții ar putea include implementarea unor mecanisme de feedback care să permită algoritmului să învețe din performanțele sale anterioare și să ajusteze comportamentul în consecință.

În concluzie, limitările identificate în cadrul acestei cercetări oferă un punct de plecare important pentru direcții viitoare de cercetare. Necesitatea de a optimiza performanța algoritmilor prin ajustarea parametrilor și prin implementarea unor metode mai robuste și eficiente este evidentă. Abordarea acestor provocări va contribui nu doar la îmbunătățirea algoritmilor existenți, ci și la dezvoltarea unor noi tehnici de optimizare capabile să răspundă cerințelor complexe și variate ale producției moderne.