



ZASTOSOWANIE ALGORYTMU GENETYCZNEGO DO PLANOWANIA PRZEPŁYWU PRZEDMIOTÓW W ZŁOŻONYCH SYSTEMACH PRODUKCYJNYCH

Andrzej Jardzioch, Bartosz Jardzioch

West Pomeranian University of Technology in Szczecin, Poland

Corresponding author:

Andrzej Jardzioch

West Pomeranian University of Technology in Szczecin

al. Piastów 19, 70-310 Szczecin, Poland

phone: +91 4494989

e-mail: andrzej.jardzioch@zut.edu.pl

THE APPLICATION OF A GENETIC ALGORITHM FOR SCHEDULING MATERIAL FLOW IN COMPLEX PRODUCTION SYSTEMS

ABSTRACT

Modern production systems are characterised by a high degree of complexity, resulting from the use of many different technological processes, the parallel production of complex products, the use of advanced numerically controlled (CNC) machine tools and complex transport systems. At the same time, it is necessary to take into account many variables and constraints such as the availability of machines, tools and workers, stock levels in the warehouse, forecasted product demand, material handling capacities and the sequence in which individual tasks must be performed. Effective planning of the flow of items in such systems is key to achieving high productivity, minimising costs and ensuring on-time delivery. Traditional planning methods often prove insufficient in the face of dynamic and unpredictable production conditions. In this context, genetic algorithms (AG) represent a promising tool for optimising production processes. This paper presents an example of the application of a genetic algorithm to optimise the production process in an exemplary robotic production system. As the main optimisation criterion, the total sum of delays to be reckoned with when accepting a defined set of orders for execution. In addition, the total execution time for the set of orders and the machine tool utilisation rates during the entire production process were analysed. In order to be able to apply the genetic algorithm, it was necessary to build a parametric simulation model and integrate this model with the developed genetic algorithm. The simulation model was used to determine the objective function in the optimisation process implemented by the genetic algorithm.

KEYWORDS

Production process, scheduling of production orders, genetic algorithm.

1. Wprowadzenie

Współczesne systemy produkcyjne charakteryzują się wysokim stopniem złożoności, wynikającym ze stosowania wielu różnorodnych procesów technologicznych, równoległej produkcji skomplikowanych wyrobów, stosowania zaawansowanych obrabiarek sterowanych numerycznie (CNC) oraz złożonych systemów transportowych. Jednocześnie konieczne jest uwzględnienie wielu zmiennych i ograniczeń typu: dostępność maszyn, narzędzi i pracowników, ilość zapasów w magazynie, prognozy zapotrzebowania na produkty, możliwości przemieszczania materiałów oraz sekwencje, w jakich muszą być wykonywane poszczególne zadania. Efektywne planowanie przepływu przedmiotów w takich systemach jest kluczowe dla osiągnięcia wysokiej wydajności, minimalizacji kosztów oraz zapewnienia terminowości dostaw. Tradycyjne metody planowania często okazują się niewystarczające w obliczu dynamicznych i nieprzewidywalnych warunków produkcyjnych. W tym kontekście algorytmy genetyczne (AG) stanowią obiecujące narzędzie do optymalizacji procesów produkcyjnych.

Problem planowania produkcji, opracowywania harmonogramów i szeregowania zleceń produkcyjnych prezentowany jest w pracach [1, 5]. Autorzy wskazują na konieczność ciągłej poprawy efektywności wytwarzania oraz spełniania specyficznych wymagań klientów. Wyroby muszą spełniać funkcjonalne i cenowe oczekiwania klientów, lecz – co jest równie ważne – muszą być terminowo dostarczane do odbiorców. W pracy [2] autorzy zaproponowali zastosowanie logiki rozmytej do szeregowania zleceń produkcyjnych, wskazując na jej zalety w przypadku występowania niepewności w zakresie dostępności maszyn i pracowników. W pracy [3] zaproponowano zastosowanie innowacyjnego algorytmu wsadowego do poprawy efektywności produkcji. Algorytm ten ze względu na swoją prostą strukturę może być stosowany w przypadku bardzo dużych zbiorów zleceń produkcyjnych i ograniczonych mocy w zakresie przetwarzania komputerowego.

W ostatnich latach coraz więcej publikacji wskazuje na możliwość zastosowania algorytmów genetycznych do wspomagania procesów planowania produkcji [1, 3, 7]. Algorytmy genetyczne (AG), inspirowane procesami ewolucji biologicznej, wykorzystują mecha-

nizmy selekcji, krzyżowania i mutacji do generowania rozwiązań problemów optymalizacyjnych. Dzięki swojej zdolności do przeszukiwania dużych przestrzeni rozwiązań oraz adaptacyjności, AG są szczególnie skuteczne w rozwiązywaniu złożonych problemów, takich jak planowanie przepływu przedmiotów w systemach produkcyjnych. W pracy [9] przedstawiono matematyczny model zintegrowanego planowania procesów w heterogenicznym środowisku produkcyjnym oraz zaproponowano algorytm genetyczny do rozwiązywania problemów harmonogramowania produkcji. W pracy [8] zwrócono uwagę na trudności w zrozumieniu procesu optymalizacji realizowanego przez AG. Zaproponowano specjalny moduł objaśniający i wizualizujący proces znajdowania rozwiązania suboptymalnego. W pracy [6] wskazano na możliwość zastosowania algorytmów genetycznych w rozwiązywaniu problemów harmonogramowania procesów konserwacji maszyn. W tym przypadku autorzy starali się uwzględnić niepewność, jaka pojawia się w trakcie budowy harmonogramu (niepewność dotycząca rozkładu awarii maszyn i czasu naprawy). W pracy [10] zaprezentowano problemy harmonogramowania przy montażu samolotów. Autorzy zaproponowali ulepszony algorytm genetyczny oparty na algorytmie Q-learning z modułem uczenia ze wzmocnieniem. Przeprowadzone badania potwierdziły doskonałą wydajność przeszukiwania opracowanego algorytmu. Stwierdzono znaczne skrócenie całkowitego czasu montażu samolotów. W artykule zaproponowano dwa kierunki przyszłych badań: uwzględnienie niepewności dotyczącej czasów ręcznej obróbki oraz optymalizację liczby pracowników przydzielonych do poszczególnych operacji. W pracy [11] zaproponowano zastosowanie hybrydowego algorytmu genetycznego (HGTSA), który łączy algorytm genetyczny (GA) i algorytm przeszukiwania tabu search (TS). Algorytm ten zastosowano do harmonogramowania zadań w rozproszonym elastycznym systemie produkcyjnym. Zdefiniowano zestawy zleceń, które muszą być przetwarzane w przykładowym przedsiębiorstwie. Każde zlecenie składa się z listy operacji i ma własną trasę przetwarzania. Każda operacja musi być zrealizowana na określonym podzbiore obrabiarek w jednej z fabryk. Przyjęto, iż wszystkie operacje tego samego zadania muszą być przetwarzane w tej samej fabryce. Ponadto w artykule założono, że wszystkie fabryki oraz obrabiarki są dostępne od czasu zero. Przeprowadzone badania potwierdziły skuteczność opracowanego algorytmu, wskazując jednocześnie na decydujące znaczenie modułu TS odzwierciedlającego wiedzę związaną ze specyfiką analizowanego problemu. W pracy [4] przedstawiono typowy problem harmonogramowania, polegający na optymalizacji całkowitego czasu produkcji (makespan), czyli czasu potrzebnego na zakończenie wszystkich zadań. W artykule założono idealne środowisko pracy bez niepewności i wpływów stochastycznych. Autorzy zdefiniowali funkcję celu w postaci średniej ważonej kosztu produkcji i całkowitego czasu produkcji.

W niniejszym artykule przedstawiono przykład zastosowania algorytmu genetycznego do optymalizacji

procesu produkcji w zrobotyzowanym systemie produkcyjnym. Jako główne kryterium optymalizacji przyjęto całkowitą sumę opóźnień, z jaką należy się liczyć przyjmując do realizacji zdefiniowany zestaw zleceń. Dodatkowo analizowano całkowity czas realizacji zestawu zleceń oraz współczynniki wykorzystania obrabiarek w trakcie całego procesu produkcyjnego. W celu przedstawienia możliwości zastosowania algorytmu genetycznego konieczne było zbudowanie parametrycznego modelu symulacyjnego oraz zintegrowanie tego modelu z opracowanym algorytmem genetycznym. Model symulacyjny służył do wyznaczania funkcji celu w procesie optymalizacyjnym realizowanym przez algorytm genetyczny.

Artykuł składa się z następujących części: wprowadzenia, przedstawienia problemu, prezentacji struktury elastycznego systemu produkcyjnego, opisu przeprowadzonych badań symulacyjnych oraz podsumowania.

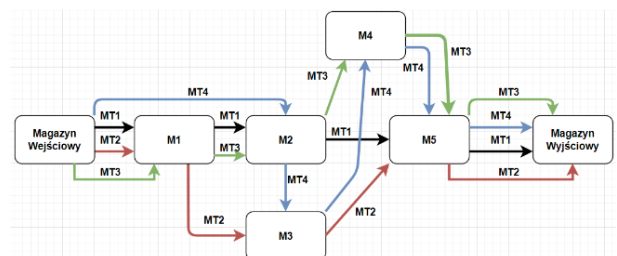
2. Przedstawienie problemu

W celu zaprezentowania sposobu wykorzystania badań symulacyjnych do analizy złożonych systemów produkcyjnych wybrano system wytwarzający różne elementy metalowe typu wałek, tuleja lub tarcza. System ten składa się z pięciu obrabiarek (M1, M2, M3, M4, M5) oraz podsystemu transportowego (przenośniki taśmowe oraz roboty przemysłowe). Na stanowisku M1 realizowana jest operacja cięcia na pile taśmowej, na stanowiskach M2, M3 i M4 realizowane są operacje obróbki skrawania na obrabiarkach CNC, a na stanowisku M5 realizowana jest automatyczna kontrola jakości.

Na podstawie wstępnej analizy rzeczywistych, realizowanych w tym systemie procesów wytwórczych stwierdzono, iż można wyróżnić cztery dominujące marszrut technologiczne:

- MT1: (M1, M2, M5),
- MT2: (M1, M3, M5),
- MT3: (M1, M2, M4, M5),
- MT4: (M2, M3, M4, M5).

Na rysunku 1 przedstawiono schemat rozważanego systemu produkcyjnego z zaznaczeniem realizowanych marszrut technologicznych (MT1).



Rys. 1. Uproszczony schemat procesów produkcyjnych z zaznaczeniem realizowanych marszrut technologicznych.

W analizowanym przedsiębiorstwie dominującym typem produkcji jest produkcja małoseryjna. W każdym momencie w dziale planowania znajduje się od kilkunastu do kilkudziesięciu zleceń produkcyjnych posia-

dających zdefiniowane marszruty technologiczne, czasy obróbki na poszczególnych obrabiarkach, potrzebne czasy przebrojeń oraz uzgodnione z klientem terminy realizacji. Zlecenia produkcyjne dotyczą kilku lub kilkunastu sztuk wyrobów tego samego rodzaju. Występuje stosunkowo duża różnorodność produktowych elementów zależnych od specyficznych potrzeb klientów. Na podstawie zleceń klientów formowane są serie produkcyjne. Każda seria różni się od poprzedniej zarówno pod względem wymaganego procesu technologicznego jak również potrzebnych narzędzi i uchwytów obróbkowych. Z tego powodu bardzo często konieczne jest przebrojenie obrabiarek w celu ich przystosowania do wytwarzania kolejnego zlecenia. Przebrojenie obrabiarek polega najczęściej na zamontowaniu potrzebnych narzędzi, wczytaniu odpowiedniego programu obróbkowego CNC oraz kontroli poprawności działania. Czasami konieczna jest jeszcze zmiana uchwytu obróbkowego. W takim przypadku czas przebrojenia znacząco się wydłuża. Na podstawie wstępnie przeprowadzonych badań stwierdzono, iż czasy przebrojeń w analizowanym systemie produkcyjnym nie są stałe. Zależą one od konkretnego zlecenia, które było obrabiane na danej obrabiarence oraz od zlecenia, które będzie wykonywane na tej obrabiarence jako następne. W analizowanym systemie produkcyjnym bardzo często dochodziło do nieterminowej realizacji zleceń produkcyjnych. Wynikało to z faktu, iż na etapie przyjmowania zleceń bardzo trudno było oszacować możliwy termin wykonania zlecenia. Zaproponowanie długiego terminu wykonania narażało firmę na utratę klienta. Z kolei zaproponowanie krótkiego terminu realizacji, opartego tylko na doświadczeniu technologa, powodowało często powstawanie opóźnień. Ze względu na duży stopień skomplikowania procesów realizowanych w analizowanym systemie wyznaczenie czasów wykonania poszczególnych zleceń produkcyjnych oraz czasów ewentualnych opóźnień zleceń przyjętych do realizacji było bardzo trudne. Bardzo istotne było także znalezienie odpowiedzi, czy jest możliwe takie zaplanowanie procesu produkcyjnego, które pozwoliłoby na wykonanie wszystkich zleceń w wymaganym terminie albo przynajmniej na zredukowanie powstających opóźnień. W celu rozwiązania przedstawionych powyżej problemów zaproponowano zbudowanie modelu symulacyjnego procesów realizowanych w analizowanym systemie produkcyjnym, który pozwoliłby na dokładne określenie czasów, w których przyjęte do realizacji zlecenia zostaną wykonane. Następnie zastosowano algorytm genetyczny, który pozwolił na takie uszeregowanie zleceń produkcyjnych, które zminimalizowało występujące opóźnienia zleceń produkcyjnych.

3. Badania symulacyjne

Do budowy modelu symulacyjnego zastosowano program Tecnomatix Plant Simulation. Program ten pozwala na budowę skomplikowanych modeli symulacyjnych dyskretnych procesów produkcyjnych oraz analizę występujących w nich konfliktów zasobowych.

Do budowy modelu symulacyjnego wykorzystano następujące predefiniowane obiekty:


- Source – obiekt generujący zlecenia produkcyjne,
- Conveyor – obiekt modelujący przenośnik taśmowy,
- Station – obiekt modelujący obrabiarkę,
- Buffer – obiekt modelujący magazyn między stanowiskowy,
- Data Table – tabela danych,
- Drain – obiekt zbierający wyprodukowane przedmioty,
- FlowControl – obiekt pozwalający na sterowanie przepływem przedmiotów.

Do sterowania przepływem zleceń zastosowano obiekt FlowControl. Cechą charakterystyczną tego obiektu jest możliwość wyboru strategii, według której będzie sterowany przepływ przedmiotów wytwarzanych w modelowanym systemie. W celu zamodelowania różnych marszrut technologicznych wybrano strategię „MU Name”, zgodnie z którą przedmioty przemieszczane są do kolejnych obrabiarek w zależności od przypisanych im marszrut technologicznych. W analizowanym przypadku do zleceń przypisane są następujące marszruty:

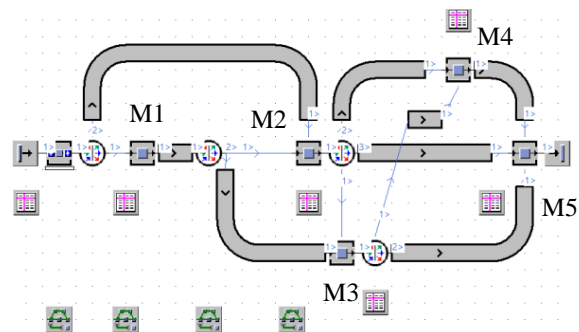
- zlecenia Z1–Z3 marszruta MT1,
- zlecenia Z4–Z6 marszruta MT2,
- zlecenia Z7–Z9 marszruta MT3,
- zlecenia Z10–Z12 marszruta MT4.

Na rysunku 2 przedstawiono gotowy model symulacyjny wykonany w programie Tecnomatix Plant Simulation. Między obrabiarkami wstawiono obiekty FlowControl, które rozdzielają zlecenia ze zdefiniowanymi marszrutami technologicznymi.

a) Model 3D



a) Model 2D



Rys. 2. Model symulacyjny pozwalający na odwzorowanie analizowanych procesów produkcyjnych: a) model 3D, b) model 2D.

Tabela 1
Czasy obróbki poszczególnych zleceń.

Nr zlecenia	TM1 [min]	TM2 [min]	TM3 [min]	TM4 [min]	TM5 [min]	T _{real} [min]
z1	12	12	0	0	18	150
z2	5	15	0	0	5	180
z3	20	12	0	0	10	200
z4	50	0	30	0	28	210
z5	36	0	10	0	20	220
z6	6	0	15	0	26	240
z7	6	18	12	18	15	280
z8	12	6	25	20	10	300
z9	15	10	18	15	16	320
z10	0	30	20	16	10	360
Z11	0	12	30	14	18	400
Z12	0	20	25	10	5	430

Tabela 2
Czasy przebrojeń obrabiarki M1 zależne od kolejności obróbki zleceń.

Z	Numer kolejnego zlecenia								
	z1	z2	z3	z4	z5	z6	z7	z8	z9
	Czasy przebrojenia [min]								
-	15	10	20	30	20	30	25	10	10
z1	0	10	30	20	22	14	25	15	10
z2	20	0	10	30	15	20	22	12	15
z3	10	20	0	20	20	15	25	15	10
z4	10	20	10	0	20	30	25	10	10
z5	20	30	20	30	0	14	25	15	10
z6	25	20	30	20	15	0	22	12	15
z7	20	30	20	30	40	15	0	10	20
z8	10	5	10	30	40	20	10	0	15
z9	5	5	20	40	10	20	15	20	0

W celu sprawdzenia działania opracowanego modelu przeprowadzono badania symulacyjne dla przykładowego zestawu zleceń produkcyjnych. W badaniach uwzględniono 12 zleceń, które zostały przyjęte do realizacji i znajdowały się w magazynie wejściowym. Czasy obróbki poszczególnych zleceń podane są w tabeli 1. Dodatkowo, każde zlecenie posiada przypisany wymagany czas realizacji zlecenia $T_{real(i)}$. Wymagany czas realizacji zleceń został ustalony przez eksperta na podstawie doświadczenia przy realizacji podobnych zleceń w przeszłości. W tabeli 2 zamieszczono czasy przebrojeń, koniecznych do przygotowania obrabiarki M1 do wytwarzania kolejnych zleceń. Znajdują się tam czasy przebrojeń dla zleceń Z1, Z2, Z3, Z4, Z5, Z6, Z7, Z8, Z9, ponieważ tylko te zlecenia są obrabiane na tej maszynie. Podobne dane zdefiniowano dla wszystkich obrabiarek uczestniczących w analizowanym procesie produkcyjnym. Ponieważ czasy przebrojeń zależą od zlecenia poprzedzającego i zlecenia aktualnego, konieczne było utworzenie dwuwymiarowej macierzy przebrojeń.

Pierwsza kolumna (Z) zawiera numery zleceń, które były obrabiane na obrabiarce M1, a kolejne kolumny czasy przebrojeń w zależności od numeru zlecenia, które będzie obrabiane jako kolejne. W przypadku, gdy na obrabiarce M1 było obrabiane zlecenie nr Z4, a ja-

ko kolejne będzie obrabiane zlecenie Z5, to czas przebrojenia wyniesie 20 min. Jeżeli po zleceniu Z4 będzie wykonywane zlecenie Z6, to czas przebrojenia będzie wynosił 30 minut. W pierwszym wierszu tabeli 2 podano czasy przebrojenia, które trzeba przyjąć do badań na początku pracy systemu (gdy na maszynie nie było obrabiane żadne zlecenie).

Po zbudowaniu modelu symulacyjnego przeprowadzono badania symulacyjne. Celem pierwszego badania symulacyjnego było określenie czasów realizacji całego zestawu zleceń, czasów realizacji poszczególnych zleceń oraz czasów ewentualnych opóźnień. Przyjęto, iż zlecenia będą wykonywane według kolejności, w jakiej zostały zarejestrowane w systemie (reguła FIFO). Należy zauważyć, iż w analizowanym przypadku kolejność ta jest tożsama z kolejnością wyznaczaną na podstawie reguły szeregującej zlecenia według wymaganego czasu realizacji (reguła Earliest Due Date EDD). W tabeli 3 przedstawiono otrzymane wyniki.

Najważniejszym wnioskiem z przeprowadzonych badań jest stwierdzenie, że bez dysponowania odpowiednio dokładnym modelem symulacyjnym ekspert nie był w stanie prawidłowo oszacować rzeczywistych terminów realizacji zleceń produkcyjnych. Zgodnie z przyjętym planem produkcyjnym (reguła EDD) tylko trzy

Tabela 3

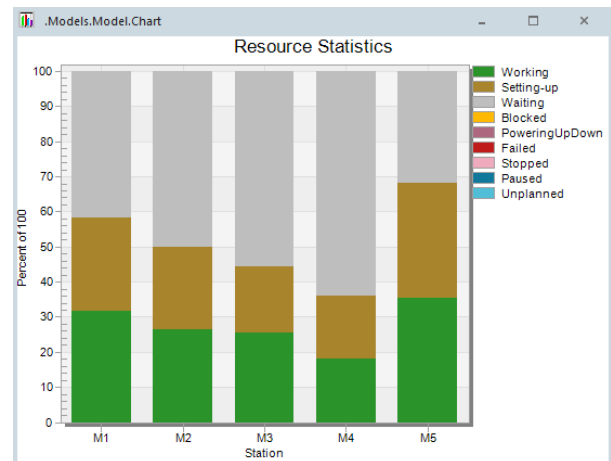
Czas wykonania poszczególnych zleceń oraz ich opóźnienia.

Nr zlecenia	Wymagany termin realizacji T_{real} [h:min]	Rzeczywisty termin wykonania [h:min]	Opóźnienie OP [h:min]
z1	2:30	1:27	0
z2	3:00	1:42	0
z3	3:20	2:02	0
z4	3:30	4:10	0:40
z5	3:40	4:50	1:10
z6	4:00	5:30	1:30
z7	4:40	6:09	1:29
z8	5:00	6:29	1:29
z9	5:20	7:06	1:46
z10	6:00	7:26	1:26
Z11	6:40	7:59	1:19
Z12	7:10	8:30	1:20
Suma opóźnień [min]			12:11
Całkowity czas realizacji wszystkich zleceń			8:30

pierwsze zlecenia były wykonane w terminie. Dziewięć pozostałych zleceń produkcyjnych nie zostanie wykonanych w terminie. Średnie opóźnienie zlecenia wynosi około 60 minut, ale największe opóźnienia wynoszą około 90 minut (zlecenia Z6, Z7, Z8, Z9, Z10). Nieterminowa realizacja zleceń produkcyjnych może mieć szereg negatywnych skutków, które wpływają na różne aspekty działalności firmy, jej reputację oraz relacje z klientami i partnerami biznesowymi. Najważniejszymi konsekwencjami występowania opóźnień jest utrata zaufania klientów skutkująca utratą przyszłych kontraktów oraz konieczność zapłacenia kar umownych. Aby tego uniknąć, należy starać się tak planować proces produkcyjny, aby opóźnienia nie występowały albo przynajmniej były minimalne. Jednym z możliwych rozwiązań jest dopasowanie wymaganych terminów realizacji zleceń do danych uzyskanych w wyniku przeprowadzonych badań symulacyjnych badanego procesu produkcyjnego. W takim przypadku przyjmując kolejne zlecenie należy przeprowadzić badania symulacyjne i na tej podstawie określić możliwy termin jego wykonania. Stosując tę zasadę można ustalić nowe terminy wykonania zleceń, które miały opóźnienie (dodając do pierwotnego wymaganego terminu wykonania czas opóźnienia zgodnie z wynikami uzyskanymi w wyniku badań symulacyjnych).

Drugim rozwiązaniem jest zastosowanie nowego uszeregowania zleceń produkcyjnych, które pozwoli lepiej wykorzystać potencjał produkcyjny maszyn i skrócić czasy realizacji poszczególnych zleceń. W analizowanym przykładzie, w wyniku szczegółowej analizy realizowanego procesu produkcyjnego, zauważono występowanie stosunkowo dużych rezerw w pracy poszczególnych maszyn. Na rysunku 3 przedstawiono wykres udziałów czasu pracy poszczególnych obrabiarek w całkowitym czasie pracy systemu produkcyjnego.

Współczynnik wykorzystania obrabiarek jest bardzo mały. Na przykład obrabiarka M4 realizowała ob-



Rys. 3. Udziały czasów pracy poszczególnych obrabiarek w całkowitym czasie pracy systemu produkcyjnego.


róbkę tylko przez 18,23% całego czasu pracy systemu, a przez 17,64% czasu trwały konieczne przezbrojenia. Trochę lepiej wyglądała sytuacja w przypadku obrabiarki M5, gdzie współczynnik wykorzystania wynosił 35,48%, a współczynnik czasów przezbrojeń 32,74%. Zidentyfikowanie rezerw w analizowanych systemie produkcyjnym pozwoliło na zaproponowanie lepszej strategii pracy systemu produkcyjnego. Postawiono tezę, iż możliwe jest znalezienie takiej kolejności realizacji zleceń produkcyjnych, przy której suma opóźnień wszystkich zleceń będzie mniejsza niż w przypadku uszeregowania pierwotnego (EDD). W celu znalezienia suboptymalnego uszeregowania zastosowano algorytm genetyczny. Algorytmy genetyczne, dzięki efektywnemu mechanizmowi przeszukiwania przestrzeni rozwiązań, bardzo dobrze radzą sobie z problemami o dużej złożoności. Poza tym algorytmy genetyczne stosują operację mutacji i wprowadzają pewien element losowości, który pozwala na unikanie zatrzymania procesu optymalizacji w lokalnych minimach. W analizowanym przypadku liczba możliwych rozwiązań nie była zbyt duża, ponieważ dla 12 zleceń było to około 479 milionów możliwych przypadków. Jednak w systemie produkcyjnym bardzo często występuje problem jednoczesnego planowania produkcji dla 15, 20 na nawet 30 zleceń. W takich przypadkach zastosowanie przeglądu zupełnego byłoby niemożliwe ze względów czasowych. W przypadku planowania procesu produkcyjnego czas, w którym algorytm jest w stanie wygenerować rozwiązanie, jest parametrem krytycznym.

Algorytm genetyczny został zintegrowany z opracowanym modelem symulacyjnym. Elementem optymalizowanym był zestaw zleceń produkcyjnych. W tym przypadku zastosowano kodowanie rzeczywiste, w którym istotne było miejsce poszczególnych zleceń w planowanym do realizacji zestawie. Jako funkcję celu (*fitness function*) przyjęto sumę opóźnień wszystkich zleceń znajdujących się w analizowanym uszeregowaniu. Dla każdego uszeregowania znajdującego się w populacji wyliczono opóźnienia zgodnie ze wzorem:

$$OP_k = \sum_{i=1}^n \max(0, RT_i - WT_i),$$

gdzie OP_k – suma opóźnień zleceń wynikająca z uszeregowania k , RT_i – rzeczywisty czas realizacji zlecenia i , WT_i – wymagany czas realizacji zlecenia i , n – liczba zleceń produkcyjnych w zestawie.

Funkcja dopasowania przypisuje każdemu uszeregowaniu sumę opóźnień, która jest wyliczona za pomocą opracowanego modelu symulacyjnego. Przyjęto następujące parametry dla algorytmu genetycznego: wielkość populacji 20 chromosomów, liczba generacji 30. Na rysunku 4 przedstawiono proces poszukiwania rozwiązania przez algorytm genetyczny. Przyjęta liczba generacji jest wystarczająca, ponieważ zauważono, iż dalsze zwiększanie liczby generacji nie poprawiało uzyskanego rozwiązania.



Rys. 4. Proces poszukiwania rozwiązania przez algorytm genetyczny.

W wyniku zastosowania algorytmu genetycznego uzyskano dwa równoważne suboptymalne uszeregowania postaci:

- 1: Z8, Z1, Z2, Z5, Z3, Z10, Z6, Z12, Z7, Z9, Z11, Z4;
- 2: Z8, Z1, Z2, Z5, Z3, Z10, Z6, Z7, Z12, Z9, Z11, Z4.

W tabeli 4 podano porównanie wyników uzyskanych dla uszeregowania według wymaganych terminów realizacji zleceń (EDD) oraz uszeregowania uzyskanego za pomocą algorytmu genetycznego (AG).

Realizując zaplanowaną produkcję według uszeregowania wygenerowanego przez algorytm genetyczny uzyskano zdecydowanie lepsze wyniki. Całkowite opóźnienie zmniejszyło się z ponad 6 godzin do niecałych 4 godzin. Zmniejszyło się też średnie opóźnienie, które teraz wynosi niecałe 18 minut. Zwiększono liczbę zleceń, które udało się wykonać bez opóźnień (przy EDD były to tylko 3 zlecenia, przy AG uzyskano 7 zleceń bez opóźnień). Poprawie uległy też współczynniki wykorzystania poszczególnych maszyn. Obrabiarka M4 zwiększyła ten współczynnik z 18,23% do 23,05%, a obrabiarka M5 z 35,48% do 44,85%. W wyniku przeprowadzonej optymalizacji znacznemu zwiększeniu uległo opóźnienie zlecenia nr 4 (do ponad 3 godzin). Jeżeli istniałyby przeciwskazania w wydłużaniu opóźnień konkretnych zleceń, należałoby wprowadzić odpowiednie wagi (koszt

Tabela 4
Porównanie czasów opóźnień w przypadku uszeregowień EDD i AG.

Nr zlecenia	$RT_{(i)real}$ [h:min]	$OP_{(i)}$ [h:min]	$RT_{(i)real}$ [h:min]	$OP_{(i)}$ [h:min]
		Uszeregowanie AG		
z1	1:27	0	1:39	0
z2	1:42	0	2:14	0
z3	2:02	0	3:25	0:5
z4	4:10	0:40	6:43	3:13
z5	4:50	1:10	2:55	0
z6	5:30	1:30	4:06	0:6
z7	6:09	1:29	4:53	0:13
z8	6:29	1:29	4:53	0
z9	7:06	1:46	5:26	0:6
z10	7:26	1:26	4:28	0
Z11	7:59	1:19	6:05	0
Z12	8:30	1:20	5:08	0
Suma opóźnień [min]		12:11		3:45
Całkowity czas realizacji wszystkich zleceń		8:30		6:43

opóźnienia) w celu odzwierciedlenia ich znaczenia w wartości całkowitej funkcji celu. W takim przypadku funkcja celu powinna przyjąć następującą postać:

$$FOP_k = \sum_{i=1}^n \max(0, w_i \times \{RT_i - WT_i\}),$$

gdzie FOP_k – funkcja celu związana z sumą opóźnień zleceń wynikająca z uszeregowania k , w_i – waga odzwierciedlająca znaczenie opóźnienia zlecenia i , RT_i – rzeczywisty czas realizacji zlecenia i , WT_i – wymagany czas realizacji zlecenia i , n – liczba zleceń produkcyjnych w zestawie.

4. Wnioski

W artykule przedstawiono sposób zastosowania algorytmu genetycznego do planowania produkcji w złożonym systemie produkcyjnym. Jako przykład przyjęto zrobotyzowany system produkcyjny, w którym proces produkcyjny realizowany jest według kilku alternatywnych marszrut technologicznych. Wszystkie przyjęte do realizacji zlecenia produkcyjne posiadały zdefiniowane marszrut technologiczne wraz z czasami obróbki na poszczególnych obrabiarkach. Dodatkową cechą analizowanego systemu produkcyjnego było występowanie czasów przebrojenia zależnych nie tylko od planowanego do obróbki elementu, ale także od typu przedmiotu, który był obrabiany na obrabiarkę wcześniej. Ze względu na stopień skomplikowania procesów wytwórczych, występujących w analizowanym systemie dział planowania produkcji nie był w stanie określić optymalnej strategii szeregowania zleceń produkcyjnych. W przypadku 12 zleceń liczba wszystkich możliwych uszeregowień wynosiła powyżej 400 milionów. W praktyce do szeregowania zleceń stosowano najprostsze strategię typu FIFO lub EDD. W wyniku przeprowadzonych badań stwierdzono, iż zastosowanie algorytmu genetycz-

nego pozwoliło na zdecydowanie lepsze zaplanowanie procesu produkcyjnego. Uszeregowanie zleceń wygenerowane za pomocą algorytmu genetycznego spowodowało zdecydowane skrócenie sumy opóźnień związanych z nieterminową realizacją zleceń produkcyjnych (z ponad 12 godzin do niecałych 4 godzin). Znacznemu skróceniu uległ też całkowity czas realizacji zestawu zleceń (z 8 godzin 30 minut do 6 godzin i 40 minut). Pozwoliło to na zwiększenie współczynnika wykorzystania poszczególnych maszyn. Należy zwrócić uwagę na to, że powyższe efekty uzyskane zostały bez konieczności ponoszenia dodatkowych kosztów. Uzyskane efekty uzyskano tylko poprzez lepsze zaplanowanie procesu produkcyjnego. Następnym etapem powinno być przeanalizowanie czasów potrzebnych na przebrojenia maszyn. W analizowanym systemie czasy te zajmują około 25% całkowitego czasu pracy maszyn i ich skrócenie pozwoliłoby na uzyskanie jeszcze większych oszczędności. Dlatego też przyszłe badania będą koncentrować się na opracowaniu systemu, który pozwoliłby na wspomaganie technologa w ograniczaniu czasu przebrojeń wskazanych maszyn.

Literatura

- [1] Jarczoch A., Skobiej B., *Zastosowanie algorytmu wsadowego do szeregowania zadań produkcyjnych*, Podstawy Foundations of Computing and Decision Sciences, 36, 3–4, 207–217, 2011.
- [2] Jarczoch A., Witkowska W., *Zastosowanie logiki rozmytej do szeregowania zleceń produkcyjnych*, Zarządzanie Przedsiębiorstwem, Enterprise Management, 25, 3–4, 25–36, 2022.
- [3] Jarczoch A., Skobiej B., *Job scheduling problem in a flow shop system with simulated hardening*, Advances in Manufacturing, 13, 391–400, 2018
- [4] Kinast A., Doerner K.F., Rinderle-Ma S., *Biased random-key genetic algorithm for cobot assignment in an assembly/disassembly job shop scheduling problem*, Procedia Comput. Sci., Proceedings of the 2nd International Conference on Industry 4.0 and Smart Manufacturing (ISM 2020), 180, 328–337, 2021.
- [5] Patalas-Maliszewska J., Kłos S., Dostatni E., *Integrating the assessment of sustainability and an ERP system in small and medium manufacturing enterprise – A case study*, [in:] Trojanowska J., Kujawińska A., Machado J., Pavlenko I. [Eds.], Advances in Manufacturing III. MANUFACTURING 2022. Lecture Notes in Mechanical Engineering, Springer, Cham, 2022, doi: 10.1007/978-3-030-99310-8_5.
- [6] Ruiz-Rodríguez M.L., Kubler S., Robert J., Le Traon Y., *Dynamic maintenance scheduling approach under uncertainty: Comparison between reinforcement learning, genetic algorithm simheuristic, dispatching rules*, Expert Syst. Appl., 248, 123404, 2024.
- [7] Wang H.-K., Chou C.-W., Wang C.-H., Ho L.-A., *Sustainable scheduling of TFT-LCD cell production: A hybrid dispatching rule and two-phase genetic algorithm*, Int. J. Prod. Econ., 278, 109412, 2024, doi: 10.1016/j.ijpe.2024.109412.
- [8] Wang Y.-C., Chen T., *Adapted techniques of explainable artificial intelligence for explaining genetic algorithms on the example of job scheduling*, Expert Syst. Appl., 237, 121369, 2024, doi: 10.1016/j.eswa.2023.
- [9] Wen X., Qian Y., Lian X., Li H., Wang H., Zhang Y., *Improved genetic algorithm for integrated process planning and scheduling in distributed heterogeneous manufacturing environment*, Eng. Appl. Artif. Intell., 133, 108569, 2024, doi: 10.1016/j.engappai.2024.108569.
- [10] Wen X., Zhang X., Xing H., Ye G., Li H., Zhang Y., Wang H., *An improved genetic algorithm based on reinforcement learning for aircraft assembly scheduling problem*, Comput. Ind. Eng., 193, 110263, 2024, doi: 10.1016/j.cie.2024.110263.
- [11] Xie J., Li X., Gao L., Gui L., *A hybrid genetic tabu search algorithm for distributed flexible job shop scheduling problems*, J. Manuf. Syst., 71, 82–94, 2023, doi: 10.1016/j.jmsy.2023.09.002.