



## Wykorzystanie algorytmów genetycznych do optymalizacji wielokryterialnej

A. Irla<sup>a</sup>, W. Sitek<sup>b</sup>

<sup>a</sup> Student Politechniki Śląskiej, Wydział Mechaniczny Technologiczny  
email: artur.irla@gmail.pl

<sup>b</sup> Politechnika Śląska, Wydział Mechaniczny Technologiczny, Instytut Materiałów Inżynierskich i Biomedycznych, Zakład Inżynierii Materiałów Biomedycznych  
email: wojciech.sitek@polsl.pl

**Streszczenie:** W artykule przedstawiono możliwość wykorzystania algorytmu genetycznego do optymalizacji, a także przedstawiono podstawowe definicje związane z algorytmami genetycznymi oraz pojęciem optymalizacji. Ponadto wykonano optymalizację wielokryterialną metodą sumy ważonej dla analizowanej stali. Jako kryteria optymalizacyjne przyjęto wytrzymałość na rozciąganie stali poddanej badaniom oraz cenę dodatków stopowych wykorzystanych w badanym materiale, w tym C, Mn, Si, P, S, Cr, Ni, Cu.

**Abstract:** The aim of the paper is to demonstrate the example usage of genetic algorithm for multicriterial optimization. Also the basic definitions connected to genetic algorithms and optimization were presented. Multicriterial optimization using a weighted sum was performed for the steel. Tensile strength of steel and the price of alloying elements (C, Mn, Si, P, S, Cr, Ni, Cu) were adopted as the optimization criterions.

**Słowa kluczowe:** algorytmy genetyczne, optymalizacja wielokryterialna, wytrzymałość na rozciąganie

### 1. WPROWADZENIE

W procesie projektowania konstrukcji należy wziąć pod uwagę wiele kryteriów, które inżynier musi pogodzić, aby wytwarzane konstrukcje właściwie spełniały swoją rolę. Najpopularniejszy materiał konstrukcyjny jakim jest stal charakteryzuje wytrzymałość na rozciąganie  $R_m$ , którą wyznacza się przeważnie w statycznych próbach rozciągania. Własność ta jest stosunkiem największej siły zarejestrowanej podczas tego badania do przekroju poprzecznego próbki, czyli odpowiada największemu naprężeniu w materiale [1].

Wytrzymałość na rozciąganie często jest brana pod uwagę jako jeden z podstawowych czynników, które decydują o doborze materiału inżynierskiego na projektowane elementy o zadanych własnościach. Prócz obróbki cieplnej i mechanicznej, w wytrzymałości stali istotne są pierwiastki stopowe, które są dodawane w celu dokonania zmian strukturalnych, a co za tym idzie zmianę własności wytrzymałościowych – najczęściej ich polepszenie [1].

Ponadto, oprócz własności mechanicznych, wpływ na analizę wielokryterialną mają również składniki stopowe zastosowanej stali. Wśród pierwiastków, których używa się w stalach konstrukcyjnych niestopowych i stopowych, należy wymienić przede wszystkim mangan (Mn), krzem (Si), chrom (Cr), nikiel (Ni), miedź (Cu) oraz oczywiście węgiel (C). Mangan oraz krzem przede wszystkim zwiększają twardość i wytrzymałość stali, ale Mn jednocześnie obniża własności plastyczne – są stosowane jako odtleniacze. Chrom jest dodawany ze względu na dodatni wpływ na zwiększenie odporności na korozję oraz jest standardowym dodatkiem w stalach do ulepszania cieplnego powodując zwiększenie hartowności. Nikiel korzystnie wpływa na podwyższenie wytrzymałości oraz twardości przy zachowaniu wysokiej udarności. Wraz ze wzrostem stężenia węgla w stali zwiększa się jej wytrzymałość na rozciąganie, granica plastyczności oraz twardość, ale jednocześnie zmniejsza się udarność, wydłużenie i przewężenie. W stalach występują także fosfor (P) i siarka (S), które są zanieczyszczeniami, ale nawet niewielkie ich ilości mają wpływ na własności – powodują przede wszystkim kruchość stali. Siarka może jednak wpływać pozytywnie zwiększając skrawalność, dlatego też dodawana jest do stali automatowych. Wszystkie z wymienionych powyżej dodatków (poza S) zwiększają wytrzymałość na rozciąganie stali wraz ze wzrostem ich stężenia [1].

Pierwiastki stopowe nadając stali pewnych cech podwyższają również jej cenę jednostkową, która jest wymieniana jako podstawowe kryterium ekonomiczne decydujące o wyborze danego materiału inżynierskiego obok takich czynników jak koszty pozyskania, koszty przetwarzania oraz koszty eksploatacji. Dodatki potrafią wpływać w znacznej mierze na końcowy koszt danego gatunku stali oraz jego wytrzymałość, dlatego też ważne jest równoważenie ceny i wytrzymałości na rozciąganie [1].

W trakcie dobierania materiałów inżynierskich należy wziąć pod uwagę wiele kryteriów, dla których konieczne jest znalezienie kompromisu. Do takich właśnie celów służy optymalizacja wielokryterialna, która może zostać wykonana przy wykorzystaniu algorytmów genetycznych. GA mogą być traktowane jako skuteczne narzędzie wspomagające projektowanie, planowanie i sterowanie. Są matematycznym podejściem do opisu i optymalizacji procesów technicznych i organizacyjnych.

Algorytmy genetyczne są bardzo uniwersalnym narzędziem komputerowym, które może być stosowane w różnorodnych przypadkach. Autor pracy [3] pokazał możliwość wykorzystania ich w inżynierii produkcji do planowania przebiegu produkcji w gnieździe, gdzie pozwoliły one na ustalenie optymalnej kolejności zadań.

Algorytmy genetyczne często mogą okazać się niewystarczającym narzędziem i konieczne jest wykorzystanie dodatkowo innych metod, jak np. opisywana tutaj regresja liniowa lub mogą wspomagać inne narzędzie. Taki przypadek pokazał autor w pracy [6], gdzie GA zostały wykorzystane wraz ze sztucznymi sieciami neuronowymi do wyznaczania współczynnika tarcia blachy.

W pracy podjęto próbę wykorzystania narzędzi sztucznej inteligencji jakimi są algorytmy genetyczne do zoptymalizowania składu chemicznego stali, który wpływa bezpośrednio na własności stali oraz w pewnej części na jej cenę.

## 2. OPTYMALIZACJA WIELOKRYTERIALNA

Zadaniem optymalizacji jest znalezienie najlepszego rozwiązania, czyli takiego, które spełnia określone kryterium. Jednak istnieje przypadek, kiedy nie jest to tak oczywiste. Gdy mamy do czynienia z polioptymalizacją (optymalizacją wielokryterialną), w której istnieje wiele czynników jednocześnie, które powinny być spełnione – nie można wybrać rozwiązania w oparciu o jedno kryterium. Przypadki takich zadań występują najczęściej tam, gdzie decyzje należy podjąć w oparciu o kompromis pomiędzy wieloma sprzecznymi ze sobą celami [4,5].

W przypadku jednego kryterium poszukuje się najlepszej – największej lub najmniejszej, wartości funkcji celu, natomiast w optymalizacji wielokryterialnej otrzymuje się zbiór rozwiązań nazywanych optymalnymi w sensie Pareto lub krótko Pareto-optymalnymi. To które z rozwiązań zostanie wybrane zależy np. od przyjętych wag kryteriów. Funkcją celu nazywa się funkcję wyrażającą zależność przebiegu jakiegoś procesu, tzn. własności od wartości parametrów, które mają na to wpływ [4,5].

Otrzymany zbiór rozwiązań Pareto-optymalnych nie zawiera wskazówek odnośnie ostatecznego wyboru i w gestii osoby rozwiązującej leży dokonanie selekcji. Rozwiązania optymalne w sensie Pareto należą do zbioru rozwiązań dopuszczalnych, czyli zbioru zmiennych decyzyjnych spełniających postawione ograniczenia. Zbiór ten w optymalizacji jednokryterialnej jest uporządkowany wzdłuż funkcji celu, natomiast w przypadku wielokryterialnej jest on uporządkowany częściowo, tzn. jest ograniczony z niektórych stron funkcjami [4,5].

Istnieją różne metody optymalizacji wielokryterialnej, które w najprostszy sposób można podzielić na dwie kategorie:

- techniki skalaryzacji,
- techniki Pareto.

Pierwsze z nich sprowadzają wielowymiarowy problem do jednego wymiaru, co na końcu prowadzi do jednego rozwiązania. Do tych technik należą m.in. metoda sumy ważonej, logika rozmyta, programowanie kompromisowe i programowanie celów. Drugi rodzaj technik w wyniku daje zbiór rozwiązań – należą do niego algorytmy genetyczne, metoda przecięć obszaru granicznego, symulowane wyżarzanie [4].

### 3. ALGORYTMY GENETYCZNE

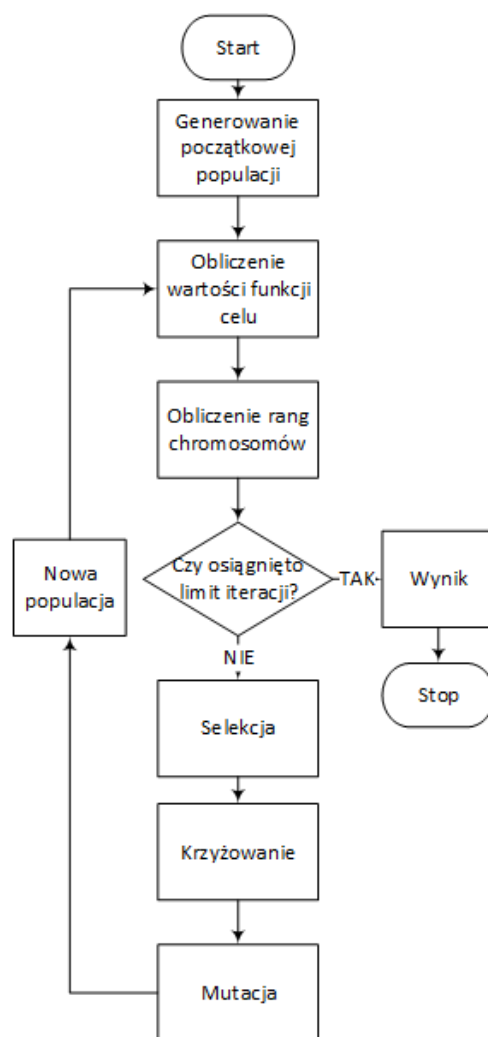
Jednym z narzędzi komputerowych używanych do optymalizacji są algorytmy genetyczne (ang. *genetic algorithm*, w skrócie GA), które bazują na algorytmach ewolucyjnych. Zaliczają się one do działu informatyki zwanego sztuczną inteligencją i są niejako próbą zasymulowania z pomocą komputera procesów zachodzących w naturze – naśladują one takie naturalne zjawiska jak selekcja, krzyżowanie, mutacje. Do czynności tych dochodzi, podobnie jak w prawdziwym świecie, w ramach pojedynczych osobników i ich grup, czyli populacji [3,4].

Podstawy algorytmów ewolucyjnych jako metody optymalizacji sięgają lat 50-tych, które w kolejnych latach przekształciły się w inne narzędzia jak programowanie ewolucyjne czy właśnie algorytmy genetyczne. Algorytmy genetyczne stosują podobną nomenklaturę jak biologia, dlatego też bardzo łatwo zrozumieć stosowane słownictwo i definicje [4].

Algorytmy opierają swoje działanie na doborze naturalnym oraz dziedziczeniu. Całość rozpoczyna się od wybrania populacji początkowej, którą jest podzbiór zbioru dopuszczalnych rozwiązań. Wybrana populacja składa się z osobników, tzw. chromosomów, które mogą być zakodowane liczbą binarną o stałej długości (jeden bit to jeden gen), jak również liczbą całkowitą lub rzeczywistą [4,6].

W kolejnym kroku oblicza się funkcję przystosowania całej populacji – funkcję kryterium, której wartość wpływa na wprowadzone zmiany w osobnikach poprzez krzyżowanie i selekcję. W trakcie krzyżowania dochodzi do wymiany genów pomiędzy losowo wybranymi osobnikami, w taki sposób, że dzieli się w losowym miejscu (punkcie krzyżowania) chromosom i wymienia równe części – wymienia się podciągi rodziców między sobą tworząc ciągi potomków. Natomiast selekcja jest wyborem najlepszych (najlepiej przystosowanych) osobników do następnej populacji. W algorytmach genetycznych stosuje się także sporadyczne mutacje (o niskim prawdopodobieństwie), w celu zróżnicowania puli genów w populacji, a co

za tym idzie, umożliwienia wyjścia ze zbioru rozwiązań generowanych na początku – w jej wyniku powstają nowe osobniki. Czynności te powtarza się do momentu uzyskania najlepszego osobnika, co w praktyce oznacza, że wykonuje się z góry założoną ilość operacji lub wartość funkcji zmienia się w bardzo małym stopniu. Schemat algorytmu genetycznego przedstawia rysunek 1 (warunkiem zakończenia jest ilość iteracji) [4,6].



Rysunek 1. Schemat algorytmu genetycznego  
*Figure 1. Scheme of genetic algorithm*

Algorytmy genetyczne są popularne w optymalizacji zawdzięczają łatwości stosowania, a także dzięki sprawdzaniu się w przypadkach z wieloma sprzecznymi kryteriami oraz w dużych przestrzeniach dopuszczalnych rozwiązań [4].

#### 4. OPTIMALIZACJA SKŁADU CHEMICZNEGO I CENY

Szukanie kompromisu pomiędzy własnościami mechanicznymi (tutaj reprezentowanymi przez wytrzymałość na rozciąganie) a ceną stali, jest odwiecznym problemem inżynierów odpowiedzialnych za projektowanie i wytwarzanie danego elementu.

W celu wykonania optymalizacji przy użyciu algorytmów genetycznych potrzebny jest model matematyczny danego zjawiska w postaci funkcji, która je opisuje. Na potrzeby tej pracy stworzono dwie takie funkcje – jedna opisująca zależność składu chemicznego od wytrzymałości na rozciąganie i druga pokazująca wpływ pierwiastków stopowych na cenę stali.

Funkcja obrazująca wpływ dodatków stopowych ( $f_1$ ) na własności mechaniczne stali została stworzona przy wykorzystaniu regresji liniowej w oparciu o dane pochodzące z norm. Niektóre z wykorzystanych stali wraz z ich składem chemicznym przedstawia tablica 1. Na podstawie tej funkcji stworzono drugą funkcję ( $f_2$ ) poprzez podmianę współczynników na ceny danego pierwiastka.

Tablica 1. Przykłady wykorzystanych stali wraz ze składami chemicznymi

Table 1. The examples of used steel with the chemical compositions

Oznaczenie	C	Mn	Si	P	S	Cr	Ni	Cu
St3S	$\leq 0,22$	$\leq 1,1$	$0,1\div 0,35$	$\leq 0,5$	$\leq 0,05$	$\leq 0,3$	$\leq 0,3$	$\leq 0,3$
S235JRG2	$\leq 0,17$	$\leq 1,4$	$\leq 0,55$	$\leq 0,045$	$\leq 0,045$	$\leq 0,3$	$\leq 0,3$	$\leq 0,3$
15G	$\leq 0,18$	$0,7\div 1,3$	$0,15\div 0,5$	$\leq 0,3$	$\leq 0,04$	$\leq 0,3$	$\leq 0,3$	$\leq 0,3$
18G2	$\leq 0,22$	$1\div 1,6$	$0,2\div 0,55$	$\leq 0,05$	$\leq 0,05$	$\leq 0,3$	$\leq 0,3$	$\leq 0,3$

Algorytmy genetyczne wymagają nałożenia odpowiednich ograniczeń, które pozwolą na określenie zbioru rozwiązań dopuszczalnych – w tym przypadku przyjęto ograniczenia zastosowane w trakcie regresji liniowej. Tablica 2 przedstawia zakresy możliwych stężeń pierwiastków oraz wartości funkcji, w ramach których mogą operować GA.

Tablica 2. Ograniczenia nałożone na algorytmy genetyczne

Table 2. The constraints imposed on the genetic algorithm

C	Mn	Si	P	S	Cr	Ni	Cu	$f_1$ ( $R_m$ )
0,1	0,27	0,13	0,007	0,003	0	0	0	393
0,25	1,59	0,55	0,045	0,05	0,3	0,3	0,31	632

Ponadto ograniczono wartość  $f_2$  do wartości dodatnich:

$$f_2 \geq 0$$

Celem było otrzymanie jak największej wartości wytrzymałości na rozciąganie, przy jak najniższej cenie dodatków stopowych. Z tego powodu funkcja  $f_1$  była maksymalizowana, natomiast funkcja  $f_2$  minimalizowana. Do wykonania optymalizacji przy pomocy algorytmów genetycznych wykorzystano program MATLAB® firmy Mathworks®, dlatego też wymagane było przemnożenie funkcji  $f_1$  przez -1, gdyż powyższy program umożliwia jedynie minimalizację funkcji celu.

Optymalizację wielokryterialną przy użyciu GA wykonano w oparciu o metodę sum ważonych, tzn. ostateczna funkcja celu  $f_c$  powstaje w wyniku połączenia poszczególnych funkcji sumą ważoną. Dzięki temu możliwe jest przekształcenie zadania wielokryterialnego do postaci zadania standardowego – wykorzystano algorytmy genetyczne i metodę sum ważonych jako technikę skalaryzacji. W opisywanym przypadku funkcja celu ma postać:

$$f_c = w_1 \cdot f_1 + w_2 \cdot f_2$$

Wartości funkcji celu obliczono dla 9 różnych przypadków w zależności od przyjętych wag w sumie ważonej. Konkretnie wartości wag przedstawia tablica 3, przy czym zawsze spełniają one warunek konieczny sumy ważonej:  $w_1 + w_2 = 1$ .

Tablica 3. Wagi sumy ważonej

Table 3. The coefficient of the weighted sum

$w_1$	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9
$w_2$	0,9	0,8	0,7	0,6	0,5	0,4	0,3	0,2	0,1


Wynikiem wykonania optymalizacji wielokryterialnej metodą sum ważonych przy użyciu algorytmów genetycznych jest zbiór rozwiązań optymalnych, które tworzą tzw. front Pareto, czyli zbiór rozwiązań Pareto-optymalnych. Zazwyczaj polepszenie wartości jednej funkcji powoduje pogorszenie drugiej lub jedna pozostaje bez zmian. W tablicy 4 zestawiono wyniki otrzymane przy użyciu GA, wraz z obliczonymi składami chemicznymi.

Rysunek 2 przedstawia wykres zależności obliczonej ceny i wytrzymałości na rozciąganie.

Tablica 4. Obliczone składy chemiczne w optymalizacji wielokryterialnej

Table 4. The chemical compositions calculated in multicriterial optimization

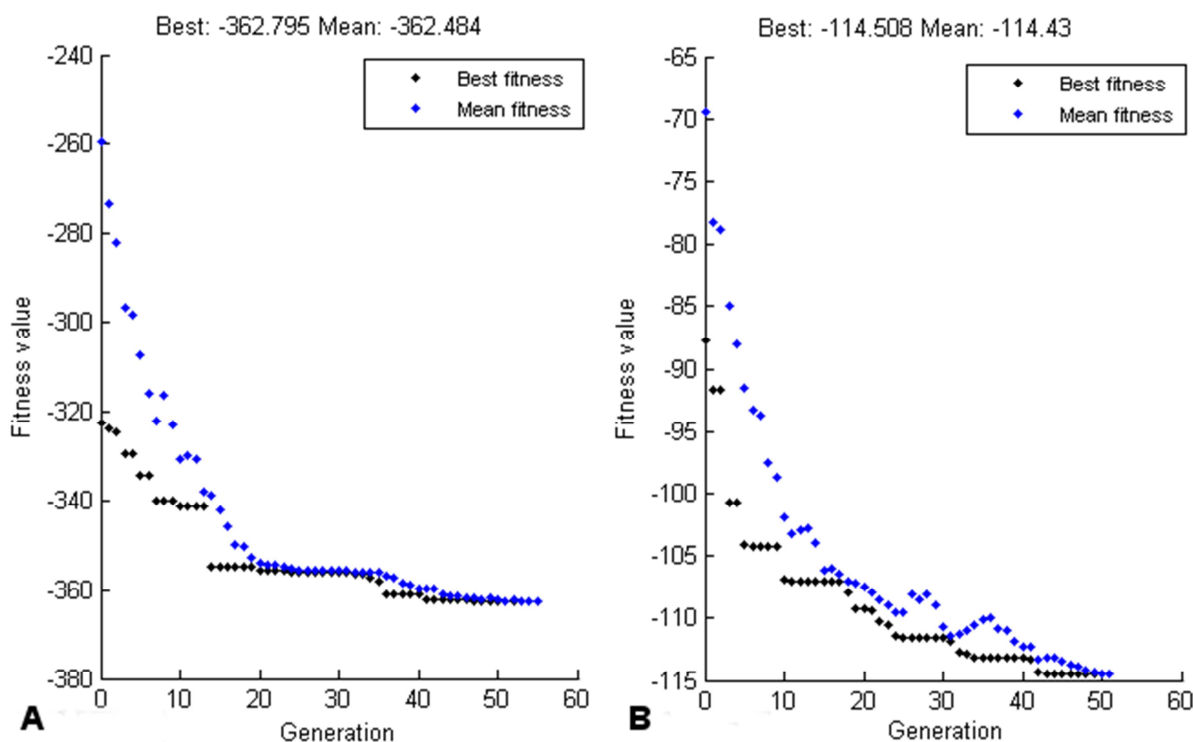
Wagi		C	Mn	Si	P	S	Cr	Ni	Cu	$R_m$	Cena
$w_1$	$w_2$										
0,1	0,9	0,250	1,59	0,434	0,037	0,028	0,001	0	0	616	12,57
0,2	0,8	0,223	1,59	0,450	0,034	0,003	0	0,01	0	623	12,62
0,3	0,7	0,224	1,59	0,449	0,037	0,003	0,050	0,01	0	624	14,16
0,4	0,6	0,250	1,59	0,419	0,031	0,003	0,044	0,19	0,062	632	24,02
0,5	0,5	0,234	1,59	0,450	0,036	0,003	0,038	0,02	0,044	632	18,00
0,6	0,4	0,212	1,59	0,317	0,036	0,003	0,150	0	0,293	632	40,94
0,7	0,3	0,250	1,59	0,299	0,012	0,003	0	0	0,31	632	37,93
0,8	0,2	0,250	1,59	0,149	0,038	0,003	0	0,01	0,251	632	32,84
0,9	0,1	0,250	1,59	0,450	0,038	0,046	0	0	0,283	632	36,14



Rysunek 2. Wykres zależności obliczonej ceny i wytrzymałości na rozciąganie

Figure 2. The chart of calculated price and tensile strength

Wykresy na rysunku 3 są przykładami zależności wartości funkcji celu od kolejnych generacji, w których wybierany jest najlepszy osobnik oraz liczona średnia całej populacji. Wartości na tych wykresach są ujemne, gdyż GA w programie MATLAB mają możliwość jedynie minimalizować funkcję.



Rysunek 3. Wartość funkcji celu w kolejnych generacjach: A)

B)

## 5. WNIOSKI

Wynikiem wykonania optymalizacji wielokryterialnej przy użyciu algorytmów genetycznych są składy chemiczne stali poddanej badaniom, na podstawie, których obliczono wytrzymałość na rozciąganie oraz koszt dodatków stopowych. Największa obliczona wartość  $R_m=632$  MPa wynika z przyjętych dla algorytmów genetycznych ograniczeń.

Dla wszystkich obliczanych przypadków funkcja celu osiągała swoją minimalną wartość w granicach 50÷60 generacji, co prezentują wykresy na rysunku 3. Stężenie manganu (Mn) zawsze jest na najwyższym poziomie, co przekłada się jednocześnie na duży wpływ tego pierwiastka na wytrzymałość stali. Również na wysokim poziomie utrzymywane jest stężenie krzemu (Si) i węgla (C), który zwiększają  $R_m$  i twardość. Pomimo dodatniego wpływu niklu (Ni) na wartość wytrzymałości na rozciąganie, jest on utrzymywany na stosunkowo niskim poziomie, ze względu na jego wysoką cenę rynkową.

Łatwość stosowania dzięki wykorzystaniu odpowiedniego oprogramowania oraz możliwość wykorzystania w przypadkach ze sprzecznymi kryteriami i o dużych przestrzeniach dopuszczalnych rozwiązań decydują o popularności algorytmów genetycznych.

Problemem algorytmów genetycznych jest możliwość niezyskania rozwiązania optymalnego, co spowodowane jest losowością podczas krzyżowania i mutacji, a także poprzez nałożone z góry ograniczenia modelu matematycznego, co może wpływać na brak powtarzalności w bardziej skomplikowanych przypadkach.

Wytrzymałość na rozciąganie jest jednym z często branych pod uwagę czynników, które wpływają na wybór materiału, jak również, we wszystkich gałęziach gospodarki liczy się cena. Autor pracy [2] wykazał, że można zmniejszyć koszt konstrukcji przy zachowaniu pierwotnych parametrów maszyny.

## LITERATURA

1. L.A. Dobrzański, Materiały inżynierskie i projektowanie materiałowe, Podstawy nauki o materiałach i metaloznawstwo, WNT, Warszawa, 2006.
2. M. Sames, K. Chrobacek, Multicriterial optimization of the asynchronous machine, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej. *Studia i Materiały* 62/28 (2008) 138-143.
3. M. Kęsy, K. Tubielewicz, Algorytmy genetyczne w inżynierii produkcji, *Przegląd Mechaniczny* 11 (2009) 18-22.
4. K. Białas-Heltowski, Wyznaczenie i ocena rozwiązań polioptymalnych na przykładzie wybranego układu technicznego, Rozprawa doktorska, Uniwersytet Zielonogórski, Wydział Mechaniczny, 2006.
5. R. Lorek, S. Płonka, Multicriteria optimization of manufacturing processes of the rotors to open end spinning machine, *Advances in Manufacturing Science and Technology* 37/1 (2013) 55-68.
6. T. Trzepieciński, Genetic algorithms as an optimization tool of neural networks modelling friction phenomenon, *Zeszyty Naukowe Politechniki Rzeszowskiej. Mechanika* 83/4 (2011) 63-72.