

Optimalizacja procesu wytłaczania jednoślindakowego tworzyw polimerowych – badania symulacyjne

Andrzej Nastaj¹⁾, Krzysztof Wilczyński^{1), *)}

DOI: [dx.doi.org/10.14314/polimery.2018.4.7](https://doi.org/10.14314/polimery.2018.4.7)

Streszczenie: Opracowano metodę optymalizacji wytłaczania jednoślindakowego tworzyw polimerowych na podstawie modelu komputerowego procesu z zastosowaniem technik ewolucyjnych (algorytmów genetycznych). Wykorzystano program symulacji procesu wytłaczania GSEM (*Global Screw Extrusion Model*) stanowiący źródło danych do optymalizacji oraz, specjalnie w tym celu opracowany, program optymalizacji ewolucyjnej GASEO – narzędzie optymalizacji. Na podstawie badań symulacyjnych dokonano optymalizacji wybranych parametrów wytłaczania – prędkości obrotowej ślimaka i długości strefy dozowania ślimaka – wg kryterium maksymalnej wydajności i minimalnej mocy procesu.

Słowa kluczowe: wytłaczanie jednoślindikowe, optymalizacja, modelowanie.

Process optimization for single screw extrusion of polymeric materials – simulation studies

Abstract: Optimization method for single screw extrusion has been developed based on the computer model of the process using evolutionary techniques (Genetic Algorithms). The single screw extrusion simulation program GSEM (*Global Screw Extrusion Model*) and the evolutionary optimization program GASEO, especially designed for this purpose, were used. Program GSEM was the source of optimization data, and program GASEO was the optimization tool. On the basis of simulation studies the selected parameters of extrusion process – screw speed and screw metering section length – were optimized from the viewpoint of maximum extrusion output and minimum power consumption.

Keywords: single screw extrusion, optimization, modeling.

Komputerowe modelowanie procesów przetwórstwa tworzyw pozwala na prognozowanie ich przebiegu na podstawie danych materiałowych, technologicznych i geometrycznych [1]. Modelowanie nie rozwiązuje jednak problemu doboru parametrów procesu w celu uzyskania pożądanego efektów, nie stwarza też możliwości optymalizacji warunków przetwórstwa według przyjętych kryteriów.

Optymalizacja procesu wytłaczania to zagadnienie złożone ze względu na bardzo dużą liczbę parametrów procesu i potencjalnych kryteriów optymalizacji. Znalezienie optimum globalnego i uniknięcie rozwiązań lokalnych jest więc bardzo trudne.

W pracy [2] dokonano przeglądu literatury dotyczącej optymalizacji procesu wytłaczania i stwierdzono, że tradycyjna optymalizacja na podstawie żmudnych badań doświadczalnych jest zdecydowanie zbyt kosztowna

i nieefektywna. Zaproponowano optymalizację na podstawie badań symulacyjnych procesu z zastosowaniem technik ewolucyjnych (algorytmów genetycznych).

W algorytmach genetycznych (inaczej technikach ewolucyjnych) parametry zadania są przetwarzane w postaci zakodowanej, poszukiwania rozwiązania są prowadzone z pewnej populacji punktów, co zmniejsza prawdopodobieństwo utknięcia w ekstremum lokalnym, stosuje się probabilistyczne reguły wyboru i korzysta tylko z funkcji celu, a nie z jej pochodnych lub innych pomocniczych informacji.

Wykorzystanie technik ewolucyjnych w wypadku wytłaczania tworzyw jest, jak dotąd, ograniczone do optymalizacji procesu tradycyjnego wytłaczania jednoślindikowego z zasilaniem grawitacyjnym [3–8] oraz wytłaczania dwuślindikowego współbieżnego [9–11]. Algorytmy genetyczne stosuje się też do skalowania tych procesów [12, 13].

Ostatnio opracowano modele matematyczne wytłaczania jednoślindikowego z dozowanym zasilaniem wytłaczarki oraz wytłaczania dwuślindikowego przeciwbieżnego [14–20], mimo to brakuje opracowań optymalizacyjnych tych procesów.

¹⁾ Politechnika Warszawska, Wydział Inżynierii Produkcji, Instytut Technik Wytwarzania, Zakład Przetwórstwa Tworzyw Sztucznych, ul. Narbutta 85, 02-524 Warszawa.

*) Autor do korespondencji:

e-mail: k.wilczynski@wip.pw.edu.pl

W niniejszej pracy przedstawiono optymalizację z wykorzystaniem symulacyjnych technik ewolucyjnych, na tle badań doświadczalnych procesu wytłaczania jednoślismakowego z zasilaniem grawitacyjnym [2].

ALGORYTMY GENETYCZNE

Algorytmy genetyczne to metoda przeszukiwania przestrzeni potencjalnych, najlepszych rozwiązań rozpatrywanego zagadnienia, wzorowana na naturalnej ewolucji, definiowana przez przestrzeń, w której znajduje się pewna populacja osobników. Osobnikami populacji są zakodowane w postaci chromosomów zbiory parametrów zadania, określane jako punkty przestrzeni poszukiwań, np. parametry procesu wytłaczania. Chromosom to uporządkowany ciąg znaków (czyli genów), np. bitów. Struktura składająca się z zespołu chromosomów danego osobnika stanowi jego genotyp, reprezentujący zestaw kilku parametrów wytłaczania, np. prędkości obrotowej ślimaka, temperatury cylindra, długości strefy dozowania ślimaka.

Działanie algorytmu przebiega zwykle w następujący sposób. Najpierw losowo wybrana populacja początkowa osobników jest poddawana ocenie. Podstawą tej oceny są wartości funkcji celu generowane przez poszczególne osobniki. Funkcją celu może być np. wydajność procesu wytłaczania. Osobniki generujące największe wartości funkcji celu biorą udział w procesie reprodukcji. Genotypy tych osobników podlegają operacjom genetycznym krzyżowania (wymiana fragmentów chromosomów) i mutacji (wprowadzanie losowych zmian w genotypie). W wyniku tych działań powstaje drugie pokolenie, które poddaje się ocenie. Taką procedurę powtarza się tak długo, aż zostanie osiągnięte dobre rozwiązanie.

Selekcję osobników zwykle realizuje się z zastosowaniem metody koła ruletki, polegającej na n-krotnym losowaniu osobników z populacji pierwotnej (n – liczba osobników w populacji), przy czym prawdopodobieństwo wylosowania każdego z osobników jest różne i określane przez stosunek wartości funkcji celu danego osobnika do sumy wartości funkcji przystosowania wszystkich osobników.


PROGRAM OPTYMALIZUJĄCY

Proponowana optymalizacja procesu wytłaczania na podstawie technik ewolucyjnych polega na pozyskaniu danych do optymalizacji na podstawie badań symulacyjnych procesu i następnie zastosowaniu odpowiedniej procedury optymalizacji ewolucyjnej. Wymaga więc współdziałania dwóch narzędzi – pozyskiwania i obróbki danych.

Podstawę badań symulacyjnych stanowi program GSEM (ang. *Global Screw Extrusion Model*), który jest rozwinięciem znanego programu symulacji tradycyjnego procesu wytłaczania jednoślismakowego z zasilaniem

grawitacyjnym SSEM (ang. *Single Screw Extrusion Model*) [20–22]. Program GSEM umożliwia dodatkowo symulację procesu wytłaczania jednoślismakowego z dozowanym zasilaniem wytłaczarki, jest więc narzędziem modelowania przepływu tworzyw w wytłaczarkach jednoślismakowych zasilanych grawitacyjnie (bez dozowania tworzywa) i z dozowaniem tworzywa, ze ślimakami konwencjonalnymi i specjalizowanymi, z zastosowaniem głowic o różnej geometrii. Program stanowi element opracowywanego w Zakładzie Przetwórstwa Tworzyw Sztucznych Politechniki Warszawskiej wielozadaniowego systemu modelowania, optymalizacji i skalowania procesów ślimakowych przetwórstwa tworzyw MultiScrew System [23].

Podstawę optymalizacji stanowi specjalnie w tym celu opracowany program GASEO, umożliwiający realizację procedury optymalizacyjnej procesu wytłaczania na podstawie algorytmów genetycznych. Program współpracuje z programem symulacji wytłaczania GSEM, będącym źródłem danych do optymalizacji. Schemat tej współpracy przedstawia rys. 1.



Rys. 1. Schemat algorytmu genetycznego (we współpracy z programem GSEM): $x_{(1-n) \min}$ – $x_{(1-n) \max}$ – zakres zmiennych wejściowych, x_{1i} – x_{ni} – wartości wejściowe, y_{1i} – y_{ni} – wartości wyjściowe, f_c – funkcja celu, W_z – warunek zatrzymania, $x_{(1-n) \text{opt}}$ – wartości optymalne zmiennych wejściowych

Fig. 1. Scheme of Genetic Algorithm (working with GSEM program): $x_{(1-n) \min}$ – $x_{(1-n) \max}$ – range of input variables, x_{1i} – x_{ni} – input values, y_{1i} – y_{ni} – output values, f_c – objective function, W_z – stop condition, $x_{(1-n) \text{opt}}$ – optimal values of input variables

Optymalizacja wykorzystująca algorytmy genetyczne obejmuje następujące etapy:

1) Zdefiniowanie globalnej funkcji celu (kryterium optymalizacji) i normalizacja parametrów zadania.

W tej pracy globalną funkcję celu zdefiniowano w postaci:

$$F_i = \sqrt[k]{f_{i(1)} \cdot f_{i(2)} \cdot \dots \cdot f_{i(k)}} \quad (1)$$

gdzie: F_i – globalna funkcja celu i -tego zestawu danych, k – liczba kryteriów optymalizacji (kryteriów indywidualnych, wielkości wyjściowych procesu), $f_{i(k)}$ – funkcja celu k -tego kryterium, przyjmująca postać (znormalizowaną):

– gdy kryterium optymalizacji stanowi maksymalna wartość wielkości wyjściowej y :

$$f_i = \frac{y_i - y_{min}}{y_{maks} - y_{min}} \quad (2)$$

– gdy kryterium optymalizacji stanowi minimalna wartość wielkości wyjściowej y :

$$f_i = \frac{y_{maks} - y_i}{y_{maks} - y_{min}} \quad (3)$$

gdzie: y – wielkość wyjściowa procesu (np. wydajność wytłaczania), i – numer kolejnej wartości ze zbioru danych rozpatrywanej wielkości wyjściowej, y_{maks} , y_{min} – maksymalna i minimalna wartość ze zbioru danych rozpatrywanej wielkości wyjściowej.

2) Zdefiniowanie algorytmu genetycznego:

- przyjęcie sposobu kodowania wielkości wejściowych,
- określenie długości ciągu znaków kodujących poszczególne parametry wejściowe, wyznaczającej dokładność poszukiwań w przestrzeni decyzyjnej,
- określenie wielkości populacji wejściowej,
- przyjęcie sposobu selekcji chromosomów,
- ustalenie prawdopodobieństwa wystąpienia operatorów genetycznych (krzyżowania i mutacji),
- przyjęcie kryterium zatrzymania ewolucji.

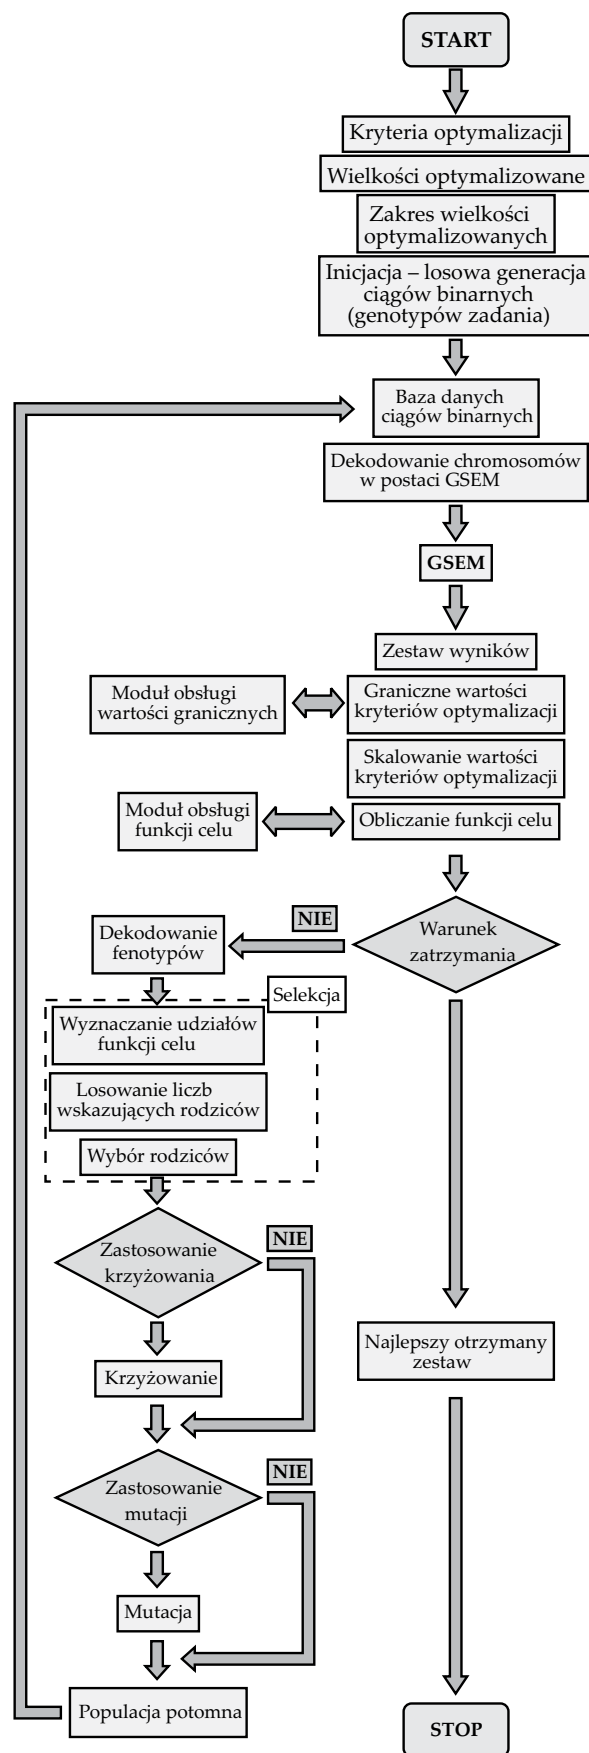
3) Realizacja algorytmu genetycznego:

- inicjacja, czyli losowy wybór populacji początkowej,
- ocena przystosowania chromosomów w populacji wg wartości funkcji celu,
- sprawdzenie warunku zatrzymania ewolucji,
- selekcja chromosomów do następnej populacji,
- zastosowanie operatorów genetycznych: krzyżowania i mutacji,
- utworzenie nowej populacji,
- wyбір rozwiązania optymalnego.

Program GASEO we współpracy z programem GSEM umożliwia przeprowadzenie optymalizacji wytłaczania z dowolną liczbą zmiennych optymalizowanych, z zastosowaniem różnych kryteriów optymalizacji procesu, np. wydajności wytłaczania lub zużycia mocy. Dokładność przeszukiwania powierzchni odpowiedzi określa liczba przyjętych przedziałów zakresu danych, wynikająca z długości zapisu tych liczb w postaci binarnej. W programie GASEO długość ciągu binarnego jest regulowana i maksymalnie wynosi 255 znaków, co umożliwia podział zakresu każdej ze zmiennych na 2^{255} wartości. Selekcję przeprowadzono metodą koła ruletki, stosunkowo prostej w implementacji komputerowej. Warunkiem zatrzymania optymalizacji jest 100-krotne wystąpienie najlepszego zestawu danych. Algorytm działania programu GASEO przedstawia rys. 2.

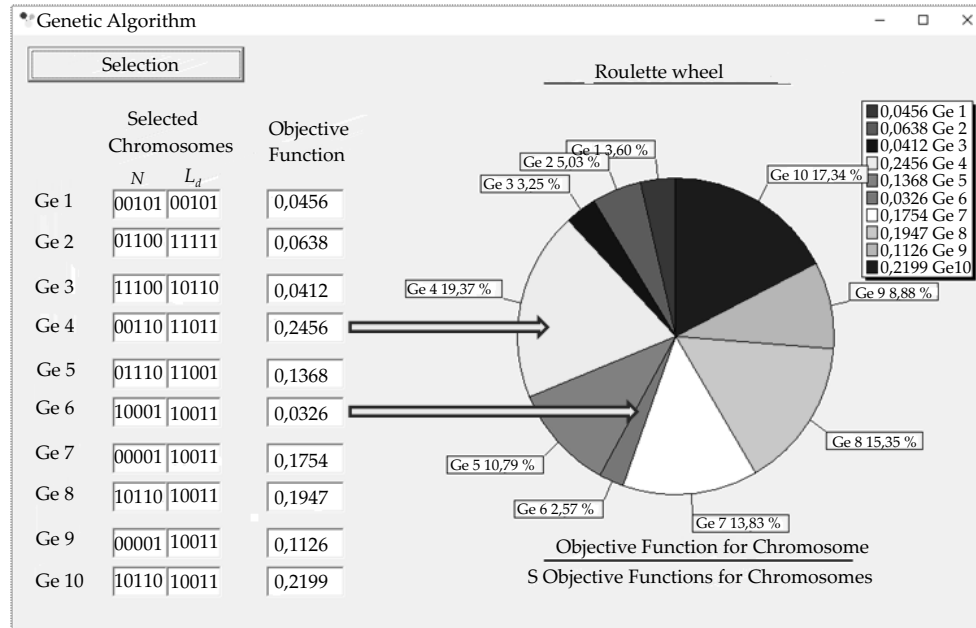
Schemat działania metody koła ruletki pokazano na rys. 3. Powierzchnie koła ruletki przyporządkowane poszczególnym genotypom są proporcjonalne do wartości funkcji celu generowanej przez te genotypy.

Program GASEO umożliwia indywidualny dobór parametrów działania algorytmu genetycznego. Wprowadzane są następujące parametry:



Rys. 2. Schemat blokowy algorytmu programu GASEO (we współpracy z programem GSEM)

Fig. 2. GASEO program flowchart (working with GSEM program)



Rys. 3. Realizacja algorytmu genetycznego: wybór populacji początkowej i ocena przystosowania chromosomów
Fig. 3. Implementation of Genetic Algorithm: selection of initial population and evaluation of chromosome adaptation

- długość chromosomów (ciągów znaków kodujących),
- wielkość populacji początkowej,
- prawdopodobieństwo wystąpienia krzyżowania,
- liczba punktów krzyżowania,
- prawdopodobieństwo wystąpienia mutacji.

OPTIMALIZACJA

Program badań

Program badań symulacyjnych obejmował wytlaczanie polietylenu dużej gęstości (PE-HD) Rigidex 6070EA (firmy BP Chemicals) o gęstości 0,952 g/cm³, wskaźniku szybkości płynięcia $MFR_{190^{\circ}C, 2,16\text{ kg}} = 7,6$ g/10 min i temperaturze topnienia 135 °C. Charakterystykę cieplno-mechaniczną PE-HD przedstawiono w pracy [2].

Właściwości reologiczne tworzywa opisuje równanie Kleina:

$$\ln \eta = A_0 + A_1 \ln \dot{\gamma} + A_{11} \ln^2 \dot{\gamma} + A_{12} T \ln \dot{\gamma} + A_2 T + A_{22} T^2 \quad (4)$$

gdzie: η – lepkość [Pa · s], $\dot{\gamma}$ – szybkość ścinania [1/s], T – temperatura [°C], A_0 , A_1 , A_{11} , A_{12} , A_2 i A_{22} – parametry równania Kleina ($A_0 = 10,918378968$, $A_1 = -0,218405893$, $A_{11} = -0,036865332$, $A_{12} = 0,001025862$, $A_2 = -0,022682083$, $A_{22} = 0,000021151$).

Warunki prowadzonych badań symulacyjnych odpowiadały warunkom badań doświadczalnych [2]: stosowano klasyczny ślimak trójstrefowy o średnicy $D = 45$ mm i stosunku długości do średnicy $L/D = 27$, o różnej długości strefy dozowania. Badania wykonano w trybie klasycznego zasilania grawitacyjnego, tzn. bez dozowania tworzywa, w szerokim zakresie prędkości obrotowej ($N = 20\text{--}80$ obr./min), przy zmiennej długości strefy do-

zowania ślimaka i w zmiennych warunkach temperatury przetwórstwa.

Na podstawie wyników badań symulacyjnych przeprowadzono optymalizację procesu wytlaczania, analogicznie jak w wypadku badań doświadczalnych [2], wg kryterium maksymalnej wydajności Q_{maks} i minimalnej mocy procesu P_{min} .

Analogicznie optymalizowano parametry technologiczne procesu (prędkość obrotową ślimaka) i parametry geometryczne ślimaka (długość strefy dozowania) wg kryterium maksymalnej wydajności i minimalnej mocy procesu.

Globalną funkcję celu zdefiniowano jako:

$$F_i = \sqrt[2]{Q_i \cdot P_i} \quad (5)$$

gdzie poszczególne dane ze zbioru wielkości wyjściowych znormalizowano w postaci:

$$Q_{i_znorm} = \frac{Q_i - Q_{min}}{Q_{maks} - Q_{min}} \quad (6)$$

$$P_{i_znorm} = \frac{P_{maks} - P_i}{P_{maks} - P_{min}} \quad (7)$$

gdzie: F_i – globalna funkcja celu, Q_{i_znorm} – znormalizowana wartość masowego natężenia przepływu, P_{i_znorm} – znormalizowana wartość mocy procesu, i – numer kolejnej wartości ze zbioru danych.

Program badań optymalizacyjnych obejmował (tabela 1):

1) Optymalizację w zakresie danych doświadczalnych: długość strefy dozowania $L_d = 230\text{--}590$ mm, prędkość obrotowa $N = 20\text{--}80$ obr./min, temperatura cylindra: $T_I = 150$ °C, $T_{II} = 160$ °C, $T_{III} = 170$ °C, $T_{IV} = 180$ °C.

T a b e l a 1. Program badań optymalizacyjnych

T a b e l e 1. Optimization studies program

Prędkość obrotowa ślimaka N , obr./min	Długość strefy dozowania ślimaka L_d , mm	Temp. cylindra T_I , °C	Temp. cylindra T_{II} , °C	Temp. cylindra T_{III} , °C	Temp. cylindra T_{IV} , °C
20–80	230–590	150	160	170	180
20–80	45–853	150	160	170	180
20–80	45–853	150	150–220	150–220	150–220

2) Optymalizację w rozszerzonym zakresie długości strefy dozowania: $L_d = 45$ –853 mm, $N = 20$ –80 obr./min, temperatura cylindra: $T_I = 150$ °C, $T_{II} = 160$ °C, $T_{III} = 170$ °C, $T_{IV} = 180$ °C.

3) Optymalizację w rozszerzonym zakresie długości strefy dozowania połączoną z optymalizacją tempera-

tury: $L_d = 45$ –853 mm, $N = 20$ –80 obr./min, temperatura cylindra: $T_I = 150$ °C, $T_{II} = 150$ –220 °C, $T_{III} = 150$ –220 °C, $T_{IV} = 150$ –220 °C.

Wyniki badań

Rysunek 4 przedstawia przykładowe wyniki badań symulacyjnych określające wpływ długości strefy dozowania ($L_d = 230, 410$ i 590 mm) na rozkład ciśnienia przy różnej prędkości obrotowej ślimaka ($N = 20, 50$ i 80 obr./min).

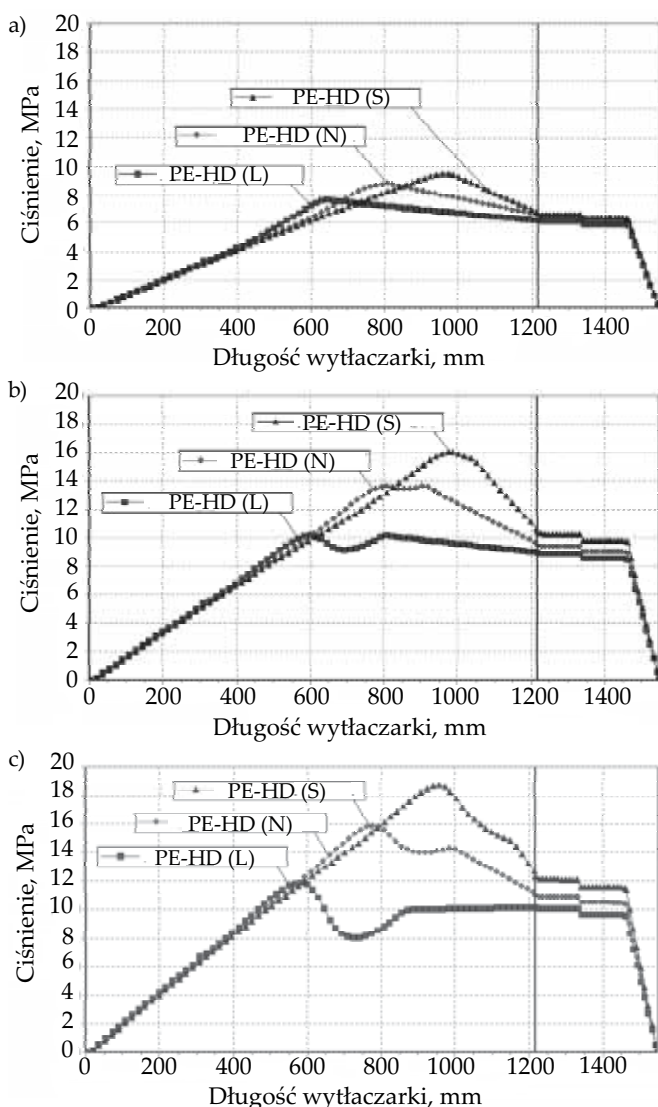
Wyniki badań optymalizacyjnych przedstawiają rys. 5–8 i tabele 2–5.

W tabeli 2 zestawiono zbiorcze wyniki trzech wykonanych działań optymalizacyjnych.

Na rys. 5 i w tabeli 3 przedstawiono szczegółowe wyniki optymalizacji (1) wykonanej w zakresie danych doświadczalnych. Największą wartość funkcji celu ($F_i = 0,55945$) uzyskano w wypadku ślimaka z krótką strefą dozowania ($L_d = 230$ mm) przy prędkości obrotowej ślimaka $N = 52$ obr./min. Parametry te są optymalne wg przyjętych kryteriów optymalizacji – maksymalnej wydajności i minimalnej mocy procesu ($L_{d,opt} = 230$ mm, $N_{opt} = 52$ obr./min). Odpowiadają im następujące wartości wielkości wyjściowych procesu: masowe natężenie przepływu $Q = 19,55$ kg/h, moc procesu $P = 2238,76$ W, jednostkowe zużycie energii $E_j = 412,25$ kJ/kg.

Na rys. 6 i w tabeli 4 przedstawiono szczegółowe wyniki optymalizacji (2), wykonanej w rozszerzonym zakresie długości strefy dozowania. Największą wartość funkcji celu ($F_i = 0,57551$) uzyskano w wypadku ślimaka z najkrótszą strefą dozowania ($L_d = 45$ mm) przy prędkości obrotowej ślimaka $N = 48$ obr./min. Są to parametry optymalne wg przyjętych kryteriów optymalizacji ($L_{d,opt} = 45$ mm, $N_{opt} = 48$ obr./min). Parametrom optymalnym odpowiadają następujące wartości wielkości wyjściowych procesu: masowe natężenie przepływu $Q = 22,49$ kg/h, moc procesu $P = 2053,51$ W, jednostkowe zużycie energii $E_j = 328,71$ kJ/kg.

Na rys. 7 i w tabeli 5 podano szczegółowe wyniki optymalizacji (3), wykonanej w rozszerzonym zakresie długości strefy dozowania, połączonej z optymalizacją temperatury. W wyniku optymalizacji rozkładu temperatury uzyskano wartości: $T_I = 150$ °C, $T_{II} = 220$ °C, $T_{III} = 220$ °C, $T_{IV} = 170$ °C. W takich warunkach największa wartość funkcji celu ($F_i = 0,45399$) odpowiadała ślimakowi z najkrótszą strefą dozowania ($L_d = 45$ mm) i prędkości obrotowej ślimaka $N = 40$ obr./min. Są to parametry optymal-



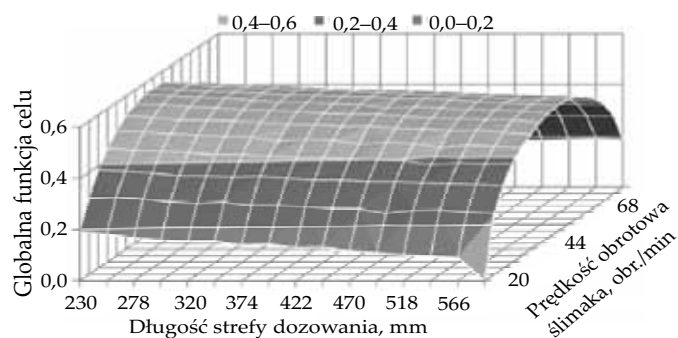
Rys. 4. Wpływ długości strefy dozowania $L_d = 230$ mm (S), 410 mm (N) i 590 mm (L) na rozkład ciśnienia przy różnej prędkości obrotowej ślimaka: a) $N = 20$ obr./min, b) $N = 50$ obr./min, c) $N = 80$ obr./min

Fig. 4. Effect of the metering section length $L_d = 230$ mm (S), 410 mm (N) and 590 mm (L) on the pressure profile at various screw speed: a) $N = 20$ rpm, b) $N = 50$ rpm, c) $N = 80$ rpm

T a b e l a 2. Wyniki badań optymalizacyjnych


T a b l e 2. Results of optimization studies

Prędkość obrotowa ślimaka N , obr./min	Długość strefy dozowania ślimaka L_d , mm	Temp. cylindra T_{IV} , °C	Temp. cylindra $T_{IV'}$, °C	Temp. cylindra $T_{III'}$, °C	Temp. cylindra T_{IV} , °C	Masowe natężenie przepływu Q , kg/h	Temp. tworzywa na wyjściu z głowicy T_g , °C	Moc P , W	Jednostk. zużycie energii E_g , kJ/kg
52	230	150	160	170	180	19,55	220,36	2238,8	412,25
48	45	150	160	170	180	22,49	214,99	2053,5	328,71
40	45	150	220	220	170	17,35	239,9	1010,5	209,67



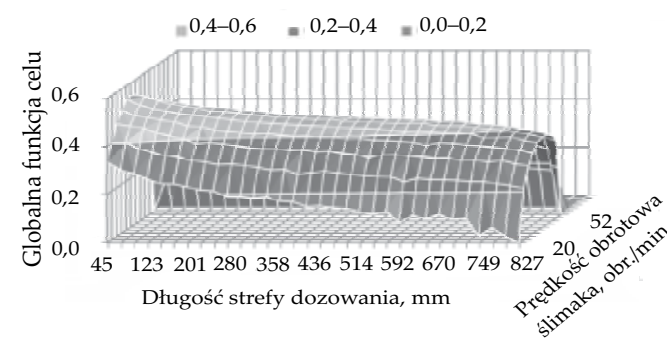
Rys. 5. Wykres globalnej funkcji celu dla danych symulacyjnych w zakresie danych doświadczalnych

Fig. 5. Global objective function chart for simulation data in the range of experimental data



Rys. 6. Wykres globalnej funkcji celu dla danych symulacyjnych w rozszerzonym zakresie długości strefy dozowania

Fig. 6. Global objective function chart for simulation data in the extended range of metering section length



Rys. 7. Wykres globalnej funkcji celu dla danych symulacyjnych w rozszerzonym zakresie długości strefy dozowania, przy optymalnym profilu temperatury

Fig. 7. Global objective function chart for simulation data in the extended range of metering section length, for the optimal temperature profile

T a b e l a 3. Wybrane wartości globalnej funkcji celu obliczone dla danych symulacyjnych w zakresie danych doświadczalnych

T a b l e 3. Selected values of global objective function for simulation data in the range of experimental data

N , obr./min	L_d , mm		
	230	422	590
Wartość globalnej funkcji celu F_i			
20	0,19252	0,12651	0,0
52	0,55945	0,52196	0,49009
80	0,0	0,17149	0,18638

T a b e l a 4. Wybrane wartości globalnej funkcji celu obliczone dla danych symulacyjnych w rozszerzonym zakresie długości strefy dozowania

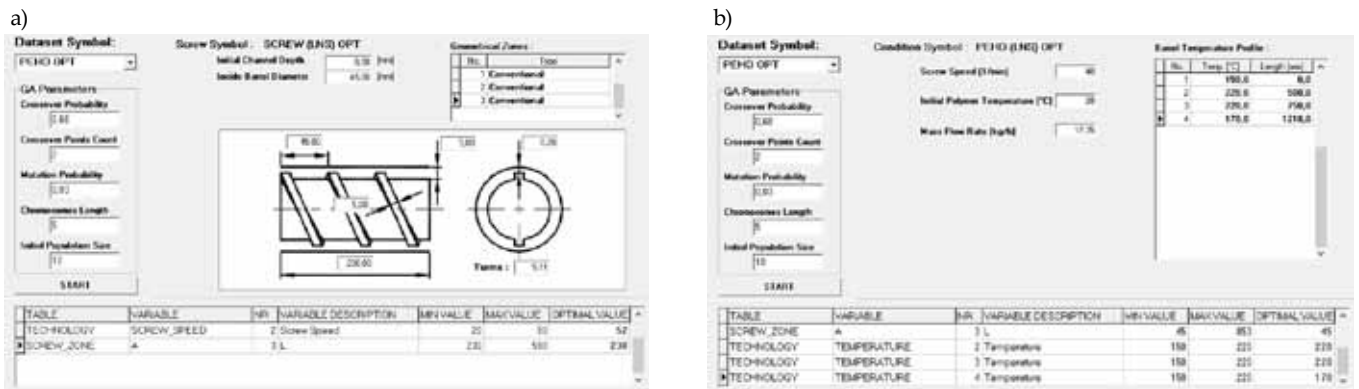
T a b l e 4. Selected values of global objective function for simulation data in the extended range of metering section length

N , obr./min	L_d , mm		
	45	410	853
Wartość globalnej funkcji celu F_i			
20	0,29154	0,16426	0,0
52	0,57551	0,47412	-
80	0,0	0,21300	0,22509

T a b e l a 5. Wybrane wartości globalnej funkcji celu obliczone dla danych symulacyjnych w rozszerzonym zakresie długości strefy dozowania, przy optymalnym profilu temperatury

T a b l e 5. Selected values of global objective function for simulation data in the extended range of metering section length, for the optimal temperature profile

N , obr./min	L_d , mm		
	45	410	853
Wartość globalnej funkcji celu F_i			
20	0,33258	0,16803	0,0
52	0,45399	0,39735	0,31787
60	0,0	0,22699	-



Rys. 8. Wyniki optymalizacji z zastosowaniem programu GASEO wykonanej: a) w zakresie danych doświadczalnych – program badań (1): Crossover Probability – prawdopodobieństwo krzyżowania, Crossover Points Count – liczba punktów krzyżowania, Mutation Probability – prawdopodobieństwo mutacji, Chromosomes Length – długość chromosomu, Initial Population Size – wielkość populacji początkowej, Initial Channel Depth – początkowa głębokość kanału, Inside Barrel Diameter – średnica wewnętrzna cylindra, Screw Speed – prędkość obrotowa ślimaka, b) w rozszerzonym zakresie długości strefy dozowania, połączonej z optymalizacją warunków temperatury – program badań (3): Initial Polymer Temperature – początkowa temperatura tworzywa, Mass Flow Rate – masowe natężenie przepływu, Barrel Temperature Profile – profil temperatury cylindra

Fig. 8. Optimization results using GASEO program: a) in the range of experimental data – test (1), b) in the extended range of metering section length, for the optimal temperature profile – test (3)

ne wg przyjętych kryteriów optymalizacji ($L_{d, opt} = 45$ mm, $N_{opt} = 40$ obr./min). Parametrom optymalnym odpowiadają następujące wartości wielkości wyjściowych procesu: masowe natężenie przepływu $Q = 17,35$ kg/h, moc procesu $P = 1010,54$ W, jednostkowe zużycie energii $E_j = 209,67$ kJ/kg.

Na rys. 8 przedstawiono zrzuty ekranów ilustrujące przykładowe okna wyników programu optymalizacyjnego GASEO zawierające parametry optymalizacji (parametry algorytmu genetycznego), wykaz parametrów optymalizowanych i zakres ich optymalizacji oraz wartości parametrów optymalnych.

Uzyskano dwa rozwiązania optymalne: $L_{d, opt} = 45$ mm, $N_{opt} = 48$ obr./min lub $L_{d, opt} = 45$ mm, $N_{opt} = 40$ obr./min. W pierwszym wypadku największa jest wydajność procesu ($Q = 22,49$ kg/h) przy umiarkowanym jednostkowym zużyciu energii ($E_j = 328,71$ kJ/kg). W drugim wypadku jednostkowe zużycie energii jest najmniejsze ($E_j = 209,67$ kJ/kg), ale najmniejsza jest też wydajność procesu ($Q = 17,35$ kg/h).

Wyniki badań wskazują na ograniczone znaczenie optymalizacji przeprowadzonej na podstawie badań doświadczalnych. Trzeba pamiętać, że liczba prób eksperymentalnych i_{exp} jest definiowana potęgową zależnością liczby optymalizowanych parametrów n i liczby poziomów wartości tych parametrów k w postaci $i_{exp} = k^n$. Przykładowo, optymalizacja tylko 4 parametrów geometrycznych klasycznego trójstrefowego ślimaka, głębokości kanału ślimaka w strefie zasilania i w strefie dozowania oraz długości tych stref na podstawie wyników badań wykonanych na 3 poziomach wartości tych parametrów wymagałaby skonstruowania $i_{exp} = 3^4 = 81$ ślimaków i przeprowadzenia tyluż prób doświadczalnych wytłaczania. Rozszerzenie optymalizacji tylko o 2 parametry

technologiczne, np. prędkość obrotową ślimaka i temperaturę głowicy, a więc zwiększenie liczby optymalizowanych parametrów do 6, spowodowałoby konieczność wykonania $i_{exp} = 3^6 = 729$ doświadczeń.

Zakres optymalizacji symulacyjnej przeprowadzonej w tej pracy jest praktycznie nieosiągalny w warunkach doświadczalnych ze względu na konieczność skonstruowania 128 ślimaków. Liczba ślimaków w optymalizacji symulacyjnej wynika z długości ciągu binarnego (7 znaków) zastosowanego do kodowania długości strefy dozowania. Zmiana długości strefy dozowania przy tym ciągu binarnym wynosi 6,3125 mm.

Proces wytłaczania określa kilkadziesiąt parametrów materiałowych, technologicznych i geometrycznych, a potencjalnych kryteriów optymalizacji może być kilkanaście, np. wydajność procesu, zużycie mocy, temperatura tworzywa, szybkość uplastycznienia tworzywa, stopień wymieszania itd. Racjonalna optymalizacja na podstawie badań doświadczalnych jest więc niemożliwa.

Przedstawiona procedura optymalizacji na podstawie badań symulacyjnych ma charakter uniwersalny i może być wykorzystana do optymalizacji nie tylko innych odmian procesu wytłaczania, np. wytłaczania dwuślimakowego, ale także do optymalizacji innych procesów przetwórstwa. Numeryczna implementacja procedury wymaga jednak odpowiedniej przebudowy programu w celu dostosowania do warunków określonego procesu przetwórczego. Warunkiem stosowania tej procedury jest również dysponowanie odpowiednim modelem komputerowym badanego procesu, a dokładniej – jego kodem źródłowym. A to nie jest już ani proste, ani oczywiste, możliwe tylko wtedy, gdy użytkownik zbuduje własny model procesu. Dlatego też prace badawcze w tym zakresie prowadzą tylko nieliczne ośrodki na

świecie, doświadczone zarówno w modelowaniu procesów przetwórczych, jak i w zagadnieniach optymalizacji.

PODSUMOWANIE

Przedstawiono zagadnienie optymalizacji procesu wytłaczania jednoślismakowego tworzyw polimerowych. Metodę optymalizacji opracowano na podstawie modelu komputerowego procesu z zastosowaniem algorytmów genetycznych. Podstawę metody stanowi program symulacji procesu wytłaczania GSEM, będący źródłem danych do optymalizacji, oraz specjalnie w tym celu opracowany program optymalizacyjny GASEO, który jest narzędziem optymalizacji. Dokonano symulacyjnej optymalizacji prędkości obrotowej ślimaka i długości strefy dozowania ślimaka wg kryterium maksymalnej wydajności i minimalnej mocy procesu. Wyniki symulacyjnych badań optymalizacyjnych zestawiono z wynikami symulacji doświadczalnej. Stwierdzono, że optymalizacja na podstawie badań doświadczalnych jest nieefektywna, dlatego też proponuje się optymalizację wytłaczania, a także innych procesów przetwórczych, na podstawie badań symulacyjnych procesu z zastosowaniem technik ewolucyjnych (algorytmów genetycznych).

LITERATURA

- [1] Wilczyński K.: „Reologia w przetwórstwie tworzyw sztucznych”, WNT, Warszawa 2001.
- [2] Nastaj A., Wilczyński K.: *Polimery* **2018**, 63, 38. <http://dx.doi.org/10.14314/polimery.2018.1.6>
- [3] Covas J.A., Cunha A.G., Oliveira P.: *International Journal of Forming Processes* **1998**, 1, 323.
- [4] Covas J.A., Cunha A.G., Oliveira P.: *Polymer Engineering and Science* **1999**, 39, 443. <http://dx.doi.org/10.1002/pen.11434>
- [5] Covas J.A., Gaspar-Cunha A.: “The Use of an Optimisation Approach to the Design of Extrusion Screw”, Materiały konferencyjne The Polymer Processing Society Sixteenth Annual Meeting (PPS-16), Shanghai, China 2000.
- [6] Gaspar-Cunha A., Covas J.A.: *International Polymer Processing* **2001**, 16, 229. <http://dx.doi.org/10.3139/217.1652>
- [7] Wilczyński K., Nastaj A.: *Mechanik* **2005**, nr 7, 606.
- [8] Wilczyński K., Nastaj A.: IMECE 2006, Chicago 2006.
- [9] Gaspar-Cunha A., Covas J.A., Vergnes B.: “An Optimisation Methodology for Setting the Operating Conditions in Twin-Screw Extrusion”, Materiały konferencyjne The Polymer Processing Society Eighteenth Annual Meeting (PPS-18), Guimaraes, Portugal 2002.
- [10] Gaspar-Cunha A., Poulesquen A., Vergnes B., Covas J.A.: *International Polymer Processing* **2002**, 17, 201. <http://dx.doi.org/10.3139/217.1701>
- [11] Gaspar-Cunha A., Covas J.A., Vergnes B.: *Polymer Engineering and Science* **2005**, 45, 1159. <http://dx.doi.org/10.1002/pen.20391>
- [12] Covas J.A., Gaspar-Cunha A.: *International Polymer Processing* **2009**, 24, 67. <http://dx.doi.org/10.3139/217.2200>
- [13] Covas J.A., Gaspar-Cunha A.: “A Scaling-up Methodology for Co-rotating Twin-extruders”, Materiały konferencyjne 27th Annual Meeting of the Polymer Processing Society (PPS-27), Marrakech, Morocco 2011, str. 1–6.
- [14] Wilczyński K., Nastaj A., Wilczyński K.J.: *International Polymer Processing* **2013**, 28, 34. <http://dx.doi.org/10.3139/217.2640>
- [15] Wilczyński K.J., Nastaj A., Lewandowski A., Wilczyński K.: *Polymer Engineering and Science* **2014**, 54, 2362. <http://dx.doi.org/10.1002/pen.23797>
- [16] Wilczyński K.J., Lewandowski A., Nastaj A., Wilczyński K.: *Advances in Polymer Technology* **2017**, 36, 23. <http://dx.doi.org/10.1002/adv.21570>
- [17] Wilczyński K.J., Lewandowski A., Nastaj A., Wilczyński K.: *International Polymer Processing* **2016**, 31, 82. <http://dx.doi.org/10.3139/217.3154>
- [18] Wilczyński K., White J.L.: *Polimery* **2008**, 53, 754.
- [19] Wilczyński K., Nastaj A., Lewandowski A., Wilczyński K.J.: *Polimery* **2011**, 56, 45.
- [20] Lewandowski A., Wilczyński K.J., Nastaj A., Wilczyński K.: *Polymer Engineering and Science* **2015**, 55, 2838. <http://dx.doi.org/10.1002/pen.24175>
- [21] Wilczyński K.: *Polymer-Plastics Technology and Engineering* **1996**, 35, 449. <http://dx.doi.org/10.1080/03602559608000931>
- [22] Wilczyński K.: *Polymer-Plastics Technology and Engineering* **1999**, 38, 581. <http://dx.doi.org/10.1080/03602559909351602>
- [23] Wilczyński K., Tyszkiewicz A., Szymaniak Z.: *Journal of Materials Processing Technology* **2001**, 109, 320. [http://dx.doi.org/10.1016/S0924-0136\(00\)00820-7](http://dx.doi.org/10.1016/S0924-0136(00)00820-7)
- [24] Wilczyński K., Nastaj A., Lewandowski A., Wilczyński K.J.: *Polymer-Plastics Technology and Engineering* **2012**, 51, 626. <http://dx.doi.org/10.1080/03602559.2012.659313>

Otrzymano 16 VIII 2017 r.