

Tomasz Trzepieciński

Politechnika Rzeszowska, Katedra Przeróbki Plastycznej

e-mail: tomtrz@prz.edu.pl

METODY OPTIMALIZACYJNE W PROBLEMACH REGRESYJNYCH

Streszczenie – Jednym z najważniejszych zadań w problemach regresyjnych jest odpowiedni dobór zestawu zmiennych objaśniających istotnie wpływających na wielkość objaśnianą. Analizie poddano zbiór danych otrzymany w próbie zginania blachy z przeciąganiem składający się z zestawu parametrów technologicznych próby i odpowiadającej im wartości współczynnika tarcia. Optymalizację liczby zmiennych wejściowych dokonano za pomocą metod selekcji krokowej, metodą Hellwiga oraz za pomocą algorytmów genetycznych.

1 Informacje wstępne


Tarcie w procesach kształtowania blach jest złożoną funkcją właściwości materiału, parametrów procesu oraz warunków kontaktu. Główne czynniki wpływające na zjawiska trybologiczne w procesach przeróbki plastycznej to między innymi makro- i mikrogeometria styku, kinematyka ruchu narzędzi, dynamika obciążeń, zjawiska fizykochemiczne na powierzchni styku oraz temperatura [1]. Siły tarcia występujące na powierzchni kontaktu metali wywierają znaczący wpływ na przebieg procesu kształtowania blach. Z uwagi na występowanie w poszczególnych obszarach wyłoczek różnicowanych warunków pod względem stanu naprężeń, odkształceń i prędkości przemieszczeń, dla potrzeb plastycznego kształtowania blach opracowano szereg prób modelujących warunki tarcia w wybranych miejscach wyłoczek [2]. Zastosowany w badaniach test zginania blachy z przeciąganiem służy do modelowania zjawiska tarcia w procesach kształtowania blach na progu ciągowym matrycy.

Systemy przetwarzania danych pozwalają na automatyczną analizę złożonego zbioru informacji i generowanie odpowiedzi na zadane pytania. Często ze względu na znaczną ilość czynników mających wpływ na określone zjawisko opracowanie analitycznych zależności służących do wyznaczenia funkcji odpowiedzi, dla danych warunków realizacji procesów, jest praktycznie niemożliwe. Zadanie to z powodzeniem realizują sztuczne sieci neuronowe należące do metod sztucznej inteligencji i których budowa i zasada działania ma podobieństwo do przetwarzania

informacji przez organizmy żywe. Warunkiem poprawnego działania sieci neuronowej jest konieczność preselekcji danych wejściowych, które w sposób istotny wpływają na wartość zmiennej objaśnianej przez zastosowanie mechanizmu dekompozycji. Celem dekompozycji danych jest znalezienie odpowiedzi na pytanie, czy pomiędzy zmiennymi wejściowymi oraz zmienną objaśnianą występuje zależność, czy związek ten jest zupełnie przypadkowy. W niniejszej pracy przedstawiono metody optymalizacji zmiennych wejściowych metodą selekcji krokowej, metodą Hellwiga oraz za pomocą algorytmów genetycznych. Przedstawione w artykule metody wyboru zmiennych wejściowych mogą także wykorzystane do doboru topologii sieci neuronowej oraz wartości wag neuronów.

2 Badania eksperymentalne

Eksperymenty wyznaczania wartości współczynnik tarcia przeprowadzono metodą przeciągania pasa blachy ze zginaniem (rys. 1), która służy do modelowania zjawiska tarcia na progu ciągowym podczas wyłaczania blach [3].



Rys. 1. Schemat próby zginania blachy z przeciąganiem: 1 – blacha, 2-4 – wałki robocze.

Badaniom poddano po trzy gatunki blach mosiężnych M70 z4, M70 z6, M90 z4 oraz blach ze stopu aluminium AA5251 r, AA5251 H14, AA5251 H22. Próbkę do testu tarcia miały kształt pasków o długości około 200 mm i szerokości 20 mm. Przeciwpróbki w postaci wałków o średnicy 20 mm zostały wykonane ze stali narzędziowej do pracy na zimno. Do badań użyto czterech kompletów wałków o następujących parametrach chropowatości Ra: 2,5; 1,25; 0,63; 0,32 μm , mierzonych

równoległe do osi wałków. Próby przeprowadzono przy kącie opasania rolki środkowej 3 równym 180° w warunkach tarcia suchego i smarowania olejem oraz ze zmiennymi prędkościami przemieszczania paska blachy $v_1=0,1$ m/min i $v_2=0,2$ m/min. Podczas badań mierzono za pomocą czujników tensometrycznych wielkość siły docisku F_D oraz siły ciągnięcia F_C . Próbę przeprowadzono w warunkach tarcia technicznie suchego oraz smarowania olejem LAN-46.

Ideą budowy przyrządu jest możliwość oddzielenia oporów odkształcenia blachy od oporów tarcia. W próbie podczas przeciągania paska blachy po rolkach zablokowanych i ruchomych mierzy się siłę ciągnięcia i siłę docisku. Przeciąganie blachy przez układ wałków ruchomych pozwala zminimalizować opory tarcia. Siła ciągnąca w tym przypadku wiąże się z pokonywaniem oporów odkształcenia blachy. Układ wałków zamocowanych nieruchomo reprezentuje całkowite opory przeciągania blachy przez próg. Różnicę siły ciągnięcia dla układu wałków ruchomego i nieruchomego można przypisać procesowi tarcia i wykorzystać do obliczenia wartości współczynnika tarcia według zależności [4]:

$$\mu = \frac{1}{\pi} \cdot \frac{F_P - F_R}{F_C} \quad (1)$$

gdzie F_P – siła przeciągania blachy przy rolkach zablokowanych, F_R – siła przeciągania blachy przy rolkach ruchomych, F_C – siła docisku rolki środkowej przy rolkach zablokowanych. Otrzymano w ten sposób 96 (6 gatunków blach * 4 zestawy rolek * 2 warunki smarowania * 2 prędkości przemieszczania) różnych zestawów uczących. W Tabeli 1 przedstawiono wartości współczynnika tarcia wyznaczonego w warunkach tarcia suchego μ_d i w warunkach smarowania powierzchni blachy olejem μ_l dla mosiądzu M70 z4.

Tabela. 1. Wartości współczynnika tarcia dla blachy M70 z4

Materiał	Prędkość przemieszczania, m/min	Ra rolek, μm	Współczynnik tarcia	
			μ_d	μ_l
M70 z4	0,1	0,32	0,21	0,15
	0,2	0,32	0,20	0,13
	0,1	0,63	0,18	0,14
	0,2	0,63	0,16	0,13
	0,1	1,25	0,22	0,15
	0,2	1,25	0,21	0,14
	0,1	2,5	0,15	0,11
	0,2	2,5	0,14	0,09

Na podstawie wcześniejszych badań [4, 5] jako zmienne objaśniające wpływające na wartość współczynnika tarcia poza parametrami technologicznymi próby wytypowano podstawowe parametry chropowatości powierzchni blach (Tab. 2) oraz parametry materiałowe blach (Tab. 3). Wartość parametrów mechanicznych wyznaczono w próbie jednoosiowego rozciągania, natomiast wartość parametrów chropowatości określono za pomocą systemu pomiarowego Subtronic 3+ firmy Rank Taylor Hobson.

Tabela. 2. Właściwości mechaniczne badanych blach

Material	Gatunek	R _{p02} MPa	R _m MPa	A ₅₀ %	C MPa	n
Mosiądz	M63 z6	474	516	0,07	628	0,04
	M70 z4	120	280	0,05	594	0,37
	M90 z4	346	384	0,12	426	0,04
Stopy aluminium	AA5251 r	68	203	0,18	252	0,28
	AA5251 H14	212	232	0,04	254	0,06
	AA5251 H22	111	201	0,19	370	0,24

Tabela. 3. Parametry chropowatości badanych blach

Material	Gatunek	R _a μm	R _q μm	R _p μm	R _t μm
Mosiądz	M63 z6	0,14	0,26	1,6	2,9
	M70 z4	0,14	0,18	0,7	1,4
	M90 z4	0,41	0,58	3,9	6,1
Stopy aluminium	AA5251 r	0,58	1,14	3,2	6,9
	AA5251 H14	0,48	0,64	2,2	4,1
	AA5251 H22	0,23	0,29	1,1	2,4

3 Optymalizacja liczby zmiennych

Jednym z najważniejszych zadań koniecznych do zbudowania optymalnego modelu regresyjnego jest odpowiedni dobór zmiennych wejściowych istotnie wpływających na wartość jednej lub wielu zmiennych wyjściowych [6]. Zbyt duża liczba zmiennych wejściowych może wprowadzać szum informacyjny natomiast nieuwzględnienie choćby jednej zmiennej istotnie wpływającej na zmienną objaśnianą doprowadzi do uzyskania fałszywych wyników. Z kolei nieuwzględnienie na wejściu sieci istotnych parametrów z punktu widzenia korelacji ze

zmiennymi wyjściowymi, może doprowadzić do obniżenia dokładności odpowiedzi sieci neuronowej.

Jako parametry wejściowe mające istotny wpływ na wartość współczynnik tarcia wytypowano następujący zestaw zmiennych:

- granicę plastyczności materiału $R_{p0,2}$, wytrzymałość na rozciąganie R_m , wydłużenie A_{50} , współczynnik umocnienia C oraz wykładnik umocnienia n materiału blachy,

- parametr chropowatości R_a powierzchni wałków,
- parametry chropowatości powierzchni blach, R_a , R_q , R_p , R_t ,
- warunki smarowania,
- prędkość przeciągania blachy.

Do optymalizacji liczby zmiennych wejściowych wykorzystano najczęściej stosowane metody tj. selekcję krokową, metodę Hellwiga oraz algorytmy genetyczne.

Istnieją dwa rodzaje selekcji krokowej zmiennych: krokowa postępująca oraz wsteczna [7]. Metoda *selekcji krokowej postępującej* polega na stopniowym dołączaniu do modelu kolejnych zmiennych począwszy od jednej zmiennej niezależnej, która charakteryzuje się największym stopniem istotności. Kolejno dodawane są zmienne, które na danym etapie selekcji powodują wzrost współczynnika determinacji R^2 . Proces selekcji zatrzymuje się w momencie braku poprawy jakości modelu po dołączeniu kolejnej zmiennej. W metodzie *selekcji krokowej wstecznej* proces selekcji rozpoczyna się od pełnego zestawu zmiennych. Kolejne kroki polegają na eliminacji zmiennych, których brak nie prowadzi do ustalonego spadku wartości współczynnika determinacji R^2 . Metody selekcji krokowej wstecznej i postępującej charakteryzują się tym, że dana zmienna może występować w modelu tylko raz. Algorytm selekcji krokowej postępującej zalecany jest dla większej liczby oczekiwanych zmiennych wejściowych, natomiast wsteczny algorytm selekcji zmiennych zaleca się stosować przy niewielkiej liczbie przewidywanych zmiennych wejściowych [7].

Metoda określania pojemności informacyjnej określana mianem *metody Hellwiga* umożliwia wybór zmiennych wejściowych słabo skorelowanych między sobą przy jednoczesnym silnym skorelowaniu ze zmienną wyjściową. Dla każdej kombinacji zmiennych objaśniających wyznaczane są wskaźniki indywidualnej pojemności nośników informacji względem każdej zmiennej występującej w tej kombinacji. Stanowią one miernik wielkości informacji wnoszonej przez daną zmienną. Wskaźnik indywidualnej pojemności nośników informacji względem każdej zmiennej X_j należącej do zbioru potencjalnych zmiennych objaśnianych $\{X_1, \dots, X_k\}$ wchodzącej w skład kombinacji n oblicza się ze wzoru:

$$h_{nj} = \frac{r_j^2}{\sum_{l=1}^{k_n} |r_{lj}|} \quad (2)$$

gdzie: n – numer kombinacji ($n = 1 \dots 2^k - 1$), k_n – liczba zmiennych w kombinacji, j – numer zmiennej ($j = 1, \dots, k$), l – pozycja zmiennej w kombinacji, r_j – współczynnik korelacji zmiennej X_j ze zmienną objaśnianą, r_{lj} ($l = 1, \dots, k_m$) – współczynniki korelacji między zmienną X_j a wszystkimi zmiennymi wchodzącymi w skład tej samej kombinacji, $2^k - 1$ – liczba wszystkich możliwych kombinacji potencjalnych zmiennych objaśniających. Wartość wskaźnika h_{nj} wzrasta jeżeli wartość współczynnika korelacji r_j wzrasta. Spadek wartości wskaźnika h_{nj} jest tym szybszy im zmienna X_j jest silniej skorelowana z pozostałymi zmiennymi objaśniającymi [8].

Wartość wskaźnika pojemności integralnej nośników informacji stanowi sumę wskaźników pojemności indywidualnej nośników informacji i dla kombinacji n wynosi:

$$H_n = \sum_{l=1}^{k_n} h_{nl} \quad (3)$$

Kombinacje zmiennych, które są słabo skorelowane między sobą, ale jednocześnie są silnie skorelowane ze zmienną objaśnianą posiadają największą wartość wskaźnika pojemności informacyjnej [7].

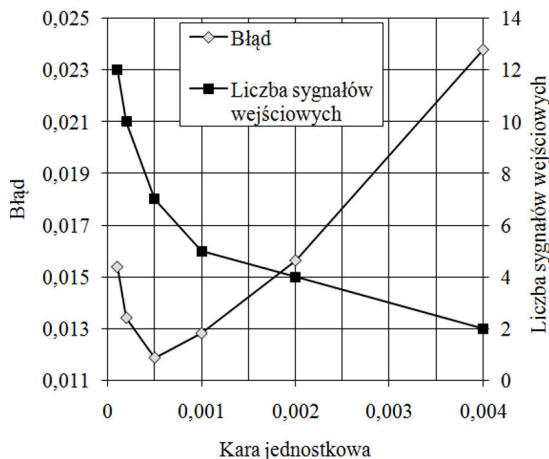
Algorytmy genetyczne oparte są na mechanizmach doboru naturalnego oraz dziedziczności i operują na populacji osobników będących potencjalnymi rozwiązaniami danego problemu. Analogicznie do warunków naturalnych osobniki podlegają procesowi reprodukcji. Mechanizmy doboru naturalnego polegają na przetrwaniu osobników najlepiej dostosowanych w danym środowisku. Mechanizmy krzyżowania i mutacji informacji genetycznej od rodziców prowadzi do sytuacji, w której kolejne pokolenia są przeciętnie coraz lepiej dostosowane do warunków środowiska [9]. Nośnikiem informacji o indywidualnych cechach osobników jest chromosom, który jest zestawem genów o określonej długości. Zbiór wielu chromosomów nazywany jest populacją, która ulega ciągłym zmianom i jest zależna od chwili t :

$$P(t) = \{v_1(t), v_2(t), \dots, v_n(t)\} \quad (4)$$

gdzie: n – liczebność populacji (liczba chromosomów), v - pojedynczy chromosom.

Chromosomy składają się z genów decydujących o dziedziczeniu jednej lub kilku cech. Ewolucja populacji chromosomów odbywa się poprzez mechanizm reprodukcji, na który składają się mechanizmy krzyżowania, mutacji i inwersji. W procesie krzyżowania geny chromosomów rodzicielskich są łączone w jeden lub wiele chromosomów potomnych. Mechanizm mutacji prowadzi do zmiany łańcucha poprzez zmianę jednego genu lub ich ciągu, inwersja z kolei odwraca fragment chromosomu. Zadaniem mutacji jest zapewnienie zmienności chromosomów i stworzenie wyjścia procedury optymalizacji z maksimów lokalnych funkcji przystosowania. Celem algorytmu genetycznego jest znalezienie takiego rozwiązania, dla którego wartość funkcji przystosowania osiąga maksimum. Algorytm pracował na populacji początkowej równej 300 osobników ze współczynnikiem krzyżowania $p_k = 0,5$, współczynnikiem mutacji $p_m = 0,1$ oraz różnymi wartościami współczynnika kary jednostkowej $\rho=0,0001$, $\rho=0,0002$, $\rho=0,0005$, $\rho=0,001$, $\rho=0,002$, $\rho=0,004$ [10]. Współczynnik kary jednostkowej jest przemnażany jest przez liczbę wybranych w każdej masce zmiennych wejściowych, a następnie dodawany do wartości błędu walidacyjnego. Do optymalizacji liczby zmiennych wejściowych zastosowano klasyczny algorytm genetyczny Hollanda. Zadaniem algorytmu genetycznego było sprawdzenie jakości sieci realizującej regresję uogólnioną dla danego zestawu zmiennych wejściowych wynikającego z mechanizmu reprodukcji populacji początkowej.

Wpływ wartości kary jednostkowej na wybór zmiennych wejściowych oraz wartość błędu AG przedstawiono na rys. 2. Zwiększenie wartości kary jednostkowej powoduje zmniejszenie liczby zmiennych wejściowych.



Rys. 2. Parametry wynikowe analizy genetycznej

Przy dużej liczbie zmiennych wejściowych zdeterminowanej małą wartością kary występuje wysoka wartość błędu algorytmu genetycznego, która następnie zaczyna maleć osiągając lokalne minimum dla wartości kary jednostkowej równej 0,0005. Dalsze zwiększanie wartości kary jednostkowej powoduje wzrost wartości błędu. Wysoką wartość błędu przy dużej liczbie zmiennych można wytłumaczyć szumem wprowadzanym przez zmienne, które mogą być w pewnych zakresach wartości ze sobą skorelowane. Z kolei duża wartość funkcji kary powoduje, że od jakości algorytmu ważniejsza staje się liczba zmiennych [11]. Do dalszej analizy wybrano zestaw 7 zmiennych wejściowych dla których wartość błędu algorytmu genetycznego jest najmniejsza.

Tabela. 4. Wyniki analiz optymalizacyjnych

Parametry wejściowe		Selekcja krokowa postępująca	Selekcja krokowa wsteczna	Metoda Hellwiga	Algorytm genetyczny
Parametry materiałowe	$R_{p0,2}$	-	-	-	-
	R_m	-	-	-	-
	A_{50}	-	-	-	-
	C	+	+	+	+
	n	+	+	+	+
Ra wałków		+	+	+	+
Parametry chropowatości blach	Ra	+	-	+	+
	Rq	-	+	-	-
	Rp	+	+		+
	Rt	-	-	+	-
Warunki smarowania		+	+	+	+
Prędkość przemieszczania, v		+	+	+	+

Wyniki przeprowadzonych analiz optymalizacyjnych mających na celu wyznaczenie sygnałów wejściowych do sieci neuronowej przedstawiono w Tabeli 4. Parametrami, które istotnie wpływają na wartość współczynnika tarcia i ich usunięcie wpłynie na pogorszenie objaśniania wartości współczynnika tarcia są parametry materiałowe C, n, parametr chropowatości wałków Ra, warunki smarowania i prędkość przemieszczania – wymienione zmienne zostały wybrane przez każdą z metod. Wśród parametrów chropowatości powierzchni blach

najistotniejszy wpływ na wartość współczynnika tarcia ma parametr Ra. Parametr Ra jest silnie skorelowany z parametrem Rq co wynika ze sposobu ich wyznaczania, dlatego w żadnej z metod obydwu z wymienionych parametrów nie zostały uznane za istotne. Parametrami, które według wszystkich metod nie mają wpływu na wartość współczynnika tarcia są R_m , $R_{p0,2}$ i A_{50} . Analizując wartości $R_{p0,2}$ (Tab. 2) można zauważyć korelację tego parametru ze współczynnikiem umocnienia, który został wytypowany jako istotny we wszystkich metodach – wzrost wartości $R_{p0,2}$ powoduje wzrost wartości C.

4 Podsumowanie

Porównując zestaw zmiennych wejściowych określony za pomocą rozpatrywanych algorytmów optymalizacji można zauważyć, że parametrami, które mają istotny wpływ na wartość współczynnika tarcia są współczynnik umocnienia, parametr Ra chropowatości wałków, warunki smarowania oraz prędkość przeciągania blachy. Na podstawie otrzymanych zestawów sygnałów wejściowych i odpowiadających im wartości współczynnik tarcia zostaną zbudowane modele regresyjne za pomocą sztucznych sieci neuronowych i oceniona zostanie ogólna skuteczność zastosowanych metod optymalizacji sygnałów wejściowych.

5 Podziękowania

Badania wykonano w ramach projektu zrealizowanego przy wsparciu udzielonym przez Islandię, Liechtenstein i Norwęgę, poprzez dofinansowanie ze środków Mechanizmu Finansowego Europejskiego Obszaru Gospodarczego oraz Norweskiego Mechanizmu Finansowego w Ramach Funduszu Stypendialnego i Szkoleniowego.

6 Literatura

- [1] Fratini L., Lo Casto S., Lo Valvo E., *A technical note on an experimental device to measure friction coefficient in sheet metal forming*, Journal of Materials Processing Technology, vol. 172, No 1, pp. 16-21, 2006.
- [2] Vallance D.W., Matlock D.K., *Applications of bending-under-tension friction test to coated sheet steels*, J. Mater. Eng. Perform., vol 1, No 5, pp. 685-693, 1992.
- [3] Nine H.D., *Draw bead forces in sheet metal forming*, Proceedings of a Symposium on Mechanics of Sheet metal Forming: Behaviour

- and Deformation Analysis, Warren, Plenum Press, pp. 179-211, 1978.
- [4] Stachowicz F., Trzepieciński T., *ANN application for determination of frictional characteristics of brass sheet metal*, Journal of Artificial Intelligence, vol. 1, No 2(24), pp. 81-90, 2004.
- [5] Trzepieciński T., *Zastosowanie regresji wielokrotnej i sieci neuronowej do modelowania zjawiska tarcia*, Zeszyty Naukowe Wyższej Szkoły Informatyki, Vol. 9, No 3, pp. 31-43, 2010.
- [6] Tadeusiewicz R., *Sieci neuronowe*, Warszawa, WNT, 1998.
- [7] Rawlings J.O., Pantula S.G., Dickey D.A., *Applied Regression Analysis: A research tool*, Second edition, New York Berlin Heidelberg, Springer-Verlag, 1998.
- [8] Barczak A., Biolik J., *Podstawy ekonometrii*, Katowice, Wyd. AE, 2003.
- [9] Michalewicz Z., *Algorytmy genetyczne + struktury danych = programy ewolucyjne*, Warszawa, WNT, 1999.
- [10] Trzepieciński T., *Genetic algorithms as an optimization tool of neural networks modelling friction phenomenon*, Zeszyty Naukowe Politechniki Rzeszowskiej - Mechanika, nr 4, z. 83, pp. 63-72, 2011.
- [11] Lula P., Tadeusiewicz R., *STATISTICA Neural Networks PL, Przewodnik problemowy*, Kraków, Statsoft, 2001

THE OPTIMIZATION METHODS IN REGRESSION PROBLEMS

Summary - One of the main tasks in regression problems are suitable selection of input variables set essentially influencing on the explained variable. The data set obtained in bending under tension test was put into analysis. The data set was consisted of technical parameters of the test and responding to them friction coefficient value. Optimization of a number of input variables was carried out using step selection, Hellwig's method and genetic algorithm.