

OPTIMALIZACJA DOŚWIADCZALNA. WARIANT JEDNOKRYTERIALNY

Marcin Bogucki

Katedra Automatykacji, Politechnika Lubelska,
ul. Nadbystrzycka 36, 20-618 Lublin, e-mail: m.bogucki@pollub.pl

Streszczenie. Praca podejmuje zagadnienia optymalizacji doświadczalnej w ujęciu proceduralnym. Przedstawione rozwiązania wykorzystują popularne schematy programy badań, a mianowicie plany czynnikowe dwuwartościowe (2^{n-p}) i ich rozwinięcie – plany kompozycyjne. W pierwszym etapie optymalizacji czyni się założenia co do pożądanych własności badanego procesu. Po ich zweryfikowaniu, przeprowadza się serię eksperymentów, których celem jest wyznaczenie poszukiwanego optimum. W każdym etapie badań stosuje się metody statystyczne i analityczne pozwalające na weryfikację poprawności podejmowanych decyzji. Dyskutowana metoda jest szczególnie przydatna w przypadku, gdy brak jest wstępnej wiedzy na temat opisu matematycznego rozważanego procesu.

Słowa kluczowe: optymalizacja, planowanie doświadczeń, Metoda Powierzchni Odpowiedzi, metoda największego spadku.

WPROWADZENIE

Obserwując współczesne trendy rozwoju metod zapewniania jakości produktów, zauważa się tendencję wpisywania działań projakościowych w szereg czynności technologicznych i organizacyjnych [4, 6, 7, 8]. Dotychczas stosowane narzędzia statystycznego nadzorowania procesów technologicznych takie jak: karty nadzoru (X/R, CUSUM, EWMA i inne) oraz pośrednie (QCPC), czy też finalne procedury nadzorowania jakości, są niekwestionowanymi metodami eliminacji zaburzeń występujących w procesach technologicznych (ang. *on-line control*) [2, 4, 6], lecz ogół wymienionych metod charakteryzuje wspólna cecha, mianowicie bierność wobec zakłóceń destabilizujących proces wytwórczy. Wynika to z tego, iż klasyczne narzędzia SPC są jedynie w stanie wykryć nieprawidłowości procesu, których konsekwencją jest pogorszenie jakości produktów, a dopiero z chwilą ich wystąpienia podejmuje się działania zaradcze (korekcyjne) mające na celu usunięcie zakłóceń specjalnych.

Zupełnie odmienne podejście do problemu zapewnienia jakości procesu technologicznego prezentują metody eksperymentalne. Tu działania projakościowe zmierzają do określenia takich warunków prowadzenia procesu x (tj. zbioru wartości zmiennych sterujących), w których wartości charakterystyk jakości J są stabilne wobec występowania ewentualnych zakłóceń losowych z . Wybór w/w warunków jest dokonywany na podstawie modelu matematycznego badanego procesu opisującego zmienność charakterystyk jakości procesu w funkcji zmiennych sterujących (nazy-


wanych inaczej: czynnikami badanymi). Problem ten sprowadza się do poszukiwania ekstremum funkcji celu wyrażającej kryteria jakości procesu. Ogólnie rzecz biorąc, procedury optymalizacyjne zmierzające do poprawy jakości procesu technologicznego są uwarunkowane kontekstem sytuacji badawczej i mogą dotyczyć:

- wyznaczenia warunków prowadzenia procesu technologicznego x (lub użytkowania produktu), dla których wartości charakterystyk jakości przyjmą wartość optymalną,
- poszukiwania takich warunków prowadzenia procesu x , dla których uzyska się korzystną redukcję wpływu zakłóceń z , przy jednoczesnym zachowaniu ustalonej lub dopuszczalnej wartości charakterystyki jakości J ,
- ustalenia warunków wytwórczych lub użytkowania produktu x , w których charakterystyka jakości J będzie stabilna ze względu na występowanie ewentualnych zakłóceń z .

Wymieniona klasyfikacja nie jest zupełna. Możliwe jest bowiem złożenie wielu kryteriów optymalizacji, by w ramach tej samej procedury badań jednocześnie wyznaczyć optymalne wartości charakterystyk jakości oraz zredukować ich rozrzut.

MATEMATYCZNE MODELOWANIE PROCESÓW TECHNOLOGICZNYCH, PODEJŚCIE DOŚWIADCZALNE

Optymalizacja procesów technologicznych związana jest przede wszystkim z praktyczną stroną wykorzystania modelu matematycznego. Wyznaczając możliwie jak najkorzystniejsze warunki jego prowadzenia (tj. określając parametry p i wartości zmiennych sterujących x i ew. zakłóceń z) ze względu na wybrane kryteria jakości J , dąży się do uzyskania statycznego modelu zależności $J(x, p, z)$ i na tej podstawie określenia współrzędnych oraz wartości poszukiwanego ekstremum (rys. 1).



Rys. 1. Klasyfikacja zmiennych procesu technologicznego

Fig. 1. General classification of variables in technological process

Identyfikując statyczny model charakterystyki jakości $J(x, p, z)$ wykorzystuje się próby doświadczalne lub/i wyniki analizy zjawisk fizycznych. Nie umniejszając znaczenia badań teo-


retycznych w tym symulacji komputerowych zjawisk fizycznych determinujących o przebiegu procesu technologicznego, rozwiązanie zadania optymalizacji na podstawie układów równań różniczkowych jest nieefektywne i nie uwzględnienia ich stochastycznego charakteru. Negatywnym aspektem tego podejścia jest to, że uzyskany układ równań opisuje jedynie przybliżony wewnętrzny stan procesu, a nie bezpośrednio - poszukiwaną zależność $J(x, p, z)$. W takiej sytuacji wymagane jest wykonanie dodatkowych prac pozwalających na ustalenie związku między zmiennymi sterującymi x , współrzędnymi stanu procesu, a wartościami charakterystyk jakości J , wraz z określeniem charakteru i oszacowaniem parametrów rozkładu zakłóceń z . Zatem, zagadnienie optymalizacji sprowadza w dużej mierze do problematyki doświadczalnej.

Postać analityczna funkcji $J(x, p, z)$ wyrażającej zmienność charakterystyki jakości może bezpośrednio wynikać z rozważań teoretycznych lub w ogólnym przypadku jest bliżej nieokreślona, stąd wstępnie postuluje się jej właściwości. Zakłada się mianowicie, że badana zależność $J(x, p, z)$ jest statyczna w sensie wartości średniej, ciągła, różniczkowalna i wyraża związek przyczynowo-skutkowy pomiędzy czynnikami badanymi x (zmiennymi sterującymi), a czynnikiem wynikowym J (tu: charakterystyką jakości). Zasadniczą rolę modelowania doświadczalnego jest ustalenie adekwatnego i możliwie jak najbardziej dokładnego przybliżenia zależności $J(x, p, z)$ na podstawie prób eksperymentalnych. Przez wzgląd na charakter pozyskiwania informacji o wartości zmiennej wynikowej, funkcję $J(x, p, z)$ nazywa się często funkcją odpowiedzi, natomiast jej obraz geometryczny – odpowiednio - powierzchnią odpowiedzi. Uzyskany w ten sposób model matematyczny pełni rolę zależności interpolacyjnej.

Modelowanie empiryczne jest złożonym procesem badawczym wymagającym zastosowania wielu pokrewnych metod obliczeniowych z zakresu analizy matematycznej i statystyki, które łącznie stanowią tzw. Metodę Powierzchni Odpowiedzi (RSM ang. Response Surface Methodology) [4, 5]. Ze względu na uniwersalny charakter badań eksperymentalnych, RSM traktuje się jako procedurę doświadczalną. W pierwszej fazie badań ustala się zakres zmienności czynników badanych x oraz postać funkcji $J(x)$ przybliżającej wybrany fragment powierzchni odpowiedzi. Na podstawie przyjętej zależności dokonuje się wyboru planu eksperymentu zapewniającego optymalną aproksymację badanej funkcji odpowiedzi ze względu na ustaloną cechę modelu np. plan typu D-optymalny (minimalizacja błędu oszacowania współczynników równania regresji) lub G-optymalny (minimalizacja błędu prognozy modelu) [9]. Następnie, w wyznaczonych punktach przestrzeni czynnikowej (tzw. układach doświadczalnych) przeprowadza się eksperyment mający na celu oszacowanie wartości powierzchni odpowiedzi. Wyniki pomiarów zmiennej zależnej oraz postać macierzy planu eksperymentu wykorzystywane są do wyznaczenia współczynników równania regresji. W końcowej fazie procedury aproksymacji, metody statystyczne weryfikują poprawność konstrukcji oraz adekwatność wybranej postaci modelu empirycznego, odnosząc je do uzyskanych wyników pomiarów.

JEDNOKRYTERIALNY WARIANT PROGRAMU BADAŃ EKSTREMALNYCH

Poniższa część artykułu zawiera propozycję doświadczalnego programu badań ekstremalnych. Uniwersalność prezentowanej metody optymalizacji przejawia się w tym, że w zależności od kontekstu prowadzonych prac dokonuje się wyboru zmiennych sterujących x (wraz z ustaleniem ich zakresu operacyjnego) oraz kryteriów jakości procesu J . Zatem, zmienne te są jedynymi argumentami wejściowymi procedury optymalizacji. Opracowana metodyka badań doświadczalnych pozwala uzyskać odpowiedź na pytanie: czy dysponując ww. zbiorem zmiennych wybranych wg preferencji badań, zasadne jest wykonanie procedury optymalizacji procesu technologicznego, a jeżeli tak, użycie jej do wyznaczenia poszukiwanego ekstremum funkcji celu.



Rys. 2. Jednokryterialny program badań optymalizacyjnych. Opracowanie własne

Fig. 2. Diagram of an experimental rule-based optimization design

Schemat jednokryterialnego, doświadczalnego programu badań optymalizacyjnych, przedstawiono na rys. 2. Zasadniczym celem procedury optymalizacji jest wyznaczenie takich warunków prowadzenia procesu technologicznego x_{opt} , dla których funkcja celu (tu: charakterystyka jakości) $J(x, p, z) \equiv J(x)$ przyjmuje wartość ekstremalną ($J(x_{opt}) = J_{min}$ lub J_{max} - zależną od kontekstu


prac badawczych). Zaproponowana metodyka badań wykorzystuje właściwości aproksymacyjne wielomianów oraz standardowe, wieloczynnikowe plany doświadczalne (dwuwartościowe i kompozycyjne). W procedurze dąży się do wyznaczenia modelu statycznego $J(x)$ adekwatnego w globalnym zakresie zmienności czynników badanych. Jeżeli dokładność aproksymacji jest niewystarczająca, wówczas poszukuje się lokalnego sąsiedztwa ekstremum metodą dynamiczną.

Każdy, zamieszczony na schemacie, etap prac lub proces decyzyjny ma nadany indeks odnoszony do poniższego komentarza. Następujące podpunkty szczegółowo dyskutują opracowaną procedurę optymalizacji jednokryterialnej.

1. Rozpoczęcie procedury optymalizacji.
2. Etap wstępny badań ma za zadanie ustalić charakterystykę jakości procesu J będącą jednocześnie funkcją celu procedury optymalizacji oraz zbiór czynników badanych x mających potencjalny wpływ na jej zmienność. W przypadku modelu empirycznego wytypowanie zmiennych niezależnych x bazuje na wynikach prób eksperymentalnych (eksperymenty przeglądowe), doświadczeniu i intuicji osoby prowadzącej badania (2a i 2b), najczęściej mającej potwierdzenie w faktach opisywanych w literaturze przedmiotu – choć nie zawsze jest to regułą. Warto bowiem wspomnieć, że model empiryczny jest adekwatny jedynie w zakresie zmienności wytypowanych czynników badanych, a co za tym idzie – fakty doświadczalne nie zawsze odnoszą się do zakresu zmienności wykorzystywanego w aktualnie prowadzonych badaniach [3]. Stąd, zmienne niezależne wchodzące w skład modelu są postulowane, a prawdziwość przyjętych założeń jest weryfikowana w kolejnych etapach prac badawczych z wykorzystaniem testów hipotez statystycznych (etapy: (8) i (9)). Ze względu na doświadczalny charakter prac badawczych, równie istotną kwestią jest określenie metody pomiaru (lub obliczania) wartości charakterystyki jakości J dla dowolnej kombinacji wartości czynników badanych x (tzw. układów doświadczalnych) wewnątrz ich globalnych przedziałów zmienności.
3. Podobnie jak we wcześniejszym etapie prac, korzystając z literatury przedmiotu badań, dokumentacji technologicznej, wyników prób eksperymentalnych oraz wiedzy eksperckiej (krok (3a) i (3b)) ustala się globalny zakres zmienności (lub inaczej: zakres działań operacyjnych) czynników badanych x wchodzących w skład zależności $J(x)$.
4. W bieżącym kroku algorytmu dokonuje się wyboru programu badań doświadczalnych (inaczej: planu eksperymentu), według którego ustalone zostaną poziomy zmienności czynników badanych (6-go) etapu procedury optymalizacji. Planując eksperyment należy wziąć pod uwagę następujące aspekty badań:
 - Postulowaną postać modelu empirycznego. Zaproponowana metodyka badań optymalizacyjnych wykorzystuje aproksymację badanej powierzchni odpowiedzi $J(x)$ wielomianami I i II stopnia z uwzględnieniem interakcji (współdziałań) dwu i wieloczynnikowych. Stąd, naturalnym wyborem wydają się tu być plany eksperymentalne wieloczynnikowe dwuwartościowe frakcyjne (ułamkowe) 2_R^{n-p} , gdzie R jest rozdzielną planu, n liczbą czynników badanych, a p -częścią ułamkową planu zupełnego. Dodatkową zaletą takiego rozwiązania jest możliwość rozszerzenia planu eksperymentu 2_R^{n-p} (tzw. jądra planu) o replikację układu centrum i tzw. układy gwiazdne, które łącznie umożliwiają aproksymację badanej powierzchni odpowiedzi wielomianem II stopnia (plan kompozycyjny). Alternatywą wydaje się być aproksymacja charakterystyk jakości $J(x)$ wielomianami wyższych stopni [5], ale z przyczyn praktycznych nie jest to zalecane. Wymagałoby to zwiększenia liczby poziomów zmienności czynników badanych, przez co konsekwentnie wzrosłaby ilość układów eksperymentalnych. Dodatkowym problemem aproksymacji powierzchni odpowiedzi wielomianami stopnia wyższego niż dwa są ich niekorzystne właściwości m. in. zjawisko “oscylacji” (liczba miejsc zerowych wzrasta wraz ze stopniem wielomianu), w tym trudności w inter-

- pretacji uzyskanych zależności funkcyjnych.
- Bieżące wyniki prac doświadczalnych. Jeżeli krok (4) algorytmu badań optymalizacyjnych poprzedza etap (12), wówczas dotychczas analizowana zależność $J(x)$ jest wprawdzie istotna statystycznie, lecz błąd dopasowania modelu jest porównywalny z tzw. błędem czystym wynikającym wyłącznie z dokładności pomiarów (komentarz: dokładnie rzecz ujmując - porównaniu podlegają wariancje a nie odchylenia standardowe wyrażające błędy). Stąd, w etapie (4) należy zmodyfikować postulowaną postać modelu regresji wykorzystując dotychczas wykonane pomiary (np. konstruując plan kompozycyjny). Alternatywnym, lecz niezalecanym rozwiązaniem byłoby zawężenie globalnego zakresu zmienności czynników badanych (etap (3)) przy jednoczesnym zachowaniu dotychczasowej postaci modelu.
5. Celem tego etapu prac jest wybór poziomów zmienności czynników badanych i wyznaczenie układów doświadczalnych (wraz z ustaleniem losowej kolejności ich realizacji) na podstawie planu eksperymentu wybranego w etapie (4-tym) procedury. Z uwagi na badanie adekwatności modelu (etap (10)) do wybranego planu eksperymentu należy dołączyć replikacje układu centrum.
 6. Realizacja programu badań. Pomiar/wyznaczenie wartości charakterystyki jakości J w warunkach określonych przez układy doświadczalne eksperymentu.
 7. Nie każdy z wytypowanych w etapie (5-tym) układów doświadczalnych może być praktycznie zrealizowany. Wynika to z tego, że wartości zmiennych sterujących procesu przyjmują skrajne wartości (komentarz: rozważany jest globalny zakres zmienności), stąd niektóre z ich kombinacji mogą okazać się być nietechnologiczne. W takim przypadku należy zawęzić globalny zakres zmienności czynników badanych – etap (3) i powtórzyć eksperyment – etapy: (4), (5), (6). W przeciwnym razie wykonywany jest kolejny (8) krok algorytmu.
 8. Wartości pomiarów charakterystyki jakości J odpowiadające poszczególnym układom doświadczalnym eksperymentu są wykorzystywane do wyznaczenia współczynników równania empirycznego $J(x)$. W dalszej kolejności przeprowadza się analizę poprawności konstrukcji modelu regresji. Weryfikacji podlegają postulaty odnoszące się do normalności rozkładu reszt modelu (różnice pomiędzy wartościami aproksymowanymi przez model a wynikami pomiarów), równości wariancji pomiarów uzyskanych w ramach każdego z układów doświadczalnych oraz braku korelacji [3]. Powyższe założenia nie są rygorystyczne, niemniej ewentualne znaczne odstępstwa negatywnie wpływają na własności aplikacyjne modelu empirycznego, w tym uniemożliwiają obiektywne przeprowadzenie testów hipotez statystycznych. Jeżeli w/w postulaty są pozytywnie zweryfikowane, wykonywany jest test porównujący ze sobą wariancję reszt z wariancją wyrażającą zmienność modelu. Niezależnej ocenie podlegają następnie wszystkie człony równania regresji. Zastosowanie ma tu wstępująca lub zstępująca procedura selekcji członów regresji [5].
 9. Test statystyczny przeprowadzany w (8) etapie badań ma na celu wykazać, że suma efektów jakie wywołują poszczególne czynniki badane różni się znacząco od zmiany wartości zmiennej zależnej spowodowanej czynnikami niekontrolowanymi. Dowodzi się tym samym, że wśród ogółu zmiennych niezależnych istnieje niepusty podzbiór czynników badanych wyjaśniający obserwowaną zmienność charakterystyki jakości. Jeżeli nie ma żadnych podstaw do odrzucenia hipotezy zakładającej, że wszystkie współczynniki równania regresji są równe zeru, prowadzenie dalszych analiz modelu empirycznego nie jest zasadne. W takim przypadku procedura badań przewiduje ponowne wykonanie (2) kroku algorytmu.
 10. Ocenę braku dopasowania modelu regresji do wycinka badanej powierzchni odpowiedzi bada się poprzez dekompozycję błędu modelu regresji na tzw. błąd czysty oraz błąd związany z niedokładnością dopasowania. Błąd czysty wynika z naturalnej zmienności czynników badanych i odnosi się wyłącznie do precyzji pomiaru. Natomiast druga składowa jest miarą

- różnic występujących pomiędzy wartością średnią pomiaru w poszczególnych układach doświadczalnych, a wartością przybliżoną przez model. Jeżeli porównanie wartości obydwu wariancji wykaże, że błąd braku dopasowania jest większy lub równy od błędu czystego, wówczas należy uznać, że dokładność dopasowania modelu regresji do wyników pomiarów zmiennej zależnej nie jest zadowalająca w odniesieniu do poziomu błędu pomiaru.
11. Negatywny wynik testu adekwatności dopasowania (etap 9) nie musi kategorycznie oznaczać, że zależność regresji jest niewłaściwa - może jedynie sugerować, że błąd pomiaru charakterystyki jakości jest relatywnie mniejszy od błędu dopasowania, co w konsekwencji oznacza, że zmiana postaci funkcji regresji (transformacja) – etap (11a) mogłaby jeszcze bardziej zminimalizować błąd aproksymacji modelu. Stąd, decyzję o tym czy zakładana postać modelu wystarczająco dobrze przybliża badaną powierzchnię odpowiedzi powinna być ostatecznie podjęta na podstawie dopuszczalnego błędu predykcji.
 12. Jeżeli pomimo prób transformacji modelu empirycznego przeprowadzonych w etapie (11a) dokładność aproksymacji (lub predykcji) modelu regresji jest niezadowalająca - możliwe są następujące warianty procedury:
 - rozszerzenie bieżącego planu eksperymentu o kolejne układy doświadczalne, tak by dopasować do badanego wycinka powierzchni odpowiedzi J wielomian wyższego stopnia (etap (4)) lub uzupełnić model $J(x)$ o dodatkowe zmienne niezależne,
 - globalny zakres zmienności czynników badanych jest zbyt szeroki, by zwiększenie stopnia wielomianu (etap (3)) lub jego ewentualna transformacja (etap (11a)) poprawiła dokładność aproksymacyjną modelu. W takiej sytuacji wyznaczenie punktu ekstremum może być obciążone dużym błędem, dlatego wymagane jest wykonanie (13-go) etapu procedury.
 13. Dotychczasowe prace mające na celu wyznaczenie modelu charakterystyki jakości w globalnym zakresie zmienności czynników badanych nie przyniosły zadowalających rezultatów. Zakres zmienności czynników badanych jest zbyt rozległy, by przybliżenie wielomianowe było adekwatne. W bieżącym kroku programu badań proponuje się jedną z dynamicznych metod poszukiwania sąsiedztwa punktu ekstremum. W ramach projektu badawczego opracowano własną implementację doświadczalnej metody największego spadku (inaczej: metody gradientowej). Schemat w/w procedury doświadczalnej przedstawiono na rys. 3, natomiast szczegółowy komentarz zamieszczono w dysertacji [1]. W wyniku prac badawczych wyznacza się równanie modelu empirycznego, adekwatnego w lokalnym zakresie zmienności czynników badanych, zawierającym punkt ekstremum.
 14. Adekwatny model empiryczny (wyznaczony w (8) lub (13) etapie badań) jest wykorzystywany do numerycznego/analytycznego wyznaczenia współrzędnych i wartości punktu ekstremum. O ile jest to zasadne proponuje się wykonanie analizy kanonicznej [9]. Rachunek ten umożliwia badanie przebiegu zmienności wielomianów drugiego stopnia funkcji wielu zmiennych. Pozwala rozstrzygnąć, czy badany obszar przestrzeni czynnikowej zawiera punkt ekstremum, a jeśli tak należy ocenić jego charakter (minimum, maksimum lub punkt siodłowy) i wyznaczyć dokładne położenie. W przeciwnym razie, wyniki analizy kanonicznej wskażą obszar przestrzeni czynnikowej, w którym należy prowadzić dalsze poszukiwania ekstremum, o ile pozwala na to zakres badań operacyjnych.
 15. Wyznaczenie przedziału predykcji punktu ekstremum. Zakończenie procedury optymalizacji jednokryterialnej.



Rys. 3. Doświadczalna implementacja metody gradientowej (największego spadku). Opracowanie własne

Fig. 3. An experimental implementation of the steepest descent method

PODSUMOWANIE

Warunkiem koniecznym do przeprowadzenia procedury optymalizacji dowolnego procesu technologicznego jest uzyskanie modelu matematycznego wiążącego jego zmienne sterujące x z przyjętymi kryteriami jakości J . W tym celu zakłada się, że poszukiwane zależności mają charakter statyczny. Warunek ten jest spełniony w przypadku stabilnych procesów technologicznych - w przeciwnym bądź razie należałoby uznać, że badany proces nie jest w stanie kontroli statystycznej i wymaga korekcji. Korzystając ze standardowych planów eksperymentalnych możliwe jest lokalne przedstawienie poszukiwanej funkcji $J(x, p, z)$ w postaci modelu regresji przy założeniu, że zmienne sterujące x oraz charakterystyki J jakości wchodzą ze sobą w związek przyczynowo-skutkowy. Prawdziwość powyższego postulatu jest formalnie weryfikowana przy użyciu testów statystycznych. Dysponując adekwatnymi modelami poszukiwanych zależności, konstruuje się sparametryzowaną, jedno- lub wielokryterialną funkcję celu. Ostatni etap procedury optymalizacji to wyznaczenie ekstremum funkcji celu J_{opt} , które odpowiada możliwie najkorzystniejszym warunkom prowadzenia procesu technologicznego x_{opt} ze względu na przyjęte kryteria jakości.

LITERATURA

1. Bogucki M.: Optymalizacja procesu wtryskiwania polietylenu. Politechnika Lubelska, Lublin 2005.
2. Montgomery D.C.: Introduction to Statistical Quality Control. John Wiley & Sons, New York, 1996.
3. Montgomery D.C.: Design and Analysis of Experiments, John Wiley & Sons, New York, 2001.
4. Montgomery D.C., Runger G.C.: Applied Statistics and Probability for Engineers. John Wiley & Sons, New York, 1999.
5. Myers R.H., Montgomery D.C.: Response Surface Methodology: Process and Product Optimization Using Designed Experiments. John Wiley & Sons, New York, 1995.
6. Płaska S., Wprowadzenie do statystycznego sterowania procesami technologicznymi. Wyd. Politechniki Lubelskiej, Lublin, 2000.
7. Płaska S., Samociuk D.: Systemy zapewniania jakości formułowane przez normy ISO serii 9000. Lublin, 1998.
8. Thomson J.R., Koronacki J.: Statystyczne sterowanie procesem. Metoda Deminga etapowej optymalizacji jakości. Akademicka Oficyna Wydawnicza PLJ, Warszawa, 1994.
9. Zieliński R.: Wybrane zagadnienia optymalizacji statystycznej: Analiza powierzchni odpowiedzi, Planowanie doświadczeń ekstremalnych. PAN, Warszawa, 1974.

EXPERIMENTAL RULE-BASED OPTIMIZATION DESIGN

Summary. The paper deals with the problem of experimental approach to rule-based optimization. The presented methods involve considerable advantages of well known experimental schemes, namely the 2^{n-p} factorial and its augmentation - the composite design. To start with, some assumptions concerning the properties of a technological process are made. If the process of the study meets the requirements, it is possible to run a series of subsequent experiments aimed at searching for the optimum. At each stage of the procedure, statistical and analytical methods are employed to validate the correctness of the taken decision. The discussed methodology is especially useful when there is no prior knowledge about the process under study.

Key words: optimization, design of experiments, Response Surface Methodology (RSM), the steepest descent method.