

Jacek STELMACH
Polwax S.A., Jasło

O WYKORZYSTANIU METOD STATYSTYCZNYCH WE WSPARCIU DECYZJI STERUJĄCYCH PROCESAMI WSADOWYMI

Streszczenie. Trafne decyzje operacyjne dotyczące poza procesami produkcyjnymi także planowania prac remontowych, decyzji zakupowych, przewidywania zmian rynkowych mogą zapewnić istotną przewagę konkurencyjną. Wsparciem takich decyzji, opartym na danych historycznych, może być wnioskowanie statystyczne. Zaawansowane metody statystyczne, pomimo empirycznych ograniczeń, mogą zapewnić wymaganą dokładność prognoz oraz moc testów statystycznych. Artykuł prezentuje propozycje wykorzystania parametrycznych i nieparametrycznych metod statystycznych oraz oszacowania mierzalnych korzyści zastosowania wnioskowania statystycznego w pewnych modelowych przedsiębiorstwach stosujących procesy wsadowe.

Słowa kluczowe: wnioskowanie statystyczne, metody nieparametryczne, procesy wsadowe.

ON APPLYING STATISTICAL METHODS IN SUPPORT OF CONTROL DECISIONS IN BATCH PROCESSES


Summary. Accurate operational decisions regarding not only production processes but also planning renovations, purchasing decisions, prediction of changes in the market can lead to a significant competitive advantage. The support of such a decision, based on historical data may be statistical inference. Advanced statistical methods can provide the required accuracy of forecasts and the power of statistical tests despite the empirical limitations. This paper presents proposals for the use of parametric and non-parametric statistical methods and estimation of quantitative advantages of statistical inference in certain models of enterprises using batch processes.

Keywords: statistical inference, non-parametrical methods, batch processes.

1. Wprowadzenie

Procesy wsadowe (okresowe, szarżowe), są często wykorzystywane w branżach: chemicznej, rafineryjnej, spożywczej czy też farmaceutycznej. Są to procesy cyklicznie powtarzane, surowce są doprowadzane, a produkty odbierane w określonych odstępach czasu. Prowadzone są one najczęściej w wyodrębnionej części instalacji technologicznej (reaktorze lub zbiorniku). W procesach wsadowych etapy procesu są możliwe do wyodrębnienia i realizowane jako zdefiniowana sekwencja zdarzeń, nazywana recepturą. Typowy proces wsadowy przedstawia poniższa sekwencja (rysunek 1).

1. Operacje przygotowawcze.
2. Napęlnienie reaktora.
3. Wymieszanie surowców i stabilizacja warunków w reaktorze.
4. Rozruch procesu wsadowego.
5. Operacje właściwe.
6. Czynności końcowe.
7. Stabilizacja warunków w reaktorze.
8. Opróżnienie reaktora.



Rys. 1. Model procesu wsadowego

Fig. 1. Batch process model

Źródło: Opracowanie własne.

Procesy wsadowe umożliwiają bardziej elastyczne wykorzystanie instalacji, łatwiejsze skalowanie produkcji i większą uniwersalność niż procesy ciągłe. Ich sterowanie jest jednak bardziej skomplikowane, a właściwości oraz jakość produktów są w większym stopniu uzależnione od jakości surowców i precyzji prowadzenia procesu. Porównanie najważniejszych cech procesów ciągłych i wsadowych przedstawia tabela 1.

Tabela 1

Najważniejsze cechy procesów ciągłych i wsadowych

Lp.	Najważniejsze cechy procesów	
	procesy wsadowe (okresowe)	procesy ciągłe
1.	Surowce wprowadza się i produkty odprowadza porcjami (szarżami).	Surowce wprowadza się i produkty odprowadza w sposób ciągły.
2.	W czasie napełniania i opróżniania aparatury proces ulega przerwaniu (zatrzymaniu).	Proces toczy się jednocześnie z wprowadzaniem surowców i odprowadzaniem produktów.
3.	Operacje i procesy jednostkowe przebiegają kolejno w jednym aparacie.	Wszystkie stadia procesu przebiegają w różnych częściach aparatu lub w różnych aparatach.
4.	Właściwości procesu (zmienne procesowe) zmieniają się w czasie.	Właściwości procesu pozostają stałe.
5.	Mniejsza wielkość produkcji (heurystycznie pomiędzy kilkaset a kilkanaście tysięcy ton rocznie).	Duże wolumeny produkcyjne.
6.	Zmienne wydajności produkcji.	Stać lub wolnozmienna wydajność produkcji.
7.	Uniwersalność instalacji produkcyjnych.	Instalacje przeznaczone do procesu technologicznego.
8.	Wymaganie bardzo wysokiej jakości produktu (na przykład przemysł farmaceutyczny).	Umiarkowane wymagania jakościowe.

Źródło: [8; 7].

2. Sterowanie w procesach wsadowych

Sterowanie procesami wsadowymi to szeroki zakres działań obejmujących między innymi (Barker i Ravtani, 2005):

- kontrolę jakości,
- planowanie produkcji,
- nadzorowanie procesu,
- reagowanie na odchylenia,
- śledzenie kosztów procesu.

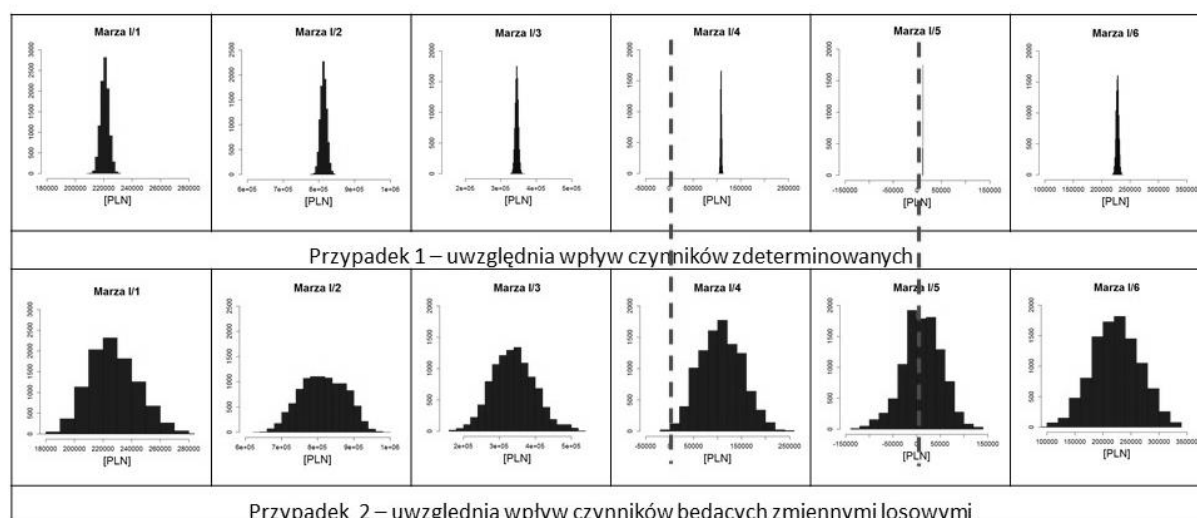
W tychże procesach niezbędna jest dynamiczna rekonfiguracja sterowania związana z aktualnym stanem procesu i planowanymi jego modyfikacjami. Dodatkowo badanie produktów trwa zwykle na tyle długo, że w tym czasie inicjowane są już kolejne procesy, co powoduje, że informacja o niestabilności procesu i działania korygujące są opóźnione. Tak złożone sterowanie wymaga najczęściej utworzenia modelu samego procesu, umożliwiającego wcześniejsze przygotowanie scenariuszy działania oraz optymalizację ekonomiczno-jakościową planowanego procesu (lub ciągu procesów) wsadowego. Umożliwi to pełne wykorzystanie zalet procesów wsadowych: uniwersalność, szybkie dostosowanie się do zmian otoczenia, skalowanie produkcji. Można zauważyć podobieństwo pomiędzy procesami wsadowymi i ekonometrią. W obu przypadkach dane nie pochodzą z kontrolowanego eksperymentu, ale są gromadzone z obserwacji rzeczywistości.

W przeciwieństwie do procesów ciągłych, dla których opracowano i opublikowano wiele metod sterowania zapewniających maksymalizację przyjętych funkcji celu, techniki sterowania procesów wsadowych nie są tak powszechne. Po części jest to wynikiem wykorzystania w sterowaniu metod heurystycznych i zdobytego przez obsługę doświadczenia, po części rezultatem trudności w matematycznym sformalizowaniu takich metod. Dodatkowym problemem jest duża – jak na standardy przemysłowe – liczba zmiennych). Przykładem może być proces destylacji atmosferycznej (AlGhazzawi i Lennox, 2009), w którym zidentyfikowano: 30 wielkości pomiarowych, 17 zmiennych sterujących oraz 6 zmiennych zakłócających. Budowa modelu analitycznego, a nawet wykorzystanie typowych metod SPC są w takim przypadku bardzo trudne. Rozwiązaniem może być wykorzystanie zaawansowanych metod statystycznych oraz technik Data Mining. Abel i in. (2000) zaznaczają, że sterowanie wykorzystujące między innymi analizę głównych składowych (wyznaczenie optymalnych trajektorii temperatury reaktora i prędkości przepływu substancji) przyniosło skrócenie czasu trwania procesu o 28%. Marjanovic i in. (2006) natomiast podkreślają znaczenie trafnego prognozowania czasu trwania szarży uwodorniania surowca. Dostępne metody są jednak bardzo kosztowne, wchodzi zwykle w skład zaawansowanych systemów sterowania, wymagają ogromnej ilości danych (a więc ogromnej liczby czujników wielkości fizycznych i rozbudowanego systemu dystrybucji sygnałów) i nie są w Polsce powszechne w mniejszych zakładach produkcyjnych. Nie oznacza to oczywiście, że wykorzystanie metod statystycznych w polskich przedsiębiorstwach nie jest celowe i możliwe. Zaprezentowana przez autora (Stelmach, 2014) symulacja Monte Carlo pierwszych marż 6 produktów chemicznych, uwzględniająca zidentyfikowaną losowość czynników mających wpływ na prowadzenie procesów, pozwala na przykład na oszacowanie ryzyka wystąpienia strat (marży ujemnej) i umożliwia podjęcie decyzji korygujących (rysunek 2, linią przerywaną zaznaczono zerową marżę).

Istotnymi przesłankami ograniczającymi stosowanie metod statystycznych nadal są:

- brak prawidłowo przeszkolonych operatorów i służb wspierających,
- brak odpowiednich aplikacji komputerowych,
- permanentne modyfikacje i udoskonalanie procesów,
- nieoptymalny sposób dostrajania systemów sterowania oraz mało dokładne modele procesów,
- ryzyko nieuwzględniane w teoretycznych opracowaniach – braku zaufania do skomplikowanych systemów wspierających, w których informacja przekazywana obsłudze zbyt często odbiega od rzeczywistości.

W rezultacie w podejmowaniu decyzji wykorzystywane jest nadal podejście heurystyczne oraz doświadczenie menedżerów i operatorów procesu, co stwarza z jednej strony ryzyko podejmowania nieoptymalnych decyzji, z drugiej zaś powoduje zbytne uzależnienie się od wiedzy wybranej grupy pracowników.



Rys. 2. Symulacja zmienności marż pierwszych, wynikająca z uwzględnienia czynników losowych
 Fig. 2. Simulation of margin variation taking into account random predictors

Źródło: Opracowanie własne.

Przeprowadzona w 2014 roku w pewnym przedsiębiorstwie burza mózgów, z udziałem przedstawicieli: kontrolingu, handlu i marketingu, badań i rozwoju, planowania produkcji, kontroli jakości oraz zarządu, pozwoliła na identyfikację zagadnień, w przypadku których zauważono potrzebę wsparcia decyzji operacyjnych przy wykorzystaniu odpowiednich metod statystycznych. W tabeli 2 przedstawiono te zagadnienia wraz z podaniem proponowanych metod statystycznych.

Tabela 2
 Zidentyfikowane zagadnienia, których wsparcie metodami statystycznymi może być celowe

Lp.	Zagadnienie	Metody statystyczne
1.	Prognoza krótkoterminowa cen surowców podstawowych.	Modele regresyjne.
2.	Prognoza krótkoterminowa cen produktów podstawowych.	Modele regresyjne.
3.	Prognoza krótkoterminowa cen produktów dodatkowych.	Modele regresyjne.
4.	Prognoza długoterminowa cen surowców podstawowych.	Modele regresyjne.
5.	Prognoza długoterminowa cen produktów podstawowych.	Modele regresyjne.
6.	Prognoza wydajności szarży.	Modele regresyjne.
7.	Prognoza jakości produktów szarży.	Modele regresyjne.
8.	Prognoza krótkoterminowa wyniku przedsiębiorstwa.	Modele regresyjne.
9.	Prognoza długoterminowa wyniku przedsiębiorstwa.	Modele regresyjne.
10.	Prognozy, w których informacje starsze mają mniejsze znaczenie niż informacje nowsze.	Modele regresyjne, regresja ważona.
11.	Identyfikacja zmian jakości surowców.	Weryfikacja hipotezy o równości populacji.
12.	Budowa formuł cenowych.	Modele regresyjne.
13.	Identyfikacja zmian parametrów instalacji.	Weryfikacja hipotezy o równości populacji.
14.	Identyfikacja zmian kosztów procesu.	Weryfikacja hipotezy o równości populacji.
15.	Identyfikacja wpływu przeprowadzonych działań marketingowych.	Weryfikacja hipotezy o równości populacji.

cd. tabeli 2

17.	Identyfikacja starzenia się modeli.	Weryfikacja hipotezy o równości populacji.
18.	Stwierdzenie zależności (związku) pomiędzy zjawiskami (np. akcja promocyjna – wielkość sprzedaży, temperatura zewnętrzna – koszty zmienne, ceny sprzedaży produktów – notowania substytutów).	Weryfikacja hipotezy o korelacji pomiędzy zmiennymi.
19.	Stwierdzenie braku związku pomiędzy zjawiskami (np. wielkość sprzedaży różnych grup produktowych, czas transportu kolejowego – pora roku, wydajność procesu – pora roku).	Weryfikacja hipotezy o korelacji pomiędzy zmiennymi.
20.	Siła wpływu wybranych czynników na wybrane mierniki (np. wielkość remontów – koszty awarii, koszty modernizacji – koszty produkcji, jakość surowca – jakość produktu).	Modele regresyjne.
21.	Modelowanie zjawisk i procesów (cykl konwersji gotówki, model procesu wsadowego, kształtowanie się zapasów, rentowność).	Modele regresyjne.
22.	Prognoza cen surowców i energii na podstawie niepełnych i różnych informacji w różnych okresach.	Modele regresyjne zagregowane, regresja nieparametryczna.
23.	Określenie opóźnienia (czasu reakcji) pomiędzy działaniem (np. promocje, modernizacje, zmiany organizacyjne) a rezultatem tego działania.	Weryfikacja hipotezy o korelacji pomiędzy zmiennymi (opóźnionymi).

Źródło: Opracowanie własne.

3. Wykorzystanie metod statystycznych

Analizując metody przedstawione w tabeli 2, można dojść do wniosku, że największe znaczenie we wsparciu decyzji sterujących powinny mieć metody statystyczne służące do:

1. budowy modeli regresyjnych, zarówno do tworzenia prognoz, jak i określania siły wpływu zmiennych niezależnych na zmienną zależną, także zagregowanych,
2. weryfikacji hipotez statystycznych: porównywania dwóch populacji wielowymiarowych oraz istnienia korelacji pomiędzy zmiennymi.

Najbardziej popularne i najczęściej wykorzystywane metody parametryczne wymagają zwykle spełnienia licznych wymagań, często bardzo niewygodnych, szczególnie w rzeczywistych warunkach przemysłowych. Budując modele regresyjne za pomocą Metody Najmniejszych Kwadratów, należy spełnić założenia *Gaussa-Markowa*, między innymi:

1. składnik losowy $\boldsymbol{\varepsilon}$ modelu jest sferyczny, to znaczy: $E(\boldsymbol{\varepsilon}\boldsymbol{\varepsilon}^T) = \delta^2\mathbf{I}$, co oznacza, że:
 - a) wariancja składnika losowego jest stała (składnik losowy jest homoskedastyczny),
 - b) nie występuje autokorelacja składnika losowego,
2. składnik losowy $\boldsymbol{\varepsilon}$ ma rozkład normalny,
3. liczba obserwacji jest co najmniej równa liczbie estymowanych parametrów modelu i nie występuje współliniowość zmiennych objaśniających,
4. model jest niezmienniczy ze względu na obserwacje, uchylenie założenia o stabilności relacji prowadzi do modeli o parametrach zmiennych w czasie [9; 14].

Rezygnacja ze spełnienia takich założeń może prowadzić do znacznego pogorszenia jakości modeli regresyjnych i mniejszej dokładności prognoz. Generalizując, można stwierdzić wykorzystanie parametrycznych metod statystycznych wymaga weryfikacji spełnienia odpowiednich, powiązanych z tymi metodami założeń. Zaniechanie tego etapu może prowadzić do błędnych wyników – i do wspomnianego w rozdziale drugim braku zaufania do samych metod statystycznych. Istnienie w rzeczywistych warunkach obserwacji odstających (zakłóceń, pomyłek) oraz często występująca niewielka liczba dostępnych obserwacji wielowymiarowych utrudnia weryfikację odpowiednich założeń, co może spowodować niezamierzone, lecz nieuprawnione zastosowanie metod parametrycznych. Bardzo wiele cennych uwag o najczęstszych praktycznych błędach prezentuje Sokołowski [12].

Rozwiązaniem może być wykorzystanie statystycznych metod nieparametrycznych. Regresyjne metody nieparametryczne mogą być bardziej elastyczne, chociaż opis matematyczny modelu parametrycznego jest zwykle prostszy i pozwala na interpretację parametrów tegoż modelu. Na uwagę zasługuje dokonana przez Hastiego i in. (2008) próba podsumowania cech nieparametrycznych metod regresyjnych, umieszczona w tabeli 3. Z kolei testy nieparametryczne można uważać za bardziej realistyczne, uniwersalne i pewne [4]. Należy zauważyć, że – szczególnie w przypadkach wielowymiarowych – weryfikacja niezbędnych dla testów parametrycznych założeń może być bardzo złożona i trudna, a w związku z tym ich przyjęcie może być podejmowane bez wystarczającego uzasadnienia.

Tabela 3

Podsumowanie wybranych nieparametrycznych metod regresyjnych

Charakterystyka metody	Sieci neuronowe	SVM	Drzewa	MARS	k-NN
Wykorzystanie danych różnych typów	-	-	+	+	-
Mała wrażliwość na obserwacje brakujące	-	-	+	+	+
Odporność na obserwacje odstające	-	-	+	-	+
Niewrażliwość na transformacje zmiennych	-	-	+	-	-
Złożoność obliczeniowa (dla dużych prób)	-	-	+	+	-
Mała wrażliwość na zmienne nieistotne	-	-	+	+	-
Zdolność do wyodrębnienia liniowych kombinacji cech	+	+	-	-	+/-
Możliwość interpretacji parametrów modelu	-	-	+/-	+	-
Jakość prognoz	+	+	-	+/-	+

Źródło: Opracowanie własne na podstawie [6].

Na szczególną uwagę zasługują mało znane, choć coraz częściej wykorzystywane testy permutacyjne. Testy te wymagają w zasadzie spełnienia jednego założenia. Wymagane jest, aby obserwacje w próbie były niezależne i pochodziły z tej samej populacji. Ponadto w testach tych można wykorzystywać dowolne, także niestablicowane statystyki testowe, co w praktyce znacznie rozszerza ich możliwości. Odiase i Ogbonmwan (2007) podkreślają, że w wielu przypadkach testy permutacyjne są jedyną metodą pozwalającą w sposób wiarygodny testować hipotezy statystyczne. Good (2005) natomiast twierdzi, że w przypadku prób o małych liczebnościach testy permutacyjne mają największą moc. Przeprowadzone przez autora badania symulacyjne wskazują na widoczną przewagę w stosowaniu w rzeczywistych warunkach przemysłowych nieparametrycznych metod statystycznych. Przyjmijmy dwa modele przedsiębiorstw wykorzystujących procesy wsadowe, różniące się rentowością, nowoczesnością instalacji i strukturą kosztów operacyjnych:

1. **Przedsiębiorstwo 1.** Podstawowe informacje finansowe:

- przychody ze sprzedaży 300 000 [tys. PLN],
- zysk na sprzedaży 20 000 [tys. PLN].

2. **Przedsiębiorstwo 2.** Podstawowe informacje finansowe:

- przychody ze sprzedaży 300 000 [tys. PLN],
- zysk na sprzedaży 60 000 [tys. PLN].

Krótkookresowy rachunek wyników z funkcjonalnym ujęciem kosztów obu modelowych przedsiębiorstw przedstawiono w tabeli 4.

Tabela 4

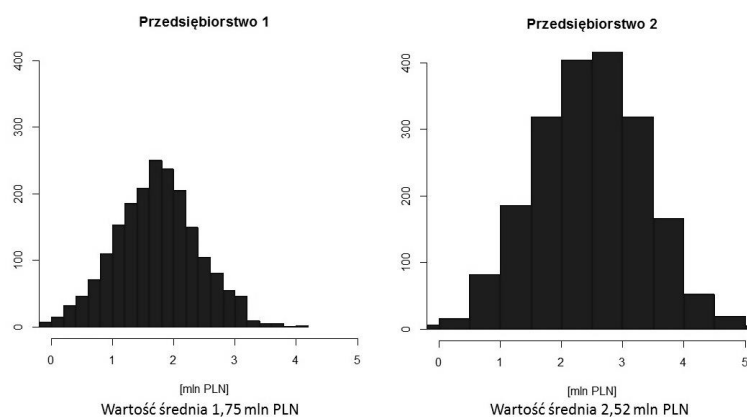
Krótkookresowy rachunek wyników modelowych przedsiębiorstw

Wyszczególnienie	Przedsiębiorstwo 1 [PLN]	Przedsiębiorstwo 2 [PLN]
Przychody ze sprzedaży	300 000 000	300 000 000
Koszty sprzedanych wyrobów	250 000 000	200 000 000
koszty wydziałowe	30 000 000	50 000 000
pozostałe koszty stałe	10 000 000	20 000 000
koszty surowców i materiałów	160 000 000	110 000 000
koszty energii	30 000 000	10 000 000
pozostałe koszty zmienne	20 000 000	10 000 000
Koszty ogólnego zarządu	15 000 000	30 000 000
Koszty sprzedaży	10 000 000	15 000 000
Koszty zakupu	5 000 000	5 000 000
Zysk na sprzedaży	20 000 000	60 000 000

Źródło: Opracowanie własne.

Przyjęto w modelu, że **Przedsiębiorstwo 2** zajmuje się produkcją nowocześniejszych wyrobów, których wytworzenie wymaga mniejszej energochłonności, wysokość nakładów utrzymaniowych i remontów nowoczesnego sprzętu oraz oprzyrządowania jest zaś znacznie wyższa. Nowoczesność wyrobów ma też bezpośrednie odzwierciedlenie w wyższych nakładach na badania i rozwój, ujętych w kosztach ogólnych zarządu, wyższych kosztach osobowych oraz w wyższej osiąganym marży, czego efektem jest większy zysk na sprzedaży,

będący wynikiem większej wartości dodanej w procesie produkcyjnym. Przyjmując dodatkowe założenia prawdopodobieństwa wsparcia decyzji operacyjnych nieparametrycznymi metodami statystycznymi, przy założeniu rozkładu normalnego ilościowych korzyści wynikających z zastosowania tych metod, przeprowadzono symulację Monte Carlo zmian zysków na sprzedaży obu modelowych przedsiębiorstw. Wyniki zaprezentowano na rysunku 3. Pomimo bezwzględnego wyższego przyrostu w **Przedsiębiorstwie 2**, wzrost względny był blisko dwukrotnie (9%) wyższy w **Przedsiębiorstwie 1** przy podobnych prawdopodobieństwach poniesienia strat w wyniku wykorzystania wsparcia metodami statystycznymi – na poziomie 0,40%.



Rys. 3. Symulacja zmienności marż pierwszych, wynikająca z uwzględnienia czynników losowych
Fig. 3. Simulation of margin variation taking into account random predictors

Źródło: Opracowanie własne.

4. Podsumowanie

Zastosowanie metod statystycznych we wsparciu decyzji sterujących może prowadzić do uzyskania bądź powiększenia przewagi konkurencyjnej. Wymaga to jednak, poza oczywistym wsparciem ze strony kierownictwa, właściwego doboru stosowanych metod, uwzględniających właściwości wykorzystywanych danych i wynikające z tego powodu ograniczenia. Jest to szczególnie istotne w sterowaniu procesami wsadowymi, opisywanymi najczęściej nieliniowymi, wielowymiarowymi zależnościami, w przypadku których dysponuje się ponadto ograniczoną liczbą obserwacji. Bardzo często znacznie lepsze efekty można osiągnąć, wykorzystując metody nieparametryczne, w tym testy permutacyjne. Chociaż metody te są mniej znane, wyniki ich wykorzystania mogą prowadzić do większej dokładności wnioskowania statystycznego, a więc do trafniejszych decyzji. Właściwe stosowanie wnioskowania statystycznego pozwala, bez poniesienia większych nakładów ekonomicznych, na osiągnięcie wymiernych korzyści przy bardzo minimalnym poziomie ryzyka.

Bibliografia

1. Abel O., Helbig A., Matquardt W., Zwisk H., Daszkowski T.: Productivity optimization of an industrial semi-batch polymerization reactor under safety constraints, *Journal of Process Control*, vol. 10, 2000, p. 351-362.
2. AlGhazzawi A., Lennox B.: Model predictive control monitoring using multivariate statistics, *Journal of Process Control*, vol. 19, 2009, p. 314-327.
3. Barker M., Rawtani J.: *Practical batch process management*, Elsevier, Oxford 2005.
4. Domański C., Pruska K.: *Nieklasyczne metody statystyczne*, PWN, Warszawa 2000.
5. Good P. I.: *Resampling Methods. A Practical Guide to Data Analysis*, Birkhauser, Boston 2005.
6. Hastie T., Tibshirani R., Friedman J.: *The Elements of Statistical Learning. Data Mining, Inference, and Prediction*, Springer Science+Business Media B. V., New York 2008.
7. Korovessi E., Linninger A.: *Batch processes*, Taylor@Francis Group, Boca Raton 2006.
8. Kępiński J.: *Technologia chemiczna nieorganiczna*, PWN, Warszawa 1984.
9. Maddala G.S.: *Ekonometria*, Wydawnictwo Naukowe PWN, Warszawa 2008.
10. Marjanovic O., Lennox B., Sandoz D., Smith K., Milton C.: Real-time monitoring of an industrial batch process, *Science Direct*, vol. 30, 2006, p. 1476-1481.
11. Odiase J.I., Ogbonmwan S.M.: Correlation Analysis: Exact Permutation Paradigm, *Matiemaczkii Wiesnik*, vol. 59, 2007, p. 161-170.
12. Sokołowski A.: *O niewłaściwym stosowaniu metod statystycznych*, StatSoft Polska, 2004.
13. Stelmach J.: The use of Monte Carlo simulation to support management decisions of industrial batch processes. *Proceedings of the 8th Professor Aleksander Zelias International Conference on Modelling and Forecasting of Socio-Economic Phenomena in Zakopane 2014*, p. 185-193.
14. Welfe A.: *Ekonometria*, PWN, Warszawa 2003.

Abstract

Applying statistical methods allows to increase competitive advantage of the company. This requires, however, the use of appropriate methods. Better known, parametric methods needs to fulfill embarrassing assumptions, often impossible to implement in industrial environment. Especially in batch processes, difficult to control and with limited available samples. Then non-parametric methods can give better results in support of control decisions in such processes. Identified needs are connected with regression models and verifying the hypotheses with certain statistical tests. With Monte Carlo simulation, there were estimated measurable advantages of using statistical inference that are visible regardless of the technological level of the enterprise.