

Marcin Miczka

Instytut Metalurgii Żelaza im. Stanisława Staszica
w Gliwicach

Zarządzanie ryzykiem w systemach intelligent manufacturing z zastosowaniem analizy bayesowskiej

Streszczenie

Głównym celem artykułu jest zaprezentowanie zarysu nowoczesnej metodyki prognozowania i analizy ryzyka procesu produkcyjnego oraz cech charakterystycznych pomiarów dokonywanych podczas trwania procesu hutniczego. Metodyka oparta jest na reprezentacji systemu dynamicznego w przestrzeni stanu oraz na wnioskowaniu bayesowskim. Pozwala to przede wszystkim uchylić założenie o stałości szacowanych parametrów, prowadzić analizę dla całości rozkładu statystycznego oraz uwzględnić tzw. informację *a priori*, czyli pochodzącą spoza zbioru danych. Praca ma charakter przeglądowy i stanowi podstawę do dalszych badań, które dotyczą wdrożenia koncepcji *intelligent manufacturing* w polskich przedsiębiorstwach przemysłowych.

Słowa kluczowe: proces produkcyjny, ryzyko, prognozowanie, hutnictwo, temperatura, reprezentacja przestrzeni stanu, Bayes.

1. Wprowadzenie

Artykuł ma na celu zaprezentowanie zarysu nowoczesnej metodyki prognozowania i analizy ryzyka procesu produkcyjnego oraz cech charakterystycznych pomiarów dokonywanych podczas trwania procesu hutniczego. Jest podstawą do

prowadzenia dalszych badań w wybranej dziedzinie. Autorski wkład to przede wszystkim zaprezentowanie zagadnienia *intelligent manufacturing* w szerszym kontekście, co stanowi o indywidualnym charakterze opracowania. Istotne jest również uzasadnienie stosowania metod statystycznych do sterowania procesem hutniczym, co nie zawsze jest jasne dla przedsiębiorców i inżynierów metalurgów. Artykuł służy także uporządkowaniu wiedzy w wybranej dziedzinie.

W gospodarce zachodzą istotne przemiany strukturalne, które nazywane są już trzecią rewolucją przemysłową. Ma ona doprowadzić do przywrócenia niektórych rodzajów przemysłu, a co za tym idzie – miejsc pracy, w wysoko rozwiniętych gospodarkach europejskich. Masowe wytwarzanie podobnych do siebie produktów ma zostać zastąpione bardziej zindywidualizowaną produkcją (*mass customisation*). Ponieważ przetwórstwo przemysłowe staje się w coraz większym stopniu z informatyzowane, w przedsiębiorstwach gromadzone są duże zbiory danych. Wiedza w nich zawarta oraz umiejętne jej wykorzystanie stają się podstawami do osiągnięcia wysokich wskaźników wzrostu gospodarczego oraz wysokiej pozycji rynkowej. Powstała idea przedsiębiorstwa inteligentnego, które charakteryzuje się również tym, że ludzie nie pracują w nim w ciężkich warunkach. Wiąże się to z wyeliminowaniem człowieka z niektórych procesów decyzyjnych, które zostaną przejęte przez systemy informatyczno-automatyczne, a to wiąże się z powstaniem nowych rodzajów ryzyka.

W artykule rozwinięto przedstawione powyżej problemy oraz pokazano przykłady zastosowań metod statystycznych w dziedzinie *intelligent manufacturing* dla procesów hutniczych. Badania wstępne zostały przeprowadzone w jednej z polskich stalowni. Są one podstawą do opracowania rozwiązań dla innych etapów hutniczego procesu produkcyjnego.

Przedstawiono podstawy metodyczne prognozowania i analizy ryzyka procesu produkcyjnego w hutnictwie żelaza i stali, ze szczególnym uwzględnieniem prognozowania temperatury w różnych fazach procesu stalowniczego. Metodyka oparta jest na reprezentacji systemu dynamicznego w przestrzeni stanu oraz na wnioskowaniu bayesowskim. Pozwala to przede wszystkim uchylić założenie o stałości szacowanych parametrów, prowadzić analizę dla całości rozkładu statystycznego oraz uwzględnić tzw. informację *a priori*, czyli pochodzącą spoza zbioru danych. Praca ma charakter przeglądowy i stanowi podstawę do dalszych badań, których ostatecznym celem jest wdrożenie systemu prognozowania i analizy ryzyka w jednej z polskich stalowni, a następnie opracowanie podobnych rozwiązań dla innych faz procesu hutniczego.

W artykule określono cechy charakterystyczne wybranych parametrów mierzonych podczas hutniczego procesu produkcyjnego oraz wskazano kierunki rozwoju metodyki pozwalającej takie cechy uwzględnić.

2. Przemiany strukturalne w systemie gospodarczym

Długoterminowy rozwój gospodarczy opisywany jest obecnie przez modele ekonometryczne wywodzące się z endogenicznej teorii wzrostu [Makroekonometryczny... 2009]. P.M. Romer w 1994 r. wyszczególnił w rozwoju tej teorii podejście neoschumpeterowskie [Romer 1994, Miczka 2008], w którym wzrost nie jest generowany przez akumulację kapitału rzeczowego czy ludzkiego, ale przez wprowadzanie nowych produktów, procesów produkcji oraz metod organizacji działalności gospodarczej. W wyniku tego zachodzą przemiany strukturalne, które wiążą się z problemem bezrobocia. Proces likwidowania i powstawania nowych miejsc pracy jest wynikiem działania zjawiska twórczej destrukcji [Miczka 2013]. Transformacja współczesnej gospodarki w kierunku gospodarki opartej na wiedzy i innowacji, która przeciwstawiana jest dominującej od XIX w. gospodarce przemysłowej, wiąże się więc z koniecznością powstania nowego rodzaju przedsiębiorstw oraz pojawienia się nowego rodzaju pracowników [Barczak 2002, Miczka 2014]. Praca charakterystyczna dla gospodarki przemysłowej przestaje być na tyle efektywna, żeby dzięki niej można było zaspokoić potrzeby powstające w najbardziej rozwiniętych gospodarkach¹.

W skali świata obserwowane jest przemieszczanie masowej produkcji wyrobów niskiej i średniej jakości z rejonu Atlantyku w rejon Pacyfiku, gdzie koszty pracy były jak dotąd niższe. Ceny dóbr tam produkowanych są również niższe od cen oferowanych w Europie, co powoduje większą konkurencyjność przedsiębiorstw. W związku z tym, aby osiągnąć przewagę konkurencyjną, proces reindustrializacji w Europie powinien wiązać się z rozwinięciem bardzo precyzyjnych procesów technologicznych pozwalających na produkcję wyrobów wysokiej jakości. Produkcja precyzyjna to utrzymywanie parametrów procesów technologicznych blisko granic, których przekroczenie wiąże się ze stratami biznesowymi, a zatem prawdopodobieństwo wystąpienia takich strat jest większe, co wymaga zaawansowanej analizy tego rodzaju ryzyka.

3. Zmiany w metodyce prowadzenia badań naukowych

Oprócz przemian w systemach gospodarczych można również zaobserwować przemiany w metodyce prowadzenia badań naukowych. Zgodnie z podejściem zaprezentowanym w „Harvard Business Review” wyróżnia się cztery paradygmaty prowadzenia takich badań:

¹ Wraz ze wzrostem dochodów pracowników potrzeby zmieniają się w kierunku potrzeb wyższego rzędu (dóbr i usług luksusowych).

- 1) eksperymentowanie (*experimentation*),
- 2) teorię (*theory*),
- 3) symulacje komputerowe (*computation simulation*),
- 4) analizę dużych zbiorów danych (*data mining, data analysis*), inaczej zastosowanie wszystkich znanych metod statystycznej analizy danych w celu odkrywania zależności istniejących w systemach przyrodniczych, technicznych czy gospodarczych.

W związku z tym, że w przedsiębiorstwach gromadzone są obecnie duże zbiory danych, które lepiej opisują procesy technologiczne niż eksperymenty prowadzone w laboratoriach, rozwój metodyki prowadzenia badań naukowych wiąże się z opracowywaniem metod ich analizy, a w szczególności statystycznej analizy danych. Istotne jest również to, że ciężar badań naukowych przenoszony jest z odkrywania nowych zależności na bardziej precyzyjny pomiar zależności już znanych, z uwzględnieniem czynników charakterystycznych dla danego miejsca, co pozwala lepiej zarządzać procesami produkcyjnymi.

4. Zarządzanie ryzykiem

Zarządzanie ryzykiem kojarzone jest najczęściej z naukami ekonomicznymi. Istnieje również dziedzina wiedzy, której przedmiotem jest ryzyko istniejące w systemach technicznych – jest to część ryzyka operacyjnego przedsiębiorstwa przemysłowego. Zwykle w systemach takich procesy techniczne i technologiczne są w wysokim stopniu kontrolowane. W związku z tym szczególnym przedmiotem badań w tej dziedzinie są zdarzenia w przemyśle przetwórczym charakteryzujące się niskim prawdopodobieństwem zajścia i poważnymi konsekwencjami, które obejmują wszelkie nieplanowane zdarzenia lub wypadki powodujące znaczące straty biznesowe, w tym poważne zakłócenia gospodarcze, które wynikają z zagrożeń naturalnych, poważnych awarii czy zakłóceń w łańcuchu dostaw. Zdarzenia te mogą mieć naturalne źródła lub wynikać ze złego funkcjonowania systemu zarządzania oraz mogą być związane z poważniejszymi, zewnętrznymi czynnikami ryzyka, takimi jak zmiany klimatu lub nagłe zmiany w technologii i regulacjach prawnych. Ponieważ tego rodzaju zdarzenia mogą mieć poważne i długoterminowe konsekwencje mogą być rozpatrywane w kontekście długofalowego, zrównoważonego rozwoju.

5. Intelligent manufacturing

Analiza ilościowych aspektów procesu produkcyjnego jest klasycznym zagadnieniem z dziedziny analizy ekonometrycznej, która była do tej pory wykorzystywana przez pracowników przedsiębiorstw we wspomaganie procesów podejmowania decyzji. W ostatnich latach funkcję tę przejmują *intelligent manufacturing systems*. Ich konstrukcja oraz mechanizmy działania w coraz większym stopniu decydują o efektywności ekonomicznej działalności gospodarczej (wydajność czy jakość produkcji) oraz możliwości szybkiego dostosowywania działalności przedsiębiorstw do zmian w otoczeniu gospodarczym, czego przykładem może być przemysł samochodowy. Systemy takie są również istotne z punktu widzenia bezpieczeństwa, co przejawia się w stosowaniu systemów wczesnego ostrzegania np. w przemyśle chemicznym.

W artykule skoncentrowano się na zastosowaniach opisanej metodyki w przemyśle hutniczym. *Intelligent manufacturing* to kluczowy kierunek rozwoju badań stosowanych w hutnictwie, wyróżniony w dokumencie *European Steel Technology Platform (ESTEP)* z maja 2013 r. [*Strategic...* 2013]. Polega na budowaniu zintegrowanych systemów sterowania procesami produkcyjnymi, które obejmują aspekty techniczne i technologiczne z dodatkiem inteligentnego reagowania, opartego na stosowaniu np. modelowania, metod optymalizacji i symulacji, wiedzy eksperckiej oraz metod sztucznej inteligencji.

Jednym z wyróżnionych obszarów w dziedzinie *intelligent manufacturing* jest uczenie się maszyn (*machine learning*), którego głównym celem jest praktyczne zastosowanie dokonań w dziedzinie sztucznej inteligencji do stworzenia automatycznego systemu potrafiącego doskonalić się za pomocą zgromadzonego doświadczenia (czyli danych) i nabywania na tej podstawie nowej wiedzy. Ostatnio znaczącą rolę w dziedzinie sztucznej inteligencji, zwłaszcza w uczeniu się maszyn, odgrywają metody oparte na twierdzeniu sformułowanym przez T. Bayesa. Można ogólnie stwierdzić, że wzór Bayesa stał się podstawą do rozwoju teorii i algorytmów różnych form wnioskowania probabilistycznego w tej dziedzinie. Poniżej przedstawiono przykład zastosowania takiej metodyki w prognozowaniu temperatury w procesie wytwarzania stali.

6. Prognozowanie temperatury w procesie wytwarzania stali

Prognozowanie temperatury w procesie wytwarzania stali jest klasycznym zagadnieniem z dziedziny metalurgii. Znane są dwa podejścia do tego zagadnienia: modele fizyczne (wywodzące się z teorii termodynamiki) oraz modele statystyczne. Pierwsze podejście, w najbardziej zaawansowanej formie, wymaga

stosowania złożonych metod obliczeniowych, takich jak metoda elementów skończonych, w celu symulacji procesów opisujących zjawiska termodynamiczne oraz dynamikę przepływu cieczy. W metodzie tej najczęściej przyjmowane jest założenie o braku składnika losowego, które jest uchylane w modelach statystycznych.

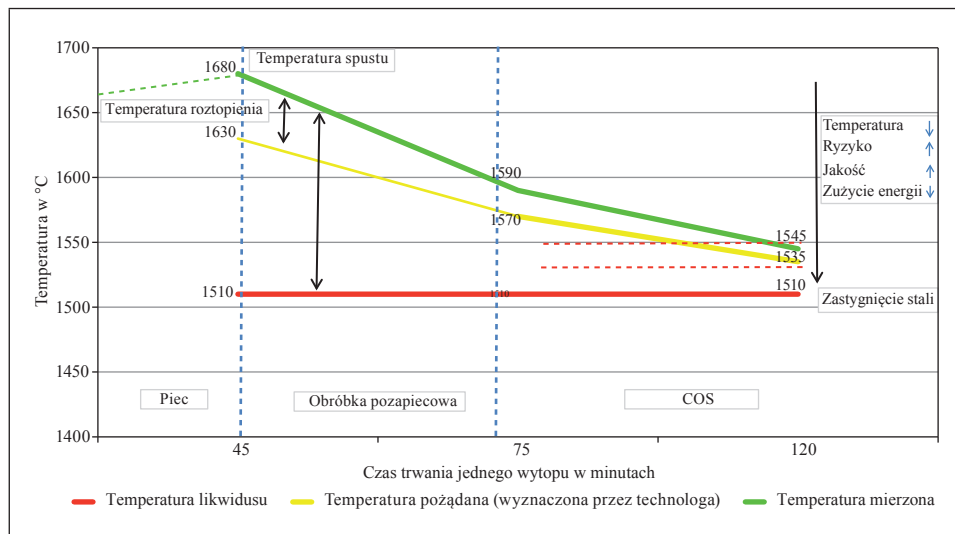
W metodach tej klasy najczęściej wykorzystywane są sieci neuronowe (*extreme learning machine*). Według źródeł literaturowych predykcja za pomocą metod statystycznych wymaga znacznie mniej czasu, a to ma istotne znaczenie praktyczne. Znane są również przykłady integracji obu podejść.

Występowanie składnika losowego jest związane z działalnością człowieka w trakcie procesu produkcyjnego. Stąd decyzje podejmowane w tych samych warunkach nie są w pełni powtarzalne. Jest to podstawowe uzasadnienie zastosowania metod statystycznych w analizie procesów produkcyjnych i zarządzaniu nimi.

Powyższe metody, te obejmujące teorie fizyczne oraz te wykorzystujące zarejestrowane w przedsiębiorstwach dane liczbowe, opisujące stosunkowo stabilne procesy metalurgiczne, pozwalają jedynie na punktową prognozę temperatury. Uogólnienie prognozy na cały rozkład statystyczny oraz uwzględnienie dodatkowej informacji spoza próby, co jest konieczne w przypadku wystąpienia nieplanowanych zdarzeń (np. postojów) w celu skorygowania prognozy, wymaga zastosowania nieklasycznych metod statystycznych, do których należą metody bayesowskie.

7. Zarys metodyki stosowanej w prognozowaniu temperatury

Przedstawiony przykład dotyczy jednej z polskich stalowni, w której analizowany proces produkcyjny rozpoczyna się w piecu elektrycznym, skąd wytopiona stal wlewana jest do tzw. kadzi głównej i dalej przelewana jest do kadzi pośredniej, która jest częścią urządzenia do ciągłego odlewania stali (COS). Istotne jest to, że w kadzi pośredniej nie ma możliwości regulacji temperatury. Aby osiągnąć odpowiednią jakość stali, a przy tym zużyć jak najmniejszą ilość energii potrzebnej do podgrzania, temperatura powinna być utrzymywana jak najbliżej granicy wyznaczonej przez technologię oraz jak najbliżej temperatury likwidusu (zastygnięcia stali). Jest to związane z ryzykiem zastygnięcia stali, a zatem poniesienia strat biznesowych (rys. 1). Precyzyjna produkcja wymaga zbliżania się do takich granic w celu zwiększenia efektywności (obniżenia kosztów czy zwiększenia wydajności oraz jakości produkowanych wyrobów). Planowanie procesu produkcyjnego musi zatem uwzględniać analizę ryzyka, czyli np. określenie prawdopodobieństwa osiągnięcia niebezpiecznego poziomu wybranego parametru (rys. 3).



Rys. 1. Zagadnienie praktyczne w zarządzaniu procesem produkcyjnym

Źródło: opracowanie własne.

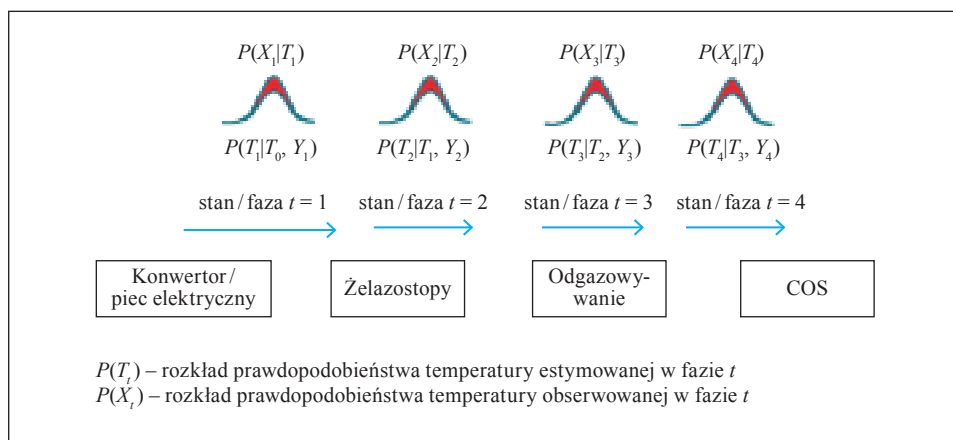
Zaproponowana metodyka pozwala prognozować poziom temperatury i jej rozkład prawdopodobieństwa [Ahmad i in. 2014]. Model może być zastosowany do:

- planowania procesu wytwarzania stali,
- analizy wrażliwości temperatury na zmiany parametrów procesu,
- sterowania poziomem temperatury w różnych fazach procesu.

Formalnie zagadnienie rozwiązywane jest z zastosowaniem reprezentacji przestrzeni stanu, a więc metodyki charakterystycznej dla nauk technicznych. W naukach ekonomicznych modele takie wykorzystywane są np. do analizy cyklu koniunkturalnego, który podobnie jak proces produkcyjny charakteryzuje się różnymi fazami. Są one zaliczane do grupy metod analizy szeregów czasowych².

² Większość modeli szeregów czasowych można zapisać w następującej formie: $y_t = g(z_t, \theta, \varepsilon_t)$, gdzie g jest znaną funkcją, z_t jest wektorem zmiennych objaśniających zmiany y_t , θ jest wektorem nieznanymi parametrów podlegających estymacji, a ε_t opisuje składnik losowy. Przy niezmienniej postaci funkcji g wartość θ opisuje jeden stan systemu, jeżeli natomiast θ jest zmiennie w czasie – θ_t , to mamy do czynienia z opisem różnych stanów systemu. Ogólna postać klasy modeli przestrzeni stanów jest następująca: $y_t = A\alpha_t + Bz_t + \varepsilon_t$ – równanie dla zmiennych obserwowanych, $\alpha_t = C\alpha_{t-1} + \eta_t$ – równanie stanu. Modele tej klasy są użyteczne m.in. do opisu dynamiki charakteryzowanej przez zmiany stanów, które zdają się nie mieć obserwowalnej i mierzalnej przyczyny, a także dynamiki zależnej od tzw. zmiennej przełącznikowej pomiędzy stanami, której realizacjami nie dysponujemy oraz dla której nie istnieje odpowiednia zmienna zastępcza.

Prognozowanie temperatury polega na oszacowaniu parametrów odpowiednich rozkładów prawdopodobieństwa, co pokazano na rys. 2. Prognoza nie dotyczy zatem tylko średniej, ale wszystkich parametrów opisujących rozkład prawdopodobieństwa.

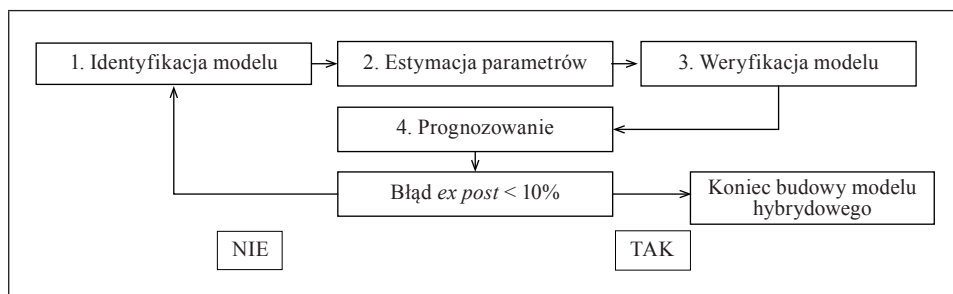


Rys. 2. System prognozowania temperatury z zastosowaniem prawdopodobieństwa warunkowego

Źródło: opracowanie własne.

Temperatura T_t jest estymowana z wykorzystaniem sekwencyjnej analizy Monte Carlo oraz wnioskowania bayesowskiego.

Ogólny schemat postępowania w przypadku budowy systemu prognozowania temperatury jest zgodny z metodyką Boxa-Jenkinsa, co przedstawia rys. 3.



Rys. 3. Ogólny plan badań zgodny z metodyką Boxa-Jenkinsa

Źródło: opracowanie własne.

8. Badania własne w dziedzinie zastosowań wnioskowania bayesowskiego

Punktem wyjścia do stworzenia systemu prognozowania temperatury w kadzi pośredniej jest zbiór obserwacji temperatury dla procesu produkcyjnego wybranego gatunku stali (zob. rys. 4):

- na wyjściu z elektrycznego pieca łukowego (*electric arc furnace* – EAF),
- na wejściu stanowiska obróbki pozapiecowej (*ladle heating furnace* – LHF We),
- na wyjściu stanowiska obróbki pozapiecowej (LHF Wy),
- pierwszy i ostatni pomiar w kadzi pośredniej na maszynie COS oraz zużycia energii elektrycznej na stanowisku obróbki pozapiecowej.

Pomiary temperatury oraz zużycia energii elektrycznej zostały zarejestrowane przez systemy informatyczne pracujące w jednej z polskich stalowni. Do obliczeń wykorzystano oprogramowanie Matlab.

Średnie, wariancje, odchylenia standardowe oraz współczynniki zmienności dla analizowanych procesów zaprezentowano w tabeli 1.

Tabela 1. Miary statystyczne dla szeregów czasowych temperatury i zużycia energii

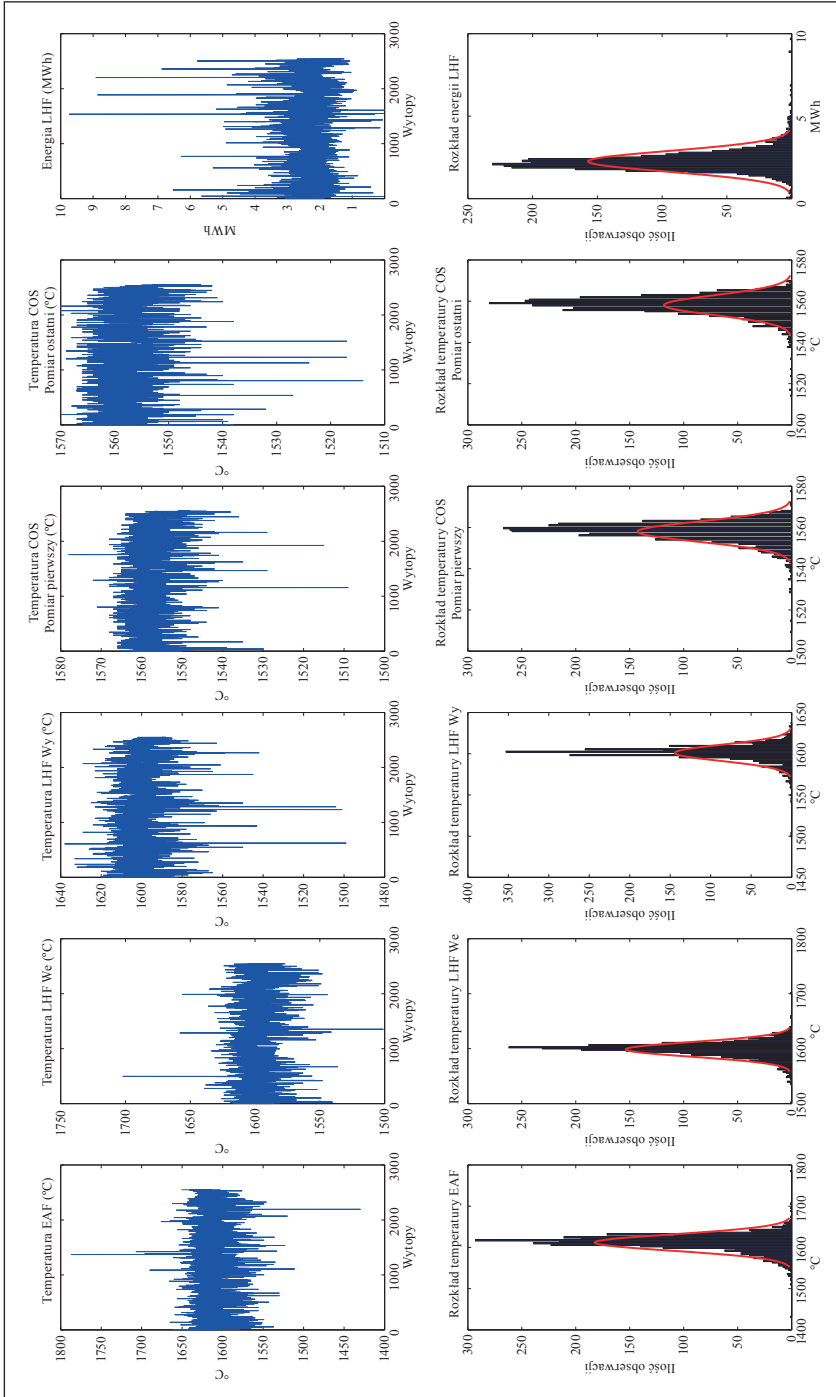
| Wyszczególnienie | Temperatura na wyjściu (EAF) | Temperatura na wejściu (LHF) | Temperatura na wyjściu (LHF) | Pierwszy pomiar temperatury na COS | Ostatni pomiar temperatury na COS | Zużycie energii (LHF) |
|-------------------------|------------------------------|------------------------------|------------------------------|------------------------------------|-----------------------------------|-----------------------|
| | T1 (°C) | T2 (°C) | T3 (°C) | T4 (°C) | T5 (°C) | E (MWh) |
| Średnia | 1 612 | 1 599 | 1 601 | 1 558 | 1 558 | 2 |
| Wariancja | 395,7 | 176,7 | 95,9 | 24,2 | 23,2 | 0,4 |
| Odchylenie standardowe | 19,9 | 13,3 | 9,8 | 4,9 | 4,8 | 0,6 |
| Współczynnik zmienności | 1,23% | 0,83% | 0,61% | 0,32% | 0,31% | 27,86% |

Źródło: opracowanie własne.

Powyższa analiza jest przykładem klasycznego wnioskowania statystycznego. Przyjmowane jest założenie, że rozkład temperatury X ma postać rozkładu normalnego (Gaussa):

$$X|\theta \sim N(\theta, \sigma^2).$$

Wnioskowanie bayesowskie wychodzi od założenia o istnieniu wiedzy spoza analizowanego zbioru obserwacji [Osiewalski 2001]. Przyjęto, że wariancja



Rys. 4. Szeregi czasowe i rozkłady prawdopodobieństwa dla temperatur i zużycia energii w wybranych fazach procesu odlewania stali dla przykładowego przedsiębiorstwa

Źródło: opracowanie własne.

rozkładu danych zarejestrowanych σ^2 jest znana, a rozkład *a priori* średniej ma również postać rozkładu normalnego:

$$\theta \sim N(\mu, \tau^2).$$

Rozkład ten reprezentuje wiedzę *a priori* o temperaturze w danym miejscu procesu produkcyjnego, a zatem średnia μ i wariancja τ^2 są znane. Wiedza ta może wynikać ze zdobytego doświadczenia opartego na wcześniejszych badaniach, intuicji czy wiedzy eksperckiej (opartej w tym przypadku np. na fizycznych teoriach termodynamiki i dynamiki przepływu cieczy).

Podstawę wnioskowania statystycznego stanowi ciągle informacja uzyskana z obserwacji, stąd przy dostatecznej ich ilości, nawet dość znaczne zmiany rozkładu *a priori* nie pociągają za sobą większych zmian w otrzymywanych rozkładach *a posteriori*. Niewielkie zmiany mogą być jednak istotne w przypadku bardzo precyzyjnego sterowania procesami produkcyjnymi. Źródłem dodatkowej informacji mogą być dłużej pracownicy przedsiębiorstw, dzięki których intuicji można poprawić trafność prognozowania.

W prezentowanym przykładzie przyjęto *a priori*, że średnia temperatura na wyjściu ze stanowiska obróbki pozapiecowej będzie wynosić 1580°C, a odchylenie standardowe 3°C (rys. 3).

Wnioskowanie o parametrze θ (średnia temperatura) dokonywane jest na podstawie rozkładu warunkowego tego parametru przy ustalonych obserwacjach, czyli na podstawie tzw. rozkładu *a posteriori* o gęstości danej wzorem Bayesa:

$$P(\theta|X) = \frac{P(X|\theta)P(\theta)}{P(X)},$$

gdzie $P(X) = \int_{\Theta} P(Y|\theta)P(\theta)d\theta$ jest brzegową gęstością wektora obserwacji.


Rozważana jest rodzina rozkładów prawdopodobieństwa indeksowana przez wektor $\theta \in \Theta \subset R^s$. Centralnym punktem wnioskowania bayesowskiego jest wyznaczenie rozkładu *a posteriori* łączącego informacje o parametrze pochodzące z funkcji wiarygodności i rozkładu *a priori*³:

$$P(\theta | X) \propto L(\theta, X)P(\theta),$$

gdzie:

- \propto – symbol proporcjonalności (równości z dokładnością do stałej dodatniej),
- $L(\theta, X)$ – funkcja wiarygodności definiowana jako $L(\theta, X) = P(X, \theta)$.

³ Wiarygodność bayesowska jest tożsama z klasyczną funkcją wiarygodności. Mianowicie w statystyce klasycznej funkcją wiarygodności nazywamy funkcję gęstości rozkładu prawdopodobieństwa zmiennej losowej rozpatrywaną jako funkcję parametrów, od której ona zależy (prawdopodobieństwo otrzymania obserwacji przy danych parametrach rozkładu statystycznego).



Rys. 5. Rozkład *a priori*, funkcja wiarygodności i rozkład *a posteriori* oraz poziom graniczny dla średniej temperatury
 Źródło: opracowanie własne.

Łącząc wiedzę z obserwacji z wiedzą *a priori*, osiąga się większą efektywność estymatorów⁴. Rozkład *a priori*, funkcję wiarygodności oraz rozkład *a posteriori* dla średniej temperatury na wyjściu ze stanowiska obróbki cieplnej przedstawiono na rys. 5.

Powyżej przedstawiono przykład jednowymiarowej analizy statystycznej temperatury w kadzi odlewniczej z zastosowaniem wnioskowania bayesowskiego. Następnym krokiem jest analiza wielowymiarowa oraz analiza regresji, która pozwala poznawać powiązania pomiędzy różnymi zjawiskami. W przypadku wnioskowania bayesowskiego rozkład *a priori*, funkcja wiarygodności oraz rozkład *a posteriori* dotyczą szacowanych parametrów funkcji regresji. Dalszym uogólnieniem jest analiza szeregów czasowych, która pozwala uwzględnić ich właściwości oraz zależności występujące w czasie.

9. Podsumowanie

Z analizy danych przeprowadzonej dla wybranej stalowni w Polsce wynika, że pomiary temperatury oraz zużycia energii elektrycznej charakteryzują się zmiennością, a to oznacza obecność składnika losowego w badanych procesach technologicznych. W związku z tym zmienne te powinny być traktowane jako zmienne losowe, opisane rozkładem prawdopodobieństwa zbliżonym do rozkładu normalnego. Właściwość ta powinna być brana pod uwagę w przypadku modelowania procesu produkcyjnego.

Wysoka precyzja sterowania procesami technologicznymi wymaga zmniejszenia tej zmienności oraz uwzględnienia dodatkowej informacji spoza zbioru danych (np. wynikającej z doświadczenia pracowników), co jest możliwe dzięki zastosowaniu np. metod bayesowskich. Dotychczasowe analizy danych rejestrowanych w wybranej stalowni wskazują, że przeciętna zmienność temperatury sięga kilkunastu stopni Celsjusza. Proponowane rozwiązanie powinno doprowadzić do obniżenia tego wskaźnika o kilka stopni, a w dalszej perspektywie znacznie poniżej 10°C. Większa stabilność procesów pozwoli na bardziej trafne prognozowanie.

Prognozowanie temperatury w kadzi odlewniczej i kadzi pośredniej ma istotne znaczenie dla uzyskania odpowiedniej jakości stali, wydajności związanej z szybkością odlewania oraz ograniczenia zużycia energii potrzebnej do podgrzewania. Osiągnięcie tych celów wymaga rozwiązania problemów zarówno natury

⁴ Estymator parametru (np. średnia temperatura) powinien być nieobciążony, czyli najbardziej zbliżony do prawdziwej wartości, efektywny, czyli charakteryzujący się najmniejszym rozrzutem spośród wybranych estymatorów, oraz zgodny, czyli wraz ze wzrostem liczby obserwacji jego wariancja i obciążenie powinny dążyć do zera.

technicznej i technologicznej, jak i tych dotyczących dziedziny zarządzania i organizacji procesów produkcyjnych. Ostatecznie działania takie powinny wpłynąć na obniżenie jednostkowego kosztu zmiennego produkcji oraz powinny mieć korzystny wpływ na środowisko naturalne.

Zbliżanie temperatury w kadzi pośredniej do temperatury krytycznej (odpowiednio większej od temperatury likwidusu) wiąże się z większym ryzykiem zastygnięcia stali, ale obniża koszty zużycia energii i polepsza jakość produktu. Takie zarządzanie procesami technologicznymi wymaga bardzo precyzyjnego sterownia oraz pomiaru ryzyka, czyli w tym przypadku prawdopodobieństwa osiągnięcia temperatury krytycznej w kadzi pośredniej. Podstawową miarą ryzyka jest odchylenie standardowe, czyli jeden z parametrów rozkładu statystycznego. W przypadku analizowanych procesów współczynnik zmienności (stosunek odchylenia standardowego do średniej) waha się w granicach od 1,23–0,31%, co odpowiada wahaniom temperatury od kilkunastu do kilku stopni. Wydaje się, że jest to niewielki rozrzut obserwacji, ale efektem tego jest utrzymywanie temperatury procesu na poziomie nawet o kilkadziesiąt stopni Celsjusza przekraczającym temperaturę likwidusu. Obniżenie temperatury procesu wytwarzania stali wymaga więc lepszego zarządzania ryzykiem, które obejmuje jego pomiar za pomocą metod statystycznych. Rezultatem tego rodzaju projektów będzie więc przede wszystkim zbliżenie temperatury procesu do temperatury krytycznej, co wiąże się z większym ryzykiem zastygnięcia stali, a co za tym idzie – spowodowania znaczących strat biznesowych. Jest to szczególny przypadek szerszego problemu zbliżania parametrów procesów technologicznych do nieprzekraczalnych granic, wtedy kiedy jest to korzystne z punktu widzenia efektywności produkcji (jakości i rentowności).

Zastosowanie praktyczne zaprezentowanej metodyki wiąże się z odpowiednim opomiarowaniem procesu produkcyjnego oraz oprogramowaniem pozwalającym na szybkie tworzenie i przetwarzanie dużych zbiorów danych o wymaganej strukturze. Rozwinięcie w Polsce bardzo precyzyjnych procesów technologicznych pozwalających na produkcję wyrobów wysokiej jakości jest istotne dla procesu reindustrializacji, ponieważ masowa produkcja wyrobów niskiej i średniej jakości została przeniesiona z Europy w rejon Pacyfiku.

Literatura

- Ahmad I., Kano M., Hasebe S., Kitada H., Murata N. [2014], *Prediction of Molten Steel Temperature in Steel Making Process with Uncertainty by Integrating Gray-Box Model and Bootstrap Filter*, „Journal of Chemical Engineering of Japan”, vol. 47, nr 11, <http://dx.doi.org/10.1252/jcej.14we067>.

- Barczak A.S. [2002], *Modelowanie ewolucji obiektu gospodarczego* [w:] *Przestrzenno-czasowe modelowanie i prognozowanie zjawisk gospodarczych*, red. A. Zeliaś, Wydawnictwo Akademii Ekonomicznej w Krakowie, Kraków.
- Makroekonomiczny model gospodarki opartej na wiedzy* [2009], red. W. Welfe, Wydawnictwo Uniwersytetu Łódzkiego, Łódź.
- Miczka M. [2008], *Strukturalne modelowanie ekonomiczne ewolucji obiektu gospodarczego*, „Wiadomości Statystyczne”, nr 7.
- Miczka M. [2013], *Schumpeterowskie modele wzrostu gospodarczego* [w:] *Zastosowanie metod ilościowych i jakościowych w modelowaniu i prognozowaniu zjawisk społeczno-gospodarczych*, red. B. Pawełek, Wydawnictwo Uniwersytetu Ekonomicznego w Krakowie, Kraków.
- Miczka M. [2014], *Analiza funkcji produkcji i wydajności pracy dla wybranych działów polskiego przemysłu – weryfikacja empiryczna z zastosowaniem metodyki badań panelowych* [w:] *Modelowanie i prognozowanie zjawisk społeczno-gospodarczych. Teoria i praktyka*, red. B. Pawełek, Wydawnictwo Uniwersytetu Ekonomicznego w Krakowie, Kraków.
- Osiewalski J. [2001], *Ekonometria bayesowska w zastosowaniach*, Wydawnictwo Akademii Ekonomicznej w Krakowie, Kraków.
- Romer P.M. [1994], *The Origins of Endogenous Growth*, „Journal of Economic Perspectives”, vol. 8, nr 1, <http://dx.doi.org/10.1257/jep.8.1.3>.
- Strategic Research Agenda: A Vision for the Future of the Steel Sector* [2013], European Steel Technology Platform, 2nd ed., May, <ftp://ftp.cordis.europa.eu/pub/estep/docs/sra-052013-en.pdf>.

Risk Management in Intelligent Manufacturing Systems Using Bayesian Analysis

(Abstract)

The article presents the range of modern methods used to forecast and conduct risk analysis of the production process and the characteristics of the measurements taken during the steel production process. The methodology is based on the state space representation of a dynamic system and Bayesian inference. The methodology enables us to reject the assumption of constant estimated parameters, analyse the statistical distribution of the whole and take into account *a priori* information, which is to say outside the dataset. The article is a review and the basis for further studies that include implementation of the concept of intelligent manufacturing in Polish industrial enterprises.

Keywords: production process, risk, forecasting, metallurgy, temperature, Bayes, states pace representation.