



BIG DATA W ZARZĄDZANIU DZIAŁALNOŚCIĄ OPERACYJNĄ PRZEDSIĘBIORSTW PRODUKCYJNYCH

Magdalena Jurczyk-Bunkowska¹, Ilona Pawełoszek²,
Jędrzej Wieczorkowski³

¹Politechnika Opolska, Wydział Inżynierii Produkcji i Logistyki

²Politechnika Częstochowska, Wydział Zarządzania

³Szkoła Główna Handlowa w Warszawie, Kolegium Analiz Ekonomicznych

Streszczenie: Artykuł dotyczy problematyki zastosowania koncepcji Big Data we wspomaganiu zarządzania działalnością operacyjną przedsiębiorstwa produkcyjnego. Daje ona dużą szansę na znaczne poprawienie wskaźników operacyjnych związanych z szybkością, elastycznością, wydajnością i kosztami produkcji, jednak stanowi również ogromne wyzwanie dla przedsiębiorstwa, dotyczące zarówno znalezienia adekwatnych rozwiązań, jak i poniesienia określonych nakładów inwestycyjnych. Zaproponowano model sukcesywnego wdrożenia koncepcji Big Data w zarządzaniu operacyjnym. Pozwala on na sukcesywne budowanie i ocenę efektów uzyskiwanych dzięki tym nowym rozwiązaniom. Odniesiono się do przykładowych efektów w każdym z proponowanych etapów wdrożenia oraz wskazano na dylematy im towarzyszące.

Słowa kluczowe: Big Data, zarządzanie operacyjne, Przemysł 4.0, Internet przemysłowy, systemy cyberfizyczne

DOI: 10.17512/znpcz.2017.2.09

Wprowadzenie

Współczesne przedsiębiorstwa funkcjonują w warunkach charakteryzujących się dużą zmiennością i niepewnością. Celem istnienia każdej organizacji jest zaspokojenie potrzeb klientów przez wytwarzanie określonych produktów. Działania związane bezpośrednio z wytwarzaniem tych produktów nazywane są operacjami i pełnią w każdej organizacji kluczową rolę. By skutecznie konkurować, należy je doskonalić w kierunku dopasowania do indywidualnych wymagań klienta, wzrostu elastyczności i skrócenia czasu realizacji zlecenia. Im skuteczniejsze zarządzanie operacyjne, które obejmuje wszystkie działania bezpośrednio dotyczące wytwarzania produktu, poczynając od gromadzenia składników wejściowych, aż po ich przetwarzanie i dostarczanie końcowego produktu (Waters 2001, s. 32), tym wyższa zdolność przedsiębiorstwa do zwycięstwa w wyścigu o klienta. Koncepcja indywidualizacji produktu w warunkach produkcji masowej powoduje, że systemy produkcyjne stają się coraz bardziej złożone. Wspomaganie informatyczne wielu procesów podstawowych powoduje nieustanne generowanie danych różnego rodzaju, które są potencjalnie cenne, jako źródło wiedzy prowadzącej do diagnozy, predykcji i optymalizacji działalności operacyjnej. W sytuacji presji czasowej i zróżnicowania

wania asortymentowego poszukiwane są rozwiązania umożliwiające analizę tego typu danych w czasie rzeczywistym bądź zbliżonym do rzeczywistego. Dlatego zaawansowane analizy danych i Big Data to rozwiązania, które umożliwiają rozpoczęcie nowej ery w zarządzaniu operacyjnym, wpisując się silnie w koncepcję Przemysłu 4.0 (Kagermann, Wahlster 2013). Jednak by to osiągnąć, potrzebne są nowe rozwiązania technologiczne zapewniające możliwości przechowywania większej ilości danych oraz ich przetwarzania z większą szybkością i udostępniania większej liczbie odbiorców (Gross, Veeramuthu 2013). Na przykład korelacja danych z systemu ERP choćby z liczbą braków, zużyciem energii elektrycznej, wydajnością systemu, a nawet danymi dotyczącymi pogody itp. może prowadzić do wykrycia zbieżności i zależności bezcennych z punktu widzenia podejmowania trafnych decyzji w zarządzaniu operacyjnym. Dotychczasowe systemy BI (Business Intelligence) ze scentralizowanymi modelami danych są już niewystarczające. Zarządzający działalnością operacyjną muszą mieć możliwość samodzielnej analizy danych w dowolnym momencie, a nie za pośrednictwem działów analiz czy controllingu. Co więcej, systemy produkcyjne powinny samodzielnie analizować sytuację i szukać możliwości dynamicznego dopasowania do zaistniałych warunków. Dzięki algorytmom analizy sytuacji powinny zyskać swoistą samoświadomość umożliwiającą błyskawiczną reakcję bazującą na uwzględnieniu wielu różnych czynników kształtujących obecne i przyszłe warunki produkcji.

Celem artykułu jest prezentacja koncepcji sukcesywnego wdrożenia Big Data do wspomagania zarządzania działalnością operacyjną przedsiębiorstw produkcyjnych. Zaproponowano obejmujący sześć etapów model rozwoju zastosowania tych technologii w systemie produkcyjnym. W poszczególnych etapach zwiększany jest sukcesywnie zakres integracji danych, co determinuje możliwość wsparcia decyzji w działalności operacyjnej w kolejnych horyzontach zarządzania. W punkcie pierwszym wskazano główne zadania zarządzania operacyjnego, a w kolejnym omówiono tę problematykę w kontekście wdrażania koncepcji Przemysłu 4.0. Punkt trzeci omawia koncepcję Big Data oraz potrzebę podnoszenia kompetencji w przedsiębiorstwach w tym zakresie. Punkt czwarty prezentuje model sukcesywnego wdrażania Big Data w zarządzaniu działalnością operacyjną. Natomiast w podsumowaniu wskazano kierunki dalszych prac autorów nad koncepcją sukcesywnego wdrażania Big Data w zarządzaniu działalnością operacyjną.

Zadania zarządzania operacyjnego w przedsiębiorstwie produkcyjnym

Zarządzanie operacyjne odnosi się głównie do planowania, organizowania kontrolowania produkcji rozumianej jako wytwarzanie wyrobów lub świadczenie usług. Jest skoncentrowane na efektywnym przekształcaniu czynników wejścia w elementy wyjścia z systemu produkcyjnego. Obejmuje procesy biznesowe zmierzające do projektowania, wytwarzania (lub świadczenia usług) i dostarczania odbiorcom produktów. Można zatem powiedzieć, że obejmuje przepływy rzeczowe, finansowe i informacyjne w łańcuchu tworzenia wartości. Im bardziej klienci przedsiębiorstwa są zadowoleni z tych procesów, im niższe są ich koszty, tym lepsze jest zarządzanie operacyjne w przedsiębiorstwie. Pierwotnie pojęcie „zarządza-

nie operacyjne” odnoszone było przede wszystkim do produkcji przemysłowej, jednak obecnie powszechnie łączone jest również z działalnością usługową (Jacobs, Chase 2008). Podkreśla to również definicja, w której zarządzanie operacyjne jest definiowane jako projektowanie, eksploatawanie i rozwijanie systemu, w którym odbywa się podstawowa produkcja lub prowadzona jest działalność usługowa (Jacobs, Chase 2012).

Głównym celem właściwego zarządzania operacyjnego jest uzyskanie maksymalnych efektów z zaangażowanych zasobów lub uzyskanie zakładanego efektu przy zaangażowaniu możliwie najmniejszych zasobów (Pająk, Klimkiewicz, Kosieradzka 2014, s. 22). Ma ono zatem zapewnić organizacji sprawne i skuteczne osiągnięcie celów. Przez sprawność należy rozumieć wykonywanie działań we właściwy sposób, czyli taki, gdy nakłady są dostosowywane do planowanych potrzeb. Natomiast skuteczność oznacza umiejętność wyboru właściwych celów. Realizacja zadań zarządzania operacyjnego różni się ze względu na specyfikę produkcji, np. ze względu na powtarzalność produkcji wyróżnia się typ jednostkowy, seryjny i masowy; ze względu na organizację przebiegu produkcji – produkcję ciągłą i dyskretną, a ze względu na relacje z klientami – produkcję na zamówienie indywidualnego klienta i produkcję na magazyn (dla anonimowego klienta). Można jednak wymienić pewne klasy zadań w ramach zarządzania operacyjnego typowe dla wszystkich organizacji (Karlsson 2009):

1. Zrozumienie i rozwój strategicznych celów organizacji, aby wspierać jej długoterminowy wzrost. Tworzy to zbiór generalnych zasad podejmowania decyzji operacyjnych, który gwarantuje realizację strategii przedsiębiorstwa.
2. Projektowanie wykorzystania zasobów organizacji w sposób, który zapewnia uzyskanie pożądaných właściwości procesów, produktów i usług, układów zasilających, przepływu materiałów i półproduktów, organizacji pracy itp.
3. Planowanie i sterowanie przebiegiem operacji poprzez decydowanie, które z posiadanych zasobów operacyjnych powinny być wykorzystane, oraz zapewnienie ich właściwego wykorzystania. Obejmuje ono takie obszary, jak: zdolności produkcyjne, materiały, wyposażenie, procesy transformacji, projekty i jakość.
4. Doskonalenie wydajności poszczególnych działań, w kontekście usprawniania całych procesów, które stanowi obowiązek zarządzających produkcją na wszystkich szczeblach.

Zarządzanie operacyjne obejmuje szereg powiązanych ze sobą decyzji, takich jak np. planowanie zdolności produkcyjnych, harmonogramowanie, zarządzanie zapasami, zapewnienie jakości, motywowanie pracowników, lokalizacja obiektów produkcyjnych itp.

Zarządzanie operacyjne u progu rewolucji Przemysłu 4.0

Postęp techniczny niesie dla produkcji daleko idącą transformację określaną nazwą Przemysłu 4.0. W tej transformacji czujniki, maszyny, elementy obrabiane i systemy informatyczne będą połączone wzdłuż łańcucha wartości, wykraczając poza pojedyncze przedsiębiorstwo. Systemy produkcyjne będą zastępowane systemami cyberfizycznymi (ang. *Cyber Physical Systems* – CPS), będącymi kolejną

generacją inteligentnych systemów wytwórczych, łączącymi świat fizyczny i wirtualny (Hermann, Pentek, Otto 2015). Nazwa ta odnosi się do adaptacyjnych układów, na które składają się m.in.: maszyny, urządzenia z wbudowanymi mikroprocesorami, systemy informatyczne i monitoring, sterowniki PLC, kontrolery i czujniki. Wspólnie stanowią one współpracujące ze sobą elementy obliczeniowe kontrolujące zasoby fizyczne głównie za pomocą sprzężeń zwrotnych z różnego rodzaju czujników i sterowników. Połączone systemy cyberfizyczne będą współdziałać ze sobą za pomocą standardowych protokołów internetowych i analizować dane, aby przewidzieć awarię, samokonfigurować się i dostosowywać do zmian w różnych horyzontach czasowych. Koncepcja Przemysłu 4.0 budowana jest w oparciu o dziewięć technologii (Wang, Wang 2016).

1. Analiza dużych zbiorów danych (Big Data).
2. Inteligentne roboty, które mogą być ze sobą połączone i w ten sposób współpracować i automatycznie integrować swoje działania.
3. Symulacje 3D wykorzystujące dane w czasie rzeczywistym do odzwierciedlenia świata fizycznego w wirtualnym modelu, który może obejmować maszyny i ludzi (procesy produkcyjne) albo produkty.
4. Horyzontalna i wertykalna integracja przedsiębiorstwa dostawców i klientów przy wykorzystaniu systemów informatycznych, umożliwiającą wymianę danych nie tylko pomiędzy działami przedsiębiorstwa, ale również jego partnerami.
5. Internet przemysłowy umożliwiający komunikację i współdziałanie ze sobą różnego rodzaju urządzeń przemysłowych.
6. Cyberbezpieczeństwo mające kluczowe znaczenie dla niezawodnej komunikacji, a także identyfikacja i zarządzanie dostępem maszyn i użytkowników.
7. Oprogramowanie w chmurze umożliwiające szersze udostępnianie danych.
8. Technologie przyrostowe (*additive manufacturing*), dzięki którym można tworzyć gotowe części bez oprzyrządowania, eliminując związane z nimi koszty i opóźnienia.
9. Rozszerzona rzeczywistość zapewniająca pracownikom informacje w czasie rzeczywistym w celu poprawy procesu podejmowania decyzji i procedur pracy.

Bazą zarządzania operacyjnego w warunkach wdrożenia koncepcji przemysłu 4.0 będzie Internet przemysłowy. Wywodzi się on z Internetu rzeczy (*Internet of Things* – IoT), który określa połączenie wielu różnorodnych urządzeń elektronicznych w sieć i ich wzajemną komunikację za pośrednictwem uniwersalnych protokołów. W ten sposób urządzenia wymieniają między sobą dane bez pośrednictwa człowieka, poszerzając tym samym swoje funkcje. IoT w zastosowaniach przemysłowych nazywany jest Internetem przemysłowym (*Industrial Internet of Things* – IIoT). Oprócz Big Data integralnymi technologiami Internetu przemysłowego są M2M (*Machine to Machine*), uczenie maszynowe (*Machine Learning*) i RFID (*Radio Frequency Identification*) (Gobble 2014). Termin „M2M” oznacza możliwość komunikacji i transferowania danych pomiędzy poszczególnymi maszynami w linii produkcyjnej. Do uzyskania łączności między nimi wykorzystywany jest jeden główny interfejs, który gromadzi wszystkie dane, a następnie pozwala na zarządzanie poszczególnymi maszynami. W ten sposób zwiększana jest efektywność poszczególnych okresów produkcji, a elementy integrowane są tak, by praco-

wać precyzyjniej. Natomiast uczenie maszynowe jest dziedziną na pograniczu matematyki, statystyki i programowania, którego celem jest tworzenie złożonych algorytmów samodoskonalących bazujących na sieciach neuronowych. Dzięki nim urządzenia są w stanie podejmować decyzje, modyfikować je w oparciu o popełniane błędy i dostępne bieżące dane. Realizacja wyżej wymienionych funkcji wymaga zasilenia systemu analitycznego dużą ilością danych oraz określania ich wzajemnych powiązań semantycznych. Dzięki połączeniu maszyn i urządzeń oraz ich współpracy możliwe będzie przewidywanie stanów systemu produkcyjnego i podejmowanie decyzji operacyjnych prowadzących np. do zapobiegania awariom, dostosowanie funkcjonowania procesów produkcyjnych do popytu i warunków zewnętrznych, zmniejszanie zapotrzebowania na energię i surowce, minimalizacja odpadów.

Czwarta rewolucja przemysłowa wiąże się z zastosowaniem nowoczesnych, inteligentnych technologii informatycznych i automatyzacji w produkcji. Do najważniejszych z nich należą Big Data i IIoT, jako platforma komunikacyjna dla systemów cyberfizycznych (Kagermann, Wahlster 2013). To głównie połączenie tych dwóch elementów otwiera możliwość zautomatyzowania zadań zarządzania operacyjnego prowadzących do samosterowania systemu produkcyjnego, a w dłuższym okresie także jego samodoskonalenia.

Koncepcja, charakterystyka i perspektywy Big Data

Big Data jest dość nowym pojęciem, które na chwilę obecną nie jest jeszcze jednoznacznie definiowane. Przeglądy definicyjne (Boyd, Crawford 2012; Tabakow, Korczak, Franczyk 2014; Polańska, Wassilew 2015) pokazują, że zwraca się uwagę przede wszystkim na ilość i charakter wykorzystywanych danych, zagadnienia technologiczne wynikające z przetwarzania bardzo dużych wolumenów danych oraz kwestie stosowanych metod analitycznych. Na podstawie analizy literatury można przyjąć, że koncepcja Big Data związana jest z gromadzeniem i przetwarzaniem bardzo dużych wolumenów danych, które wymuszają stosowanie nowych rozwiązań technologicznych i analitycznych. W zakresie gromadzenia i przechowywania danych szczególną rolę odgrywają bazy NoSQL oraz rozproszony system plików, w szczególności HDFS (*Hadoop Distributed File System*), natomiast w zakresie przetwarzania danych – rozwiązanie równoległe, rozproszone przetwarzanie i obliczenia wielkoskalowe, w szczególności w oparciu o koncepcję MapReduce i Hadoop. Powyższe rozwiązania wspierane są przetwarzaniem *in-memory*, *Cloud Computing* i in.

Jednakże zdaniem autorów niniejszego artykułu nie można ograniczać zagadnienia Big Data wyłącznie do technologii, należy traktować je jako szerszą koncepcję, łączącą takie obszary, jak m.in. technologie informacyjne, metody analizy danych (statystyka, Data Mining, uczenie maszynowe) z obszarami zastosowań koncepcji (np. zarządzanie różnorodnymi organizacjami, w tym państwem, procesy produkcyjne), a także ekonomiczno-społecznymi konsekwencjami stosowania metod. W niniejszym artykule skupiono się w szczególności na zastosowaniach w zarządzaniu przedsiębiorstwem i inżynierii produkcji. Punktem wyjścia dla wła-

ściwego rozumienia koncepcji Big Data jest jednak charakter wykorzystywanych danych, który najlepiej oddaje klasyczny model 3V, w którym wskazano trzy cechy danych: duży wolumen (*volume*), zmienność (*velocity*) i różnorodność (*variety*) (Laney 2001). Choć model ten niejednokrotnie rozbudowywano, dodając kolejne elementy, wymienione w nim trzy podstawowe cechy można uznać za zdecydowanie najistotniejsze. Przykładowo Gartner Group określa Big Data jako zasoby informacyjne dużych rozmiarów, szybko zmieniające się i/lub charakteryzujące się dużą różnorodnością, które wymagają efektywnych kosztowo i innowacyjnych form przetwarzania, umożliwiając poprawę wglądu w dane, podejmowanie decyzji i automatyzację procesów (Gartner 2017). W zarządzaniu procesami przedsiębiorstw produkcyjnych typowy jest duży wolumen danych wynikający z automatyzacji produkcji i robotyki. Różne sterowniki, czujniki, mierniki i inne urządzenia wchodzące w skład Internetu rzeczy są źródłem olbrzymiej ilości danych. Z punktu widzenia zarządzania działalnością operacyjną takich przedsiębiorstw, poza bardzo dużym wolumenem wykorzystywanych danych, charakterystyczna jest ich zmienność. Jest ona typowa dla danych dynamicznych, generowanych w bardzo krótkich odstępach czasu, analizowanych w czasie zbliżonym do rzeczywistego, takich jak dane sensoryczne i strumieniowe pochodzące z taśm produkcyjnych. Istotne mogą być także typowe dla Big Data dane nieustrukturyzowane lub słabo ustrukturyzowane, takie jak obrazy, materiały wideo i inne, nie w pełni nadające się do przechowywania w klasycznych bazach relacyjnych.

Problematyczna przy bardzo dużej ilości danych jest ich jakość, a także wybór danych istotnych z punktu widzenia celu ich analizy. W klasycznych metodach statystycznej analizy danych opartej na próbie losowej bardzo istotne było czyszczenie danych oraz usuwanie danych o wątpliwej jakości. Opierano się na założeniu typowym dla niewielkiego wolumenu dostępnych danych, że jakość i dokładność danych jest ważniejsza niż ilość. W różnych analizach dokonywano ograniczenia liczby analizowanych rekordów do wystarczającej próby i wyboru istotnych atrybutów. W podejściu typowym dla Business Intelligence wykorzystywano hurtownie danych, które w procesie ETL (*Extraction, Transformation, Loading*) zasilane były danymi elementarnymi pochodzącymi z innych systemów. Proces ETL powodował opóźnienie, lecz jednocześnie dawał możliwość czyszczenia danych. Często jednakże w hurtowni rezygnowano z przechowywania danych elementarnych na rzecz wyłącznie danych zagregowanych. Ewolucja IT prowadzi jednak stopniowo do możliwości analizowania wszystkich dostępnych szczegółowych danych w czasie zbliżonym do rzeczywistego. Przy takim podejściu niejednokrotnie ilość i szybkość stają się ważniejsze niż jakość danych. Jeśli zbiory są odpowiednio liczne, w wielu przypadkach niska jakość części danych przestaje stanowić istotny problem. Można wykorzystywać dane nieuporządkowane, częściowo błędne, o niższej precyzji, ponieważ brak jest ekonomicznego uzasadnienia czyszczenia ich (Mayer-Schonberger, Cukier 2013). Związane jest to m.in. z coraz szerszym wykorzystaniem korelacji w badaniu takich zjawisk, w których można zrezygnować z badania przyczynowości. Możliwe jest poszukiwanie nieznanych zależności zamiast stawiania z góry hipotez badawczych. Big Data niesie więc rewolucyjne zmiany, które są zbliżone bardziej do metod eksploracji (Data

Mining) niż do analizy statystycznej. W konsekwencji ich stosowania dochodzi do odkrywania nowych, często do tej pory nieznanymi zależności między danymi, a nawet do odkrywania nowych zjawisk przydatnych w procesach poznawczych, badawczych czy decyzyjnych.

Problemem więc w praktyce jest nie jakość poszczególnych danych, a umiejętność zbudowania zbiorów danych mających faktyczne znaczenie, wśród innych danych nieprzydatnych (Lee, Sohn 2016). W koncepcji Big Data, poza wykorzystywaniem danych w czasie zbliżonym do rzeczywistego, gromadzi się dane w celu ich późniejszego wykorzystania. Jednakże często z góry nie ma możliwości przewidywania późniejszej potencjalnej przydatności danych. Stąd różnorodne dane gromadzone są niejednokrotnie w sposób pasywny przy okazji zbierania innych danych. Zjawisko takie, określane jako „danetyzacja” (*datafication*), uzasadnione jest ekonomicznie niskim kosztem pozyskania i gromadzenia danych o nieznanej jeszcze przydatności. Takie, niejednokrotnie stare, dane dotyczące np. procesów produkcyjnych mogą być nadal surowcem dla różnorodnych analiz w przyszłości (Mayer-Schonberger, Cukier 2013).

Pytaniem pozostaje świadomość możliwości zastosowań koncepcji Big Data wśród kadry zarządzającej przedsiębiorstwami produkcyjnymi. Badania (PwC 2016) pokazują, że wiele firm przemysłowych już rozumie kluczowe znaczenie analizy danych. Ponad połowa (54%) uważa to za ważne lub bardzo ważne dla swoich firm, a liczba ta wzrasta do 88%, gdy respondentów poproszono o ocenę w perspektywie pięciu lat. Te same badania wskazują jednak ciągły niedostatek zaawansowania, jeżeli chodzi o analizę danych produkcyjnych. Jedynie 18% określiło te umiejętności jako dojrzałe. Kluczowym problemem wskazywanym przez pozostałe firmy był niedostatek umiejętności.

Możliwości zastosowań koncepcji Big Data związane są z zapewnieniem wykwalifikowanych kadr. Autorzy w 2015 roku przeprowadzili badanie oferty przedmiotów odwołujących się w tytule lub w sylabusie do pojęcia Big Data na polskich wyższych uczelniach (Pawełoszek, Wiczorkowski 2015). Zidentyfikowano wówczas 15 przedmiotów pochodzących z oferty dla różnych poziomów nauczania. Uwagę zwraca fakt, że przedmioty realizowane były w ramach bardzo różnych kierunków, zarówno technicznych, ekonomicznych, jak i humanistycznych. W zależności od kierunku studiów poruszane są zupełnie inne treści. W przypadku studiów technicznych i informatycznych najczęściej były to przedmioty związane z technologią, w przypadku studiów ekonomicznych – także z metodami analitycznymi. Na studiach humanistycznych pojęcie pojawiało się w kontekście zastosowań związanych z analizą mediów społecznościowych.

Podjęmowane są także próby tworzenia kierunków studiów adresowanych do przyszłych specjalistów od Big Data. Taki charakter ma kierunek studiów magisterskich w SGH *analiza danych – Big Data*. Jest on z założenia interdyscyplinarny i umiejscowiony w dyscyplinach naukowych: ekonomii, nauki o zarządzaniu, matematyki i informatyki. Ma kształcić specjalistów w zakresie pozyskiwania danych z różnych źródeł oraz ich analizy, dostarczając kompetencji umożliwiających podjęcie pracy zawodowej na stanowisku specjalisty zaawansowanej analizy danych m.in. w przedsiębiorstwach produkcyjnych (SGH 2017). W SGH realizowane są

także studia podyplomowe *inżynieria danych – Big Data*, nastawione na wszechstronną podbudowę informatyczną szeroko definiowanej analityki dużych wolumenów danych. Zarówno powyższe studia magisterskie, jak i podyplomowe cieszą się bardzo dużą popularnością.

Wnioskując na podstawie wymienionych przykładów, można więc stwierdzić, że instytucje edukacyjne dostrzegają problematykę Big Data, a zainteresowanie tą tematyką pozwala sądzić, że świadomość możliwości koncepcji Big Data będzie stopniowo rosła. Tym niemniej zapewne będzie to proces stopniowy, typowy dla adaptacji nowości technicznych w obszarze zarządzania.

Model wdrażania Big Data w zarządzaniu działalnością operacyjną


Od wielu lat analiza danych jest wykorzystywana w zarządzaniu operacyjnym w celu poprawy jakości i wydajności funkcjonowania przedsiębiorstw. Znaczenie analizy danych w tym obszarze jest widoczne ze względu na ogromną zmianę produktywności osiągniętą w tzw. erze komputerów, dzięki wdrażaniu poszczególnych rozwiązań IT. Szczególnie duże firmy tworzą złożone systemy, które monitorują przebieg procesu produkcyjnego i umożliwiają wykrywanie zaistniałych zmian i podejmowanie adekwatnych decyzji. Skuteczność tych systemów jest jednak ograniczona ze względu na możliwości gromadzenia danych, a także czas potrzebny na przygotowywanie danych i ich analizę. Dopiero integracja systemów informatycznych, produkcyjnych i operacyjnych pozwala kompleksowo śledzić i analizować system produkcyjny. Wymaga to jednak odpowiednich rozwiązań. Głównym celem wykorzystania dużych zbiorów danych w zastosowaniach przemysłowych jest osiągnięcie bezbłędnego i oszczędnego przebiegu procesu, przy jednoczesnym osiągnięciu pożądanego poziomu wydajności, zwłaszcza w odniesieniu do jakości. Jest to możliwe przy zastosowaniu rozwiązań umożliwiających predykcję zdarzeń i dobór najwłaściwszych w danych warunkach sposobów realizacji działań operacyjnych. Wysoka elastyczność procesu produkcji i integracja danych produkcyjnych zapewnia konkurencyjność działań operacyjnych przedsiębiorstwa poprzez umożliwienie wytwarzania zindywidualizowanych produktów w warunkach produkcji masowej (Da Silveira, Borenstein, Fogliatto 2001). Oddzielne przetwarzanie poszczególnych grup danych znacznie ogranicza możliwości wnioskowania na ich podstawie.

Dane istotne dla zarządzania operacyjnego pochodzą z różnych źródeł, systemów informatycznych oraz operacyjnych, np.: różnego rodzaju czujników, kamer, termowizji, a także systemów ERP, MES, SCADA, CRM, platformy PLM itp. Efektem ich działania są m.in. zestawy danych, których rozmiar jest poza zdolnością typowych narzędzi analitycznych. Dlatego można stwierdzić, że mimo dostępu do dużych zbiorów danych możliwość uzyskania z nich wiedzy dotyczącej funkcjonowania systemu produkcyjnego jest ograniczona. Obecnie analiza danych bazuje na znanych rozwiązaniach, takich jak: reguły asocjacyjne, wzorce sekwencji, klasyfikacja, grupowanie itd. Jednak dopiero teraz, za sprawą technologii skoncentrowanych wokół koncepcji Big Data, jest ona możliwa na tak dużą skalę. Szybko rosnąca ilość i zmienność tych danych rodzi konieczność stosowania zupełnie no-

wych technologii, które umożliwią ich efektywną archiwizację i wydajną analizę. Dzięki rozwiązaniom Big Data możliwe jest wyciągnięcie z ogromu danych tylko tych informacji, które są niezbędne do podjęcia określonej decyzji produkcyjnej, a także odkrywanie wielu zależności wiążących poszczególne działania i operacje produkcyjne. Zbiory danych produkcyjnych mogą być integrowane na różnych poziomach procesu produkcyjnego, począwszy od zamówienia klienta, aż po badanie jego satysfakcji z użytkowania produktu.

znaczenie decyzji

zarządczych



etap 1	Doskonalenie wydajności poszczególnych działań poprzez przetwarzanie sygnałów i informacji w tempie pozwalającym na podjęcie działań prewencyjnych.
etap 2	Sterowanie przebiegiem operacji (np. procesu wytwórczego) poprzez monitorowanie warunków ich przebiegu i ocenę efektywności.
etap 3	Planowanie zdolności produkcyjnych i optymalizacja kosztów. Rozwój nowych produktów.
etap 4	Projektowanie wykorzystania zasobów systemu produkcyjnego, układów zasilających, zużycia materiałów, kooperacji.
etap 5	Opracowanie zbioru generalnych zasad wspierających długoterminowy rozwój systemu produkcyjnego, który gwarantuje realizację strategii przedsiębiorstwa.
etap 6	Automatyczna logistyka na bazie wielowymiarowej analizy danych z łańcucha dostaw początkowo odbiorców i dostawców pierwszego rzędu.

Rysunek 1. Model rozwoju wykorzystania Big Data w zarządzaniu działalnością operacyjną przedsiębiorstwa

Źródło: Opracowanie własne

Rozważanie kwestii wykorzystania Big Data w zarządzaniu operacyjnym wymaga oceny nakładów i możliwych do uzyskania efektów. W końcowym etapie sprowadzi się to do analizy ekonomicznej. Potencjalne korzyści, jakie można uzyskać dzięki wykorzystaniu dużych danych, a także wyzwań, jakie stwarzają, będą

oczywiście różniły się w zależności od zakresu ich zastosowania. Kolejne etapy będą też wymagały zmierzania się z problemami wymienionymi w *Tabeli 1* w coraz szerszym zakresie. Z tego względu autorzy proponują model sukcesywnego wdrażania rozwiązań Big Data, omawiając ich potencjalne efekty (*Rysunek 1*).

Podejście takie jest możliwe do zastosowania dzięki dużej skalowalności narzędzi informatycznych wspomagających koncepcję Big Data. Wdrożenie rozwiązań w poprzednim etapie może być wstępem do kolejnych etapów z zachowaniem zaimplementowanych rozwiązań.

Zaproponowane podejście zapewnia stopniowe ponoszenie nakładów i sukcesywne rozwiązywanie problemów. Wdrożenie Big Data w zarządzaniu operacyjnym proponuje się rozpocząć od jednej, szczególnie ważnej lub złożonej fazy procesu produkcyjnego. Na przykład firma Siemens i niemiecki producent narzędzi maszynowych opracowały maszynę wirtualną, która może symulować obróbkę części przy użyciu danych z fizycznej maszyny. Skróciło to czas ustawiania dla rzeczywistego procesu obróbki aż o 80%. Zatem w efekcie wdrożenia Big Data w węższym zakresie – odnoszącym się do pojedynczej komórki produkcyjnej – można ocenić efekty i podać decyzję co do poszerzenia zakresu integracji danych na potrzeby decyzji zarządzania operacyjnego.

Inspiracją dla opracowania modelu było zestawienie badań zamieszczone w artykule: *Big Data Analysis in Smart Manufacturing: A Review* (Nagorny i in. 2017). Przedstawiono m.in. studia przypadków wdrożenia Big Data w systemach produkcyjnych. Z zamieszczonego zestawienia wynika, że Big Data są wdrażane na różnym poziomie: poczynając od prostej analizy danych ograniczonych do zdefiniowanego wąsko obszaru, aż po pełną automatyzację pozyskiwania i analizy danych. Problemy badawcze zaprezentowane w ramach analizy przypadków zostały pogrupowane w sześć obszarów różniących się ze względu na poziom zaawansowania analizy Big Data. Wykorzystano to w zaproponowanym modelu, wiążąc zaawansowanie analiz bazujących na Big Data ze znaczeniem decyzji zarządczych wynikających m.in. z horyzontu czasu ich oddziaływania. W dalszych pracach rozszerzono model o zakres pozyskiwania i integracji danych operacyjnych, który wynika z automatyzacji procesów produkcyjnych (np. CNC) i zarządczych (np. ERP) w przedsiębiorstwie. Bazowano tu na założeniu, że im szerszy zakres pozyskiwania danych, tym bardziej pogłębione analizy powinny być na ich podstawie prowadzone, tak by racjonalnie spożytkować wysiłek i nakłady związane z gromadzeniem, przetwarzaniem i przechowywaniem danych. W efekcie tych prac przygotowany został model, którego istotą jest zaproponowanie przedsiębiorcom systematycznego rozwoju zakresu wdrożenia Big Data w działalności operacyjnej ich organizacji. Ponadto będzie on bazą dla dalszych badań mających na celu zidentyfikowanie narzędzi, technologii i procedur koniecznych do zaimplementowania w przedsiębiorstwie na poszczególnych etapach wdrożenia Big Data.

Pierwszy etap zaproponowanego modelu (*Rysunek 1*) odnosi się do sytuacji, gdy dane z monitorowania komórki produkcyjnej zaczynają być wykorzystywane do analiz predykcyjnych mających na celu przewidywanie opóźnień i przestojów, określenie właściwego momentu konserwacji urządzenia, dobór odpowiednich narzędzi dla określonego materiału, ocenę liczby braków itp. Analiza danych daje

również możliwość obserwacji różnic jakości i wydajności na poszczególnych stanowiskach bądź na tym samym stanowisku pracy różnych operatorów. Dzięki temu można podjąć decyzję dotyczącą wprowadzenia szkoleń pracowników. Predykcja w takim zakresie prowadzi do redukcji błędów w ramach realizacji poszczególnych działań, a tym samym do lokalnego podniesienia wydajności. Jeżeli zakres integracji zwiększy się tak, że będzie obejmował cały proces (etap 2), to możliwe będzie ujawnienie, w których jego fazach częstość występowania błędów jest wyższa, a także które elementy wpływają w największym stopniu na jego koszty, co umożliwi wykrycie wąskich gardeł w procesach produkcyjnych lub porównanie wydajności poszczególnych technologii stosowanych np. podczas kontroli jakości, pakowania, transportu itp. Integracja danych – procesu wytwórczego pozwoli z dużą precyzją przewidzieć czas realizacji zamówienia, skrócić przestoje zasobów, zmniejszyć zapasy robót w toku. W przypadku procesu zaopatrzenia będzie możliwe bardziej efektywne zarządzanie zapasami materiałów i zamówieniami. Natomiast w przypadku procesu magazynowania możliwe będzie ustalenie właściwego doboru wyposażenia magazynów. Już na tym etapie można skutecznie wspierać systemy zarządzania ryzykiem, a możliwości te rozszerzają się z każdym kolejnym etapem. Integracja danych pomiędzy kilkoma powiązаныmi procesami (etap 3) pozwala ocenić, które parametry mają największe znaczenie dla zarządzania jakością, jakie wielkości parametrów diagnostycznych poszczególnych procesów można uzyskać w danych warunkach. Badanie zgodności dostarczania materiałów, ich jakości i wydajności surowców wraz z wynikami produkcji umożliwia wskazanie okresów i dostawców, w których dostarczane materiały są poniżej oczekiwanego standardu, co jest szczególnie istotne w branży spożywczej, farmaceutycznej itp. Ten etap integracji będzie już pozwalał na optymalizację procesów poprzez wielokryterialny dobór zasobów do zadań. Rozszerzenie integracji analizowanych danych do całego systemu (etap 4) umożliwi:

- zrozumienie relacji wpływających na wydajność zakładu i dopasowanie jego zdolności produkcyjnych do popytu;
- odniesienie działalności operacyjnej do budżetu w poszczególnych okresach;
- powiązania programu DMAIC (*Define, Measure, Analyze, Improve and Control*) i Six Sigma;
- określenie relacji w poszczególnych obszarach produkcji i powiązanie ich z oczekiwaniami klienta.

Ponadto jest możliwe stworzenie cyfrowego modelu całego procesu produkcyjnego, gdzie dzięki symulacji obejmującej wszystkie maszyny, pracowników i urządzenia można projektować najbardziej wydajny system przy określonym portfolio wyrobów. Inżynierowie procesów, zamiast eksperymentować na fizycznym systemie produkcyjnym (co może być bardzo trudne, jeśli nie niemożliwe), mogą wykorzystać techniki symulacji bazujące na ogromnej ilości pomiarów w celu predykcji zachowań dynamicznych rzeczywistego systemu. Integracja danych, obejmująca oprócz procesów wewnątrz systemu produkcyjnego przedsiębiorstwa także wybrane procesy dostawców i klientów (etap 5), prowadzi do usprawnień w projektowaniu wyrobów, powiązania tego etapu z klientem i ostatecznego skrócenia czasu rozwoju produktu i wprowadzenia go na rynek. Możliwe

jest również podejmowanie dynamicznych decyzji odnośnie wykorzystania możliwości kooperacji lub outsourcingu wybranych procesów. Możliwa jest także optymalizacja harmonogramów produkcji w oparciu o dostępność materiałów, klienta, dostępność parku maszynowego i ograniczenia kosztów. Integracja danych obejmująca większe fragmenty łańcucha dostaw (etap 6) umożliwia pełną synchronizację przepływu fizycznego pomiędzy poszczególnymi ogniwami tego łańcucha, stając się podstawą dobrze funkcjonujących sieci logistycznych.

Fundamentem pełnego wykorzystania możliwości Big Data w zarządzaniu operacyjnym jest szczegółowe opracowanie koncepcji działania systemu informatycznego. Niełatwym początkiem będzie właściwe wskazanie źródeł pozyskiwania danych. Zaproponowany model stopniowego wykorzystania Big Data do zarządzania operacyjnego pozwala systematycznie rozbudowywać tę koncepcję i w coraz szerszym zakresie rozwiązywać problemy omówione w *Tabeli 1*.

Tabela 1. Wyzwania i problemy wykorzystania Big Data w zarządzaniu operacyjnym

Wyzwania	Główne problemy
Pozyskiwanie danych	Stworzenie możliwości obserwacji działań operacyjnych, filtrowanie danych, tworzenie zbiorów metadanych
Zapewnienie jakości danych	Porządkowanie danych dające możliwość ich analizy w kierunku decyzji zarządzania operacyjnego → niejednorodność i niekompletność danych, usunięcie błędnych danych
Semantyczna integracja danych	Koordinacja zbiorów danych z różnych systemów, opracowanie semantyki powiązań danych z różnych obszarów
Analiza danych	Modele i wzorce przetwarzania danych, dobór technologii pozwalających przetwarzać dane w czasie rzeczywistym na potrzeby określonych decyzji zarządzania operacyjnego
Interpretacja danych	Weryfikacja rezultatów analizy w odniesieniu do określonego kontekstu, dobór skali analizy pod kątem obszaru i przedziału czasu, wizualizacja danych

Źródło: Opracowanie własne na podstawie (Tabakow, Korczak, Franczyk 2014)

W zarządzaniu operacyjnym istotną rolę odgrywa możliwość szybkiej analizy danych, nawet w czasie zbliżonym do rzeczywistego. W związku z tym jednym z najważniejszych wyzwań, które już stoi przed naukowcami, jest rozwijanie służących temu odpowiednich metod analitycznych.

Systemy przedsiębiorstw produkcyjnych wykorzystujących IIoT generują każdego dnia więcej danych niż sieci społecznościowe. Jednakże wyzwania w zakresie Big Data nie ograniczają się do rozwiązania problemów szybkiego zapisu szeregów czasowych, przechowywania dużych zbiorów danych i odtwarzania ich w celu dokonania analiz.

Równie ważnym i trudnym problemem techniczno-organizacyjnym jest integracja danych pochodzących z różnych źródeł, dostarczanych w różnym czasie, na odmiennych poziomach agregacji i w innych formatach. Niezbędna jest zatem ich normalizacja i transformacja do formatu wymaganego przez narzędzia analizy i wizualizacji danych. Problem ten nabiera szczególnego znaczenia w warunkach

dynamicznych zmian pochodzenia danych (etap 6 proponowanego modelu). Zbiory danych mogą zawierać encje odmienne leksykalnie, ale równoznaczne lub powiązane w sensie semantycznym – np. opisujące ten sam proces z różnych perspektyw (zużycia materiałów, narzędzi, ich pochodzenia, warunków środowiska). Powiązanie takich informacji pozwala uzyskać dodatkową wiedzę na temat monitorowanego procesu i wyciągać na jej podstawie kolejne wnioski, np. poprzez badanie korelacji, wyznaczanie i porównywanie trendów, poszukiwanie wzorców, analizy przyczynowo-skutkowe itp.

Kluczem do wykorzystania tych danych przez operatorów automatycznych systemów produkcyjnych jest stworzenie użytecznych reprezentacji tematycznych (tzw. widoków), które pozwolą w czasie rzeczywistym monitorować proces produkcyjny w powiązaniu z innymi równolegle zachodzącymi procesami i reagować na wszelkie zakłócenia.

Rozwiązanie problemu integracji wymaga nowego podejścia do projektowania architektury danych, które uwzględniłoby rosnącą liczbę i różnorodność źródeł danych. W celu integracji różnorodnych źródeł danych coraz częściej stosuje się podejście bazujące na zasadach i standardach semantycznej sieci Web. Celem rozwiązań semantycznych jest dostarczenie zestandaryzowanego ujednoliconego sposobu dostępu do operacyjnych danych pochodzących z różnych systemów przedsiębiorstwa. Aby to osiągnąć, konstruowane są modele semantyczne opisujące znaczenie danych i ich wzajemne powiązania.

Integracja semantyczna pozwala odkrywać powiązania między danymi, jak np. dostarczony sygnał w czasie rzeczywistym o awarii urządzenia może być powiązany ze statusem innych urządzeń w tej samej chwili oraz pochodzącymi z innych źródeł danymi historycznymi, które mogą być powiązane z bieżącą awarią. Modele semantyczne pozwalają w tym przypadku uzyskać szerszy kontekst analizy zdarzeń w procesie produkcyjnym.

Zaletą technologii semantycznej sieci Web jest możliwość integracji danych bez ingerencji w źródła i mechanizmy ich powstawania. Modele semantyczne tworzą warstwę znaczeniową, która w uwarunkowaniach dynamicznych zmian otoczenia może być uzupełniana o nowe źródła i typy danych oraz ich wzajemne relacje. Zatem powiązanie możliwości, jakie daje przetwarzanie dużych zbiorów danych, z rozwiązaniami integracji semantycznej stwarza duże pole do poprawy szybkości reagowania i efektywności operacyjnej systemów wytwórczych.

Podsumowanie i wnioski

Rozwiązywanie dobrze rozpoznanych i zdefiniowanych problemów zarządzania operacyjnego związanych z zapewnieniem jakości, odpowiedniej wydajności parku maszynowego czy utrzymania zadanego poziomu kosztów produkcji realizowane jest tradycyjnie poprzez ciągłe doskonalenie i wdrażanie dobrych praktyk. W ciągu ostatnich kilkunastu lat przedsiębiorstwa żmudnie, z różnym skutkiem redukowały marnotrawstwo, optymalizując swoje procesy zgodnie z takimi koncepcjami jak Lean Production czy Six Sigma. Wykorzystywane są też specjalne metody i technologie mające zapewnić właściwą współpracę między dostawcami i partnerami.

Jednak mimo wielu wysiłków często nie udaje się osiągnąć zadowalających rezultatów. Wdrożenie koncepcji Przemysłu 4.0 powoli otwiera w tym obszarze nowe możliwości, które już dziś w niektórych sektorach, np. lotniczym czy farmaceutycznym, stają się rzeczywistością. Tym samym można założyć, że analiza Big Data pozwoli udoskonalić takie podejścia jak Just in Time czy Six Sigma, a być może będzie impulsem dla powstania nowych koncepcji zarządzania wykorzystujących w szerszym stopniu masowe dane dostępne w czasie zbliżonym do rzeczywistego. Kluczowe znaczenie dla usprawnienia zarządzania operacyjnego ma gromadzenie i analizowanie danych w celu poprawienia wydajności i elastyczności produkcji, a w efekcie – poprawy konkurencyjności poprzez oferowanie towarów lepszej jakości przy obniżonych kosztach działań operacyjnych. W zarządzaniu operacyjnym tkwi duży potencjał, który można rozwinąć poprzez wykorzystanie koncepcji Big Data, szczególnie w przypadku takich środowisk produkcyjnych, w których występuje duża złożoność i zmienność procesu oraz ograniczenia zdolności produkcyjnych. Najistotniejszymi zagadnieniami, które wymagają wykorzystania nowych narzędzi wspierających zarządzanie operacyjne, są:

- zapewnienie elastyczności reagowania na popyt,
- dynamiczne kształtowanie zdolności produkcyjnych,
- skrócenie czasów realizacji zleceń,
- wyeliminowanie nieterminowości realizacji zleceń,
- skrócenie czasów wdrożenia nowych produktów,
- wyeliminowanie kosztów związanych z zapasami,
- właściwa lokalizacja zasobów,
- odpowiednie zaprojektowanie zasileń systemu (surowcowych, energetycznych i in.),
- efektywne wykorzystanie zasobów,
- wysoki poziom utrzymania ruchu,
- redukcja odpadów,
- ekonomiczne wytwarzanie małych partii produkcyjnych.

Efekty, które są możliwe do uzyskania, zależą od zakresu integracji danych i zastosowanych technologii ich analizy. Możliwości usprawnienia dotyczą nie tylko dużych przedsiębiorstw, ale również firm z sektora MŚP, a nawet mikroprzedsiębiorstw. Jednak inwestowanie w rozwiązania Big Data w zarządzaniu operacyjnym odnosi się do sytuacji, w której uzyskane efekty przewyższą poniesione nakłady. Konieczne jest zatem powiązanie zaproponowanego modelu sukcesywnego wdrażania koncepcji Big Data z ilościową oceną jego efektów oraz z narzędziami szacowania kosztów.

W toku dalszych prac autorzy przewidują przeprowadzenie badań o charakterze systematycznego przeglądu literatury z wykorzystaniem metaanalizy. Będą one ukierunkowane na sformułowanie hipotez badawczych w dwóch obszarach:

1. pozyskiwania danych na potrzeby zarządzania operacyjnego, w tym:
 - metod oceny obecnie posiadanych w przedsiębiorstwie danych i ich integracji,
 - identyfikacji i oceny zewnętrznych i wewnętrznych źródeł danych,
 - narzędzi pozyskiwania danych;

2. analizy danych, w tym:

- narzędzi i technologii przetwarzania danych,
- określenia celów analizy danych na potrzeby zarządzania operacyjnego,
- sposobów udostępniania wyników analiz.

Przyjęto założenie, że z przeprowadzonych badań zostaną sformułowane odrębne wnioski dla każdego etapu modelu rozwoju wykorzystania Big Data w zarządzaniu działalnością operacyjną. W ten sposób będzie opracowany swoisty przewodnik dla przedsiębiorców rozważających rozwój tej technologii w swojej działalności produkcyjnej. Na dalszym etapie badań konieczne też stanie się rozważanie kwestii archiwizacji i zabezpieczenia danych.

Literatura

1. Boyd D., Crawford K. (2012), *Critical Questions for Big Data in Information*, „Communication & Society”, Vol. 15, Issue 5, s. 662-679.
2. Da Silveira G., Borenstein D., Fogliatto F.S. (2001), *Mass Customization: Literature Review and Research Directions*, „International Journal of Production Economics”, Vol. 72, Issue 1, s. 1-13.
3. Gobble M.M. (2014), *News and Analysis of the Global Innovation Scene*, „Research Technology Management”, November/December, Vol. 57, Issue 6, s. 2-8.
4. Gross R.G., Veeramuthu K. (2013), *Heading Towards Big Data Building a Better Data Warehouse for More Data, More Speed, and More Users*, Advanced Semiconductor Manufacturing Conference (ASMC) 24th Annual SEMI, Saratoga Springs.
5. Hermann M., Pentek T., Otto B. (2015), *Design Principles for Industrie 4.0 Scenarios: A Literature Review*, Working Paper, Nr 1, TU Dortmund University, Germany.
6. <http://www.gartner.com/it-glossary/big-data/> (dostęp: 05.03.2017).
7. Jacobs F.R., Chase R.B. (2008), *Operations and Supply Management. The Core*, McGraw-Hill, 2nd Edition.
8. Jacobs F.R., Chase R.B. (2013), *Operations and Supply Chain Management: The Core*, McGraw-Hill/Irwin, Series Operations and Decision Sciences, 3rd Edition.
9. Kagermann H., Wahlster W. (2013), *Securing the Future of German Manufacturing Industry: Recommendations for Implementing the Strategic Initiative Industrie 4.0*, Working Group, Acatech National Academy of Science and Engineering, Final Report of the Industrie 4.0, Germany.
10. Kagermann H., Wahlster W., Helbig J. (2013), *Recommendations for Implementing the Strategic Initiative Industrie 4.0. Final Report of the Industrie 4.0*, Working Group, National Academy of Science and Engineering, Germany.
11. Karlsson C. (2009), *Researching Operations Management*, [w:] Karlsson C. (ed.), *Researching Operations Management*, Taylor & Francis, New York, s. 43-83.
12. Laney D. (2001), *Application Delivery Strategies*, META Group, Stanford.
13. Lee H., Sohn I. (2016), *Fundamentals of Big Data Network Analysis for Research and Industry*, John Wiley & Sons, Hoboken.
14. Mayer-Schonberger V., Cukier K. (2013), *Big Data – A Revolution That Will Transform How We Live, Work, and Think*, An Eamon Dolan Book Houghton Mifflin Harcourt, Boston.
15. Pająk E., Klimkiewicz M., Kosieradzka A. (2014), *Zarządzanie produkcją i usługami*, PWE, Warszawa.

16. Pawełoszek I., Wieczorkowski J. (2015), *Big Data as a Business Opportunity: an Educational Perspective*, *Annals of Computer Science and Information Systems, Volume 5*, Proceedings of the 2015 Federated Conference on Computer Science and Information Systems, Polskie Towarzystwo Informatyczne, IEEE Computer Society Press, Warsaw, Los Alamitos, s. 1563-1568.
17. Polańska K., Wassilew A. (2015), *Analizy Big Data w serwisach społecznościowych*, „Nie-równości Społeczne a Wzrost Gospodarczy”, z. 44, cz. 2, s. 117-128.
18. PwC (2016), *Industry 4.0: Building the Digital Enterprise*, <https://www.pwc.com/gx/en/industries/industries-4.0/landing-page/industry-4.0-building-your-digital-enterprise-april-2016.pdf> (dostęp: 05.03.2017).
19. SGH (2017), <http://oferta.sgh.waw.pl/pl/studiamagisterskie/ada/Strony/default.aspx> (dostęp: 05.03.2017).
20. Tabakow M., Korczak J., Franczyk B. (2014), *Big Data – definicje, wyzwania i technologie informatyczne*, „Business Informatics”, nr 1(31), s. 138-153.
21. Wang L., Wang G. (2016), *Big Data in Cyber-Physical Systems Digital Manufacturing and Industry 4.0*, „International Journal Engineering and Manufacturing”, Vol. 6, No. 4, s. 1-8.
22. Waters D. (2001), *Zarządzanie operacyjne. Towary i usługi*, Wydawnictwo Naukowe PWN, Warszawa.

BIG DATA IN SUPPORTING OPERATIONAL MANAGEMENT OF MANUFACTURING ENTERPRISES

Abstract: The paper discusses the subject of application of Big Data to support operational activities of a manufacturing company. Big Data solutions offer significant improvement of operational factors related to speed, flexibility, efficiency and production costs. However it is also a big challenge for the company to find proper solutions and incur investment costs. The proposed model of successive implementation of Big Data was proposed by the Authors. The model allows for successive building and evaluation of effects of Big Data implementation. The example effects are presented in each of the proposed stages of implementation along with the accompanying dilemmas.

Keywords: Big Data, operational management, Industry 4.0, industrial internet, cyber-physical systems