

Ilona Pawełszek

Wydział Zarządzania
Politechniki Częstochowskiej

Rola kreatywności w analityce biznesowej w kontekście analizy danych marketingowych

Streszczenie

Wraz ze wzrostem zainteresowania tematyką analityki biznesowej pojawiło się zapotrzebowanie na specjalistów z dziedziny określanej mianem „data science”, czyli nauki poświęconej danym i ich analizie (algorytmom, narzędziom i zastosowaniom). W dobie dynamicznego rozwoju i upowszechnienia technologii informacyjnej jest ona warunkiem koniecznym do funkcjonowania na rynku, o konkurencyjności decyduje natomiast kreatywne wykorzystanie dostępnych danych i technologii. Niniejszy artykuł ma na celu wskazanie możliwości i obszarów działań kreatywnych w procesie analizy danych. Działania te mają na celu stworzenie wartości dodanej dla firmy i klienta. Rozważania zaprezentowane zostały na podstawie standardowego modelu procesu analizy danych CRISP-DM a wnioski są poparte obserwacjami i doświadczeniami autora, nabytymi podczas realizacji projektu eksploracji danych marketingowych sieci sklepów sprzedaży detalicznej w Polsce.

Słowa kluczowe: kreatywność, kompetencje, analityka biznesowa, analiza danych marketingowych

Kody klasyfikacji JEL: M31, J24, C55, C18

1. Wprowadzenie

Idea gromadzenia danych i wydobywania z nich wiedzy w celu tworzenia wartości biznesowej jest znana od lat, jednak obecnie tematyka ta nabiera szczególnego znaczenia praktycznego¹. Przedsiębiorstwa używały narzędzi inteligencji biznesowej od wielu dziesięcioleci a naukowcy studiowali zbiory danych, aby odkryć tajemnice wszechświata. Niektóre z algorytmów używanych obecnie, będące podstawą eksploracji danych, liczą sobie nawet kilkaset lat². Jednak skala zbiorów danych zmienia się, a wzrastająca ilość dostępnych danych i mocy obliczeniowej komputerów stwarza nowe możliwości ekstrapolacji informacji i wiedzy.

W dobie dynamicznego rozwoju technologii informacyjnej efektywne i innowacyjne wykorzystanie dostępnych danych w wielu przypadkach staje się podstawą konkurencyjności przedsiębiorstw³. W teorii i praktyce zarządzania organizacjami zawsze dostrzegano rolę informacji i potencjalnych wniosków płynących z jej analizy w celu podejmowania lepszych, inteligentniejszych i szybszych decyzji, przede wszystkim opartych na faktach. Zapotrzebowanie na pogłębioną wiedzę od dawna było motorem napędzającym rozwój narzędzi analizy danych i systemów wspomagania decyzji. Obecnie praca menedżerów staje się coraz bardziej uzależniona od technologii, wymagająca szybkości i trafności podejmowanych decyzji.

Mimo zwiększających się możliwości i roli technologii informacyjnej, skuteczność pracy menedżerów w coraz większym stopniu uzależniona jest od kreatywnego podejścia do rozwiązywania problemów przy wykorzystaniu posiadanych narzędzi i źródeł informacji⁴. Kwestia kreatywności staje się szczególnie ważna w świetle zwiększającej się liczby możliwości wyboru alternatywnych narzędzi analizy danych, źródeł informacji, możliwości ich łączenia i wizualizacji. Niniejszy artykuł ma na celu wskazanie miejsca i roli kreatywności w procesie biznesowej analityki danych. Szczegółowym celem jest odpowiedź na pytanie badawcze, na których etapach tego procesu i przy realizacji jakich szczegółowych zadań istnieje pole dla kreatywności. Kontekst kreatywności pojawił się podczas projektu realizowanego przez autorkę, który miał na celu wydobywanie wiedzy ze zbioru danych transakcyjnych udostępnionego przez sieć sprzedaży sklepów detalicznych z bielizną.

¹ M. Tabakow, J. Korczak, B. Franczyk, *Big Data – definicje, wyzwania i technologie informatyczne*, „Informatyka Ekonomiczna” 2014, nr 1(31).

² W 1763 r. opublikowano pośmiertnie artykuł autorstwa Thomasa Bayesa będący podstawą współczesnych algorytmów data mining, pozwalających zrozumieć skomplikowane realia oparte na szacowaniu prawdopodobieństwa. Natomiast w 1805 r. Adrien-Marie Legendre i Carl Friedrich Gauss stworzyli algorytm regresji i metodę najmniejszych kwadratów, które do dziś są kluczowymi narzędziami Data Mining.

³ R. Subashini, S. Rita, M. Vivek, *The Role of ICTs in Knowledge Management (KM) for Organizational Effectiveness*, „Communications in Computer and Information Science” 2012, vol. 270, s. 542–549, http://dx.doi.org/10.1007/978-3-642-29216-3_59.

⁴ T. Dewett, *Understanding the Relationship Between Information Technology and Creativity in Organizations*, „Creativity Research Journal” 2003, no. 15, s. 167–182.

2. Analiza danych w podejmowaniu decyzji biznesowych

Analityka danych jest dziedziną skupiającą się na badaniu surowych danych w celu znalezienia wzorców, testowania hipotez oraz prognozowania i wyciągania wniosków na temat rzeczywistości poprzez zastosowanie odpowiednich algorytmów. Odkrywane prawidłowości nie są z góry znane ani jawnie zaprezentowane w zbiorze danych, można je odkryć jedynie poprzez wnioskowanie. Jednak ilość danych, które są dostępne i mogą zawierać istotne fakty jest obecnie tak duża, iż niemożliwością jest ich przeanalizowanie bez pomocy komputera lub polegając wyłącznie na intuicji.

Analiza danych jest jedną z funkcji organizacji, ukierunkowaną na zdobywanie wiedzy niezbędnej do przygotowania i doskonalenia strategii biznesowych oraz planów marketingowych. Z punktu widzenia strategicznego do najważniejszych zadań należy ocena ryzyka działalności gospodarczej poprzez analizę danych statystycznych takich jak trendy sprzedaży i rynku w różnych sektorach gospodarki, pod kątem odkrywania i oceny szans oraz zagrożeń.

W dziedzinie marketingu analityka danych obejmuje procesy i technologie, które umożliwiają menedżerom ocenę sukcesu działań marketingowych. Jest to realizowane poprzez mierzenie efektywności różnych kanałów marketingowych (blogi, media społecznościowe, sklepy internetowe i tradycyjne). Dane marketingowe pozyskane w ten sposób mogą być konsolidowane w celu stworzenia całościowego obrazu działań firmy w obszarze kontaktów z klientem.

Można wyróżnić dwa podejścia do analityki biznesowej: deskrypcyjne i predykcyjne. Zadaniem tego pierwszego jest pomoc w poznaniu i zrozumieniu rzeczywistości poprzez charakterystykę danych i wyodrębnienie wzorców w nich zawartych. Analiza deskrypcyjna może się ograniczać do określonego punktu w czasie lub uwzględniać trendy w wybranym przedziale czasowym. Analizę tego typu stosuje się np. w celu badania efektywności finansowej, skuteczności działalności marketingowej, czy profilowania klientów. Rezultaty analizy mogą być użyte w celu wspomagania decyzji w każdym obszarze działalności a zatem analiza deskrypcyjna jest podstawowym źródłem informacji w zarządzaniu firmą.

Natomiast zadaniem analizy predykcyjnej jest stworzenie modeli, które pozwalają przewidzieć przyszłe zdarzenia na podstawie danych teraźniejszych i przeszłych. Analiza predykcyjna wykorzystuje statystykę, uczenie maszyn lub techniki data mining. W biznesie najczęściej wykorzystywana jest w celu przewidywania odpływu pracowników z organizacji, odejścia klientów firmy i ich lojalności.

3. Kompetencje i rola analityka danych

Do niedawna stanowisko analityka danych kojarzone było głównie z przetwarzaniem danych liczbowych za pomocą arkusza kalkulacyjnego. Jednak w ostatnich latach zawód ten nabrał znaczenia i zwiększyła się także świadomość roli i zadań analityków danych.

Analityka biznesowa obejmuje dużo większy zakres działań niż przetwarzanie danych liczbowych, prezentowanie ich w postaci raportów, tabel i wykresów przeznaczonych dla kierownictwa. Praca analityka biznesowego polega w dużej mierze na wnioskowaniu, które jest procesem prowadzącym do ustalenia nowych faktów na podstawie tego co jest już wiadome. Na przykład analiza dwóch odrębnych zbiorów danych, na temat pogody i wielkości zakupów określonych produktów, pozwala ustalić zależność pomiędzy nimi bądź stwierdzenie braku zależności. Jeśli taka zależność wystąpi, można na jej podstawie zbadać korelację i tworzyć modele predykcyjne pozwalające zaplanować z wyprzedzeniem akcje promocyjne. Analityka biznesowa jest stosowana w wielu gałęziach gospodarki w celu umożliwienia organizacjom podejmowania lepszych decyzji oraz weryfikowania istniejących teorii i modeli.

Analitik biznesowy powinien posiadać szereg kompetencji, wśród których najczęściej wymieniane to umiejętności gromadzenia i przygotowania danych do analizy, wykorzystania metod statystycznych, matematycznych, programowania i rozwiązywania problemów. Bardzo istotna jest także umiejętność postrzegania świata w sposób nieszablonowy, niezbędna do stawiania hipotez badawczych, szukania skojarzeń wzorców i zależności ukrytych w zbiorach danych.

Obecnie, w związku z rozwojem mediów elektronicznych i Internetu rzeczy, pojawia się coraz większy potencjał pozyskiwania wiedzy ze źródeł zewnętrznych – niezależnych od danej organizacji. Można przypuszczać, iż umiejętne wykorzystanie tych źródeł może przynieść niespotykaną dotąd wartość biznesową płynącą z lepszego poznania otoczenia i wyodrębnienia nowych zjawisk wpływających na funkcjonowanie przedsiębiorstwa (np. identyfikacja ryzyka, zachowań klientów i konkurencji). W tym obszarze pojawia się kolejne wyzwanie dla analityków danych, polegające na operowaniu danymi niestrukturalnymi bądź semi-strukturalnymi, które można pozyskać ze źródeł internetowych. Dane niestrukturalne nie posiadają predefiniowanego modelu, który można byłoby w prosty sposób importować do baz danych lub arkuszy kalkulacyjnych w celu analizy. Większość informacji wykorzystywanych na co dzień nie posiada wyraźnej struktury pozwalającej w efektywny, zautomatyzowany sposób wyodrębnić z nich fakty (są to np. dokumenty, e-maile, informacje publikowane w prasie i mediach społecznościowych). Pojawia się zatem zapotrzebowanie na specjalistów umiających wykorzystywać narzędzia analizy danych niestrukturalnych. Tutaj znaczenie ma analiza semantyczna i przetwarzanie języka naturalnego.

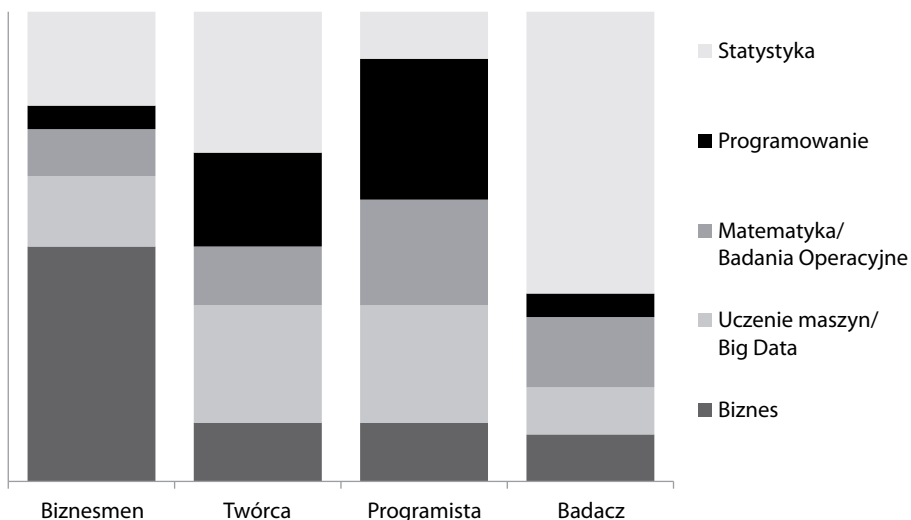
Można zatem powiedzieć, iż nauka o danych jest dziedziną, która obejmuje wszelkie działania związane z pozyskiwaniem, przygotowaniem i analizą danych w celu wydobycia z nich informacji i wiedzy. Rola zawodu analityka danych jest dostrzegana także w środowisku akademickim. Coraz więcej uczelni w Polsce i na świecie odpowiada na wyzwanie rynku tworząc nowe kierunki i specjalności kształcące analityków danych⁵, ukierunkowane

⁵ A. Jadczyk, *9 kierunków kształcących specjalistów od data science w Polsce*, 2015 <https://itwiz.pl/9-kierunkow-ksztalcacych-specjalistow-od-data-science-polsce/> (17.04.2018).

zwłaszcza na analizy Big Data⁶. Istnieje również potrzeba opracowywania nowych narzędzi i metod analitycznych potrafiących sprostać wyzwaniom płynącym z rozwoju i wzrostu znaczenia Internetu. W odpowiedzi na te potrzeby badacze zgłębiają zastosowania uczenia maszyn, rozpoznawania wzorców, sieci neuronowych oraz statystycznej analizy i wizualizacji danych. Zbiór działań w tym zakresie tworzy dziedzinę określaną mianem eksploracji danych, data mining (DM), drążeniem danych lub odkrywaniem wiedzy z danych (*Knowledge Discovery from Databases*, KDD).

Analitik danych jest praktykiem, który posiada kompetencje w ząębiających się obszarach: potrzeb biznesowych, wiedzy dziedzinowej, analityki, inżynierii oprogramowania i inżynierii systemów. Kompetencje w wymienionych dziedzinach mogą występować w różnych proporcjach w zależności od ukierunkowania na rozwiązywanie określonych problemów. Członkowie zespołów mogą posiadać różne proporcje umiejętności wzajemnie się uzupełniające i wyznaczające ich rolę w zespole. Różne kombinacje wiedzy i umiejętności zidentyfikowano w badaniu wykonanym przez firmę O'Reilly. Ze względu na różne proporcje kompetencji dziedzinowych, wyróżniono 4 nieformalne specjalizacje w analizie danych⁷: biznesmen, twórca, programista, badacz. Istotę zagadnienia dobrze obrazuje skumulowany wykres kolumnowy (rys. 1).

Rysunek 1. Proporcje kompetencji członków zespołów analitycznych



Źródło: Y. Demchenko, A. Belloum, T. Wiktorski, *EDISON Data Science Framework: Part 1. Data Science Competence Framework (CF-DS) Release 2*, 2017, http://edison-project.eu/sites/edison-project.eu/files/filefield_paths/edison_cf-ds-release2-v08_0.pdf (17.04.2018).

⁶ I. Pawełoszek, J. Wiczorkowski, *Big Data as a Business Opportunity: An Educational Perspective*, „Computer Science and Information Systems (FedCSIS)” 2015, Federated Conference on IEEE.

⁷ H.D. Harris, S.P. Murphy, M. Vaisman, *Analysing the Analysers. O'Reilly Strata Survey*, 2013, http://cdn.oreillystatic.com/oreilly/radarreport/0636920029014/Analyzing_the_Analysers.pdf (17.04.2018).

Należy zauważyć, iż obraz przedstawiony jako wynik badania O'Reilly jest niepełny, gdyż nie zawiera bardzo ważnego czynnika jakim są kompetencje interpersonalne. Jednak mimo to może być bardzo przydatny w procesie rekrutacji. Świadomość istnienia tych nieformalnych profili zawodowych pozwala lepiej zidentyfikować potrzeby firmy i dobrać odpowiednią osobę do realizacji określonych ról.

4. Istota kreatywności

Analizując oferty pracy, nie tylko na stanowiska gdzie praca jest typowo umysłowa, można zauważyć, iż wśród pracodawców często pojawia się zapotrzebowanie na osoby kreatywne. Można zatem sądzić, iż kreatywność jest cechą osobowości wpływającą w istotny sposób na jakość pracy, jak również na potencjał organizacji w zakresie innowacji i konkurencyjności na rynku⁸. W obecnych czasach technologia informacyjna jest tak rozpowszechniona, iż można założyć, że każdy uczestnik rynku ma dostęp do mniej więcej zbliżonych możliwości obliczeniowych i źródeł danych. Zatem wartość dodana, pozwalająca wyróżnić firmę na tle konkurencji może być uzyskana jedynie poprzez kreatywne wykorzystanie dostępnych zasobów. Jak dotąd kreatywność jest cechą typowo ludzką, chociaż od dawna powstają inicjatywy naukowo-badawcze mające na celu wyposażenie w tę cechę narzędzi sztucznej inteligencji⁹. Jednak mimo wielu ciekawych efektów, człowiek jest jak na razie pod względem kreatywności bezkonkurencyjny.

Pojęcie kreatywności posiada wiele definicji, często utożsamiane jest z twórczością. Według E. Nęckiej¹⁰ kreatywność obejmuje zarówno cechy intelektu, jak i aspekty motywacyjne oraz cechy osobowości. Działanie kreatywne ma na celu generowanie rozwiązań nowych/oryginalnych i zarazem wartościowych pod względem poznawczym, estetycznym, pragmatycznym lub etycznym¹¹. Według M.I. Steina¹² kreatywność jest procesem prowadzącym do powstania czegoś nowego, co jest akceptowane i uznawane za użyteczne dla określonej grupy odbiorców w pewnym okresie. Kreatywność jest w sposób oczywisty powiązana z wielowymiarowością analizowanego problemu i swobodą działania¹³, dlatego tak ważne jest postrzeganie przez kierownictwo obszarów działania o choćby najmniejszym potencjale kreatywnym pozwalającym stworzyć dodatkową wartość dla klienta bądź organizacji. Wartość

⁸ E. Miron, M. Erez, E. Naveh, *Do Personal Characteristics and Cultural Values that Promote Innovation, Quality, and Efficiency Compete or Complement Each Other?* „Journal of Organizational Behavior” 2004, no. 25, s. 175–199.

⁹ M.A. Boden, *Creativity and Artificial Intelligence*, „Artificial Intelligence Journal” 1998, no. 103, s. 347–356.

¹⁰ E. Nęcka, *Twórczość*, w: *Psychologia. Podręcznik akademicki*, t. 2, red. J. Strelau, Gdańsk 2000.

¹¹ K. Szczepańska-Woszczyzna, *Kompetencje menedżerskie w obszarze innowacyjności i kreatywności*, ZS WSH, „Zarządzanie” 2014, nr 1, s. 101–110.

¹² M.I. Stein, *Creativity and Culture*, „Journal of Psychology” 1953, vol. 36.

¹³ K. Ferlic, *Creativity Perspective on Multidimensional and Infinitely Dimensional*, 2006, http://ryuc.info/common/creativity_perspective/cp_on_multidimensional.htm (17.04.2018).

dla klienta w sposób oczywisty przekłada się na zyski firmy i jej wizerunek, natomiast wartość dla organizacji może stanowić o zadowoleniu pracowników, większej efektywności ich działania bądź tworzeniu kapitału intelektualnego.

Z punktu widzenia analityki danych ciekawe ujęcie kreatywności zaprezentowała Rosabeth Moss Kanter, której zdaniem, kreatywność jest specyficzną umiejętnością myślenia kalejdoskopowego, które polega na „wstrząśnięciu” posiadanymi informacjami, aby ułożyć je w nową całość, która łamie powszechnie przyjęte schematy¹⁴. Nieco inny punkt widzenia prezentuje L. Neiman¹⁵, założycielka „Creativity at Work” – międzynarodowego konsorcjum ekspertów kreatywności i innowacji. Definiuje kreatywność jako akt przekształcania nowych, pomysłowych koncepcji w rzeczywistość. Jej zdaniem nieodłącznym elementem kreatywności oprócz myślenia jest twórcze działanie. Zatem w tym ujęciu osoba, która ma pomysły, ale nie pracuje nad ich realizacją jest jedynie pomysłowa, ale nie kreatywna.

Analizując różne definicje można stwierdzić, iż kreatywność to zdolność do tworzenia połączona z twórczym zapałem, rozumieniem i docenianiem celu twórczego działania oraz odwagą do realizacji swoich wizji. Większość autorów traktuje kreatywność jako cechę osobowości, przy czym podkreślany jest fakt, iż kreatywności można się nauczyć. Wiele opracowań podejmuje temat zależności pomiędzy posiadaną wiedzą a kreatywnością w różnych dziedzinach¹⁶. Zależność ta jednak nie jest tak prosta i oczywista jakby się z pozoru mogło wydawać. Wiedza jest podstawą kreatywności i innowacyjności, lecz w pewnych warunkach może także je hamować¹⁷. Doświadczenie i liczne obserwacje poczynione przez autorkę w środowisku naukowym i biznesowym pozwalają potwierdzić tezę, iż kreatywność w procesie analizy danych jest w bezpośredni sposób powiązana z posiadaną wiedzą. Można tutaj odwołać się do wcześniej przedstawionej definicji R. Kanter, która porównuje proces kreatywny do wstrząśnięcia kalejdoskopem. Różnorodność obrazów generowanych przez kalejdoskop jest związana z ilością elementów jakimi to narzędzie dysponuje. Można sądzić, iż podobnie jest w przypadku kreatywności ludzkiej – im więcej elementów wiedzy i informacji tym większa liczba możliwych do stworzenia konfiguracji. Kalejdoskop jest dość prostym narzędziem, generującym losowe kombinacje z posiadanego zbioru elementów, zatem porównanie to stanowi duże uproszczenie. W przypadku wiedzy ludzkiej istotne znaczenie ma umiejętność znalezienia połączeń między posiadanymi elementami wiedzy, i to takich połączeń, które

¹⁴ R.M. Kanter, *eVolve: Succeeding in the Digital Culture of Tomorrow*, Harvard Business School Press, Boston 2001, s. 261.

¹⁵ L. Neiman, *Creativity at Work: What is Creativity?*, 2012, <http://www.creativityatwork.com/2014/02/17/what-is-creativity/> (17.04.2018).

¹⁶ A. Sokół, I. Figurska, *Creativity As One of the Core Competencies of Studying Knowledge Workers*, „Entrepreneurship and Sustainability Issues” 2017, no. 5(1), s. 23–35; B. Ibrahim, M.A. DeMiranda, T.J. Siller, *The Correlation Between Creativity and Engineering Knowledge Among Engineering Undergraduate Students*, „Institute of Electrical and Electronics Engineers Inc.” 2016, no. 38, DOI: 10.1109/ICEED.2016.7856090; A.M. Smith, M. Mateas, *Knowledge-Level Creativity in Game Design*, Proceedings of the 2nd International Conference on Computational Creativity ICC3, 2011.

¹⁷ D. Leonard, M. Barton, *Knowledge and the Management of Creativity and Innovation*, w: *The Oxford Handbook of Innovation Management*, red. M. Dodgson, D. Gann, N. Phillips, Oxford University Press, 2014.

będą przynosiły wartość dodaną w postaci nowych, użytecznych rozwiązań. W omawianej dziedzinie analityki biznesowej wiedza ta jest wielotematyczna i obejmuje zarówno zagadnienia, jak i metody z zakresu pozyskiwania danych, źródeł, obróbki danych, algorytmów ich przetwarzania, jak i technik wizualizacji. Ważną umiejętnością jest też poszukiwanie brakujących elementów, czyli uzupełnianie wiedzy.

5. Identyfikacja roli kreatywności w procesie analizy danych

Większość rozwiązań w dziedzinie analizy danych jest budowana na podstawie istniejących algorytmów i dostępnych narzędzi informatycznych. W celu identyfikacji roli i miejsca kreatywności w procesie analizy danych postanowiono przeanalizować kolejne kroki tego procesu wraz z możliwymi wariantami ich wykonania. Założono, iż miejsce dla kreatywności pojawia się w szczególności w procesach, w których poszczególne kroki nie są do końca ustrukturyzowane i dzięki temu stwarzają możliwość wprowadzenia własnych rozwiązań, nieszablonowego postępowania lub wykorzystania metod i źródeł danych już znanych, które dotąd nie były stosowane w danym obszarze.

Eksploracja danych powinna być procesem niezawodnym i powtarzalnym, w którym obok analityków uczestniczą także menedżerowie, nie koniecznie posiadający wykształcenie z zakresu analizy danych. Dlatego też w latach 90. opracowano standard procesu data mining, znany jako The Cross-Industry Standard Process for Data Mining CRISP-DM, który jest rezultatem wielu prac badawczych z udziałem ponad 300 organizacji¹⁸. Model ten stanowi specyfikację działań, wyznacza wskazówki i dobre praktyki w zakresie eksploracji danych. Według modelu CRISP-DM odkrywanie wiedzy z danych jest procesem cyklicznym składającym się z 6 etapów. W ramach każdego z etapów zdefiniowane są zadania, które należy zrealizować. Model ten zakłada, że zbieranie i analiza danych nie mogą być prowadzone bez zrozumienia kontekstu funkcjonowania organizacji¹⁹. Wskazuje także, że ostatecznym celem analizy danych jest pozyskanie wiedzy pozwalającej na wdrożenie praktycznych rozwiązań. Założeniem modelu jest także płynność przechodzenia pomiędzy etapami. Rysunek 2 przedstawia schemat modelu CRISP-DM, na którym uwzględniono współpracę zespołów biznesowego i analitycznego oraz wyróżniono linią przerywaną szczegółowe działania, w których kreatywność zajmuje kluczowe miejsce.

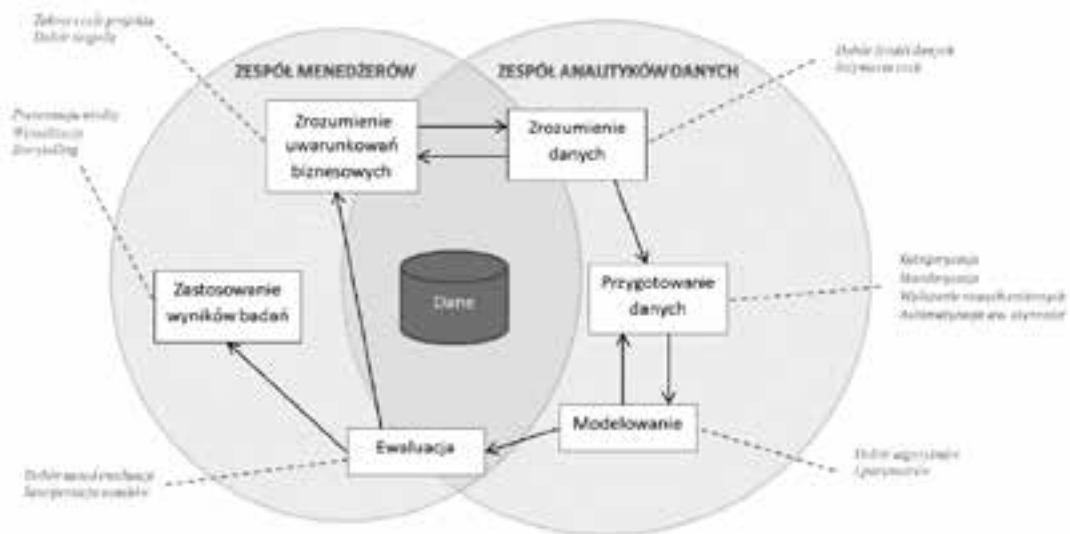
Pierwszym etapem wyróżnionym w modelu CRISP-DM jest zrozumienie potrzeb biznesowych. W trakcie tego etapu podejmowane są kluczowe decyzje mające wpływ na dalsze działania. Wyznaczanie zakresu projektu (*project scoping*) jest typem analizy *ex-ante*, która pozwala ocenić projekt zanim zostanie formalnie uruchomiony, ustalić na jakie pytania

¹⁸ Data Mining Processes, 2012, <http://www.zentut.com/data-mining/data-mining-processes/> (17.04.2018).

¹⁹ K. Kulikowski, *Zastosowanie modelu Cross Industry Standard Process for Data Mining (CRISP-DM) w badaniach postaw i opinii pracowników*, „Zeszyty Naukowe Politechniki Śląskiej”, Seria: „Organizacja i Zarządzanie” 2015, no. 82, s. 111–121.

ma odpowiadać model i kto będzie odbiorcą analiz. Na tym etapie podjęta jest już decyzja o realizacji projektu, jednak należy zdecydować, jak projekt będzie zorganizowany, zwłaszcza jaki jest jego cel (na jakie pytania ma odpowiadać model i kto będzie jego odbiorcą), skala działania i kluczowe założenia (na przykład objęcie analizą określonych segmentów rynku, grupy klientów a wykluczenie innych), jakie są możliwe czynniki ryzyka niepowodzenia. Ważnym zadaniem jest także określenie zapotrzebowania na zasoby do realizacji projektu, w przypadku analizy danych jest to dobór źródeł danych, zewnętrznych bądź wewnętrznych a także zasoby ludzkie, czyli dobór członków zespołu.

Rysunek 2. Etapy procesu CRISP-DM



Źródło: opracowanie własne na podstawie: C. Shearer, *The CRISP-DM Model: The New Blueprint for Data Mining*, „Journal of Data Warehousing” 2000, no. 5, s. 13–22.

Jak pokazują badania, przedsiębiorstwa wykorzystują do celów analitycznych głównie dane pozyskiwane z własnych systemów transakcyjnych i większość przedsiębiorstw uważa te dane za najbardziej wartościowe. Można zatem sądzić, iż przełamanie tego stereotypu i ukierunkowanie analiz w stronę większego wykorzystania zewnętrznych zbiorów danych może tworzyć wartość dodaną dla biznesu wynikającą z kreatywnego podejścia. Ciekawą opcją jest zaangażowanie klientów w tworzenie innowacyjnych rozwiązań przedsiębiorstw kreatywnych²⁰. Rozwój tego typu relacji jest często ukierunkowany na analizę danych portali społecznościowych, gdzie klienci mają swobodę wyrażania opinii i sugestii.

Tradycyjnie dane używane w procesach analitycznych mają postać strukturalną – tabel wydobytych z relacyjnych baz danych. Jednak obecnie technologia stwarza możliwości

²⁰ D. Jelonek, *Rola klienta w rozwoju organizacji kreatywnej*, „Studia Ekonomiczne. Zeszyty Naukowe Uniwersytetu Ekonomicznego w Katowicach” 2012, nr 113.

pozyskiwania i gromadzenia danych np. stron internetowych, baz danych i dokumentów udostępnianych przez inne organizacje oraz inteligentnych sieci różnego typu obiektów komunikujących się w ramach Internetu Rzeczy. Wraz z popularyzacją sieci Web i dokumentów tekstowych coraz większą wagę zyskują techniki eksploracji tekstu (*text mining*) oraz grafów. Szczególnego znaczenia nabiera zatem kwestia doboru członków zespołu analitycznego, przy czym należy zwrócić uwagę na kompetencje, które wykraczają poza standardowe wymagania Data Mining, jak np. znajomość zastosowań ontologii, Linked Data, przetwarzania języka naturalnego i analizy sentymentu²¹.

Z doświadczeń i obserwacji autorki wynika, iż największe pole do działań kreatywnych stwarza etap zrozumienia danych. Zwłaszcza inżynieria cech jest działaniem w procesie analizy danych stwarzającym duże możliwości kreatywnego podejścia. Jest to sztuka tworzenia nowych zmiennych w zbiorze danych na podstawie tych już istniejących oraz wykorzystania zewnętrznych zbiorów danych i wiedzy dziedzinowej analityka. Inżynieria cech jest jedną z najistotniejszych technik mających wpływ na wartość informacyjną analizy, jej zasięg i przydatność. Nowe zmienne pozwalają wydobyć ze zbioru danych fakty, które mogą wzbogacić analizę, zmienić jej perspektywę, odkryć nowe zależności i nowe klasyfikacje.

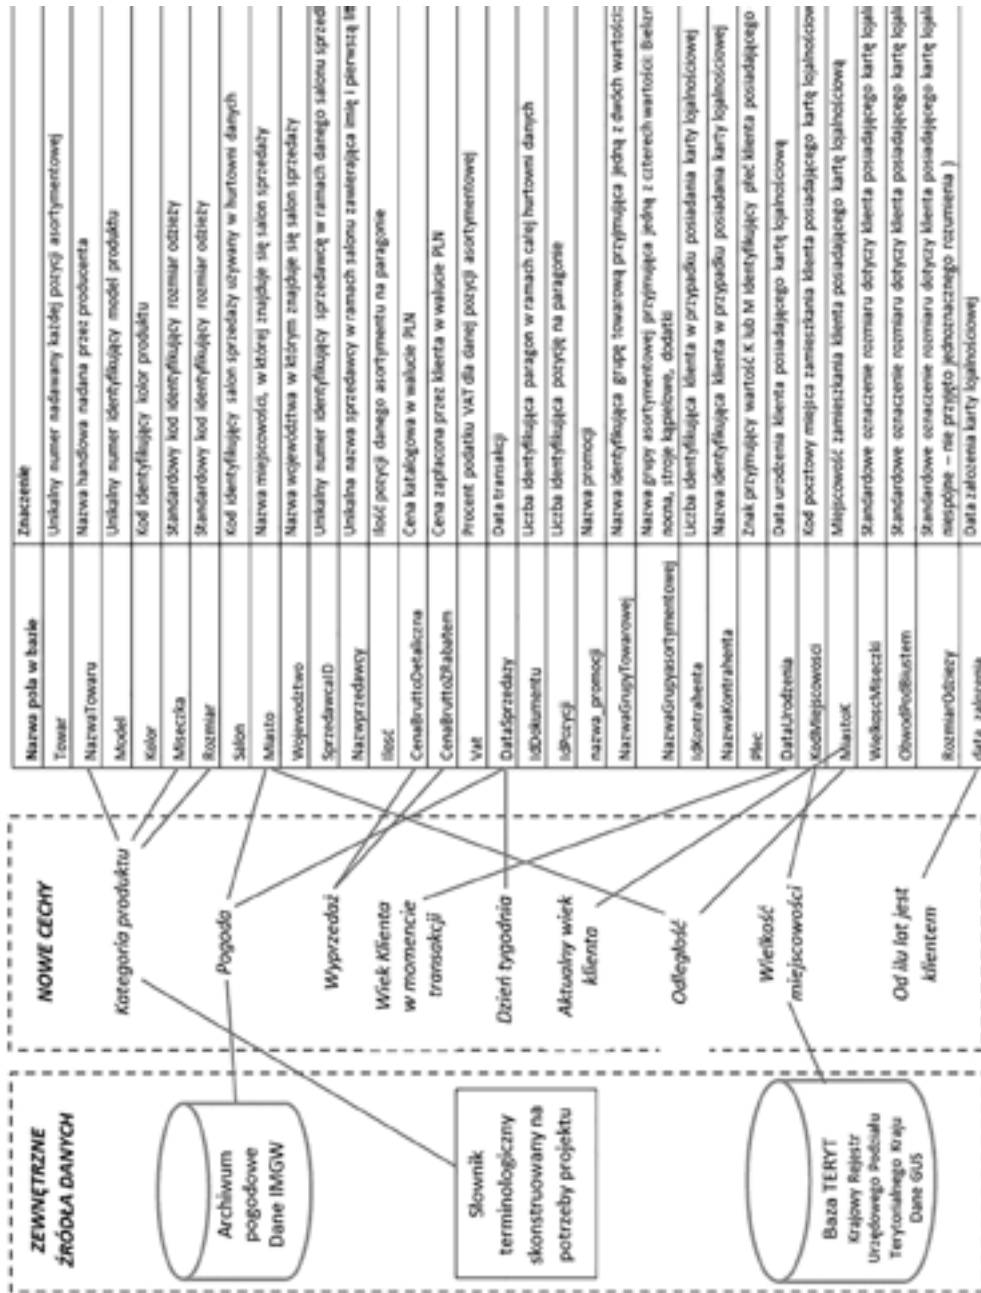
W inżynierii cech główne znaczenie obok rozumienia danych ma umiejętność kojarzenia. Kreatywność uruchamiana jest w przypadku odkrywania, w jaki sposób zmienne są wzajemnie powiązane oraz jakie relacje łączą je ze światem rzeczywistym. Dostrzeżenie takich relacji umożliwi wyznaczenie nowych zmiennych poprzez stworzenie cech pochodnych, standaryzację czy dyskretyzację. Wiedza dziedzinowa pozwala stwierdzić, czy nowe cechy są przydatne, jak zmiany ich wartości wpływają na środowisko i odwrotnie – w jaki sposób parametry środowiska wpływają na wartości zmiennych.

Nową zmienną można wyznaczyć opierając się na już istniejących polach w zbiorze danych bądź poprzez zestawienie z zewnętrznym zbiorem danych. Zbiory danych mogą być łączone tematycznie w celu uzyskania nowego spojrzenia na badane zjawisko, w konsekwencji dochodzi do odkrywania nowych, często do tej pory nieznanych zależności między danymi, a nawet do odkrywania nowych zjawisk przydatnych w procesach poznawczych, badawczych czy decyzyjnych. Rysunek 3 przedstawia przykład tworzenia nowych zmiennych w zbiorze danych marketingowych, które są przedmiotem projektu badawczego z zakresu analizy danych prowadzonego przez autorkę artykułu.

Ciekawym i obiecującym kierunkiem rozwoju eksploracji danych jest zastosowanie paradygmatu Linked Data do łączenia różnych zbiorów danych. Podejście takie daje niemalże nieograniczone możliwości kombinacji semantycznie powiązanych informacji i odkrywania w tych połączeniach nowych nieznanych dotąd zależności.

²¹ L. Ziora, *The Sentiment Analysis As a Tool of Business Analytics in Contemporary Organizations*, „Studia Ekonomiczne, Zeszyty Naukowe Uniwersytetu Ekonomicznego w Katowicach” 2016, nr 281.

Rysunek 3. Nowe źródła i cechy zbioru danych marketingowych stworzone w wyniku inżynierii cech



Źródło: opracowanie własne.

Etap przygotowania danych jest najbardziej czasochłonny w całym procesie analitycznym. Dane wydobyte z hurtowni danych, bądź ze źródeł zewnętrznych o różnej strukturze i formacie należy przystosować do wymagań algorytmów DM. Ze względu na dużą ilość danych zadanie to nie sposób wykonać manualnie. Przydaje się umiejętność programowania i stworzenia algorytmów, które wykonają to zadanie jak najszybciej przy dostępnych zasobach mocy obliczeniowej komputera i z minimalną ingerencją człowieka.

Ideą eksploracji danych jest, jak wspomniano, w pierwszym rzędzie odkrywanie nowych, nieznanych, użytecznych i prawidłowych wzorców ukrytych w zbiorze danych. Jednak często wykorzystywanym podejściem jest również testowanie określonych hipotez, (wynikających np. z obserwacji), które są wstępnie postawione przed dokonaniem jakichkolwiek analiz. Hipotezą taką może być założenie, iż w zbiorze danych istnieją interesujące prawidłowości, które można odkryć na przykład za pomocą metod klasteryzacji. Następnie wygenerowane klastry można interpretować, czyli odkrywać reguły przyporządkowania instancji do określonego klastra za pomocą np. drzew decyzyjnych.

Przy tworzeniu modeli analitycznych kluczowe znaczenie ma wybór atrybutów. W przypadku budowy drzew decyzyjnych, które są jedną z najczęściej stosowanych technik klasyfikacji. Wybór atrybutów decyduje o efektywności i trafności wyników²². Celem jest wygenerowanie takiego drzewa, które jak najtrafniej sklasyfikuje dane. Uzyskany model powinien być jak najprostszy według zasady Brzytwy Ockhama²³.

Etap ewaluacji polega na ocenie zastosowanych modeli pod względem ich praktycznej użyteczności. Pytania, na które należy odpowiedzieć na etapie ewaluacji, to w szczególności: Czy model spełnił postawione na wstępie założenia biznesowe? Czy jakieś cele biznesowe lub badawcze nie zostały uwzględnione? Czy wyniki dały zadowalające odpowiedzi na pytania? Ewaluacja koncentruje się także na ocenie całego procesu, jaki doprowadził do stworzenia modeli. Na tym etapie ustala się kolejne kroki postępowania. Jeśli efekty nie są zadowalające można powrócić do odpowiedniego etapu w cyklu analizy danych, aby skorygować nieprawidłowości.

Na etapie interpretacji danych, wiedza uzyskana z danych jest asymilowana w procesie twórczej aktywności poznawczej. Etap ten ma na celu rozpoznanie wartości biznesowej wzorców wygenerowanych przez algorytmy Data Mining i odpowiednia wizualizacja. Identyfikacja wartości biznesowej jest zadaniem podobnym do układanki, w której elementami są fakty wydobyte w procesie eksploracji danych, które należy ułożyć w całość w taki sposób, aby były przydatne do celów biznesowych. Ten etap oparty jest na współdziałaniu analityków i menedżerów, bowiem znaczenie wzorców uzyskanych w procesie eksploracji danych musi być wyjaśnione a zdobyta wiedza powiązana z postawionymi na początku celami projektu.

²² B. Baykara, *Impact of Evaluation Methods on Decision Tree Accuracy*, University of Tampere, Finland 2015, <http://tampub.uta.fi/bitstream/handle/10024/97207/GRADU-1432814149.pdf;sequence=1> (17.04.2018).

²³ Zasada opracowana przez Williama Ockhama na przełomie XIII i XIV wieku, zgodnie z którą w wyjaśnianiu zjawisk należy dążyć do prostoty, wybierając takie wyjaśnienia, które opierają się na jak najmniejszej liczbie założeń i pojęć. T. Mitchell, *Decision Tree Learning*, „Machine Learning” 1997, no. 414, McGraw Hill.

W celu właściwej interpretacji wzorców kluczowe znaczenie ma dobór narzędzi wizualizacji, co wymaga dużej kreatywności. Zastosowanie skomplikowanych algorytmów i uzyskanie wyników powinno prowadzić do pewnych wniosków, które trzeba wytłumaczyć i uzasadnić ich przydatność oraz zilustrować skalę problemu. Jest dostępnych wiele możliwości, zarówno prostych jak wykresy kołowe, histogramy, jak i bardziej zaawansowanych np. infografiki, użycie animacji, symboli i metafor. W przekazywaniu wiedzy, bardzo skuteczna okazuje się metoda opowiadania historii (*storytelling*), która zyskuje ostatnio na popularności w kręgach marketingu. Okazuje się, iż może ona być skuteczna także w komunikacji zespołu analitycznego z odbiorcami – decydentami. Dobra i interesująca interpretacja rozpala emocje i kreatywność, prowadzi do efektywnych decyzji biznesowych, natomiast słaba i nieciekawa interpretacja może być bezużyteczna i prowadzić do niedostrzeżenia pojawiających się okazji.

6. Podsumowanie

Obecnie dane produkowane są w wielkich ilościach, w podobnym tempie rosną także możliwości ich gromadzenia i moc obliczeniowa komputerów. Istnieje zatem duży potencjał wydobywania z danych użytecznej wiedzy w celu wspomaganie decyzji biznesowych. Wiedza potencjalnie użyteczna w podejmowaniu decyzji może być ukryta w wielu zewnętrznych zbiorach danych, które stworzone były dla innych celów niż wspomaganie działalności marketingowej. Wykorzystanie tego potencjału zależy jednak od kreatywności menedżerów i analityków. Menedżerowie dzięki współpracy z analitykami danych poznają nowe fakty, oceniają ich przydatność i dostrzegają nowe okazje. Natomiast analitycy inspirowani celami biznesowymi znajdują nowe możliwości i użyteczne źródła danych. Obecnie kształtująca się dziedzina wiedzy, jaką jest Data Science, skupia się na dużych, dynamicznie zmieniających się zbiorach danych. Kombinacja powiązanych dziedzin takich jak Data Mining, statystyka czy wizualizacja danych stwarza pole ogromne do kreatywnego działania i poszukiwań badawczych. W niniejszym artykule poświęcono uwagę procesowi wydobywania wiedzy z danych pod kątem wyodrębnienia możliwości działań kreatywnych. Przedstawiona analiza ma za zadanie naświetlić aspekty procesu analizy danych zmierzające do uzyskania wartości dodanej mającej potencjał wyróżnienia firmy spośród konkurencji. Przedstawione etapy procesu wg metodyki CRISP-DM stanowią ogólne ramy analityki biznesowej, systematyzują proces analizy danych dając jednak spore pole manewru i możliwości wprowadzania nowych rozwiązań. Podsumowując rozważania, można stwierdzić, iż największe znaczenie w kreatywnym procesie analityki biznesowej ma odpowiedni dobór członków zespołu, tak aby ich kompetencje wzajemnie się uzupełniały w obszarach biznesu, analityki i zadań typowo informatycznych. Drugim ważnym elementem jest jasne zdefiniowanie celów biznesowych analizy i zapewnienie zespołowi swobody działania w obszarach takich jak dobór źródeł danych, algorytmów i metod wizualizacji.

Temat eksploracji danych cieszy się nieustającą popularnością, ponieważ wiedza uzyskana w procesie analitycznym jest aktualna na dany moment, natomiast zachowania klientów zmieniają się w czasie. Dlatego też wymagane jest ciągle i kreatywne doskonalenie opracowanych modeli analitycznych i metod rozwiązywania problemów. Można sądzić, iż dziedzina eksploracji danych będzie coraz istotniejsza dla biznesu a jednocześnie wymagająca kreatywnych podejść w związku z rozszerzaniem się wachlarza źródeł danych, metod ich pozyskiwania i narzędzi służących ich przetwarzaniu.

Bibliografia

1. Boden M.A., *Creativity and Artificial Intelligence*, „Artificial Intelligence Journal” 1998, no. 103, s. 347–356.
2. Dewett T., *Understanding the Relationship Between Information Technology and Creativity in Organizations*, „Creativity Research Journal” 2003, no. 15, s. 167–182.
3. Ibrahim B., DeMiranda M.A., Siller T.J., *The Correlation Between Creativity and Engineering Knowledge Among Engineering Undergraduate Students*, „Institute of Electrical and Electronics Engineers Inc.” 2016, no. 38, DOI: 10.1109/ICEED.2016.7856090.
4. Jelonek D., *Rola klienta w rozwoju organizacji kreatywnej*, „Studia Ekonomiczne. Zeszyty Naukowe Uniwersytetu Ekonomicznego w Katowicach” 2012, nr 113.
5. Kanter R.M., *eVolve: Succeeding in the Digital Culture of Tomorrow*, Harvard Business School Press, Boston 2001, s. 261.
6. Kulikowski K., *Zastosowanie modelu Cross Industry Standard Process for Data Mining (CRISP-DM) w badaniach postaw i opinii pracowników*, „Zeszyty Naukowe Politechniki Śląskiej”, Seria: „Organizacja i Zarządzanie” 2015, no. 82, s. 111–121.
7. Leonard D., Barton M., *Knowledge and the Management of Creativity and Innovation*, w: *The Oxford Handbook of Innovation Management*, red. M. Dodgson, D. Gann, N. Phillips, Oxford University Press, 2014.
8. Miron E., Erez M., Naveh E., *Do Personal Characteristics and Cultural Values that Promote Innovation, Quality, and Efficiency Compete or Complement Each Other?* „Journal of Organizational Behavior” 2004, no. 25, s. 175–199.
9. Mitchell T., *Decision Tree Learning*, „Machine Learning” 1997, no. 414, McGraw Hill.
10. Nęcka E., *Twórczość*, w: *Psychologia. Podręcznik akademicki*, t. 2, red. J. Strelau, Gdańsk 2000.
11. Pawełozek I., Wieczorkowski J., *Big Data as a Business Opportunity: An Educational Perspective*, „Computer Science and Information Systems (FedCSIS)” 2015, Federated Conference on IEEE.
12. Shearer C., *The CRISP-DM Model: The New Blueprint for Data Mining*, „Journal of Data Warehousing” 2000, no. 5, s. 13–22.
13. Smith A.M., Mateas M., *Knowledge-Level Creativity in Game Design*, Proceedings of the 2nd International Conference on Computational Creativity ICC3, 2011.
14. Sokół A., Figurska I., *Creativity As One of the Core Competencies of Studying Knowledge Workers*, „Entrepreneurship and Sustainability Issues” 2017, no. 5(1), s. 23–35.

15. Stein M.I., *Creativity and Culture*, „Journal of Psychology” 1953, vol. 36.
16. Subashini R., Rita S., Vivek M., *The Role of ICTs in Knowledge Management (KM) for Organizational Effectiveness*, „Communications in Computer and Information Science” 2012, vol. 270, s. 542–549, http://dx.doi.org/10.1007/978-3-642-29216-3_59 (17.04.2018).
17. Szczepańska-Woszczyzna K., *Kompetencje menedżerskie w obszarze innowacyjności i kreatywności*, ZS WSH, „Zarządzanie” 2014, nr 1, s. 101–110.
18. Tabakow M., Korczak J., Franczyk B., *Big Data – definicje, wyzwania i technologie informacyjne*, „Informatyka Ekonomiczna” 2014, nr 1(31).
19. Ziora L., *The Sentiment Analysis As a Tool of Business Analytics in Contemporary Organizations*, „Studia Ekonomiczne, Zeszyty Naukowe Uniwersytetu Ekonomicznego w Katowicach” 2016, nr 281.

Materiały internetowe

1. Baykara B., *Impact of Evaluation Methods on Decision Tree Accuracy*, University of Tampere, Finland 2015, <http://tampub.uta.fi/bitstream/handle/10024/97207/GRADU-1432814149.pdf;sequence=1> (17.04.2018).
2. Data Mining Processes, 2012, <http://www.zentut.com/data-mining/data-mining-processes/> (17.04.2018).
3. Demchenko Y., Belloum A., Wiktorski T., *EDISON Data Science Framework: Part 1. Data Science Competence Framework (CF-DS) Release 2*, 2017, http://edison-project.eu/sites/edison-project.eu/files/filefield_paths/edison_cf-ds-release2-v08_0.pdf (17.04.2018).
4. Ferlic K., *Creativity Perspective on Multidimensional and Infinitely Dimensional*, 2006, http://ryuc.info/common/creativity_perspective/cp_on_multidimensional.htm (17.04.2018).
5. Harris H.D., Murphy S.P., Vaisman M., *Analysing the Analysers. O’Reilly Strata Survey*, 2013, http://cdn.oreillystatic.com/oreilly/radarreport/0636920029014/Analyzing_the_Analyzers.pdf (17.04.2018).
6. Jadczyk A., *9 kierunków kształcących specjalistów od data science w Polsce*, 2015 <https://itwiz.pl/9-kierunkow-ksztalcacych-specjalistow-od-data-science-polsce/> (17.04.2018).
7. Neiman L., *Creativity at Work: What is Creativity?*, 2012, <http://www.creativityatwork.com/2014/02/17/what-is-creativity/> (17.04.2018).

The Role of Creativeness in Business Analysis in the Context of Marketing Data Analysis

Summary

As the interest in business analytics was growing, there was a demand for specialists in the area called *data science*, i.e. the science devoted to data and their analysis (algorithms, tools and applications). In the era of the dynamic development and popularization of information technology, it is a prerequisite for the market operation; and competitiveness is determined by the creative application of available data and technologies. The aim of this article is to indicate the possibilities and areas of creative activities in the process of data analysis. These activities are meant to create value added for the company and customers. The presented considerations are based on a standard model of data analysis process CRISP-DM, and the conclusions are supported by the author's observations and experience acquired in the course of implementation of the project exploring the marketing data of retail shops in Poland.

Keywords: creativeness, competences, business analytics, marketing data analysis
