



Jakub Opalka

Uniwersytet Ekonomiczny w Poznaniu
Wydział Informatyki i Gospodarki Elektronicznej
Katedra Informatyki Ekonomicznej
jakub.opalka@kie.ue.poznan.pl

Witold Abramowicz

Uniwersytet Ekonomiczny w Poznaniu
Wydział Informatyki i Gospodarki Elektronicznej
Katedra Informatyki Ekonomicznej
w.abramowicz@kie.ue.poznan.pl

Wioletta Sokolowska

Uniwersytet Ekonomiczny w Poznaniu
Wydział Informatyki i Gospodarki Elektronicznej
Katedra Informatyki Ekonomicznej
wioletta.sokolowska@kie.ue.poznan.pl

Mateusz Kubaczyk

Uniwersytet Ekonomiczny w Poznaniu
Wydział Informatyki i Gospodarki Elektronicznej
Katedra Informatyki Ekonomicznej
mateusz.kubaczyk@kie.ue.poznan.pl

Karol Fabisz

Uniwersytet Ekonomiczny w Poznaniu
Wydział Informatyki i Gospodarki Elektronicznej
Katedra Informatyki Ekonomicznej
karol.fabisz@kie.ue.poznan.pl

Tymoteusz Hossa

Uniwersytet Ekonomiczny w Poznaniu
Wydział Informatyki i Gospodarki Elektronicznej
Katedra Informatyki Ekonomicznej
tymoteusz.hossa@kie.ue.poznan.pl

AUTOMATYCZNA ANALIZA WYDŹWIĘKU OPINII O OPERATORACH ENERGETYCZNYCH JAKO ELEMENT WSPARCIA PODEJMOWANYCH DECYZJI

Streszczenie: Wdrażanie infrastruktury Smart Grid (tzw. inteligentnej sieci elektroenergetycznej) spowodowało pojawienie się nieznanych wcześniej problemów związanych z przetwarzaniem oraz analizowaniem dużych i zróżnicowanych zbiorów danych, które z uwagi na bezpieczeństwo sieci i uczestników gry rynkowej powinny być realizowane w czasie niemal rzeczywistym. Co więcej, postępujące na rynku energii elektrycznej zmiany implikują przejście od modelu tradycyjnego do rynku bardziej zorientowanego na klienta. Wynika to przede wszystkim ze zwiększonego dostępu do narzędzi i informacji pozwalających na monitorowanie i redukcję zużycia energii oraz rosnącej świadomości konsumentów odnośnie do przysługującego im prawa zmiany sprzedawcy energii elektrycznej. Portale internetowe czy media społecznościowe stają się miejscem dyskusji, porównania i oceny obecnie dostępnych ofert. Tym samym odpowiednio przeanalizowane informacje publikowane za ich pośrednictwem mogą być źródłem budowania przewagi konkurencyjnej firmy.

Artykuł ocenia możliwości wsparcia potrzeb informacyjnych przedsiębiorstw funkcjonujących na rynku energii elektrycznej poprzez wykorzystanie analizy wydźwięku opinii klientów o operatorach energetycznych oraz o produktach przez nich oferowanych.

Słowa kluczowe: analiza wydźwięku, eksploracja opinii, rynki energii, podejmowanie decyzji biznesowych.

Wprowadzenie

Sektor energetyki funkcjonujący w oparciu o model scentralizowanych elektrowni konwencjonalnych, zdominowany przez ogromne koncerny energetyczne, przechodzi powoli do historii. Wdrożenie i przestrzeganie zasad podziału (ang. *unbundling*) oraz dostępu stron trzecich (tzw. *Third Party Access*, TPA) obowiązujących w porządku prawnym umożliwiło rozpoczęcie procesu liberalizacji rynku energii elektrycznej. Pierwsza z zasad dotyczy rozdziału, w ramach przedsiębiorstw zintegrowanych pionowo, działalności wytwórczej, dystrybucyjnej oraz działalności związanej z obrotem energią [www 3]. Druga z kolei daje odbiorcom końcowym prawo indywidualnego i swobodnego wyboru sprzedawcy energii. Lokalny dostawca energii (Operator Systemu Dystrybucyjnego) zobowiązany jest do przesyłu zakupionej energii do znajdującego się na jego obszarze klienta [Janiszewska, 2006].

Ewolucja sektora energetyki w kierunku liberalnego rynku energii elektrycznej implikuje pojawianie się nowych, konkurujących ze sobą podmiotów oraz zwiększa dynamikę zmiany sprzedawcy energii elektrycznej. W Polsce, zgodnie ze stanem na koniec marca 2015 r., liczba odbiorców korzystających z zasady TPA, sklasyfikowanych w grupach taryfowych A, B oraz C, wyniosła 136 990 podmiotów. W przypadku gospodarstw domowych (grupa taryfowa G) w okresie od grudnia 2010 r. do marca 2015 r. aż 318 627 z nich zdecydowało się na zmianę swojego sprzedawcy energii [www 5]. Tej sytuacji sprzyja fakt, że obecnie na krajowym rynku funkcjonuje już kilkadziesiąt konkurujących w obszarze obrotu energią elektryczną firm.

Wzrost konkurencyjności rynku, a przy tym zintensyfikowane wykorzystanie zdywersyfikowanych i rozproszonych źródeł generacji energii (w szczególności odnawialnych źródeł energii) oraz rozwój koncepcji inteligentnych sieci elektroenergetycznych (ang. *Smart Grid*) wymusza na spółkach energetycznych zmianę dotychczas wykorzystywanych modeli biznesowych [Amin i Wollenberg, 2005; Matusiak, 2013]. Skuteczność funkcjonowania spółki zajmującej się obrotem energią elektryczną zależy bowiem w dużej mierze od jej zdolności

oferowania nowych produktów i usług, ich promocji oraz pozyskiwania nowych, ale także budowania lojalności obecnych klientów. Dostęp do narzędzi pozwalających na monitorowanie i redukcję zużycia energii, rosnąca świadomość konsumentów oraz możliwość swobodnego komentowania, porównywania i oceny dostępnych ofert na portalach internetowych powoduje, że to klienci zaczynają powoli dyktować warunki, na jakich konkurują i w przyszłości będą konkurować ze sobą sprzedawcy energii elektrycznej. Przedsiębiorstwa energetyczne powinny zatem wykorzystać potencjał informacyjny źródeł dostępnych w Internecie, by za jego pośrednictwem budować swoją przewagę konkurencyjną.

Artykuł wskazuje na możliwości wsparcia potrzeb informacyjnych przedsiębiorstw funkcjonujących na rynku energii elektrycznej poprzez wykorzystanie analizy wydźwięku opinii klientów o operatorach energetycznych oraz o produktach przez nich oferowanych. Praca składa się z trzech zasadniczych części. W części pierwszej znajduje się propedeutyka eksploracji opinii i analizy wydźwięku oraz ich zastosowanie. Część druga obejmuje charakterystykę danych oraz opis metody analizy wydźwięku, którą opracowano z wykorzystaniem technologii SAP HANA. Omówienie wyników przygotowanej metody znajduje się w części trzeciej. Artykuł kończy podsumowanie zawierające wnioski z przeprowadzonych prac.

1. Nowe formy komunikacji i technologii – możliwości wykorzystania w budowaniu przewagi konkurencyjnej przedsiębiorstw

Szybkemu rozwojowi informacji cyfrowych dotyczących produktów, usług i marek (stron internetowych, kampanii, ofert i promocji) towarzyszy pojawianie się ocen, komentarzy czy opinii użytkowników na ich temat. Publikowane są one nie tylko na specjalistycznych stronach, ale także w formie krótkich wiadomości, postów czy na prywatnych blogach [Banic, Mihanovic i Brakus, 2013].

Wśród udostępnianych wypowiedzi można wyróżnić w ogólności fakty i opinie. Faktem nazywamy „to, co zaszło lub zachodzi w rzeczywistości, zjawisko, zdarzenie, określony stan rzeczy” [Dubisz, 2003], natomiast opinia to „przekonanie o czymś, pogląd na coś” [Dubisz, 2003]. Fakty są więc wypowiedziami obiektywnymi, podczas gdy opinie cechują się subiektywnością i zależą od indywidualnych upodobań, doświadczeń itd. Sens zawarty w wypowiedzi, wywołujący u odbiorcy określone reakcje, ogólne wrażenie, odczucie, nazywamy jej wydźwiękiem [Dubisz, 2003]. Wychwycenie zabarwienia emocjonalnego wypowiedzi pozwala na poznanie subiektywnych odczuć autora wypowiedzi względem obiektu lub jego części, którego wypowiedź dotyczy.

Niezależne recenzje konsumentów są uznawane za najbardziej wiarygodne źródła informacji. Badania pokazują, że aż 47% Amerykanów, decydując się na zakup produktu lub usługi, polega na informacjach publikowanych na portalu Facebook [www 2]. Stąd tak ważne dla firm staje się budowanie długotrwałej relacji z klientem, nie tylko za sprawą kampanii marketingowych, ale także poprzez reakcje przedsiębiorstwa na treści publikowane przez internautów [Mouthami, Devi i Bhaskaran, 2013; Stadnicki, 2013]. W tej sytuacji firmy i organizacje coraz częściej są zainteresowane pozyskaniem jak najpełniejszej informacji o tym, jak postrzegane są ich produkty, usługi lub organizowane przez nie wydarzenia [www 4].

Pozyskiwaniem wiedzy z treści generowanych przez użytkowników oraz analizą ich subiektywności zajmują się eksploracja opinii (ang. *opinion mining*) oraz analiza wydźwięku (ang. *sentiment analysis*).

1.1. Eksploracja opinii i analiza wydźwięku

Eksploracja opinii to dyscyplina na styku wyszukiwania informacji, eksploracji tekstu (ang. *text mining*) oraz lingwistyki komputerowej, która próbuje wykryć opinie wyrażane w tekstach języka naturalnego [Pang i Lee, 2008]. Głównym jej celem jest automatyczna identyfikacja elementów oceny w nieustrukturyzowanym tekście oraz podsumowanie opinii w nim zawartych.

Zagadnienie eksploracji opinii składa się z następujących komponentów [Liu, 2010a; Liu, 2010b]:

- identyfikacja źródła opinii;
- identyfikacja opiniowanych obiektów docelowych;
- subiektywność wyrażen i klasyfikacja ich polarności;
- podsumowywanie opinii.

Każdy z tych problemów ma duże znaczenie i doczekał się omówienia w wielu różnych pracach. Szczególną uwagę poświęcono eksploracji opinii klientów, które stanowią cenne źródło informacji na temat produktu lub jego renomy [Tsytsarau i Palpanas, 2011; Zhai i in., 2011].

Analiza wydźwięku z kolei to obszar nauki mający na celu przeprowadzenie analizy opinii i ocen w celu wykrycia emocjonalnego nastawienia ich autorów do produktów, usług, organizacji, wydarzeń itd. [Liu, 2012]. Liu [2011] stosuje to pojęcie zamiennie z eksploracją opinii, podczas gdy niektórzy autorzy uważają analizę wydźwięku za część eksploracji opinii [Tang i in., 2009]. Według Tang [2009] analiza wydźwięku zajmuje się analizą i klasyfikacją tekstu pod względem pozytywnego lub negatywnego stosunku autora opinii do jej przedmiotu.

Automatyczna analiza wydźwięku zyskała istotnie na znaczeniu wraz z rozwojem mediów społecznościowych. Wynika to z faktu, że po raz pierwszy istnieje tak zasobny zbiór danych w postaci cyfrowej zawierających treści będące opiniami. Kolejnym czynnikiem sprzyjającym rozkwitowi analizy wydźwięku był rozwój metod uczenia maszynowego, metod przetwarzania języka naturalnego, lingwistyki obliczeniowej oraz eksploracji tekstu, będących niezbędnym fundamentem w jej procesie [Liu, 2012].

Ogólnie w ramach analizy wydźwięku wyróżnić można 6 podstawowych etapów [za: Deshpande i Sarkar, 2010]. Pierwszy z nich to etap dostarczania i czyszczenia danych. Dane, które zostaną wykorzystane w ramach analizy, powinny zostać zebrane z możliwie jak największej liczby źródeł, co zapewni większą kompleksowość analizy. Ponieważ dane pochodzące z różnych źródeł mogą być zapisane w różnych formatach, niezbędne jest oczyszczenie dokumentu, tak aby pozostał tylko sam tekst.

Drugim etapem jest klasyfikacja tekstu, którego zadaniem jest ocenienie, czy dany tekst rzeczywiście jest nacechowany emocjonalnie.

Trzecim etapem jest ekstrakcja pojęć z tekstów, a dokładniej ekstrakcja słów kluczowych podlegających analizie. Wyróżniamy trzy podejścia do ekstrakcji pojęć:

- z wykorzystaniem słownika stanowiącego zbiór nazw np. produktu i wszystkich jego możliwych wersji;
- z wykorzystaniem reguł – wzorców nazw (np. reguła pozwalająca zidentyfikować wszystkie słowa zawierające dany ciąg znaków, zaczynające się od dużej litery);
- z wykorzystaniem uczenia maszynowego, gdzie wybrane algorytmy (np. modele Markowa) tworzą zasady ekstrakcji automatycznie w procesie uczenia.

W kolejnym etapie przeprowadzane jest wyszukiwanie nacechowanych słów w obrębie danej jednostki tekstu poddanej analizie. Do tego celu zazwyczaj używany jest korpus słów z przypisanym im nacechowaniem emocjonalnym (pozytywny, neutralny, negatywny). W dalszej kolejności tworzone jest podsumowanie, w ramach którego słowa są grupowane na podstawie swojego wydźwięku – wszystkie pozytywne, negatywne i neutralne wystąpienia słów emocjonalnie nacechowanych są ze sobą zestawiane i liczona jest wartość końcowa (np. z wykorzystaniem średniej ważonej). W ramach ostatniego etapu generowany jest raport dla użytkownika.

Niezależnie od analizowanego języka można wyróżnić dwa główne podejścia do automatycznej analizy wydźwięku: podejście maszynowe oraz podejście semantyczne [Brooke, 2001]. Podejście maszynowe bazuje na metodach uczenia

maszynowego oraz licznych algorytmach przydatnych do klasyfikacji tekstu. Metody uczenia maszynowego, wykorzystywane w analizie wydźwięku, często opierają się na klasyfikacji nadzorowanej (uczeniu nadzorowanym) [Mouthami, Devi i Bhaskaran, 2013; Neethu i Rajasree, 2013]. Wśród najczęściej stosowanych podejść można wyróżnić np. naiwny klasyfikator Bayesa (NB), maksymalną entropię (ME), metodę k-najbliższych sąsiadów, drzewa decyzyjne czy maszynę wektorów nośnych (SVM). Wykorzystanie tych metod oraz ocenę ich skuteczności można odnaleźć w wielu pracach [Sharma i Dey, 2012; Mouthami, Devi i Bhaskaran, 2013; Patni i Avinash, 2013; Neethu i Rajasree, 2013; Vohra i Teraiya, 2013]. Zalety metod uczenia maszynowego to ich zdolność do adaptacji, tworzenie wyszkolonych modeli do konkretnych celów i kontekstów. Ich wadą jest natomiast dostępność oznakowanych danych, a tym samym niewielkie zastosowanie metody do nowo pozyskanych danych wejściowych [Mouthami, Devi i Bhaskaran, 2013].

Z kolei podejście semantyczne – bazujące na leksykonie – zakłada mierzenie subiektywności i opinii w tekście na podstawie wcześniej stworzonego zestawu słów – słownika. Leksykon może być tworzony ręcznie lub automatycznie [Taboada i in., 2011]. Przykłady otwartych leksykonów wykorzystywanych w analizie wydźwięku to m.in. ANEW, SentiWordNet, Q-WordNet, WordNet-Affect, LIWC, PANAS-t [Zhou i in., 2013; Palanisamy, Yadav i Elchuri, 2013]. Zastosowania podejścia leksykalnego do analizy wydźwięku można odnaleźć np. w [Taboada i in., 2011; Singh i in., 2013]. Chociaż metody leksykalne nie opierają się na oznakowanych danych, ich podstawową wadą jest trudność utworzenia unikalnego słownika, który mógłby być używany w różnych kontekstach, także do analizy treści z portali społecznościowych. Poza powyższymi w literaturze można wyróżnić także podejście hybrydowe, łączące uczenie maszynowe i techniki semantyczne [Tan i in., 2008; Fang i Chen, 2011; Zhang i in., 2011; Mudinas, Zhang i Levene, 2012].

1.2. Zastosowania analizy wydźwięku

Na rynku dostępnych jest coraz więcej narzędzi wspierających użytkownika w przeprowadzeniu automatycznej analizy wydźwięku. Z nielicznymi wyjątkami są one dostosowane do języka angielskiego. Obszarem zainteresowania twórców oprogramowania umożliwiającego dokonywanie analizy wydźwięku są przeważnie media społecznościowe. Jest to widoczne np. w liczbie narzędzi służących do analizy treści portalu Twitter, do których należą m.in. Tweetfeel¹,

¹ <http://www.tweetfeel.com/>.

Sentiment140² czy Socialmention³. Dostępne są również systemy, takie jak wspomniana SAP HANA, które pozwalają na stworzenie rozwiązania przeprowadzającego automatyczną analizę wydźwięku wybranych przez użytkownika źródeł informacji. W literaturze można wyróżnić kilka przykładów wykorzystania systemu SAP HANA do analizy wydźwięku danych z portalu społecznościowego. Z pomocą narzędzia SAP HANA Freyburger [2013] przedstawił analizę wiadomości pojawiających się w dniu amerykańskich wyborów prezydenckich w 2012 r. Bliss [2013] zaprezentował propozycję analizowania danych z Twittera dotyczących opinii widzów na temat fenomenu wybranego filmu. Z kolei Zhou [www 6] na blogu SAP HANA Developer Center przedstawił autorską metodę pozwalającą na analizowanie ocen filmów w czasie rzeczywistym oraz umożliwiającą wykorzystanie wyników w przygotowaniu aplikacji webowej.

Mając na uwadze przedmiot niniejszego artykułu, warto podkreślić, że eksploracja opinii i analiza wydźwięku mają wiele zastosowań w różnych dziedzinach. Przykładem może być wykorzystanie w systemach rekomendacyjnych [Tatemura, 2000; Terveen i in., 1997], do filtrowania poczty elektronicznej [Spertus, 1997], dla potrzeb reklamy internetowej [Jin i in., 2007] itp. Aplikacja eksploracji opinii w życiu codziennym jest jeszcze bardziej interesująca – może być wykorzystana do poprawy interakcji człowiek – komputer [Liscombe i in., 2005; Tokuhisa i Terasima, 2006] w systemach klasy Business Intelligence [Mishne i Glance, 2006] czy do analizy cytowań [Piao i in., 2007] itp.

Przeprowadzona analiza literatury pozwala stwierdzić, że dotychczas nie podjęto się przeprowadzenia badania analizy wydźwięku w obszarze energetyki, w tym opracowania dedykowanych metod oraz narzędzi. Automatyczna analiza wydźwięku opinii na temat sprzedawców energii, publikowanych przez ich klientów w sieci Web, może być w niedalekiej przyszłości rozwiązaniem zapobiegającym retencji obecnych i sprzyjającym pozyskiwaniu nowych klientów. Na liberalnym rynku eksploracja opinii może przyczynić się do podejmowania decyzji biznesowych, których efektem będą usługi dostosowane do potrzeb odbiorców końcowych. W ocenie autorów artykułu poziom liberalizacji brytyjskiego sektora energetycznego oraz dostępność opinii publikowanych na dedykowanych portalach pozwalają na przeprowadzenie eksperymentu polegającego na opracowaniu odpowiedniej metody analizy wydźwięku oraz jej walidację. Niestety, obecny niski poziom liberalizacji polskiego sektora energetycznego skutkuje brakiem dobrych źródeł do przeprowadzenia tego typu analiz, jednak wraz z postępującym uwolnieniem rynku tego typu źródeł powinno przybywać.

² <http://www.sentiment140.com/>.

³ <http://socialmention.com/>.

2. Opis eksperymentu

Niniejsza część w pierwszej kolejności skupia się na przedstawieniu charakterystyki danych, które znalazły się w badaniu analizy wydźwięku dla komentarzy o usługach świadczonych przez brytyjskich sprzedawców energii elektrycznej. W drugiej części przedstawiony jest opis metody służącej przypisaniu wydźwięku do poszczególnych opinii klientów.

2.1. Charakterystyka danych

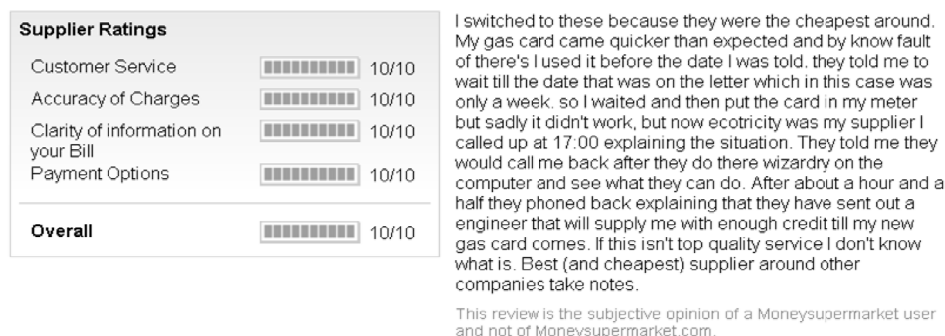
Do badania pobranych zostało 10 012 wpisów z dwóch brytyjskich portali skupiających się na gromadzeniu opinii dotyczących różnego rodzaju usług oferowanych przez podmioty rynkowe, m.in. banki, agencje finansowe, biura podróży, operatorów telefonii komórkowej, dostawców energii elektrycznej itp.:

- www.moneysupermarket.com, zakładka „Energy”, „Energy Supplier Reviews”;
- www.reviewcentre.com, zakładka „Utilities and Services”, „Electricity Suppliers”.

Opinie zostały pobrane z wykorzystaniem dedykowanego skryptu (ze względu na strukturę każdej ze stron oraz samych opinii) przygotowanego w języku Python. Należy podkreślić, że w opisywanym badaniu analizie poddano wyłącznie tekst pochodzący z opinii. Analiza i problematyka wydźwięku przypisywanego w formie gwiazdek odnoszących się do różnych wartości (m.in. *customer service*, *accuracy of charges*, *clarity of information of your bill*, *payment options*, *value for money*) jest przedmiotem oddzielnych badań ze względu na swoją złożoność. Poza tym celem badań było zbudowanie metody analizy wydźwięku dla niejednorodnych opinii, co nie jest trywialnym zadaniem.

Rys. 1 przedstawia przykład wpisu odnoszącego się do dostawcy energii elektrycznej o nazwie Ecotricity⁴ i pochodzącego ze strony www.moneysupermarket.com.

⁴ W kontekście dostawcy Ecotricity warto dodać, że według badań przeprowadzonych przez portal Which?Switch jest to obecnie najlepszy dostawca energii elektrycznej na rynku brytyjskim pod względem poziomu satysfakcji ze świadczonych usług. W badaniu opinii odbiorców zdeklasował tzw. wielką szóstkę, czyli głównych dostawców energii (British Gas, EON, EDF Energy, RWE, npower, Scottish Power, SSE) [www 1].



Rys. 1. Przykład opinii pochodzącej z serwisu www.moneysupermarket.com

Źródło: www.moneysupermarket.com.

Rys. 2 przedstawia przykład opinii odnoszącej się do dostawcy o nazwie Spark Energy i pochodzi z serwisu www.reviewcentre.com.



Rys. 2. Przykład opinii pochodzącej z serwisu www.reviewcentre.com.

Źródło: www.reviewcentre.com.

2.2. Opis metody

Głównym celem przeprowadzonego eksperymentu było:

- 1) Zbudowanie metody umożliwiającej pobranie komentarzy oraz zapisanie ich w tabelach w SAP HANA.
- 2) Wykorzystanie zaimplementowanego w SAP HANA modułu *Text Analysis* wraz z metodą *Voice of Customer* do przeprowadzenia analizy komentarzy o operatorach energetycznych na potrzeby określenia ich polarności.
- 3) Przygotowanie nowego algorytmu działającego we współpracy z SAP HANA i pozwalającego określać polarność w trójstopniowej (pozytywny, neutralny lub negatywny), a nie tak jak to było dotychczas w SAP HANA – pięciostopniowej skali.

- 4) Wywołanie opracowanego algorytmu w module *Text Analysis* z wykorzystaniem standardowego słownika.
- 5) Walidacja otrzymanych wyników z wykorzystaniem Gold Standard.

Pobrane komentarze zostały umieszczone w dwóch tabelach w SAP HANA, po jednej na każde źródło danych. Do przeprowadzenia badania niezbędne było jednak zebranie wszystkich wpisów w jednej tabeli, którą nazwano *PROJECT*. Następnie na kolumnie *OPINION*, zawierającej każdy z pobranych wpisów, wywołano procedurę *Text Analysis* z konfiguracją *Voice of Customer*, czego efektem było utworzenie tabeli *&TA_PROJECT_SA*, w której znajdowały się wszystkie encje komentarzy (także te, które wyrażały wydźwięk pozytywny i negatywny). Dalszemu przetwarzaniu podlegały jedynie encje o *TA_TYPE*: *weakpositivesentiment*, *weaknegativesentiment*, *majorproblem*, *minorproblem*, *strongpositivesentiment*, *strongnegativesentiment*. Było to uzasadnione tym, że tylko te encje mogły mieć wpływ na określenie wydźwięku każdego z wpisów.

W kolejnym etapie dla każdej z opinii wyliczone zostały wartości *POS* i *NEG*, będące kolejno sumą encji wyrażających pozytywny charakter (tj. *weakpositivesentiment* i *strongpositivesentiment*) oraz takich, które zidentyfikowano jako nacechowane negatywnie (tj. *weaknegativesentiment*, *majorproblem*, *minorproblem*, *strongnegativesentiment*).

W kolejnym kroku dla każdej z opinii wyliczona została suma *POS* i *NEG*, oznaczona jako *POSNEG_SUM*. W tym momencie dokonano usunięcia tych wpisów, dla których *POSNEG_SUM* wynosiła 0. Następnie ponumerowano od nowa pozostałe wpisy, rozpoczynając od *ID = 1*. Tym samym liczba wpisów zmniejszyła się do 9583.

Najważniejszym krokiem opracowanej metody było wyliczenie miary dla każdego wpisu, którą zapisywano do kolumny *MEASURE*. Miara była stosunkiem wartości *POS* do *POSNEG_SUM*, czyli stosunkiem encji o pozytywnym wydźwięku do sumy encji pozytywnego i negatywnego wydźwięku dla każdego z wpisów. Utworzona została także kolumna *POLARITY*, w której umieszczono słowne interpretacje wyliczonej miary. Dla wartości od 0 do 0,4 włącznie wpis otrzymywał wydźwięk negatywny, dla wartości od 0,4 do 0,6 neutralny, a dla wartości od 0,6 włącznie do 1 pozytywny.

Omówienie wyników zaproponowanej metody znajduje się w kolejnej części.

3. Walidacja metody z wykorzystaniem podejścia Gold Standard

Na obecnym etapie każda z badanych opinii ma już przypisaną wartość polaryzacji wydźwięku: pozytywną, negatywną albo neutralną. Wyniki w tej po-

staci mogłyby posłużyć np. do podjęcia decyzji związanych z prowadzeniem polityki wobec klientów przez operatorów energetycznych. Niemniej jednak jednym z celów przeprowadzonego eksperymentu było również sprawdzenie poprawności działania opracowanej metody.

Dla pozyskanego zbioru komentarzy wylosowano reprezentacyjną próbę, składającą się z 370 opinii, które następnie zostały ocenione przez trzech niezależnych respondentów (ang. *annotator*). Analizowali oni poszczególne opinie i przypisywali do każdej z nich jedną z trzech wartości polarności (neutralną, pozytywną, negatywną). Gdy co najmniej dwóch z trzech respondentów nadało jednakową ocenę polarności określonemu wpisowi, wówczas uznawano ją za wiążącą. W pozostałych sytuacjach decyzję ustalał tzw. sędzia, to jest dodatkowa osoba oceniająca, która ponownie analizowała kolejne niezgodne przypadki i określała, jaką polarność należy ostatecznie opinii przypisać. W ten sposób dla wybranych przykładów otrzymano tzw. złoty standard.

Dzięki tej ocenie w kolejnym kroku możliwe było porównanie wyników oceny wydźwięku przeprowadzonej w sposób automatyczny z wykorzystaniem technologii SAP HANA oraz opracowanej metody z oceną wydźwięku przeprowadzoną przez uczestniczących w eksperymencie ekspertów. W tym celu wyliczono miary oceniające przygotowaną metodę, tj. *Precision*, *Recall* i *F-measure* dla wydźwięku pozytywnego, neutralnego i negatywnego. Wzory, które zostały wykorzystane do wyliczenia tych miar, zaprezentowano poniżej, na przykładzie wzorów dla polaryzacji pozytywnej:

$$Precision = \frac{True\ Positives}{True\ Positives + False\ Positives}$$

$$Recall = \frac{True\ Positives}{True\ Positives + False\ Negatives}$$

$$F - measure = \frac{2 \times (Precision \times Recall)}{(Precision + Recall)}$$

We wzorach przez *True Positives* rozumie się liczebność prawdziwych przypisań pozytywnego wydźwięku, czyli takich, w których metoda i respondenci byli zgodni w ocenie. Przez *False Positives* rozumie się liczebność fałszywych przypisań pozytywnego wydźwięku, czyli takich, w których metoda przypisała wydźwięk pozytywny do komentarzy ocenionych przez respondentów jako negatywne lub neutralne. Przez *False Negatives* rozumie się liczebność fałszywych przypisań negatywnego i neutralnego wydźwięku do komentarzy ocenionych przez respondentów jako pozytywne.

Wyniki obliczeń dla *Precision*, *Recall* i *F-measure* dla każdej z wartości wydźwięku przedstawiono w tabeli 1. Wartość *Precision* określa procent poprawnie określonego wydźwięku przez metodę w stosunku do sumy wszystkich wartości przypisanych do danej polarności. Jak można zauważyć, wartość *Precision* dla polarności pozytywnej jest na bardzo wysokim poziomie 91%. Dla wydźwięku negatywnego wartość precyzji kształtuje się na poziomie 74%. Wartość parametru *Precision* uzyskana dla neutralnego wydźwięku to zaledwie 26%, co niestety nie może zostać uznane za wynik zadowalający.

Tabela 1. Wyniki poszczególnych miar w badaniu Gold Standard dla opinii, których wydźwięk określono jako pozytywny, neutralny lub negatywny

	Precision	Recall	F-measure
Pozytywny	91%	75%	82%
Neutralny	26%	15%	19%
Negatywny	74%	95%	83%

Kolejnym miernikiem jakości badania jest wartość parametru *Recall*. Wskazuje on na stosunek liczby opinii o poprawnie określonym wydźwięku do całkowitej liczby wszystkich komentarzy, które rzeczywiście mają taką wartość wydźwięku. Jak można zauważyć, w tym przypadku zdecydowanie lepiej wypadła metoda wykrywania negatywnego wydźwięku w opiniach, tutaj *Recall* ma 95%. Trochę gorzej metoda poradziła sobie w przypadku kategorii pozytywnego wydźwięku, gdzie *Recall* jest na poziomie 75% – co jest także zadowalającym poziomem. Zdecydowanie gorzej i niesatysfakcjonująco metoda radzi sobie z neutralnym wydźwiękiem – tylko 15% parametru *Recall*.

Ostatnim parametrem jest tzw. *F-measure*, który określa efektywność analizy wydźwięku w oparciu o parametry *Recall* i *Precision*. *F-measure* jest to *de facto* średnia ważona obu tych parametrów. Jak można zauważyć, określa ona efektywność dla kategorii wykrywania pozytywnego wydźwięku na poziomie 82% i dla kategorii wykrywania negatywnego wydźwięku na bardzo zbliżonym poziomie 83%. Oba te wyniki świadczą o tym, że metoda bardzo dobrze radzi sobie z wykrywaniem tych kategorii wydźwięku. Kategoria wykrywania neutralnego wydźwięku jest na poziomie 19%, co nie jest zadowalającym wynikiem. Wynik ten może brać się z faktu, że badane opinie w większości miały wydźwięk pozytywny lub negatywny, a odsetek opinii neutralnych był bardzo niski (7,3%).

Podsumowanie

W ramach badania przeprowadzona została analiza wydźwięku na dużym zbiorze nieustrukturyzowanych danych – 9583 opiniach na temat usług dostawców energii elektrycznej w Wielkiej Brytanii. Zastosowana autorska metoda analizy wydźwięku wykorzystywała zaimplementowaną w SAP HANA procedurę oraz domyślny leksykon. Opracowana metoda została poddana ewaluacji z wykorzystaniem podejścia Gold Standard i uzyskała wysoką efektywność wykrywania pozytywnego i negatywnego wydźwięku. Jednakże wyniki osiągnięte przez metodę dla neutralnego wydźwięku nie mogą satysfakcjonować.

Wnioski z wykonanych prac są następujące:

- Automatyczna analiza wydźwięku zapewnia możliwość przetwarzania dużych ilości opinii pochodzących bezpośrednio od klientów z wysoką dokładnością i efektywnością, przy niskim jednostkowym koszcie i nakładzie pracy przypadającym na pojedynczą opinię. Z powodzeniem może ona stanowić uzupełnienie, czy wręcz zastąpić tradycyjne metody badania satysfakcji klientów przedsiębiorstw, które działają w sektorze energetycznym.
- Dane nieustrukturyzowane wymagają sporego nakładu pracy, zanim będą mogły być zwizualizowane w łatwy do odczytania i zinterpretowania sposób. Znalazienie wiarygodnych (kompletnych, dokładnych, wolnych od błędów i pomyłek) źródeł danych wydaje się kluczowym krokiem. Proces ekstrakcji danych oraz ich przygotowania do badania przy wykorzystaniu technologii SAP HANA jest czasochłonny.
- Duży nacisk należy położyć na wybór odpowiednich metod analizy wydźwięku oraz ich implementację w środowisku SAP HANA. Nie można pominąć faktu, że SAP HANA jest wciąż w fazie rozwoju, zatem warto zadbać o stworzenie uniwersalnych metod, które będą w miarę niezależne od kolejnych wersji oprogramowania.
- Podejmowanie właściwych decyzji dotyczących zastosowania określonych metod, programów, środowiska analitycznego itp. ma strategiczne znaczenie w kontekście przygotowania odpowiedniego narzędzia dla konkretnej grupy odbiorców.

Przedstawione badania oraz ich wyniki należy rozpatrywać w szerszym kontekście, tj. jako element prototypu aplikacji Business Intelligence, która ma wspomagać decyzje podejmowane przez analityków biznesowych w sektorze energetycznym. W ramach prowadzonych prac udało się połączyć analizę danych nieustrukturyzowanych (opinie o dostawcach energii elektrycznej) oraz analizę i prognozowanie na podstawie danych ustrukturyzowanych (historyczne zużycie energii, historyczna generacja energii z odnawialnych źródeł energii, dane meteorologiczne) [Abramowicz i in., 2014; Abramowicz i in., 2015].

Literatura

- Abramowicz W., Sokołowska W., Hossa T., Opalka J., Fabisz K., Kubaczyk M., Ćmil M. (2015), *Sentiment Analysis for the needs of benchmarking the Energy Sector* [w:] *HPI Future SOC Lab Project Report – Fall 2014*, Potsdam.
- Abramowicz W., Sokołowska W., Hossa T., Opalka J., Fabisz K., Filipowska A., Kubaczyk M. (2014), *Smart Data Analysis for the Support of Rational Decision Making in the Energy Sector* [w:] *HPI Future SOC Lab Project Report – Spring 2014*, Potsdam.
- Amin S.M., Wollenberg B.F. (2005), *Toward a smart grid: Power delivery for 21st century*, „IEEE Power & Energy Magazine”, No. 5.
- Banic L., Mihanovic A., Brakus M. (2013), *Using Big Data and sentiment analysis in product evaluation* [w:] *Proceedings of the 36th International Convention on Information & Communication Technology Electronics & Microelectronics*.
- Bliss H. (2013), *Sharkando Social Media Analytices with SAP HANA and Predictive Analysis*, „Analytics Practice Lead Decision First Technologies”, June.
- Brooke J. (2001), *A semantic approach to automated text sentiment analysis*, Master's thesis, Stanford University.
- Deshpande M., Sarkar A. (2010), *BI and sentiment analysis*, „Business Intelligence Journal”, No. 15(02).
- Dubisz S. (2003), *Uniwersalny słownik języka polskiego*, WN PWN, Warszawa.
- Fang J., Chen B. (2011), *Incorporating Lexicon Knowledge into SVM Learning to Improve Sentiment Classification* [w:] *Proceedings of the Workshop on Sentiment Analysis where AI meets Psychology (SAIIP)*.
- Freyburger K. (2013), *Sentiment Analysis with SAP HANA*, OSBI-Workshop, Hochschule Ludwigshafen am Rhein.
- Janiszewska K. (2006), *Zasada TPA w elektroenergetyce w prawie wspólnotowym i polskim*, „Miesięcznik Gospodarczy Nowy Przemysł”, nr 2.
- Jin X., Li Y., Mah T., Tong J. (2007), *Sensitive webpage classification for content advertising* [w:] *Proceedings of the International Workshop on Data Mining and Audience Intelligence for Advertising*.
- Liscombe J., Riccardi G., Hakkani-Tür D. (2005), *Using context to improve emotion detection in spoken dialog systems*, „Interspeech”.
- Liu B. (2010a), *Sentiment analysis and subjectivity* [w:] N. Indurkha, F.J. Damerau (eds.), *Handbook of Natural Language Processing*, Taylor & Francis Group.
- Liu B. (2010b), *Opinion mining and sentiment analysis: NLP meets social sciences*, Honolulu.
- Liu B. (2011), *Web Data Mining. Exploring Hyperlinks, Contents, and Usage Data*, Springer.
- Liu B. (2012), *Sentiment analysis and opinion mining*, Morgan & Claypool Publishers, San Rafael.

- Matusiak B.E. (2013), *Modele biznesowe na nowym zintegrowanym rynku energii*, Wydawnictwo UE, Łódź.
- Mishne G., Glance N. (2006), *Predicting movie sales from blogger sentiment* [w:] *AAAI Symposium on Computational Approaches to Analysing Weblogs (AAAI-CAAW)*.
- Mouthami K., Devi K.N., Bhaskaran V.M. (2013), *Sentiment analysis and classification based on textual reviews* [w:] *Proceedings of the 2013 International Conference on Information Communication and Embedded Systems (ICICES)*.
- Mudinas A., Zhang D., Levene M. (2012), *Combining lexicon and learning based approaches for concept level sentiment analysis* [w:] *Proceedings of the First International Workshop on Issues of Sentiment Discovery and Opinion Mining*, ACM, New York.
- Neethu M.S., Rajasree R. (2013), *Sentiment analysis in twitter using machine learning techniques* [w:] *Proceedings of the Fourth International Conference on Computing, Communications and Networking Technologies (ICCCNT)*.
- Palanisamy P., Yadav V., Elchuri H. (2013), *Serendio: Simple and Practical lexicon based approach to Sentiment Analysis* [w:] *Proceedings of International Workshop on Semantics Evaluation*.
- Pang B., Lee L. (2008), *Opinion mining and sentiment analysis*, „Foundations and Trends in Information Retrieval”, No. 1-2.
- Patni S., Avinash W. (2013), *Comparative Study of Available Technique for Detection in Sentiment Analysis*, „International Journal of Computational Engineering Research”, No. 5.
- Piao S., Ananiadou S., Tsuruoka Y., Sasaki Y., McNaught J. (2007), *Mining opinion polarity relations of citations* [w:] *International Workshop on Computational Semantics 84 (IWCS)*.
- Sharma A., Dey S. (2012), *A Comparative Study of Feature Selection and Machine Learning Techniques for Sentiment Analysis* [w:] *Proceedings of the 2012 ACM Research in Applied Computation Symposium*, San Antonio, Texas.
- Singh V.K., Piryani R., Uddin A., Waila P. (2013), *Sentiment analysis of movie reviews: A new feature-based heuristic for aspect-level sentiment classification* [w:] *Proceedings of the 2013 IEEE International Multi Conference on Automation, Computing, Control, Communication and Compressed Sensing*.
- Spertus E. (1997), *Smokey: Automatic recognition of hostile messages* [w:] *Proceedings of Innovative Applications of Artificial Intelligence (IAAI)*.
- Stadnicki M. (2013), *BI w służbie budowania relacji z klientem i lepszemu zrozumieniu jego potrzeb*, „Nowoczesne Zarządzanie”, nr 1.
- Taboada M., Brooke J., Tofiloski M., Voll K., Stede M. (2011), *Lexicon-based methods for sentiment analysis*, „Computational Linguistics”, No. 37(02).
- Tan S., Wang Y., Cheng X. (2008), *Combining Learn-based and Lexicon-based Techniques for Sentiment Detection without Using Labeled Examples*, SIGIR.

- Tang H., Tan S., Cheng X. (2009), *A survey on sentiment detection of reviews*, „Expert Systems with Applications”, No. 36(7).
- Tatemura J. (2000), *Virtual reviewers for collaborative exploration of movie reviews* [w:] *Proceedings of Intelligent User Interfaces (IUI)*.
- Terveen L., Hill W., Amento B., McDonald D., Creter J. (1997), *PHOAKS: A system for sharing recommendations*, „Communications of the Association for Computing Machinery (CACM)”, No. 40(3).
- Tokuhisa R., Terashima R. (2006), *Relationship between utterances and “enthusiasm” in nontask-oriented conversational dialogue* [w:] *Proceedings of the SIGdial Workshop on Discourse and Dialogue*, Association for Computational Linguistics, Sydney.
- Tsytsarou M., Palpanas T. (2011), *Survey on mining subjective data on the web*, „Data Mining and Knowledge Discovery”, No. 10.
- Vohra S., Teraiya J. (2013), *A comparative study of sentiment analysis techniques*, „Journal of Information, Knowledge and Research in Computer Engineering”, No. 2.
- Zhai Z., Liu B., Xu H., Jia P. (2011), *Clustering product features for opinion mining*, ACM International Conference on Web search and data mining, Hong Kong.
- Zhang L., Ghosh R., Dekhil M., Hsu M., Liu B. (2011), *Combining Lexicon-based and Learning-based Methods for Twitter Sentiment Analysis*, HP Laboratories Report.
- Zhou X., Tao X., Yong J., Yang Z. (2013), *Sentiment analysis on tweets for social events* [w:] *Proceedings of the 2013 IEEE 17th International Conference on Computer Supported Cooperative Work in Design (CSCWD)*.
- [www 1] *2015 energy companies satisfaction survey*, <http://switch.which.co.uk/energy-suppliers/energy-companies-rated.html> (dostęp: 23.05.2015).
- [www 2] Bullas J. (2014), *22 Social Media Facts and Statistics You Should Know in 2014*, <http://www.jeffbullas.com/2014/01/17/20-social-media-facts-and-statistics-you-should-know-in-2014/#2XhSwCgXiGYBXauk.99> (dostęp: 15.04.2015).
- [www 3] Jagustyn S. (2014), *Granice niezależności operatorów systemowych*, <http://regulacjewenergetyce.pl/blog/granice-niezaleznosci/> (dostęp: 24.05.2015).
- [www 4] Telejko K. (2009), *Planowanie mediów społecznych*, <http://socialmediaguide.pl/index.php/tag/planowanie-mediow/> (dostęp: 15.04.2015).
- [www 5] Urząd Regulacji Energetyki, *Informacje dotyczące zmiany sprzedawcy w wybranych miesiącach za okres od XII 2010 r. do III 2015 r.*, <http://www.ure.gov.pl/download/1/7493/NewsletterTPAmarzec2015.pdf> (dostęp: 29.05.2015).
- [www 6] Zhou W. (2013), *Real-time sentiment rating of movies on SAP HANA ONE*, <http://scn.sap.com/community/developer-center/hana/blog/2013/06/19/real-time-sentiment-rating-of-movies-on-sap-hana-one> (dostęp: 15.04.2015).

AUTOMATIC SENTIMENT ANALYSIS OF OPINIONS ABOUT ENERGY OPERATORS AS AN ELEMENT OF SUPPORT FOR DECISION MAKING

Summary: The implementation of the Smart Grid infrastructure caused previously unknown problems connected with processing and analyzing large and diverse data sets. Due to the security of the electricity network and the market participants, the processing and analyzing large data sets should be achieved in the near real-time. Furthermore, the changes in the electricity market have implied a shift from the traditional market model to the customer-oriented market. This is primarily a result of the increasing access to the tools and information which allow consumers to monitor and reduce the energy consumption, and of the customers' growing awareness about the right to change their electricity supplier. Web portals and social media have become a place for discussion, comparison and review of the currently available offers. Thus, the proper analysis of the information published on such websites can be a source of competitive advantage for the electricity suppliers.

The article shows a possibility to support the information needs of electricity companies by means of the sentiment analysis of customer's reviews on energy suppliers and on the services they offer.

Keywords: sentiment analysis, opinion mining, energy markets, business decision making.