

Andrzej Paliński

AGH Akademia Górniczo-Hutnicza im. St. Staszica w Krakowie

Hurtownie danych i eksploracja danych w prognozowaniu popytu na gaz i usługi magazynowania gazu

W artykule zaprezentowano tendencje światowe dotyczące hurtowni danych i eksploracji danych w przemyśle naftowym i gazowniczym oraz potwierdzono możliwości wykorzystania narzędzi zaawansowanej eksploracji danych do prognozowania popytu na paliwo gazowe i usługi podziemnego magazynowania gazu na polskim rynku. W ramach testowania użyteczności oprogramowania do eksploracji danych, zbudowano model prognozujący odbiór gazu z polskich podziemnych magazynów gazu. Uzyskane prognozy mają wysoką trafność, a użycie kreatorów wbudowanych w oprogramowanie zminimalizowało nakłady pracy i pozwoliło na automatyzację procesu budowy modeli.

Słowa kluczowe: eksploracja danych, przemysł gazowniczy, prognozowanie.

Data warehouses and data mining in forecasting the demand for gas and gas storage services

The article presents world trends regarding data warehousing and data mining in the oil and gas industry and confirmed the possibility of using advanced data mining tools for forecasting natural gas demand and underground gas storage services on the Polish market. As part of data mining software usability testing, we built a model forecasting gas withdrawal from Polish underground gas storage facilities. The achieved forecasts have high accuracy, and the use of wizards embedded in the software, minimized the workload and allowed for the automation of the model building process.

Key words: data mining, oil and gas industry, forecasting.

Wprowadzenie

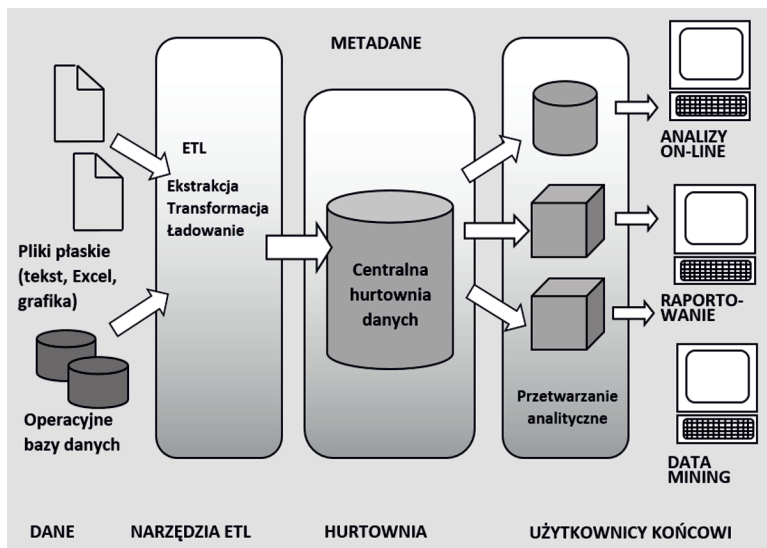
Współczesny rozwój informatyki i olbrzymich zbiorów danych wraz z możliwością ich szybkiego przeszukiwania, znacząco zmienił spojrzenie na dane jako źródło informacji. Wykorzystanie narzędzi statystycznych i uczenia maszynowego wywodzącego się z informatyki, pozwoliło na automatyczne analizowanie danych oraz wydobywanie informacji z morza danych. To przyczyniło się do powstania nowej gałęzi informatyki stosowanej – Business Intelligence.

Business Intelligence (BI) jest definiowane jako zorientowany na użytkownika proces zbierania, eksploracji, interpretacji i analizy danych, który prowadzi do usprawnienia procesu podejmowania decyzji. Tak rozumiany system wspomaganie decyzji biznesowych obejmuje [15]:

- narzędzia OLAP (ang. *on-line analytical processing*): oprogramowanie umożliwiające analizę wielowymiarową danych biznesowych poprzez integrację, agregację i odpowiedni sposób prezentacji (wizualizacji) różnego rodzaju danych,

- narzędzia eksploracji danych: algorytmy do automatycznej analizy dużych wolumenów danych, wykorzystujące metody statystyczne, ekonometryczne, czy metody maszynowego uczenia się, pozwalające na analizę danych nie tylko o charakterze ilościowym, ale również jakościowym,
- narzędzia zarządzania wiedzą: umożliwiające składowanie, indeksowanie i analizę dokumentów tekstowych oraz powiązanie ich z innymi danymi.

Systemy tej klasy budowane są z wykorzystaniem hurtowni danych, tj. baz danych dedykowanych do zbierania danych pochodzących z różnych źródeł oraz narzędzi efektywnego udostępniania danych użytkownikom końcowym. Celem hurtowni danych jest gromadzenie danych nie tylko z różnych źródeł, ale także pierwotnie różnorodnej postaci, w jednej bazie i w jednolitym formacie pozwalającym na dalszą ich obróbkę. Przykładowa architektura hurtowni danych wraz z powiązaniem z nią elementami przedstawiona jest na rysunku 1.



Rys. 1. Przykładowa architektura kompletnej hurtowni danych
 Źródło: opracowania własne na podstawie [2]

Eksploracja danych

Jednym z końcowych składników systemów BI są narzędzia *data mining*. Jest to inteligentna eksploracja danych, która ma na celu pozyskanie przydatnej wiedzy ukrytej w dużej ilości informacji. Eksploracja danych nazywana często odkrywaniem wiedzy w bazach danych jest jedną z najszybciej rozwijających się gałęzi informatyki w ostatnim czasie. Łączy w sobie wiele dziedzin naukowych, takich jak [7]:

- systemy baz danych, hurtownie danych, repozytoria, narzędzia OLAP,
- metody statystyczne,
- uczenie maszynowe i odkrywanie wiedzy,
- wizualizacja danych,
- wyszukiwanie informacji,
- sieci neuronowe,
- logika rozmyta i zbiory przybliżone,
- rozpoznawanie obrazów,
- przetwarzanie sygnałów.

Współczesne firmy zarządzają dużymi zbiorami danych, ale problemem jest ich praktyczne wykorzystanie. Natłok danych w znacznym stopniu utrudnia ich analizę i skutkuje zmniejszeniem się ilości przydatnych informacji. Za pomocą technik eksploracji danych możemy rozwiązywać takie problemy jak:

- prognozowanie sprzedaży i ustalanie cen,
- szukanie klientów, którzy przynoszą największy zysk,
- zrozumienie potrzeb klientów,
- wyszukiwanie, które towary i usługi sprzedają się razem,
- przewidywanie utraty klientów,
- ocena ryzyka,
- wykrywanie nadużyć,
- budowa skutecznych kampanii marketingowych,
- wykrywanie nieprawidłowości.

W początkowym etapie rozwoju Business Intelligence łączyło hurtownie danych z analityką danych, prostą eksplora-

cją danych i rozbudowanym raportowaniem. Obecnie wprowadza się podział na trzy obszary: zarządzanie hurtowniami danych, raportowanie i prostą analitykę (wąsko rozumiane BI) oraz zaawansowaną eksplorację danych. Czołowi producenci oprogramowania bazodanowego i analizy danych według raportu Gartnera, światowej firmy konsultingowej w branży IT, to: IBM, SAP, Oracle, Teradata, SAS, Microsoft, Rapid Miner, KNIME (por. [3, 11]).

Najczęściej stosowanymi technikami eksploracji danych, wbudowanymi zwykle w narzędzia komercyjne czołowych producentów oprogramowania, są [10]:

- analiza dyskryminacyjna (podział na rozłączne podzbiory),
- analiza asocjacji (znajdowanie zbiorów częstych i reguł),
- klasyfikacja,
- analiza regresji,
- klastrowanie (analiza skupień),
- wykrywanie zmian i odchyłeń
- prognozowanie.

Najprostszym sposobem budowy systemu do eksploracji danych jest wykorzystanie oprogramowania jednego z wymienionych wcześniej producentów systemów BI i przystosowanie go do własnych potrzeb. Rozwiązanie to nie zawsze może spełnić wymagania branży naftowej i gazowniczej, gdyż wspomniane oprogramowanie skierowane jest do zbyt ogólnego użytkownika, stąd konieczne może okazać się tworzenie własnego oprogramowania lub zakupienie specjalistycznych aplikacji. Przykładowymi dostawcami specjalistycznego oprogramowania do analityki danych w branży naftowej są: IHS, Microsoft, American Gas Association, RBAC (przyływ gazu w sieciach USA), SAS, OGSys, Total Stream GE¹.

¹ Obszerną listę oprogramowania dla branży wiertniczo-naftowej można znaleźć na stronie internetowej Top Oil and Gas Software Products [16].

Większość oprogramowanie tego rodzaju służy do gromadzenia danych i analiz w obszarze wydobywania ropy i gazu (*upstream*). W mniejszym stopniu jest ono przydatne do zarządzania zakupami i sprzedażą gazu, w tym prognozowania cen i wielkości zapotrzebowania na gaz (*midstream* i *downstream*). Można tutaj wspomnieć o hurtowni danych wdrożonej w PGNiG SA, wykorzystującej oprogramowanie firmy SAP. Nie jest to jednak narzędzie stricte zaawansowanej eksploracji danych.

Tradycyjne podejście do prognozowania w branży gazowniczej wykorzystuje modele regresji i jednoznacznie określony zbiór danych. Dane używane w klasycznym prognozowaniu cen i zapotrzebowania na gaz to [1]:

- historyczne ceny gazu (lokalne, na rynkach świtowych, bieżące i terminowe),
- dane pogodowe (temperatura, wiatr, opad i nasłonecznienie),
- liczba klientów indywidualnych i ich zużycie gazu (także współczynniki elastyczności cenowej i dochodowej popytu),
- dane dotyczące budownictwa i działalności remontowej (nowe domy, zmiany energochłonności itp.),
- duzi odbiorcy (wielkość i charakterystyka odbioru, współczynniki elastyczności cenowej i dochodowej popytu),
- dane makroekonomiczne (PKB, inflacja, płace itp.),
- sytuacja polityczna,
- metadane (dane samorządu terytorialnego, urzędów statystycznych itp.).

Współczesne podejście do budowy modeli empirycznych wykracza poza tradycyjne modele statystyczno-ekonometryczne. Klasyczne modele wymagają z jednej strony spełnienia ścisłych wymagań dotyczących wnioskowania statystycznego, z drugiej strony – narzucają konieczność określenia z góry

zbioru zmiennych objaśniających. Zbiór ten może być zawężony w toku wnioskowania, ale trudno go później rozszerzyć. Szczególny problem dotyczy zmiennych opóźnionych w modelu empirycznym. Naturalną kwestią jest opóźnienie rzeczywistego zużycia gazu odbiorców w stosunku do kwot wynikających z faktur. Jednakże mogą występować inne opóźnienia, których natura nie jest z góry znana.

Prognozowanie cen i zapotrzebowania na gaz może obecnie opierać się na dowolnie szerokim zbiorze potencjalnych zmiennych objaśniających, niekoniecznie związanych wprost z cenami gazu. Problem ten rozwiązują współczesne tzw. modele oparte na danych (ang. *data-driven models*), które wykorzystują wyniki badań z obszarów [8]:

- sztucznej inteligencji,
- inteligencji obliczeniowej – sieci neuronowe, systemy rozmyte, algorytmy ewolucyjne,
- *soft computing* – wnioskowanie oparte na pojęciach nieostrych – rozmyte systemy regulowe,
- uczenia maszynowego,
- eksploracja danych i odkrywanie wiedzy w bazach danych.

Zaletą tego podejścia jest nie tylko pozostawienie doboru zmiennych algorytmom wbudowanym w oprogramowanie, ale także możliwość częstej aktualizacji postaci modelu (np. kwartalnej, miesięcznej lub częstszej).

Co więcej, zbudowane w ten sposób modele mogą działać automatycznie po wykryciu odchylenia, zwiększając lub zmniejszając podaż gazu w określonych obszarach, przy uwzględnieniu podpisanych umów z klientami, wpisując się w tendencję rozwoju odnawialnych źródeł energii oraz ideę *smart grid*.

Przykładowy model prognozy zapotrzebowania na odbiór gazu z podziemnych magazynów gazu w Polsce

W celu sprawdzenia przydatności współczesnych narzędzi hurtowni danych i eksploracji danych w dalszej części pracy zbudowano prosty model służący prognozowaniu wielkości odbioru gazu z podziemnych magazynów gazu w Polsce. Odbiór gazu odnosi się do sumarycznego odbioru ze wszystkich polskich magazynów. Bardziej wyrafinowany model wymagałby uwzględnienia indywidualnych danych dla pojedynczych PMG oraz obszerniejszego zbioru potencjalnych zmiennych objaśniających.

Na potrzeby badań zbudowano niewielką hurtownię tematyczną (*data mart*), gromadzącą dane z kilku źródeł. Wszystkie dane zostały zaimportowane z ogólnodostępnych internetowych baz danych jako pliki CSV i załadowane do utworzonych wcześniej tabel hurtowni danych. W przypadku praktycznej realizacji takiej hurtowni konieczne byłoby zautomatyzowanie pobierania i ładowania danych z uwzględnieniem wymaganej konwersji typów danych ze źródeł do formatu docelowego oraz uwzględnienie mechanizmu wyodrębniania błęd-

nych danych. Hurtownia taka mogłaby wtedy działać automatycznie, aktualizując dane przyrostowo w cyklach dziennych, miesięcznych lub rzadszych.

Analizą objęto okres od 1 stycznia 2011 roku do 20 września 2017 roku. Dane na temat polskich podziemnych magazynów gazu pochodzą ze strony internetowej Gas Infrastructure Europe [5], dane meteorologiczne dla Warszawy pobrano ze strony internetowej Freemetoo [4]. Ze względu na to, że posiadane dane dotyczące PMG są wartościami sumarycznymi dla wszystkich polskich magazynów, dane meteorologiczne dla Warszawy potraktowano jako charakterystykę warunków pogodowych dla centralnego punktu Polski. Średnie miesięczne wynagrodzenia w Polsce pochodzą ze strony internetowej GUS [5]. Ceny gazu dotyczą Henry Hub w Luizjanie i pochodzą ze strony internetowej Index Mundi [9]. Ceny gazu nie odnoszą się bezpośrednio do polskiego rynku, ale mogą stanowić punkt odniesienia dla cen usług magazynowania i cen

gazu w Polsce, oraz cen innych nośników energii z względu na ścisłe powiązanie ze światowymi cenami ropy i produktów ropopochodnych. Koszty zakupu gazu przez PGNiG SA są także powiązane z cenami ropy na rynkach światowych, stąd pośrednio ceny gazu w Henry Hub wskazują na tendencje cenowe na polskim rynku. Z tego samego powodu uwzględniono miesięczne ceny węgla, które pobrano ze strony internetowej Polskiego Rynku Węgla [12]. Są to notowania *PSCMI 1/T Polskiego Indeksu Rynku Węgla Energetycznego 1* w sprzedaży do energetyki zawodowej i przemysłowej. Trendy w zmianach cen węgla mogą wpływać na wybór źródeł ogrzewania przez sektor komunalno-bytowy, w tym wykorzystanie gazu ziemnego, a w konsekwencji zapotrzebowanie na usługi magazynowania gazu. Podstawowe statystyki dla zmiennej objaśnianej *Odbiór*, będącej sumaryczną wartością dobowego odbioru gazu z magazynów w Polsce, oraz potencjalnych 11 ilościowych zmiennych objaśniających zawarte są w tablicy 1. Oprócz zmiennych ilościowych wykorzystywane są także trzy zmienne jakościowe: Opis 1, Opis 2 i Opis 3 zawierające opis zjawisk pogodowych o wartościach: brak doniesień pogodowych, grad, opad śniegu, deszcz, burza z piorunami, mgła.

W pierwszym etapie zbudowano modele obejmujące wszystkie dane. W podstawowym zbiorze danych, liczącym 2486 obserwacji, znajdują się także dane z okresów napełniania magazynów. Zbiór danych załadowano do hurtowni danych utworzonej w systemie Microsoft SQL Server w wersji Enterprise 2017 [14]. Jest to jeden z kilku najbardziej liczących się na świecie produktów do zarządzania relacyjnymi

bazami danych, hurtowniami danych oraz zaawansowanej analityki danych (eksploracji danych). Jest to w zasadzie grupa produktów obejmująca także narzędzia Business Intelligence i analityki danych stanowiące komponent Visual Studio – w niniejszym artykule wykorzystano wersję 2017 [13].

Te informatyczne narzędzia są w niniejszej pracy traktowane jako typowy przykład narzędzi do gromadzenia i zaawansowanej analizy danych, prezentujący możliwości tego typu programów. Produkty innych wiodących producentów oprogramowania bazodanowego i analizy danych zostały już wymienione we wcześniejszej części artykułu.

Korzystając z gotowych kreatorów służących do budowy modeli eksploracji danych, zbudowano trzy modele, wykorzystując różne techniki klasyfikacji: drzewo decyzyjne, sztuczną sieć neuronową oraz regresję logistyczną. Program automatycznie i losowo podzielił dane na próbę uczącą oraz próbę testową, na której sprawdzana jest skuteczność predykcji modeli zbudowanych na podstawie próby uczącej. Najwyższą skuteczność prognostyczną wykazało drzewo decyzyjne, a najniższą – regresja logistyczna. Wobec tego w dalszej analizie wykorzystano drzewo decyzyjne.

Początkowe wyniki były nie w pełni zadowalające, gdyż każda gałąź drzewa zaczynała się od nazwy miesiące, co wynikało z całkowicie różnej specyfiki miesięcy zimowych (odbior) i letnich (zatłaczanie). W związku z tym ostatecznie do analizy wzięto tylko dane dotyczące chłodniejszych miesięcy od września do kwietnia, co dało 1719 obserwacji. Na rysunku 2 przedstawiono wyniki budowy drzewa decyzyjnego.

Tablica 1. Podstawowe statystyki dla zmiennych w modelu

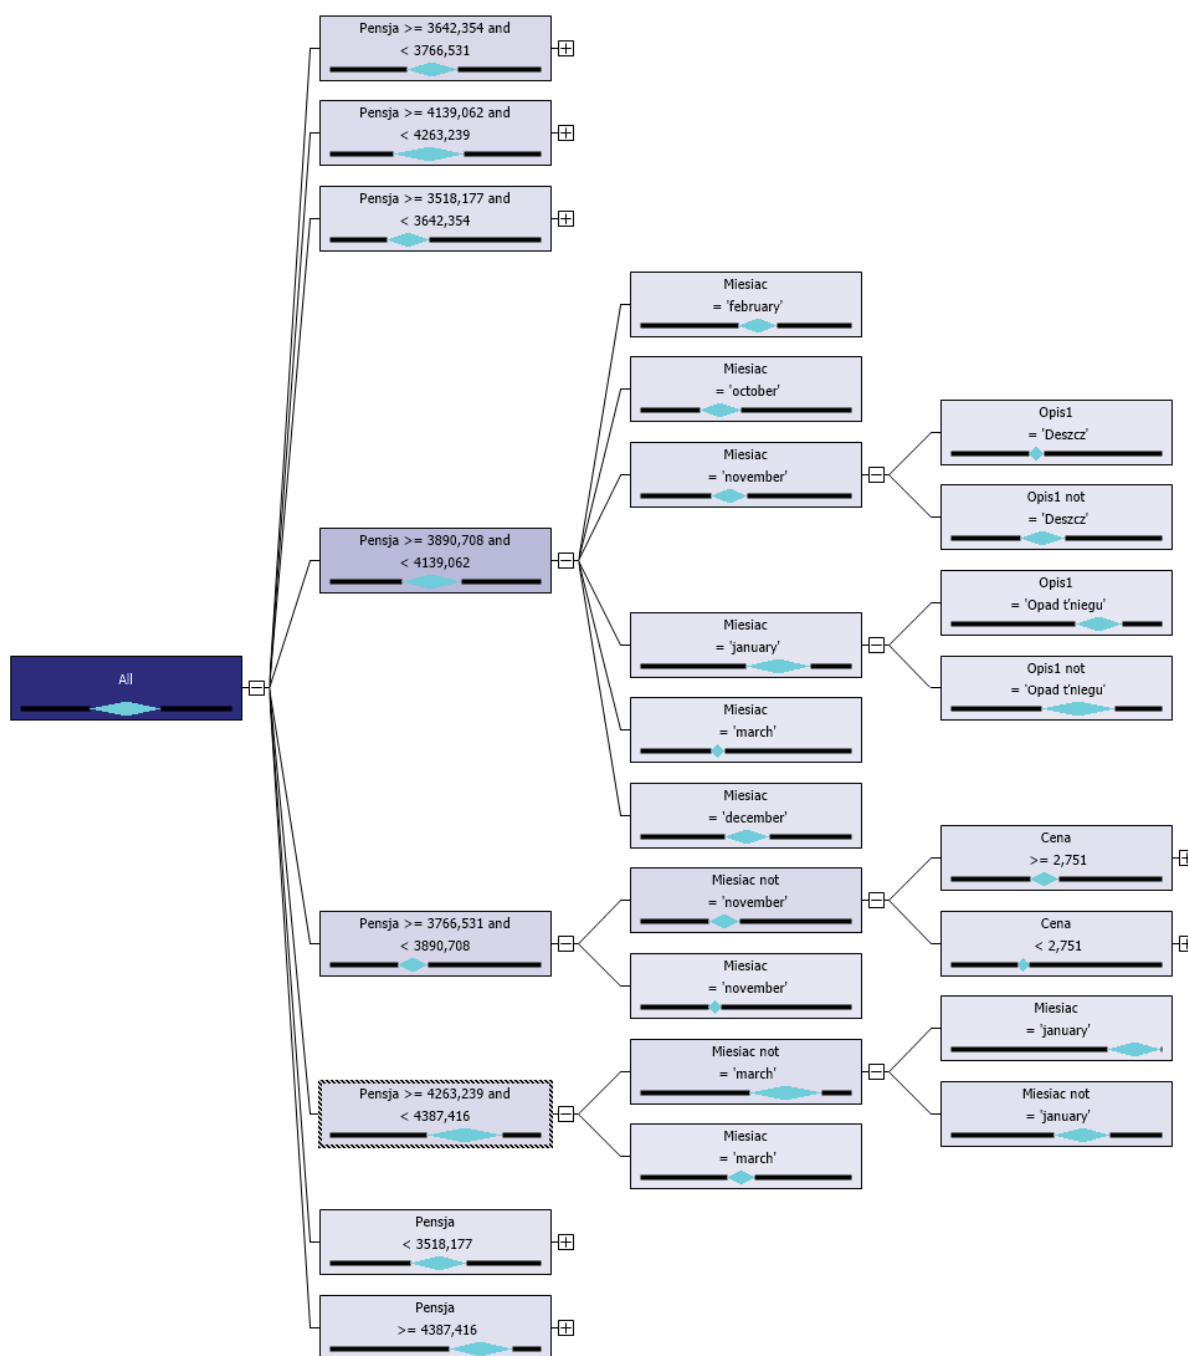
Zmienna	Jednostka	Średnia	Mediana	Odchylenie standardowe	Kurtoza	Skośność	Minimum	Maksimum
Odbiór (gazu z magazynów w Polsce)	GWh/d	41,04	0	66,19	3,15	1,88	0	355
Ilość gazu w pmg	TWh	16,81	17	7,24	-0,6	0,15	2	32
Procent napełnienia	%	72,1	75	22,16	-1,07	-0,43	25	100
Pojemność czynna	TWh	23,86	28	8,17	-0,72	-0,57	8	33
Moc odbioru	GWh/d	448,68	432	78,56	-1,37	-0,15	319	543
Temperatura min	°C	4,94	5	7,94	-0,18	-0,37	-23	22
Temperatura maks	°C	13,89	14	10,05	-0,79	-0,15	-15	37
Prędkość wiatru	km/h	23,14	22	8,11	1,21	0,78	4	66
Opady	mm	2,04	0	6,16	52,35	6,41	0	77
Pensja (średnie miesięczne wynagrodzenie w gospodarce)	zł	3 973,5	3 964,9	299,3	-0,82	0,25	3 394,0	4 635,8
Cena (gazu w Henry Hub)	EUR/mln BTU	2,65	2,65	0,52	0,54	0,05	1,48	4,38
Cena węgla (indeks PSCMI 1/T)	zł/T	233,87	234,56	28,7	-1,12	0,09	188,78	283,61

Źródło: opracowanie własne.

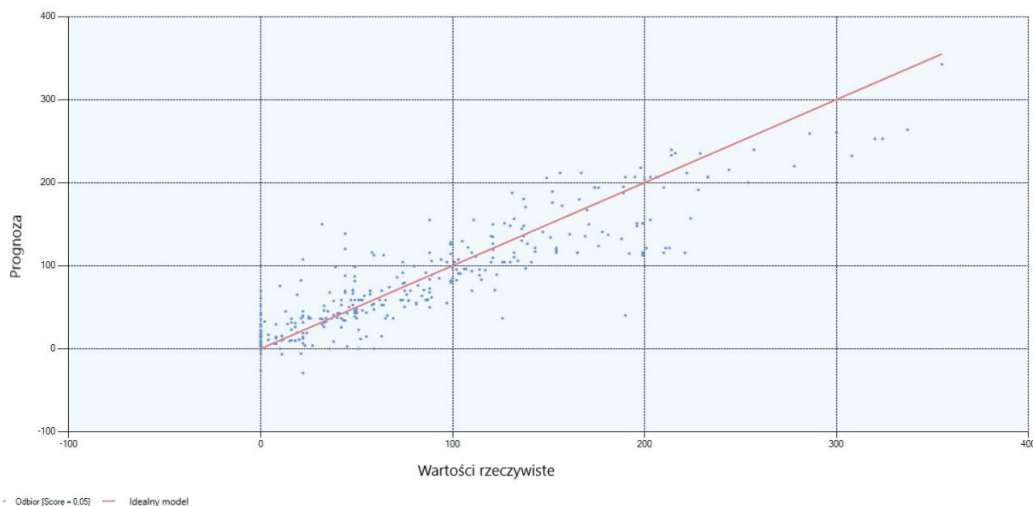
Podsumowanie wyników prognoz dla próby testowej liczącej 1000 elementów umieszczono na rysunku 3. Proces budowy, przetwarzania i testowania modeli zajął jedynie kilka minut.

W każdym z węzłów drzewa decyzyjnego algorytm wyznaczył inną funkcję regresji. Drzewo decyzyjne, a w zasadzie drzewo regresyjne, musi zawierać w węzłach funkcje regresji, gdyż zmienna prognozowana *Odbiór* jest zmienną ciągłą. Funkcje regresji w poszczególnych węzłach są następujące:

- dla całej próbki (węzeł *All*)
 $Odbiór = 73,167 - 5,171 (Temperatura Maks - 6,178) - 12,597 (Cena - 2,626)$
- węzeł [*Pensja* ≥ 3890,708 and < 4139,062]
 $Odbiór = 67,053 - 5,738 (Temperatura Maks - 6,885)$
- węzeł [*Pensja* ≥ 3890,708 and < 4139,062 and *Miesiąc* = 'november']
 $Odbiór = 42,692 - 4,473 (Temperatura Maks - 7,761) + 52,877 (Cena - 2,990)$
- węzeł [*Pensja* ≥ 3890,708 and < 4139,062 and *Miesiąc* = 'november' and *Opis1* = 'Deszcz']
 $Odbiór = 36,000 + 24,920 (Cena - 2,947) - 1,581 (Temperatura Maks - 8,619) + 0,536 (Prędkość Wiatru - 22,524)$



Rys. 2. Drzewo regresyjne dla odbioru gazu z magazynów gazu w miesiącach zimowych (ciemniejszy kolor wskazuje na większą liczbę danych w węzle)



Rys. 3. Wartości prognoz odbioru gazu w relacji do rzeczywistych wartości odbioru

Największy wpływ na zmienną objaśnianą – odbiór gazu z magazynów mierzony wartością funkcji podziału drzewa

nego modelu spośród kilku analizowanych, a jego wartości bliskie zero świadczą o dobrych własnościach prognostycznych.

Wnioski

Wykorzystanie narzędzi do budowy hurtowni danych i eksploracji danych staje się dość powszechne w obszarze poszukiwawczo-wydobywczym. Wielu światowych producentów oprogramowania kieruje swoją ofertą do tego obszaru. Istnieją także gotowe rozwiązania specjalistyczne branżowych firm IT. Brakuje jednak gotowych rozwiązań dla gazownictwa, w tym narzędzi prognozowania, wykorzystujących zaawansowaną eksplorację danych, pozwalających na budowę modeli opartych na danych.

Wykonana jako przykład prognoza odbioru gazu z podziemnych magazynów gazu okazała się dobrze dopasowana do danych rzeczywistych, mimo małej szczegółowości danych i niezbyt szerokiego zbioru potencjalnych zmiennych objaśniających. Pozyskanie bardziej szczegółowych danych wiąże się z koniecznością posiadania dostępu do danych wewnętrznych operatora magazynów oraz potrzebą zakupu danych ekonomicznych, w tym cenowych lub meteorologicznych. Co najważniejsze budowa modelu prognostycznego była szybka i prosta dzięki kreatorom wbudowanym w oprogramowanie. Oprogramowanie do eksploracji danych może stanowić bardzo dobre narzędzie prognozowania w branży gazowniczej dzięki działaniu na zasadzie „czarnej skrzynki” i poten-

cjalnie dowolnie dużemu zbiorowi zmiennych objaśniających zgromadzonych w hurtowni danych.

Możliwość zastosowania hurtowni danych wraz z narzędziami eksploracji danych nie ogranicza się do zaprezentowanego przykładu podziemnych magazynów gazu. Prognozowanie zapotrzebowania na gaz dla gazociągów przesyłowych i dystrybucyjnych, czy też inne nośniki energii, może opierać się nie tylko na klasycznych zmiennych objaśniających, przeważnie ilościowych, ale także na dowolnej liczbie zmiennych jakościowych, które bez dodatkowych przekształceń mogą znaleźć się w modelu. Dopuszczalne staje się uwzględnianie takich zagadnień jak ekologia, odnawialne źródła energii, polityka energetyczna czy nawet problemy polityczne w obszarze UE. Budowa modelu wymagałaby najpierw znalezienia kluczowych słów dla danego zagadnienia pojawiających się w serwisach informacyjnych.

Spośród technik eksploracji danych na szczególną uwagę zasługuje drzewo regresyjne, dzielące zbiór danych na podzbiory, w których odrębnie wyznaczane są linie regresji. Znacząco zwiększa to skuteczność prognostyczną tej metody w stosunku do pojedynczej linii regresji tworzonej dla całego zbioru danych.

Prosimy cytować jako: Nafta-Gaz 2018, nr 4, s. 284–289, DOI: 10.18668/NG.2018.04.04

Artykuł nadesłano do Redakcji 02.02.2018 r. Zatwierdzono do druku 22.03.2018 r.

Artykuł powstał na podstawie pracy statutowej pt.: *Zastosowanie metod matematycznych i narzędzi informatycznych do wspomagania zarządzania organizacjami* – praca AGH na zlecenie MNiSW; nr zlecenia: 11.11.200.327.

(metoda Bayesa z predykcją Dirichleta) – ma w kolejności: temperatura, cena gazu, prędkość wiatru, średnia płaca w gospodarce, miesiąc i jako ostatnia zmienna – opis warunków meteorologicznych (deszcz, śnieg itp.). Dopasowanie modelu do danych jest mierzone współczynnikiem *score* (wartość 0,05 u dołu rysunku 3), który jest średnią geometryczną odchyłeń prognoz od danych rzeczywistych. Współczynnik pozwala na wybór najlepiej dopasowa-

Literatura

- [1] Balfe P., Kelp O.: *Gas consumption Forecasting. A methodology*. Acil Allen Consulting, Sydney 2014, www.acilallen.com.au (dostęp: wrzesień 2016).
- [2] Buchnowska D.: *CRM strategia i technologia*. Wydawnictwo Uniwersytetu Gdańskiego, Gdańsk 2006.
- [3] Edjlali R., Ronthal A.M., Greenwald R., Beyer M.A., Feinber D.: *Magic quadrant for data management solutions for analytics*. Gartner 2017, <https://www.gartner.com/home> (dostęp: październik 2017).
- [4] Freemeteo, <https://freemeteo.pl/> (dostęp: grudzień 2017).
- [5] Gas Infrastructure Europe, <https://agsi.gie.eu> (dostęp: grudzień 2017).
- [6] Główny Urząd Statystyczny, <https://bdl.stat.gov.pl/BDL/dane/podgrup/temat> (dostęp: grudzień 2017).
- [7] Han J., Kamber M., Pei J.: *Data mining: concepts and techniques*. Elsevier, San Francisco 2012.
- [8] Holdaway K.: *Harness oil and gas big data with analytics: Optimize exploration and production with data driven models*. John Wiley & Sons, New Jersey 2014.
- [9] Index Mundi, <https://www.indexmundi.com> (dostęp: grudzień 2017).
- [10] Larose D.: *Odkrywanie wiedzy z danych*. PWN, Warszawa 2006.
- [11] Linden A., Krensky P., Hare J., Idoine C.J., Sicular S., Vashisth S.: *Magic quadrant for data science platforms*. Gartner 2017, <https://www.gartner.com/home> (dostęp: październik 2017).
- [12] Polski Rynek Węgla, <http://www.polskirynekwegla.pl/indekspscmi-1> (dostęp: grudzień 2017).
- [13] Strona internetowa: <https://docs.microsoft.com/en-us/visual-studio/ide/visual-studio-ide> (dostęp: październik 2017).
- [14] Strona internetowa: <https://www.microsoft.com/pl-pl/sql-server/sql-server-2017-editions> (dostęp: październik 2017).
- [15] Surma J.: *Business Intelligence. Systemy Wspomagania Decyzji Biznesowych*, Wydawnictwo Naukowe PWN, Warszawa 2009.
- [16] *Top oil and gas software products*, <http://www.capterra.com/oil-and-gas-software> (dostęp: grudzień 2017).



Dr hab. inż. Andrzej PALIŃSKI
 Adiunkt
 Akademia Górniczo-Hutnicza im. St. Staszica
 w Krakowie, Wydział Zarządzania
 ul. Gramatyka 10
 30-067 Kraków
 E-mail: palinski@zarz.agh.edu.pl

OFERTA

ZAKŁAD INFORMATYKI

Zakres działania:

- zastosowanie matematyki i technologii informatycznych do:
 - » konstrukcji dziedzinowych systemów eksperckich,
 - » budowy i eksploatacji baz danych i baz wiedzy,
 - » wykorzystania metod analiz ryzyka,
 - » konstrukcji Systemu Zarządzania Integralnością Gazociągów,
 - » budowy komputerowych systemów wspomaganie decyzji,
 - » analizy statystycznej wyników eksperymentów badawczych,
 - » tworzenia unikatowego oprogramowania,
- zarządzanie siecią komputerową i dostępem do internetu w ramach sieci korporacyjnej INiG – PIB.



Kierownik: mgr Andrzej Dietrich
Adres: ul. Bagrowa 1, 30-733 Kraków
Telefon: 12 653-25-12 w. 149
Fax: 12 650 77 50, 12 653 16 65
E-mail: andrzej.dietrich@inig.pl

