

Katarzyna Hawran, Joanna Kowalik

Wykorzystanie metody wielokryterialnej drzew decyzyjnych w przedsiębiorstwie produkcyjnym

Studia i Prace Wydziału Nauk Ekonomicznych i Zarządzania 50/1, 169-178

2017

Artykuł został opracowany do udostępnienia w internecie przez Muzeum Historii Polski w ramach prac podejmowanych na rzecz zapewnienia otwartego, powszechnego i trwałego dostępu do polskiego dorobku naukowego i kulturalnego. Artykuł jest umieszczony w kolekcji cyfrowej bazhum.muzhp.pl, gromadzącej zawartość polskich czasopism humanistycznych i społecznych.

Tekst jest udostępniony do wykorzystania w ramach dozwolonego użytku.



DOI: 10.18276/sip.2017.50/1-12

Katarzyna Hawran*

Joanna Kowalik**

Uniwersytet Szczeciński

WYKORZYSTANIE METODY WIELOKRYTERIALNEJ DRZEW DECYZYJNYCH W PRZEDSIĘBIORSTWIE PRODUKCYJNYM

Streszczenie

Działanie w niestabilnym otoczeniu i podejmowanie decyzji w warunkach wysokiego ryzyka utrudnia podejmowanie racjonalnych decyzji. Jednak dzięki takiej metodzie jak drzewa decyzyjne czy też innym metodom wielokryterialnym zarówno człowiek, jak i podmiot gospodarczy znacznie lepiej przygotowuje się do podjęcia decyzji.

Artykuł został poświęcony tematyce wykorzystania metody wielokryterialnej drzew decyzyjnych w przedsiębiorstwie produkcyjnym. Celem opracowania jest przedstawienie istoty metody drzew decyzyjnych oraz ich zastosowania na przykładzie firmy produkcyjnej działającej w przemyśle drzewnym.

Słowa kluczowe: drzewa decyzyjne, metody wielokryterialne

Wprowadzenie

Podejmowanie decyzji jest nieodłącznym elementem działalności każdego człowieka. Początkowo dotyczy mało istotnych spraw, jednak z czasem się to zmienia, nasze wybory zaczynają mieć coraz większe konsekwencje, a niekiedy nawet rzutują na resztę życia. Stąd pojawia się pytanie, czym tak naprawdę jest decyzja. Według

* Adres e-mail: kasiahawran@gmail.com

** Adres e-mail: joannakowalik02@gmail.com

Słownika języka polskiego (<https://sjp.pwn.pl>) decyzja to „postanowienie będące wynikiem dokonania wyboru”. Natomiast według Koźmińskiego (1978, s. 14) decyzja to „świadomy, nielosowy wybór jednego z rozpoznawanych i uznanych za możliwe wariantów przyszłego działania”. W związku z tym podejmowanie decyzji nie ogranicza się tylko do spraw *stricte* ludzkich, ale również do działalności gospodarczej. W ramach funkcjonowania firm właściciele czy też osoby zarządzające są zobligowani do podejmowania decyzji każdego dnia. Dotyczą one wielu aspektów, jednak na ogół są podejmowane w warunkach ryzyka i wymagają wnikliwej analizy, która przeprowadzana jest na podstawie dostępnych informacji. Specyfika rynku produkcyjnego przejawiająca się w jego niskiej efektywności i małej płynności inwestycji sprawia, że proces decyzyjny uczestników rynku jest skomplikowany, zagrożony wpływem heurystyk i wystąpieniem błędów poznawczych, a skutki decyzji są na ogół trudne do przewidzenia (Kahneman, Slovic, Tversky, 1982). Proces decyzyjny jest niezwykle skomplikowany, gdyż zależy od wielu determinant i uwarunkowań, nie tylko wynikających z otoczenia rynkowego, ale też jest silnie uzależniony od indywidualnych predyspozycji i cech inwestora. Oprócz czynników o charakterze ekonomicznym istnieją także czynniki psychologiczne wpływające na zachowania uczestników rynku produkcyjnego i decydujące o wyborze miejsca alokacji kapitału (Czechowska, 2014, s. 13–14). Aby usprawnić proces podejmowania decyzji, opracowano szereg metod mających na celu pomoc w dokonaniu właściwego wyboru. W tym opracowaniu szczególna uwaga zostanie poświęcona metodzie drzew decyzyjnych.

1. Metoda drzew decyzyjnych

Drzewa decyzyjne są graficzną metodą wspomaganą procesu decyzyjnego. Jest to jedna z najczęściej wykorzystywanych technik analizy danych. Drzewo składa się z korzenia oraz gałęzi prowadzących z korzenia do kolejnych wierzchołków. Wierzchołki, z których wychodzi co najmniej jedna krawędź, są nazywane węzłami, a pozostałe wierzchołki – liśćmi. W każdym węźle sprawdzany jest pewien warunek dotyczący konkretnej obserwacji i na jego podstawie wybierana jest jedna z gałęzi prowadząca do kolejnego wierzchołka. Klasyfikacja danej obserwacji polega na przejściu od korzenia do liści i przypisaniu do tej obserwacji klasy zapisanej w danym liści (Przywara, 2007, s. 2). W eksploracji danych i uczeniu maszynowym drzewa decyzyjne są modelami prognozującymi. Są często stosowaną metodą w *data mining*. Używane są w kilku przypadkach (Mulawka, 1996):

- a) redukcji ilości danych poprzez przekształcenie ich do formy zajmującej mniej „miejsca” przy jednoczesnym zachowaniu cech oraz zapewnieniu dokładności rozwiązania problemu;
- b) sprawdzania, czy dane zawierają oddzielne grupy obiektów, takie że te grupy można sensownie interpretować pod kątem teorii;
- c) wykrycia mapowania z niezależnych do zależnych zmiennych, które jest użyteczne przy przewidywaniu wartości zależnej zmiennej w przyszłości.

W *data mining* na drzewa decyzyjne, podobnie jak w teorii decyzji, składają się (Mulawka, 1996):

- korzeń zawierający wszystkie próbki treningowe,
- węzły posiadające pojedynczą cechę lub zespół cech z próbek treningowych,
- liście – ostatecznie uszeregowane według pewnych cech dane z próbek treningowych.

Tworzenie drzewa rozpoczyna się od rozstrzygnięcia, co będzie liściem, a co węzłem oraz doboru dla niego etykiety kategorii lub testu. Jeśli został utworzony węzeł, to poszczególnym wynikom odpowiadają gałęzie prowadzące z tego węzła do poddrzew skonstruowanych zgodnie z tym samym schematem. Konkretny algorytm różni się kryteriami podejmowania wspomnianych wyżej dwóch decyzji: o utworzeniu liścia lub o wyborze testu dla węzła. Schemat konstruowania drzewa decyzyjnego został przedstawiony poniżej (Przywara, 2007, s. 3).

Funkcja buduje – drzewo (P, d, S)

Argumenty wyjściowe:

P – zbiór przykładów etykietowanych pojęcia c ,

d – domyślna etykieta kategorii,

S – zbiór możliwych testów.

Jeśli kryterium stopu (P, S), **to:**

utwórz liść l ;

d_l : = kategoria (P, d);

zwróć l ;

koniec jeśli

utwórz węzeł n

t_n : = wybierz-test (P, S)

d : = kategoria(P, d)

dla wszystkich $r \in R_{t_n}$ **wykonaj**

$n[r]$: = buduj-drzewo ($P_{t_n}, d, S - \{t_n\}$);

koniec dla:

zwróć n

Kryterium wyboru

Kryterium stopu określa, kiedy ma być zatrzymany proces rozrostu drzewa, czyli kiedy dla pewnego zbioru przykładów nie powstanie kolejny węzeł wewnętrzny, lecz liść. Sytuacja taka nastąpi, gdy:

aktualny zbiór przykładów P jest pusty,
wszystkie przykłady ze zbioru P należą do tej samej kategorii pojęcia c ,
zbiór możliwych do użycia testów S jest pusty.

Kryterium wyboru testu

Kryterium wyboru testu decyduje o złożoności drzewa decyzyjnego. Przy wyborze testu należy zawsze kierować się zasadą, aby zbudować możliwie jak najprostsze drzewo. Popularne stało się wykorzystanie entropii do pomiaru nierównomierności rozkładu kategorii. Bazująca na niej funkcja oceny testu, nazywana przyrostem informacji, jest obliczana w następujący sposób:

$$g_t(P) = I(P) - E_t(P) \quad (1)$$

gdzie:

$E_t(P)$ – entropia zbiorów przykładów P ,

$I(P)$ – informacja zawarta w zbiorze etykietowanych przykładów P .

Entropia jest pewną miarą informacji zawartej w zjawisku, które w przypadkowy sposób może przyjmować n stanów. Oznacza więc także wartość średnią ilości informacji niezbędnej do zapamiętania faktu, że dane zjawisko przyjmuje jeden spośród n dostępnych stanów (Cichosz, 2000).

Korzystniejsze są testy maksymalizujące przyrost informacji, co jest równoznaczne z minimalizacją entropii. Czasami w praktycznym zastosowaniu drzew decyzyjnych istotnym kryterium wyboru testów podczas konstrukcji drzewa, oprócz ich jakości, jest też koszt.

Przycinanie drzew

Przycinanie drzewa polega na zastąpieniu jego wybranych poddrzew przez liście, którym przypisuje się etykietę kategorii najczęściej występującej wśród związanych z nim przykładów. Tego typu uproszczenie spowoduje na ogół pogorszenie dokładności klasyfikacji dla zbioru trenującego, ale może dawać lepsze efekty dla danych spoza tego zbioru. Uzyskane po przycięciu drzewo będzie mniejsze i prostsze, co daje lepszą czytelność dla człowieka, oszczędność pamięci i większą efektywność obliczeniową procesu przez skrócenie ścieżek łączących korzeń drzewa z liśćmi (Libal, 2015, s. 9).

Implementację algorytmów przycinania drzew decyzyjnych można przeprowadzić na kilka sposobów (Przywara, 2007, s. 4):

- a) przycinanie w trakcie wzrostu – jest to przycinanie podczas konstrukcji drzewa, jednak znalezienie kryterium stopu realizującego przycinanie w trakcie wzrostu z dobrymi efektami okazuje się trudne;
- b) przycinanie od środka – jest to zastępowanie przyciętego węzła jednym z jego węzłów potomnych; nie jest wówczas usuwane całe drzewo, a jedynie jego korzeń;
- c) przycinanie proste – jest to zastępowanie przyciętego węzła węzłem zawierającym etykietę klasy-decyzji; jest to stosunkowo prosty mechanizm i bardzo często stosowany.

Oprócz odpowiedniego algorytmu modyfikacji drzewa należy jeszcze zdecydować, w jaki sposób szacowany będzie współczynnik błędu rzeczywistego drzewa, na podstawie którego podejmuje się decyzję o przycięciu poddrzewa. Można wyróżnić dwa główne podejścia (Libal, 2015, s. 12):

1. Przycinanie z oddzielnym zbiorem przycinania – podejście to stosuje się w przypadku, jeśli jest dostępna dostatecznie duża ilość danych, które dzieli się na zbiór trenujący i testujący (np. w stosunku 1/2). Poddzewo jest przycinane, jeżeli po zastąpieniu go liściem nie zwiększy się błąd próbki na zbiorze testującym.
2. Przycinanie na podstawie przykładów trenujących – podejście musi być stosowane, jeżeli nie można sobie pozwolić na podzielenie niewielkiej ilości dostępnych danych na zbiór trenujący i testujący. Dopiero wtedy decyzja o przycięciu może być podejmowana na podstawie różnych heurystycznych oszacowań bazujących wyłącznie na zbiorze trenującym.

2. Zastosowanie drzew decyzyjnych

Drzewa decyzyjne znajdują praktyczne zastosowanie w różnego rodzaju problemach decyzyjnych, szczególnie takich, gdzie występuje dużo rozgałęziających się wariantów, a także w warunkach ryzyka. Wiele algorytmów uczenia się pojęć wykorzystuje drzewa decyzyjne do reprezentacji hipotez. Zgodnie z ogólnym celem uczenia się indukcyjnego dążą one do uzyskania drzewa decyzyjnego klasyfikującego przykłady trenujące z niewielkim błędem próbki i o możliwie niewielkim rozmiarze w nadziei, że takie drzewo będzie miało również niewielki błąd rzeczywisty.

Drzewa decyzyjne znajdują szerokie zastosowanie w (Przywara, 2007, s. 6):

- diagnostyce medycznej,
- przewidywaniu wydajności,
- akceptacji i udzielaniu kredytów.

Proces klasyfikacji z wykorzystaniem drzew decyzyjnych jest efektywny obliczeniowo, ponieważ wyznaczenie kategorii przykładu wymaga w najgorszym razie przetworzenia jednorazowo wszystkich jego atrybutów. Przykładem zastosowania drzew decyzyjnych w klasyfikacji może być działanie przedsiębiorstwa produkcyjnego. Przykład takiego drzewa został przedstawiony na rysunku 1. Odnosi się do firmy produkcyjnej „X” działającej w przemyśle drzewnym, która zastanawia się nad zmianą linii technologicznej produktów. Koszt wprowadzenia nowej technologii to wydatek inwestycyjny rzędu 250 tys. zł, natomiast przedsiębiorstwo może podjąć decyzję o remoncie starej linii technologicznej, co stanowi koszt rzędu 50 tys. zł. Ważną kwestią jest to, iż zainwestowanie w rozwój może spowodować wzrost przychodów o 1 mln zł. Istotnym elementem w podejmowaniu decyzji jest prawdopodobieństwo sukcesu, za który przyjmuje się zwiększenie produkcji (sprzedaży). Prawdopodobieństwo to zostało przedstawione w tabeli 1.

Tabela 1. Wielkość prawdopodobieństwa w przypadku zakupu nowej linii

Zwiększenie produkcji dzięki nowej technologii	Sukces	Porażka
Prawdopodobieństwo	0,9	0,1

Źródło: opracowanie własne.

Została również przewidziana sytuacja, gdy właściciele zdecydują się na remont. Prawdopodobieństwo sukcesu i porażki zostało przedstawione w tabeli 2.

Tabela 2. Wielkość prawdopodobieństwa w przypadku remontu starej linii

Zwiększenie produkcji dzięki remontowi starej linii	Sukces	Porażka
Prawdopodobieństwo	0,4	0,6

Źródło: opracowanie własne.

Dodatkowo w ramach nowej linii możliwe jest wdrożenie aplikacji, której koszt wynosi 50 tys. zł. Wprowadzenie takiego rozwiązania może się przełożyć na wzrost sprzedaży produktów. Rozkład prawdopodobieństwa wdrożenia aplikacji przedstawiono w tabeli 3.

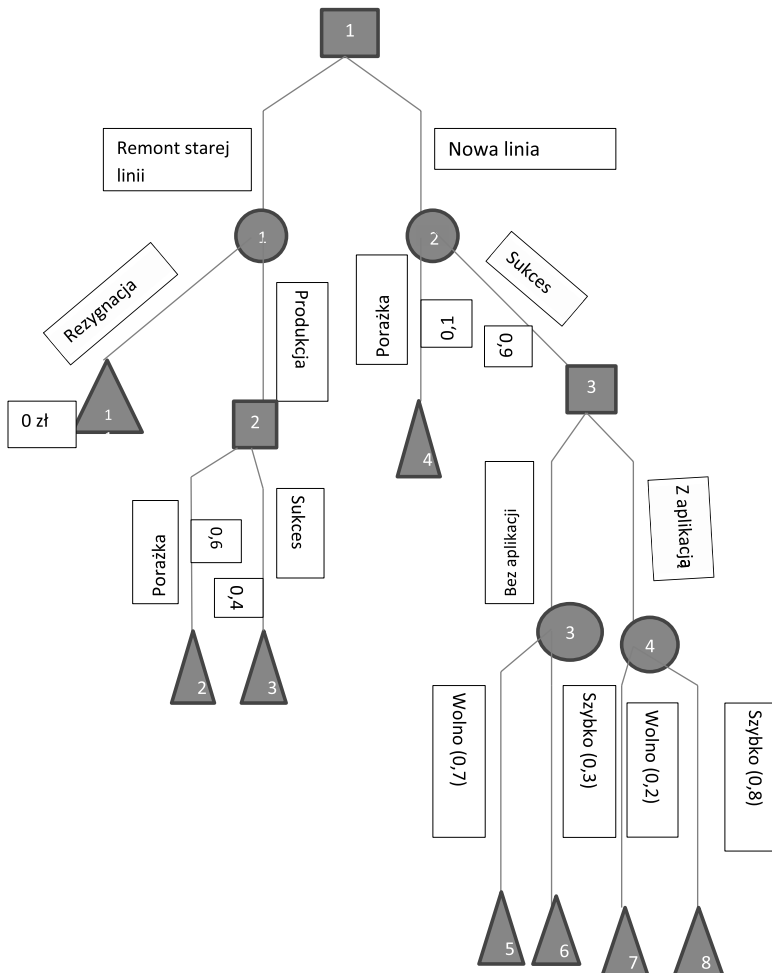
Tabela 3. Wielkość prawdopodobieństwa w przypadku wdrożenia aplikacji

Zwiększenie produkcji	Z aplikacją	Bez aplikacji
Szybkie tempo zwiększenia produkcji	0,8	0,3
Wolne tempo zwiększenia produkcji	0,2	0,7

Źródło: opracowanie własne.

Na podstawie powyższych danych stworzone zostało drzewo decyzyjne, które przedstawiono na rysunku 1.

Rysunek 1. Drzewo decyzyjne w firmie produkcyjnej „X”



Źródło: opracowanie własne

Wyniki są następujące:

Tabela 4. Możliwe opcje wyboru w ramach drzewa decyzyjnego

Trójkąt (węzły końcowe)	Końcowe wpłaty (zł)
1	0 (niepodjęcie działania)
2	-50 tys. (koszt remontu)
3	950 tys. (wielkość przychodów – koszt remontu)
4	-250 tys. (koszt nowej linii)
5	750 tys. (wielkość przychodów – koszt nowej linii)
6	750 tys. (wielkość przychodów – koszt nowej linii)
7	700 tys. (wielkość przychodów – koszt nowej linii – koszt aplikacji)
8	700 tys. (wielkość przychodów – koszt nowej linii – koszt aplikacji)

Źródło: opracowanie własne.

Tabela 5. Wyniki poszczególnych ścieżek po uwzględnieniu prawdopodobieństwa

Koła (węzły)	Wartość oczekiwana (zł)
4	$(700\ 000 * 0,8) + (700\ 000 * 0,2) = 700\ 000$
3	$(750\ 000 * 0,3) + (750\ 000 * 0,7) = 750\ 000$
2	$(750\ 000 * 0,9) + (-250\ 000 * 0,1) = 650\ 000$
1	$(950\ 000 * 0,4) + (-50\ 000 * 0,6) = 350\ 000$

Źródło: opracowanie własne.

Uzasadnienie decyzji

Optymalna ścieżka decyzji jest wyznaczona przez największe wartości oczekiwane. W podanym przykładzie z obliczeń wynika, iż firma produkcyjna „X” powinna zainwestować w nową linię produkcyjną, ale bez kupowania dodatkowej aplikacji.

Podsumowanie

W teorii podejmowania decyzji drzewo decyzyjne jest określane jako drzewo decyzji i możliwych konsekwencji stanów natury (Copeland, Koller, Murrin, 2000, s. 397). Za jego stosowaniem przemawia relatywna skuteczność oraz jednocześnie

prosta. Jednak wiadomo, że każda metoda ma swoje wady i zalety. Z całą pewnością do jej zalet zaliczyć można także (Przywara, 2007, s. 7):

- a) możliwość reprezentowania dowolnie złożonego pojęcia pojedynczego lub wielokrotnego, jeśli tylko ich definicje da się wyrazić w zależności od atrybutów;
- b) efektywność pamięciową reprezentacji drzewiastej;
- c) czas decyzyjny ograniczony liniowo przez liczbę atrybutów (maksymalna głębokość drzewa);
- d) formę prezentacji czytelną i praktyczną dla człowieka;
- e) łatwe przejście od reprezentacji drzewiastej do reprezentacji regułowej.

Natomiast wady polegają na (Przywara, 2007, s. 7):

- a) testowaniu wartości jednego atrybutu naraz, co powoduje niepotrzebny rozrost drzewa dla danych, gdzie poszczególne atrybuty zależą od siebie (inne metody prezentacji mogą być w tym przypadku o wiele mniej złożone);
- b) kosztowna jest reprezentacja alternatyw pomiędzy atrybutami – znaczny rozrost drzewa (w przeciwieństwie do reprezentacji koniunkcji, która jest zapisywana jako pojedyncza „ścieżka”, czyli droga od korzenia do liścia);
- c) drzewa decyzyjne nie stwarzają łatwej możliwości do ich inkrementacyjnego aktualizowania, algorytmy udoskonalające gotowe już drzewa poprzez zestaw nowych przykładów są bardzo złożone i zazwyczaj wynikiem jest drzewo gorszej jakości niż drzewo budowane od początku z kompletnym zestawem przykładów.

Działanie w niestabilnym otoczeniu i podejmowanie decyzji w warunkach wysokiego ryzyka utrudnia jednak podejmowanie racjonalnych działań. Niemniej dzięki takim metodom, jak drzewa decyzyjne czy też inne metody wielokryterialne, zarówno człowiek, jak i podmiot gospodarczy znacznie lepiej przygotowują się do podjęcia decyzji. Polega to na wzroście prawdopodobieństwa, iż decyzja będzie właściwa.

Literatura

- Bujak, T. (2008). *Drzewa decyzyjne*. Toruń: Wyd. UMK.
- Cichosz, P. (2000). *Systemy uczące się*. Warszawa: WNT.
- Copeland, T., Koller, T., Murrin, J. (2000). *Valuation. Measuring and Managing the Value of Companies*. Inc., New York: John Wiley & Sons.

- Czechowska, K. (2014). Wybrane uwarunkowania podejmowania decyzji inwestycyjnych na rynku nieruchomości – ujęcie behawioralne. *Studia i Prace WNEiZ*, 36 (1), 14–25.
- Kahneman, D., Slovic, P., Tversky, A. (1982). *Judgment under Uncertainty: Heuristics and Biases*. New York: Cambridge University Press.
- Koźmiński, A.K. (1978). *Decyzje. Analiza systemowa organizacji*. Warszawa: PWN.
- Libal, U. (2015). *Drzewa decyzyjne, bagging, boosting i lasy losowe*. Pobrane z: <http://ur-szula.libal.staff.iiar.pwr.wroc.pl> (10.06.2017).
- Mulawka, J. (1996). *Systemy ekspertowe*. Warszawa: WNT.
- Przywara, D. (2007). *Drzewa decyzyjne, metody budowania, zastosowania*. Wrocław: Wyd. Politechniki Wrocławskiej.
- Słownik języka polskiego PWN*. Pobrane z: <https://sjp.pwn.pl/slowniki/decyzja.html> (30.06.2017).

USE OF MULTI-CERTIFICATE METHOD OF DECISION TREE IN PRODUCTION

Abstract

Working in unstable environments and making high-risk decisions makes it difficult to make rational decisions. However, thanks to a method such as decision trees or other multicriteria methods, both man and business are much better prepared to make decisions, and thus increase the likelihood that the decision is correct.

This article is devoted to the use of multicriteria decision trees in a manufacturing enterprise. The aim of the study is to present and explain the decision tree method and its application as well as to present the results of the research on the example of the production company. The article uses a multi-criteria method, literature review and case study.

Translated by Joanna Kowalik

Keywords: decision trees, multicriteria methods

JEL Codes: C10, D81