

*Andrzej Kusz, Andrzej W. Marciniak  
Katedra Podstaw Techniki  
Akademia Rolnicza w Lublinie*

## **DYNAMICZNE SIECI PROBABILISTYCZNE JAKO SYSTEM REPREZENTACJI WIEDZY**

### **Streszczenie**

W pracy przedstawiono podstawowe założenia metodyczne związane z budową formalnych systemów reprezentacji wiedzy. Omówiono sieci probabilistyczne, które są szczególnie przydatnym systemem reprezentacji wiedzy w przypadku, gdy trzeba w sposób jawny zakodować czynnik niepewności i rozumowania w kategoriach niedeterministycznych związków przyczynowo-skutkowych. Sprecyzowano zasady budowy modelu oraz omówiono metody wnioskowania specyficzne dla sieci bayesowskich.

**Słowa kluczowe:** system reprezentacji wiedzy, sieci probabilistyczne, bayesowskie sieci dynamiczne, modele niezawodnościowe

### **Wprowadzenie**

Projektując komputerowy system wiedzy należy postępować w myśl zasady, według której każdy etap procesu projektowania kończy się produktem mogącym spełniać rolę gotowego komponentu przy późniejszym utrzymywaniu (uaktualnianiu i rozszerzaniu) zaprojektowanego systemu.

Podstawowy etap projektowania obejmuje zbudowanie pojęciowego modelu dziedziny, w którym wiedza jest reprezentowana w sposób formalny. Pojęcie model wiedzy jest rozumiane jako abstrakcyjna reprezentacja wyodrębnionego fragmentu świata fizycznego (dziedziny przedmiotowej) umożliwiająca poprawne rozumowanie (interpretację i wnioskowanie) o modelowanej dziedzinie. Model pojęciowy dziedziny (model wiedzy) ma umożliwiać nie tylko poprawną semantycznie komunikację pomiędzy systemem a użytkownikiem, ale również między różnymi systemami.

Utworzenie formalnej reprezentacji wiedzy wymaga wcześniejszego jej uporządkowania i ustrukturalizowania. Konceptualizacja nieformalna, tj. reprezentacja wiedzy w języku naturalnym, zawiera wiele niejednoznaczności i jako taka może być interpretowana jedynie przez ludzkiego eksperta. Metodyka projektowania formalnego systemu reprezentacji wiedzy powinna charakteryzować się łatwością przejścia od opisu problemu w języku naturalnym do reprezentacji w języku formalnym i wykonywalnym, tzn. mającym specyficzną, a najlepiej uniwersalną semantykę operacyjną. Jednocześnie system formalnej reprezentacji wiedzy powinien być wystarczająco ekspresywny, tzn. powinien udostępniać wystarczającą ilość struktur składniowych umożliwiających precyzyjny opis dziedziny przedmiotowej.

Formalny zapis wiedzy tworzy bazę wiedzy. Baza wiedzy jest definiowana jako ustrukturalizowana reprezentacja, do której można zastosować mechanizmy wnioskowania. Wnioskowanie jest rozumiane jako możliwość uzyskiwania odpowiedzi na wszelkie pytania o to co jest prawdą w modelowanej dziedzinie przedmiotowej w zakresie reprezentowanym w bazie wiedzy. Istotną cechą każdego systemu wiedzy jest możliwość jego adaptacji. Każda baza wiedzy ulega dezaktualizacji. Zachodzi więc konieczność adaptacji poprzez uczenie maszynowe, którego celem jest przystosowanie bazy wiedzy (modelu) do nowych warunków zarówno na poziomie zawartości (dane), jak i struktury (meta dane). Stosowane obecnie algorytmy uczenia korzystają z danych empirycznych. Wykonanie procedury uczenia wymaga połączenia ze źródłem danych, może nim być klasyczna baza danych, a w przyszłości sieć semantyczna (Semantic Web).

Celem pracy jest omówienie sieci probabilistycznych, a zwłaszcza dynamicznych sieci bayesowskich, pod kątem zastosowań w projektowaniu komputerowych systemów reprezentacji wiedzy. Uważa się, że takie sieci mogą wnieść nową jakość w badania i edukację z zakresu inżynierii rolniczej a sieci bayesowskie jako język modelowania są znacznie łatwiejsze w praktycznym zastosowaniu niż leżące u ich podstaw formalizmy matematyczne.

### **Sieci bayesowskie jako formalny i wykonywalny system reprezentacji wiedzy**

Zdecydowaną większość problemów będących przedmiotem zainteresowań inżynierii rolniczej charakteryzuje indeterminizm. Czynniki niedeterministyczne są integralnym składnikiem rolniczych procesów produkcyjnych, procesów przetwarzania i przechowywania produktów rolniczych. Sprawiają one, że zagrożone jest bezpieczeństwo i skuteczność procesu, czyli w procesie produkcyjnym występują elementy ryzyka. Innym przykładem mogą być zależności pomiędzy symptomami i ich przyczynami w problemach diagnostycznych, pomiędzy wysyłanymi

i otrzymywanymi informacjami w zagadnieniach komunikacyjnych, pomiędzy obiektami i ich cechami w zagadnieniach klasyfikacyjnych. Wszystkie te kategorie problemów mogą być w naturalny sposób opisane za pomocą sieci probabilistycznych.

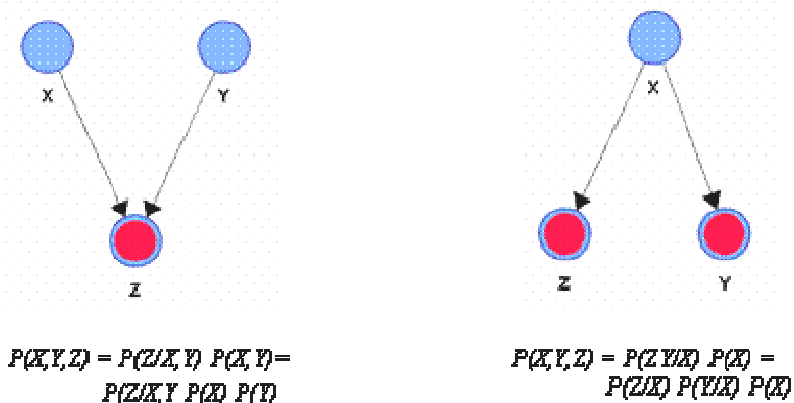
Język sieci probabilistycznych należy do formalnych języków graficznych. Tworzą one uniwersalny system semiotyczny dla specyfikacji, konceptualizacji i analizy sytuacji problemowych w warunkach niedeterministycznych. Sieć bayesowska w swojej warstwie wizualnej jest acyklicznym grafem skierowanym, którego węzły reprezentują zmienne losowe a łuki mniej lub bardziej silne rodzaje zależności między nimi. W warstwie interpretacyjnej, węzły reprezentują predykaty (zdania logiczne), których prawdziwość zależy od predykatów reprezentowanych przez węzły z nimi połączone. Stąd, ekspresywność języka sieci bayesowskich jest taka jak ekspresywność języka logiki, przy czym ze względu na problem złożoności obliczeniowej nie wykracza się tu poza logikę predykatów I-szego rzędu. W przeciwieństwie do klasycznych systemów reprezentacji wiedzy opartych na logice nieprobabilistycznej, sieci bayesowskie umożliwiają wyrażanie wszelkich relacji, w tym zależności przyczynowo-skutkowych, istniejących trwale lub tylko czasowo w każdej częściowo obserwowalnej i poznawalnej rzeczywistości, czyli takiej w której występuje element niepewności. Miarą niepewności jest prawdopodobieństwo a opisem zależności jest łączny rozkład prawdopodobieństwa.

Schemat obliczeniowy rozumowania probabilistycznego umożliwia wyprowadzanie jakościowych i ilościowych wniosków z dokładnością do rozkładu prawdopodobieństwa. Oparty jest on na formule Bayesa i twierdzeniu o warunkowej niezależności umożliwiającej zapis łącznego rozkładu prawdopodobieństwa w postaci sfaktoryzowanej, tj. jako iloczynu warunkowych rozkładów prawdopodobieństwa, [Jensen 1996]. Ażeby sieć bayesowska modelowała jakiś rozkład prawdopodobieństwa, z definicji musi być spełniony warunek, że każda zmienna losowa jest warunkowo niezależna od zmiennych odpowiadających węzłom zstępującym pod warunkiem, że znane są wartości zmiennych odpowiadających węzłom bezpośrednio ją poprzedzającym.

Budowa modelu w postaci sieci bayesowskiej wymaga określenia topologii sieci oraz apriorycznych rozkładów prawdopodobieństwa. Na rysunku 1 przedstawiono dwie elementarne topologie sieci i odpowiadający im łączny rozkład prawdopodobieństwa. Sieć o złożonej topologii jest kompozycją tych dwu topologii elementarnych, stąd w przypadku ogólnym, łączny rozkład prawdopodobieństwa można zapisać w postaci:

$$P(X_1, \dots, X_n) = \prod_{i=1}^n P(X_i | pa(X_i)) \quad (1)$$

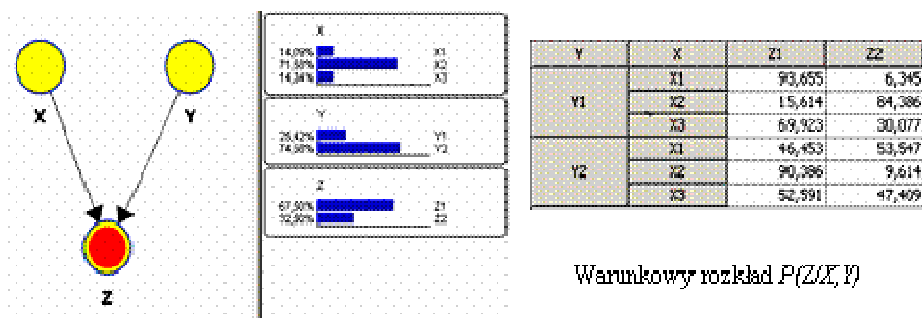
gdzie  $pa(X_i)$  jest zbiorem węzłów bezpośrednio poprzedzających węzeł  $X_i$ .



Rys. 1. Elementarne topologie sieci i odpowiadające im łączne rozkłady prawdopodobieństwa

Fig. 1. Elementary network topology and corresponding joint probability distribution

Na rysunku 2 przedstawiono aprioryczne rozkłady prawdopodobieństwa  $P(X)$  i  $P(Y)$ , oraz warunkowy rozkład prawdopodobieństwa  $P(Z|X,Y)$ .



Rys. 2. Łączny rozkład prawdopodobieństwa

Fig. 2. Joint probability distribution

Mechanizmy wnioskowania typowe dla sieci bayesowskiej to [Pearl, 1988]:

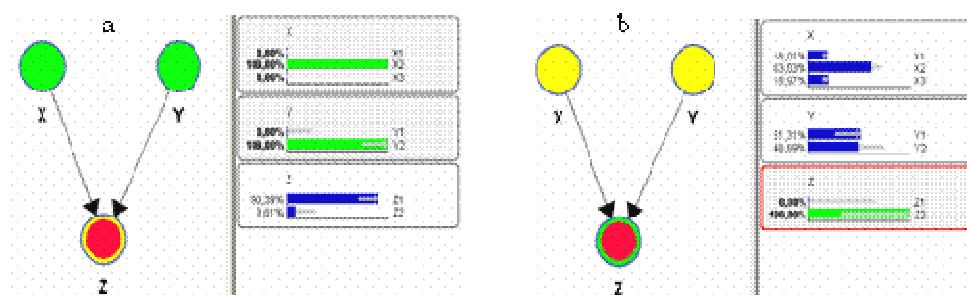
- predykcja (rys. 3 a) – znając przyczyny  $X, Y$  (symulujemy to nadając zmiennym  $X, Y$  konkretne wartości), pytamy o ich skutki (rozkład prawdopodobieństwa nad zbiorem wartości zmiennej  $Z$ ),

- wyjaśnianie (rys. 3 b) –, w tym przypadku obserwujemy skutki (zmienna  $Z$  przyjmuje konkretną wartość) i pytamy o przyczyny. Wnioskowanie to sprowadza się do wyznaczenia nowego, w kontekście uzyskanej informacji o wartości zmiennej  $Z$ , aposteriorycznego rozkładu prawdopodobieństwa nad zbiorem wartości zmiennych  $X, Y$ . Rozkład ten jest wyznaczany zgodnie z twierdzeniem Bayesa:

$$P(X, Y / Z = z) = \frac{P(Z = z / X, Y)P(X, Y)}{P(Z = z)} \quad (2)$$

$$P(Z = z) = \sum P(Z = z / X, Y)P(X, Y)$$

Możliwe jest też wnioskowanie „co by było gdyby”. W tym przypadku specyfikuje się wartości pewnych zmiennych i obserwuje jak zmieniają się rozkłady pozostałych zmiennych.



Rys. 3. Metody wnioskowania  
Fig. 3. Inference methods

Podczas gdy klasyczna sieć bayesowska przedstawia łączny rozkład prawdopodobieństwa nad zbiorem statycznych (niezależnych od czasu) zmiennych losowych to dynamiczna sieć jest reprezentacją wielowymiarowego procesu losowego. A zatem, z czysto formalnego punktu widzenia przejście od sieci statycznej do dynamicznej to tyle co przejście od zmiennych losowych do procesów losowych, [Murphy 2002]. Dynamiczna sieć bayesowska umożliwia pytanie o interpretację teraźniejszości, rekonstrukcję i rozumienie przeszłości oraz predykcję. W sieciach dynamicznych wszystko jest zlokalizowane w czasie, a lokalizacja w czasie jest uporządkowana relacją „wcześniej, później”. Ze względu na złożoność obliczeniową algorytmów inferencyjnych, czas traktujemy jako wielkość dyskretną.

## Budowa modelu

Modelowanie dziedziny przedmiotowej jest przejściem od sformułowania problemu w języku naturalnym do reprezentacji w formie sieci. Na tym etapie następuje integracja pojęciowa dwóch konceptualizacji - dziedziny przedmiotowej i sieci probabilistycznej. Ta integracja odbywa się na poziomie topologii sieci. Sieć jest dzielona na warstwy, które reprezentują kolejne ogniwa w łańcuchu przyczynowo-skutkowym. Konstruowanie topologii jest etapem, w którym przenosimy do modelu wiedzę jakościową z modelowania dziedziny przedmiotowej.

W celu uproszczenia procesu modelowania można wyodrębnić typowe schematy pojęciowe w zależności od tego co dana sieć ma opisywać a następnie skonstruować moduły sieciowe odpowiadających tym schematom. Budowa modelu polega na odpowiednim łączeniu gotowych modułów. Moduły te mogą modelować, np. zmiany stanu, problemy diagnostyczne, problemy klasyfikacji itp.

## Przykład z dziedziny niezawodności obiektów technicznych<sup>1</sup>

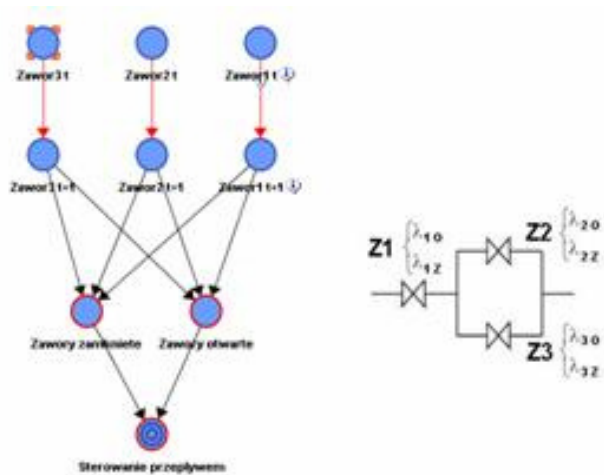
Możliwości praktycznego zastosowania dynamicznej sieci bayesowskiej do modelowania niezawodności zilustrowano na przykładzie układu zaworów połączonych zgodnie ze schematem przedstawionym na rysunku 4. Wyróżniono 3 stany zaworu, jeden stan zdadności (sprawny) i dwa stany niezadadności (niesprawny\_otwarty, niesprawny\_zamknięty). Założono, że funkcja niezawodności jest wykładnicza o intensywności przejścia do wyróżnionych stanów niezadadności odpowiednio  $\lambda_o$  i  $\lambda_z$ . Założono, że w chwili początkowej wszystkie zawory są w stanie zdadności. Przy pomocy zmiennych logicznych *Zawory zamknięte* i *Zawory otwarte* zdefiniowano uszkodzenie układu, a zmienna *Sterowanie przepływem* określa prawdopodobieństwo zdadności układu (*True*) i niezadadności (*False*). Przyjęte do obliczeń wartości intensywności uszkodzeń poszczególnych elementów układu przedstawiono w tabeli 1.

Tabela 1. Wartości intensywności uszkodzeń poszczególnych elementów układu  
Table 1. Values of damage intensity of individual parts of the structure

Element	$\lambda_o$	$\lambda_z$
Zawór 1	0,002 h <sup>-1</sup>	0,001 h <sup>-1</sup>
Zawór 2	0,003 h <sup>-1</sup>	0,002 h <sup>-1</sup>
Zawór 3	0,004 h <sup>-1</sup>	0,003 h <sup>-1</sup>


---

<sup>1</sup> Przykład opracowano w oparciu o materiały i środowisko BayesiaLab, <http://www.bayesia.com>



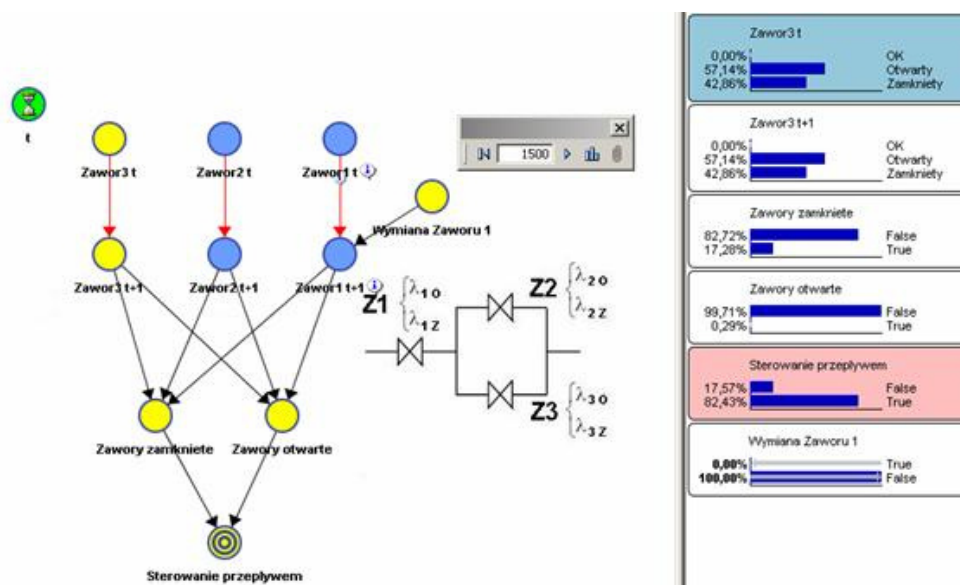
Rys. 4. Modelowanie niezawodności  
Fig. 4. Reliability modeling

Na rysunku 5 przedstawiono w formie graficznej niezawodność układu (rozkład prawdopodobieństwa zmiennej *Sterowanie przepływem*) oraz prawdopodobieństwo uszkodzenia układu.



Rys. 5. Charakterystyki niezawodnościowe  
Fig. 5. Reliability characteristics

Dynamiczne sieci bayesowskie umożliwiają modelowanie układów naprawialnych. Na rysunku 6 przedstawiono sieć, w której zamodelowano wymianę zaworu 1 po 100 cyklach czasowych. Wymianę zamodelowano poprzez wprowadzenie dodatkowej zmiennej *Wymiana zaworu 1*. W prawym oknie przedstawiono rozkłady prawdopodobieństwa poszczególnych zmiennych po 1500 przekrojach czasowych.



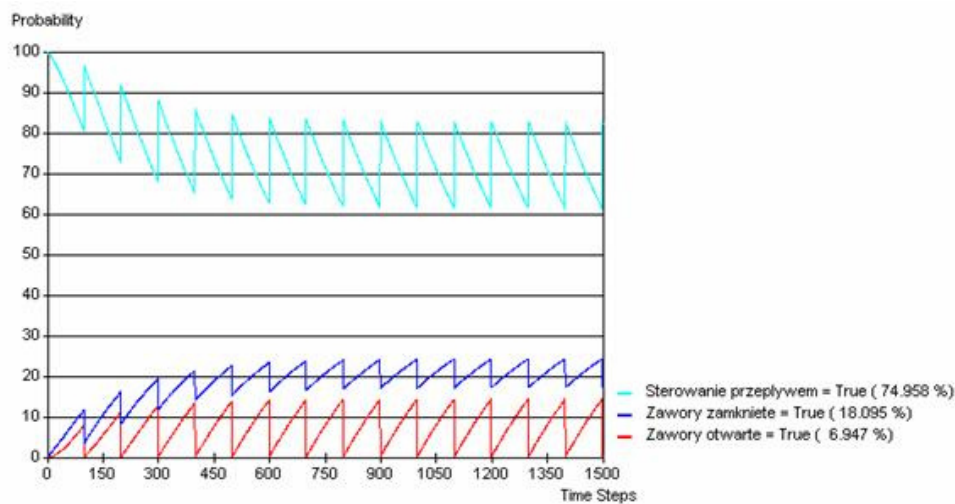
Rys. 6. Dynamiczna sieć bayesowska jako model układu naprawialnego  
 Fig. 6. Dynamic Bayesian Network model of repairable system

Na rysunku 7 przedstawiono wykres pokazujący zmianę prawdopodobieństwa bezawaryjnej pracy układu oraz prawdopodobieństwa wystąpienia uszkodzenia.

## Podsumowanie

Prezentowano technologię sieci bayesowskich w kontekście wymagań metodologicznych związanych z budowaniem systemu reprezentacji w wiedzy z zakresu inżynierii rolniczej. Sieci bayesowskie, ze swej natury, są szczególnie użyteczne do modelowania dziedzin obciążonych elementami niepewności, jak na przykład produkcja rolnicza i zarządzanie łańcuchami produkcji żywności.





Rys. 7. Charakterystyki niezawodnościowe układu naprawialnego  
Fig. 7. Reliability characteristics of reparable system

## Bibliografia

BayesiaLab Tutorial, <http://www.bayesia.com>

Jensen F. V. 1996. An introduction to Bayesian Networks. Taylor & Francis, London.

Murphy K. P. 2002. Dynamic Bayesian Networks. <http://www.ai.mit.edu/~murphyk>

Pearl J. 1988. Probabilistic reasoning in intelligent systems: networks of plausible inference. Morgan Kaufmann Publ. Inc.

## **DYNAMIC BAYESIAN NETWORKS AS KNOWLEDGE REPRESENTATION SYSTEM**

### **Summary**

The paper presents Bayesian Networks (BN) technology in the context of methodological requirements for building knowledge representation systems in the domain of agricultural engineering. BN, by their nature, are especially useful for modeling uncertain domains like agricultural production and food chains management.

**Key words:** knowledge representation system, probabilistic networks, dynamic Bayesian Networks, reliability models