

LUKASZ RADLIŃSKI

Uniwersytet Szczeciński

METODA PRZEKSZTAŁCANIA PLANÓW REAKCJI NA RYZYKO W SIECI BAYESA

Wprowadzenie

Istnieje wiele metod umożliwiających formalne ujęcie dynamiki procesu w postaci modelu prognostycznego. Niniejsza praca poświęcona jest jednej z takich metod, sieciom Bayesa. Metoda ta ma liczne zalety, jednak proces budowy modelu przez eksperta jest trudny i czasochłonny. Częściowym rozwiązaniem może być zastosowanie „szkieletu przyczynowo-skutkowego”, w którym zmienne mają przypisane role, a połączenia między zmiennymi odzwierciedlają związki przyczynowo-skutkowe, co ułatwia czytelność modelu. Szkielet ten jest w podobnej formie używany przy budowie planów reakcji na ryzyko w zarządzaniu projektami. Jednak te nie mogą być bezpośrednio wykorzystywane do analiz typu *co-jeśli* czy poszukiwania celu.

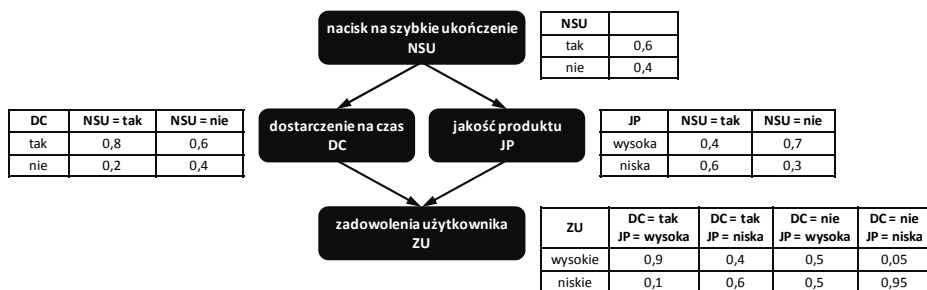
Celem niniejszej pracy jest opracowanie RRP2BN – metody przekształcania wiedzy zawartej w planach reakcji na ryzyko do postaci sieci Bayesa. Dzięki temu możliwe będzie przeprowadzanie analiz symulacyjnych, których nie da się przeprowadzić, korzystając z samych planów zarządzania ryzykiem. Metoda RRP2BN generuje sieci Bayesa zgodne ze szkieletem przyczynowo-skutkowym. Została ona zaimplementowana w postaci prototypu narzędzia informatycznego. Wstępne wyniki badań potwierdzają, że metoda może ułatwić i przyspieszyć początek procesu budowy sieci Bayesa, szczególnie ekspertom dziedzinowym bez doświadczenia w korzystaniu z sieci Bayesa czy podobnych metod.

1. Sieci Bayesa

Sieć Bayesa (*Bayesian network*) to model, który służy do odwzorowania zależności między zdarzeniami zgodnie z rachunkiem prawdopodobieństwa. Model, który zawiera zbiór zmiennych losowych $X = \{X_1, \dots, X_n\}$, ma dwa komponenty:

1. Graficzny – skierowany niecykliczny graf, w którym każda zmienna X_i reprezentowana jest w postaci węzła, a zależności między parami zmiennych jako strzałki.
2. Liczbowy – zbiór tabel prawdopodobieństw warunkowych (*conditional probability table* – CPT) $P(X_i | \text{rodzice}(X_i))$, gdzie każda zmienna X_i zdefiniowana jest za pomocą osobnej tabeli określającej lokalne zależności. Zapis $\text{rodzice}(X_i)$ oznacza zbiór zmiennych będących bezpośrednimi poprzednikami (rodzicami) zmiennej X_i .

Przykład prostej sieci Bayesa pokazano na rysunku 1.



Rys. 1. Przykład prostej sieci Bayesa

Źródło: opracowanie własne.

Sieć Bayesa jako metoda została zaproponowana przez Pearla¹ w latach osiemdziesiątych XX wieku. Obecnie sieci Bayesa uważane są za jedną z ważniejszych technik sztucznej inteligencji. Poole – w recenzji jednej z książek²

¹ J. Pearl, *Bayesian networks: a model of self-activated memory for evidential reasoning* (UCLA Technical Report CSD-850017), Proc. 7th Conf. of the Cognitive Science Society, University of California, Irvine 1985, s. 329–334; tenże, *Probabilistic reasoning in intelligent systems: networks of plausible inference*, Morgan Kaufmann, San Francisco 1988.

² A. Darwiche, *Modeling and reasoning with Bayesian network*, Cambridge University Press 2009.

poświęconych sieciom Bayesa – stwierdził jeszcze dobitniej, że sieci Bayesa „zrewolucjonizowały sztuczną inteligencję”³. Do głównych zalet tej techniki można zaliczyć: możliwość odzwierciedlenia związków przyczynowo-skutkowych; jawne ujęcie niepewności w postaci rozkładów prawdopodobieństwa dla zmiennych; graficzną reprezentację ułatwiającą czytelność modelu; możliwość tworzenia modeli opartych na wiedzy eksperta, danych empirycznych lub połączeniu wiedzy eksperta z danymi empirycznymi; możliwość ujęcia różnych typów zmiennych (liczbowych, porządkowych, nominalnych); możliwość wnioskowania wprzód i wstecz; możliwość przeprowadzania obliczeń przy niepełnych danych.

Sieci Bayesa nie są jednak pozbawione wad związanych głównie z procesem ich tworzenia. Możliwe jest szybkie generowanie modeli na podstawie danych za pomocą algorytmów uczących. Jednak takie modele rzadko poprawnie odzwierciedlają rzeczywiste zależności między zmiennymi, szczególnie gdy zestaw danych uczących jest nieliczny, co często występuje w analizie czasochłonności i jakości projektów, również informatycznych⁴.

Proces pozyskiwania wiedzy eksperta i kodowania jej w modelu jest czasochłonny oraz, szczególnie przy złożonych problemach, może prowadzić do niespójności modelu związanej z dużą liczbą prawdopodobieństw, które należy określić. Inny problem, przed którym stoją osoby bez doświadczenia z zakresu statystyki czy sztucznej inteligencji, jest związany z początkiem procesu budowy modelu. Rodzi się wtedy wiele pytań: „od czego zacząć?”, „jak łączyć poszczególne zmienne?” lub „jak liczbowo ująć zależności między zmiennymi?”. Dalsza część pracy jest właśnie im poświęcona.

Problematyka usprawnienia ujmowania wiedzy eksperckiej w sieciach Bayesa stanowi temat licznych publikacji. Dotyczą one łatwiejszego definiowa-

³ D. Poole, recenzja A. Darwiche, *Modeling and reasoning...*, <http://www.cambridge.org/us/catalogue/catalogue.asp?isbn=9780521884389>.

⁴ L. Radliński, *Building Bayesian nets for software defect prediction – a comparison of manual, semi- and fully-automated schemes*, w: *Information systems architecture and technology. New Developments in Web-Age Information Systems*, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2010, s. 321–335; tegoż, *On generating Bayesian nets from small local qualitative data for software development effort and quality prediction*, „Metody Informatyki Stosowanej” 2011 (w druku); tegoż, *Software development effort and quality prediction using Bayesian nets and small local qualitative data*, Proc. 22nd International Conference on Software Engineering and Knowledge Engineering, Redwood City, CA 2010, s. 113–116.

nia struktury modelu⁵, większość jednak skupiona jest na szybszej budowie tabel prawdopodobieństw⁶. Zaproponowana w niniejszym artykule metoda generowania sieci Bayesa jest ściśle powiązana z opracowanym wcześniej szkieletem przyczynowo-skutkowym, który wymaga dokładniejszego omówienia.

2. Szkielet przyczynowo-skutkowy

Szkielet przyczynowo-skutkowy⁷ (SPS) to ogólna struktura modelu, w której definiuje się podstawowe kategorie zmiennych i możliwe połączenia między nimi. Zastosowanie takiej struktury umożliwia szybsze tworzenie modeli przyczynowo-skutkowych, w szczególności sieci Bayesa, oraz zapewnia łatwiejszą ich interpretację. SPS ma dwa wymiary: komponenty i perspektywy. Komponenty opisują funkcję zmiennej (rolę) w danym kontekście, natomiast perspektywy – sam kontekst. Perspektywa zawiera pięć podstawowych komponentów:

- *zdarzenie niepewne* – kluczowe zdarzenie w danym kontekście,

⁵ C. Skaanning, *A knowledge acquisition tool for Bayesian-network troubleshooters*, Proc. 16th Conference on Uncertainty in Artificial Intelligence. Stanford, CA: Stanford University 2000; P. Kraaijeveld, M. Druzdzel, A. Onisko, H. Wasyluk, *GeNIeRate: An interactive generator of diagnostic Bayesian network models*, Working Notes of the 16th International Workshop on Principles of Diagnosis (DX-05), Monterey, CA 2005, s. 175–180; M. Neil, N. Fenton, L. Nielsen, *Building large-scale Bayesian networks*, “Knowledge Engineering Review” 2000, vol. 15, no. 3, s. 257–284.

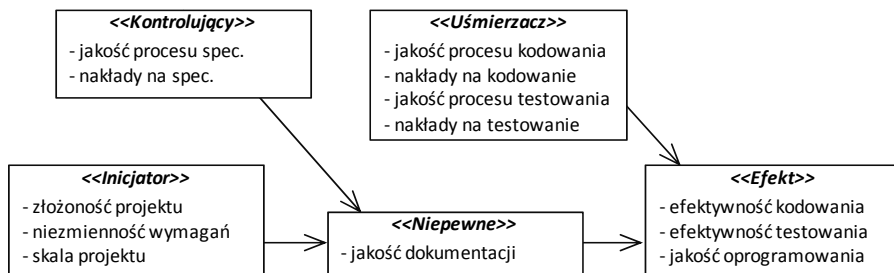
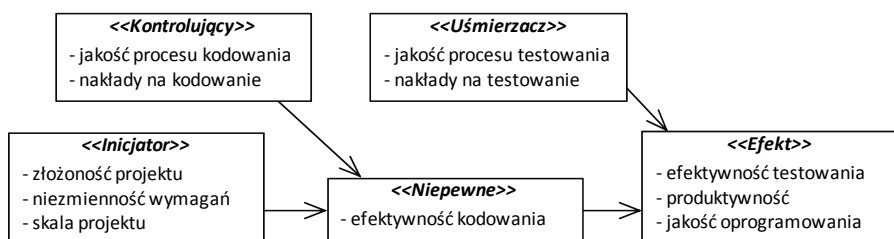
⁶ S. Nadkarni, P.P. Shenoy, *A causal mapping approach to constructing Bayesian networks*, “Decision Support Systems” 2004, vol. 38, no. 2, s. 259–281; B. Das, *Generating conditional probabilities for Bayesian networks: easing the knowledge acquisition problem*, 2004, <http://www.citebase.org/cgi-bin/citations?id=oai:arXiv.org:cs/0411034>; N.E. Fenton, M. Neil, J.G. Caballero, *Using ranked nodes to model qualitative judgments in Bayesian networks*, IEEE Transactions on Knowledge and Data Engineering 2007, vol. 19, no. 10, s. 1420–1432; E.M. Helsper, L.C. van der Gaag, A.J. Feelders, W.L.A. Loeffen, P.L. Geenen, A.R.W. Albers, *Bringing order into Bayesian-network construction*, Proc. 3rd Int. Conf. on Knowledge Capture, Banff, Alberta, Canada 2005, s. 121–128; D.A. Wiegmann, *Developing a methodology for eliciting subjective probability estimates during expert evaluations of safety interventions: application for Bayesian belief networks* (Rep. No. AHFD-05-13/NASA-05-4), Aviation Human Factors Division, Institute of Aviation, University of Illinois 2005; J. Pfautz, Z. Cox, G. Catto, D. Koelle, J. Campolongo, E. Roth, *User-centered methods for rapid creation and validation of Bayesian belief networks*, Proc. 5th Bayesian Modeling Applications Workshop, 23rd Annual Conference on Uncertainty in Artificial Intelligence, Vancouver, British Columbia 2007.

⁷ N. Fenton, M. Neil, *Measuring your risks*, Agena, www.agenarisk.com 2005; tychże, *Visualising your risks*, Agena, www.agenarisk.com 2005; Ł. Radliński, N. Fenton, *Causal risk framework for software projects*, w: *Information systems architecture and technology. IT technologies in knowledge oriented management process*, ed. Z. Wilimowska, L. Borzemski, A. Grzech, J. Świątek, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2009, s. 49–59.

- *inicjator* – zdarzenie poza kontrolą, wpływające na wystąpienie *zdarzenia niepewnego*,
- *czynnik kontrolujący działanie* – jego celem jest niedopuszczenie do wystąpienia lub ograniczenie zakresu *zdarzenia niepewnego*,
- *efekt* (inaczej: *konsekwencja*) – efekt działania *zdarzenia niepewnego*,
- *uśmierzczacz* – działanie, którego celem jest ograniczenie wpływu *zdarzenia niepewnego* na *efekt* (może powodować inne *efekty*).

Na rysunku 2 pokazano przykładowe zastosowanie SPS do zbudowanego wcześniej „modelu produktywności”⁸. Zdefiniowane zostały dwie perspektywy będące etapami projektu: analiza i kodowanie. Każdy komponent zawiera jedną lub więcej zmiennych. Główne związki między komponentami pokazano za pomocą strzałek. Dodatkowo możliwe są inne związki, w szczególności między zmiennymi pojedynczego komponentu. Cechą SPS jest to, że zmienna, która pojawia się jako określony komponent dla danej perspektywy, może wystąpić w innym komponencie w innej perspektywie, na przykład *efektywność kodowania* jako *konsekwencja* etapu analizy oraz jako *zdarzenie niepewne* etapu kodowania.

⁸ N. Fenton, P. Hearty, M. Neil, Ł. Radliński, *Software project and quality modelling using Bayesian net-works*, w: *Artificial intelligence applications for improved software engineering development: new prospects*, ed. F. Meziane, S. Vadera, Information Science Reference 2009, s. 1–25; Ł. Radliński, N. Fenton, M. Neil, D. Marquez, *Improved decision-making for software managers using Bayesian networks*, Proc. 11th IASTED International Conference Software Engineering and Applications, Cambridge, MA 2007; Ł. Radlinski, *Improved software project risk assessment using Bayesian nets*, Ph.D. Thesis, Queen Mary, University of London, London 2008.

Perspektywa: Analiza**Perspektywa: Kodowanie**

Rys. 2. Zastosowanie SPS w modelu produktywności

Źródło: opracowanie własne na podstawie Ł. Radliński, N. Fenton, *Causal risk framework for software projects...*, s. 49–59.

3. Plan reakcji na ryzyko

Zarządzanie projektami obejmuje wiele obszarów projektu. Project Management Institute określił w PMBoK⁹ dziewięć takich obszarów. Wśród nich jest zarządzanie ryzykiem projektowym polegające na planowaniu, identyfikacji, analizie jakościowej i ilościowej ryzyka, planowaniu reakcji na ryzyko, monitorowaniu i kontroli ryzyka.

Jednym z ważniejszych dokumentów tworzonych w ramach zarządzania ryzykiem jest plan reakcji na ryzyko (PRR). Dokument taki informuje o tym, jakie działanie należy podjąć w momencie wystąpienia określonego zdarzenia. Do głównych grup działań, nazwanych w PMBoK „strategiami”, zaliczyć można:

⁹ *A guide to the project management body of knowledge*, Third Edition, Newtown Square, PA, Project Management Institute 2004.

- unikanie, transfer i ograniczanie wpływu negatywnych czynników ryzyka,
- wykorzystanie, podział i rozszerzanie wpływu pozytywnych czynników ryzyka,
- akceptację ryzyka.

W tabeli 1 przedstawiono fragment przykładowego PRR zawierający najważniejsze elementy: czynniki ryzyka oraz działania niedopuszczające i ograniczające wpływ. Rzeczywiste PRR tworzone w dużych projektach są zwykle bardziej rozbudowane – mogą zawierać więcej kolumn, czynników ryzyka i innych informacji pomocniczych, a nazwy działań mogą być bardziej precyzyjne lub odwołujące się do dodatkowych dokumentów. PRR nie musi zawierać zarówno działania niedopuszczającego, jak i ograniczającego wpływ dla każdego czynnika ryzyka – w niektórych sytuacjach planuje się tylko jeden rodzaj działania, co pokazano w przykładzie dla *nowych wymagań klienta*.

Tabela 1

Fragment planu reakcji na ryzyko

Czynnik ryzyka					Działanie niedopuszczające		Działanie ograniczające wpływ	
Nazwa	Poziom	P	W	WR	Nazwa	Koszt	Nazwa	Koszt
nowe wymagania klienta	dużo	0,1	1000	100			zwiększenie zasobów	250
	średnio	0,3	500	150				150
	mało	0,4	200	80				70
	Suma							330
opóźnienie finansowania projektu	> 2 mies.	0,05	300	15	wynegocjowanie odsetek za zwłokę	50	zapewnienie alternatywnego finansowania	80
	1–2 mies.	0,2	100	20				40
	2–4 tyg.	0,6	50	30				20
	Suma							65
rotacja kluczowych pracowników	duża	0,2	800	160	zwiększenie motywacji	100	zmiana organizacji zespołów	180
	średnia	0,3	400	120				120
	mała	0,4	200	80				90
	Suma							360

Legenda: P – prawdopodobieństwo wystąpienia danego poziomu czynnika ryzyka
 W – wpływ poziomu czynnika ryzyka na projekt (w jednostkach monetarnych)
 WR – wartość ryzyka (w jednostkach monetarnych), inaczej: podatność na ryzyko (*risk exposure*); $WR = P * W$.

Źródło: opracowanie własne.

Zarówno ten przykładowy plan, jak i SPS traktują ryzyko jako coś negatywnego. Współczesne zarządzanie ryzykiem obejmuje jednak również ryzyko pozytywne, czyli szanse¹⁰. SPS może zostać rozszerzony o szanse, co będzie przedmiotem dalszych badań.

4. Metoda RRP2BN generowania sieci Bayesa na podstawie planu reakcji na ryzyko

Metoda RRP2BN (*risk response plan to Bayesian net*) służy do generowania sieci Bayesa na podstawie planów reakcji na ryzyko. Wykorzystuje ona podobieństwo koncepcji szkieletu przyczynowo-skutkowego i planu reakcji na ryzyko.

Na rysunku 3 przedstawiono schemat działania metody RPP2BN, która składa się z czterech głównych etapów. Na początku konieczna jest integracja planów reakcji na ryzyko, które zostały opracowane dla różnych projektów, etapów projektów przez różne zespoły itp. Etapy projektu i zespoły stają się perspektywami SPS. Efektem tej fazy jest zintegrowany plan reakcji na ryzyko.

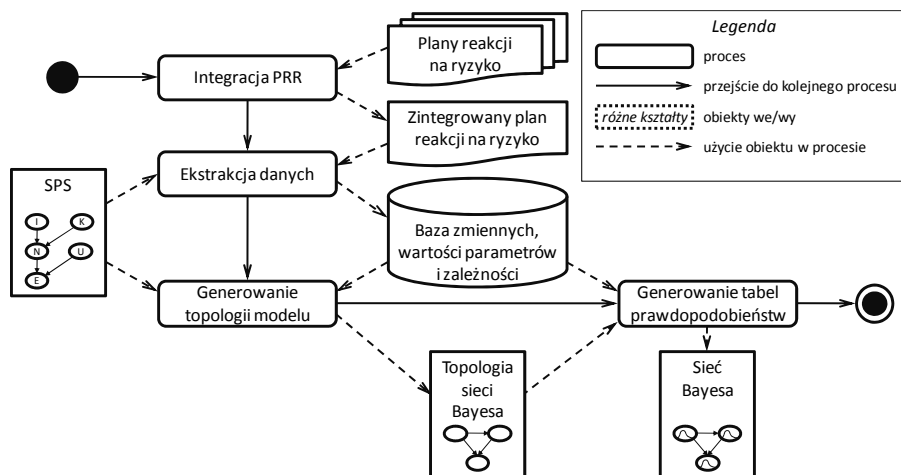
W kolejnym etapie następuje ekstrakcja danych z tego zintegrowanego planu. Dane te zapisywane są w bazie zmiennych, wartości parametrów i zależności. Etap ten zakłada wykorzystanie SPS i algorytmów przetwarzania języka naturalnego.

Następnie generowana jest topologia sieci Bayesa zgodna z SPS lub bez SPS, zależnie od decyzji użytkownika. W obu przypadkach wygenerowany model ma taką samą strukturę i tabele prawdopodobieństw. Przy generowaniu z użyciem SPS, sam SPS stanowi jedynie wizualny narzut pozwalający na pokazywanie i ukrywanie wybranych fragmentów modelu.

Ostatnim etapem jest generowanie tabel prawdopodobieństw dla każdej zmiennej. Użytkownik wybiera jeden z dwóch dostępnych trybów:

- Dokładny – tabele prawdopodobieństw zawierają jedynie dokładne dane z planów reakcji na ryzyko, a zmienne są typu nominalnego.
- Przybliżony – tabele prawdopodobieństw są zbudowane na podstawie danych z planów reakcji na ryzyko, a zmienne mogą być numeryczne z dyskretyzacją zdefiniowaną automatycznie lub przez użytkownika. Algorytm na podstawie danych próbuje znaleźć równanie opisujące zależność, a następnie przekształca to równanie na tabelę prawdopodobieństw.

¹⁰ C. Chapman, S. Ward, *Project risk management. Second edition*, John Wiley and Sons, Chichester 2003.



Rys. 3. Schemat działania metody RRP2BN

Źródło: opracowanie własne.

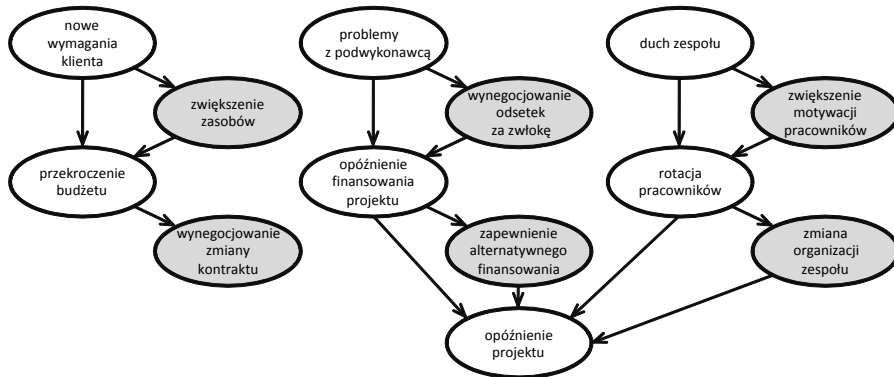
5. Użycie metody RRP2BN

Zaproponowana metoda przekształcania planów reakcji na ryzyko w sieci Bayesa poddana została weryfikacji. Jej celem było zbadanie jakości wygenerowanych sieci Bayesa. Weryfikacja ta została przeprowadzona na zestawie przygotowanych wcześniej przez autora PRR oraz na przykładowych PRR dostępnych w Internecie.

Na rysunku 4 pokazano topologię sieci Bayesa wygenerowaną na podstawie jednego z przygotowanych wcześniej PRR. Główną cechą tego modelu, jak i innych wygenerowanych z wykorzystaniem proponowanej metody przekształcania PRR, jest jego niekompletność. Model nie jest pojedynczą, kompletną strukturą, lecz zbiorem mniejszych sieci Bayesa niepołączonych ze sobą. Jest to spowodowane tym, że plany reakcji na ryzyko często zawierają takie działania, które są powiązane z niewielką liczbą czynników, a nawet pojedynczym czynnikiem. Brakuje wspólnych czynników, które mogłyby być połączone z większą liczbą zmiennych w modelu.

To rozdzielenie struktury modelu jest dodatkowo spowodowane wielością planów reakcji na ryzyko użytych do wygenerowania modelu. Co prawda tylko najbardziej odpowiednie plany powinny zostać wybrane przez eksperta, ale i one

mogą zawierać między sobą istotne różnice, szczególnie jeśli zostały opracowane przez różne zespoły, dla różnych projektów albo dla różnych etapów projektów.



Rys. 4. Topologia sieci Bayesa wygenerowanej za pomocą metody RRP2BN

Źródło: opracowanie własne.

Na rysunku 5 pokazano przykładowe tabele prawdopodobieństw wygenerowane dla zmiennej *zasoby*. W dokładnym trybie generowania wartości numeryczne oznaczające poszczególne stany zmiennej są tylko tekstowymi nazwami zmiennej nominalnej. W przybliżonym natomiast trybie generowania możliwe stany zmiennej liczbowej zostały podzielone na przedziały wartości. Tym przedziałom przypisywane są prawdopodobieństwa wyznaczone na podstawie równania matematycznego, którego parametry zostały dopasowane do danych. W tym przykładzie *zasoby* zostały określone rozkładem normalnym:

$$zasoby = \text{Normalny} (\mu = 80 * nwu, \sigma^2 = (10 * nwu + 10)^2) \quad (1)$$

gdzie *nwu* oznacza nowe wymagania użytkownika.

Równanie o takim poziomie złożoności może zostać opracowane przy udziale eksperta, a sam algorytm jest w stanie wygenerować równanie zależności liniowej (parametr μ).

zmienna zasoby	rodzic nowe wymagania użytkownika			zmienna zasoby	rodzic nowe wymagania użytkownika		
	mało	średnio	dużo		mało	średnio	dużo
70	1	0	0	0–50	0,0668	0,0001	0,0000
150	0	1	0	50–100	0,7746	0,0226	0,0002
250	0	0	1	100–150	0,1584	0,3467	0,0120
				150–200	0,0002	0,5393	0,1464
				200–250	0,0000	0,0899	0,4401
				250–300	0,0000	0,0013	0,3345
				300–350	0,0000	0,0000	0,0638
				350–400	0,0000	0,0000	0,0029

Rys. 5. Tabele prawdopodobieństw zmiennej zasoby wygenerowane przez RPP2BN w trybach dokładnym (lewa) i przybliżonym (prawa)

Źródło: opracowanie własne.

Metoda RRP2BN zakłada wykorzystanie algorytmów analizy języka naturalnego (angielskiego) do identyfikacji zmiennych przyszłego modelu oraz wartości parametrów wykorzystywanych do wygenerowania tabel prawdopodobieństw. Na obecnym etapie prototyp narzędzia implementującego RRP2BN nie udostępnia jednak takiej funkcjonalności. Użytkownik musi na podstawie PRR umieścić odpowiednie nazwy zmiennych i wartości parametrów liczbowych w odpowiednich miejscach dokumentu pośredniego (ustandaryzowanego arkusza kalkulacyjnego odzwierciedlającego strukturę PRR).

Podsumowanie

W niniejszym artykule została zaproponowana metoda RRP2BN do generowania sieci Bayesa na podstawie planów reakcji na ryzyko. RRP2BN wykorzystuje opracowany wcześniej szkielet przyczynowo-skutkowy, tak aby struktura wygenerowanej sieci Bayesa zawierała związki przyczynowo-skutkowe i była czytelna.

Metoda ta może być przydatna dla osób, które nie mają doświadczenia w budowie sieci Bayesa, ani w korzystaniu z innych metod statystycznych czy sztucznej inteligencji. Metoda usprawnia początek procesu budowy sieci Bayesa, nie generuje jednak modeli gotowych do użycia, czyli przeprowadzania analiz

i symulacji. Wygenerowane modele powinny być rozbudowane zgodnie z wiedzą eksperta dziedzinowego.

Przyszłe badania poświęcone będą rozwojowi ostatniego etapu metody, generowania tabel prawdopodobieństw, w celu udostępnienia użytkownikowi większej liczby opcji i bardziej przyjaznego pozyskiwania wiedzy eksperta. Ponadto planowane jest wykorzystanie algorytmów przetwarzania języka naturalnego w drugim etapie metody do ekstrakcji danych ze zintegrowanego planu reakcji na ryzyko.

Literatura

- A guide to the project management body of knowledge*, Third Edition, Project Management Institute, Newtown Square, PA 2004.
- Bayes T., *An essay towards solving a problem in the doctrine of chances*. By the late Rev. Mr. Bayes, F.R.S. communicated by Mr. Price, in a letter to John Canton, A.M.F.R.S., "Philosophical Transactions of the Royal Society of London" 1763, vol. 53.
- Chapman C., Ward S., *Project risk management. Second edition*, John Wiley and Sons, Chichester 2003.
- Darwiche A., *Modeling and reasoning with Bayesian networks*, Cambridge University Press, Cambridge 2009.
- Das B., *Generating conditional probabilities for Bayesian networks: easing the knowledge acquisition problem*, <http://www.citebase.org/cgi-bin/citations?id=oai:arXiv.org:cs/0411034>, 2004.
- Fenton N., Hearty P., Neil M., Radliński Ł., *Software project and quality modelling using Bayesian networks*, w: *Artificial intelligence applications for improved software engineering development: new prospects*, ed. F. Meziane, S. Vadera, Information Science Reference 2009.
- Fenton N., Neil M., *Measuring your risks*, Agena, www.agenarisk.com, 2005.
- Fenton N., Neil M., *Visualising your risks*, Agena, www.agenarisk.com, 2005.
- Fenton N.E., Neil M., Caballero J.G., *Using ranked nodes to model qualitative judgments in Bayesian networks*, "IEEE Transactions on Knowledge and Data Engineering" 2007, vol. 19, no. 10.
- Helsper E.M., van der Gaag L.C., Feelders A.J., Loeffen W.L.A., Geenen P.L., Albers A.R.W., *Bringing order into Bayesian-network construction*, Proc. 3rd Int. Conf. on Knowledge Capture, Banff, Alberta, Canada 2005.
- Helsper E.M., van der Gaag L.C., Groenendaal F., *Designing a procedure for the acquisition of probability constraints for Bayesian networks*, "Engineering Knowledge in the Age of the Semantic Web", Springer-Verlag, Berlin-Heidelberg 2004.
- Kraaijeveld P., Druzdzel M., Onisko A., Wasyluk H., *GeNIeRate: An interactive generator of diagnostic Bayesian network models*, Working Notes of the 16th International Workshop on Principles of Diagnosis (DX-05), Monterey, CA 2005.

- Nadkarni S., Shenoy P.P., *A causal mapping approach to constructing Bayesian networks*, "Decision Support Systems" 2004, vol. 38, no. 2.
- Neil M., Fenton N., Nielsen L., *Building large-scale Bayesian networks*, "Knowledge Engineering Review" 2000, vol. 15, no. 3.
- Pfautz J., Cox Z., Catto G., Koelle D., Campolongo J., Roth E., *User-centered methods for rapid creation and validation of Bayesian belief networks*, Proc. 5th Bayesian Modeling Applications Workshop, 23rd Annual Conference on Uncertainty in Artificial Intelligence, Vancouver, British Columbia 2007.
- Radliński Ł., *Building Bayesian nets for software defect prediction – a comparison of manual, semi- and fully-automated schemes*, w: *Information systems architecture and technology. New Developments in Web-Age Information Systems*, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2010.
- Radliński Ł., Fenton N., *Causal risk framework for software projects*, w: *Information systems architecture and technology. IT technologies in knowledge oriented management process*, ed. Z. Wilimowska, L. Borzemski, A. Grzech, J. Świątek, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2009.
- Radliński Ł., Fenton N., Neil M., Marquez D., *Improved decision-making for software managers using Bayesian networks*, Proc. 11th IASTED International Conference Software Engineering and Applications, Cambridge, MA 2007.
- Radlinski L., *Improved software project risk assessment using Bayesian nets*, Ph.D. Thesis, Queen Mary, University of London, London 2008.
- Radliński Ł., *On generating Bayesian nets from small local qualitative data for software development effort and quality prediction*, „Metody Informatyki Stosowanej” 2011 (w druku).
- Radliński Ł., *Software development effort and quality prediction using Bayesian nets and small local qualitative data*, Proc. 22nd International Conference on Software Engineering and Knowledge Engineering, Redwood City, CA 2010.
- Skaanning C., *A knowledge acquisition tool for Bayesian-network troubleshooters*, Proc. 16th Conference on Uncertainty in Artificial Intelligence, Stanford University, Stanford, CA 2000.
- Wiegmann D.A., *Developing a methodology for eliciting subjective probability estimates during expert evaluations of safety interventions: application for Bayesian belief networks*, Rep. No. AHFD-05-13/NASA-05-4, Aviation Human Factors Division, Institute of Aviation, University of Illinois 2005.

A METHOD FOR TRANSFORMING RISK RESPONSE PLANS TO BAYESIAN NETWORKS

Summary

Bayesian networks (BNs) have been successfully used in various fields, including software engineering and project management. One of the main obstacles preventing them from a wider use is a difficult and time-consuming process of building models. To partially solve this problem, we proposed an RRP2BN method, helping inexperienced users to start model-building process. This method generates BNs, both the structure and probability tables, from risk response plans. Resulting BN models have the most important variables and relationships defined. Then, a domain expert domain expert should adjust and extend them to make them ready to use in simulations.

Translated by Lukasz Radliński