

文章编号：1001-148X（2016）08-0163-08

供应链风险发生大小、发生与持续时间的估计： 一个动态贝叶斯的推理网络研究范式

郑小京

（哈尔滨商业大学 商业经济研究院，哈尔滨 150028）

摘要：供应链风险具有多源性、多维性、传递性以及动态性的特点，准确评估其发生的概率以及发生与持续时间的可能性非常关键。为了实现这一目标，本文根据供应链风险的特征，构建了一个动态贝叶斯网络模型，利用极大似然法对该模型参数进行估计，并采用贝叶斯推理的方法估计特定条件下供应链风险的特征，结果发现供应链风险随着时间动态变化，但都收敛到一个稳定的概率区间。

关键词：供应链风险；可能性；发生时间；持续时间

中图分类号：F274 **文献标识码：**A

对风险评价的本质在于试图分析风险发生的统计规律，因为统计规律可以发现其关键的可控风险因素，以及风险因素与风险之间的一个基本映射关系。但是，如果考虑风险的动态性，这些结果就很难描述供应链风险的多源性、多维性以及相互交叉性、传递性、动态性、非线性。本文拟构造一个供应链风险动态贝叶斯网络评估模型，通过这一模型分析供应链中若干风险之间的关系、若干风险可能发生的时间以及一旦发生可能持续的时间，试图得到一些有价值的结论。

一、供应链风险的特征及其贝叶斯网络刻画

如文献 [1]、[5]、[12] 所述，供应链风险具有高度的多源性和多维性，其风险因素与供应链若干风险之间形成非常复杂的关系，这种关系可以用一个贝叶斯网络来描述。

（一）供应链风险贝叶斯网络模型

根据供应链风险系统的特征，我们构建一个

对应的供应链风险动态贝叶斯网络推理模型，描述供应链风险因素变化可能导致的供应链风险的性质、特征、状态及其变化。根据郑小京（2015）的研究成果，在分析的过程中，我们主要考虑以下风险的发生时机、发生可能性、持续时间所满足的性质：供应链核断裂、资金流断裂、物流断裂、牛鞭效应、道德风险、双重边际化。其中，关键可控的风险因素与重要风险及其关系用图 1 的贝叶斯网络模型来描述。

图 1 中，每个节点表示一种风险因素或风险事件，箭头表示他们之间的因果关系。这些节点的涵义依次为供应商可靠性随机、互补品随机扰动、替代品随机扰动、产品结构复杂性、供应链结构复杂性、非常规突发事件驱动的需求突变、供应商认可/选择不当、产品需求随机、产品需求分布特征变化、生产系统随机、信息共享结构不当、供给订单随机、生产程序序列随机、延迟制造随机性、生产成本方差随机、订单分配随机、合作预测无效、信

收稿日期：2016-05-05

作者简介：郑小京（1975-），男，陕西白水人，哈尔滨商业大学商业经济研究院副研究员，管理学博士，研究方向：供应链管理。

基金项目：黑龙江省哲学与社会科学基金项目，项目编号：11D071；黑龙江博士后科研基金项目，项目编号：LBH-Z15109；哈尔滨商业大学博士科研启动基金项目，项目编号：13DW007。

息自身真实性随机、信息传递的扭曲程度、功能型产品信息管理系统崩溃、流行型产品信息管理系统崩溃、价格不确定、供应商库存管理无效、产品分派机制随机、供给契约参数随机波动、产品分派机制崩溃、供给契约中断、供应链核断裂、供应链网络崩溃、物流中断、双重边际化效应、牛鞭效应、资金链断裂、道德风险。通过贝叶斯网络，我们可以得到各个风险因素与风险之间错综复杂的关系以及对应的概率关系，这使得对供应链风险进行比较准确的估计有了数学基础。




图1 供应链风险的贝叶斯网络

实际上，供应链中风险因素对风险的影响表现出极强的非线性，不仅影响强度表现为随机时变性，而且风险因素结构与性质也具有随机时变性——在一开始对供应链风险影响较为重要的因素，当供应链发展到一种伪平衡状态时，这些因素将不是导致其爆发的关键因素，而可能是其中一个微不足道的因素的微弱变化将会导致供应链崩溃。本文所构造的动态贝叶斯网络模型完全可以描述这一供应链风险的动态性以及非线性特征，并通过分析把握供应链风险参数的性质，对这些供应链风险的参数进行推理，实现真正的评估。

(二) 供应链风险动态贝叶斯网络模型

为了分析方便，不妨假定每一个风险因素或风险事件有三个状态：发生态、临界态以及未发生态，在不同的时间，它可以按照一定的规律由一种状态切换到另外一种状态上。如果能把握这一风险事件发生时间以及持续时间的可能性大小，供

应链风险评估的准确性与科学意义就得以很大的提高。文献[13]构造了一个类似的模型，描述了一个简单的链状贝叶斯网络，但供应链风险贝叶斯模型比其复杂得多，且我们考虑的参数也有一些变化。

如前所述，供应链风险的发生与因素的状态有关系，而供应链风险因素的状态只有三种，即发生、不发生、临界态。一旦发生，将会引起下一个因素的变化，这种变化在供应链网络中进行传播，最终导致了供应链风险的非线性迭加效应——供应链风险复杂且具有较大的随机性。不妨假定供应链风险因素都不发生为供应链的第一种状态——未被激活的状态；供应链风险因素全都发生这一现象为第三种的状态——完全激活的状态；供应链风险因素处于临界状态这一现象为第二种状态——完全随机的状态。这三个状态中，从其中某一个供应链风险因素没有变化到随机变化，有下列参数可以描述：风险因素的状态、从一个状态到另外一个状态的持续时间、从一个状态切换到另外一个状态的概率等。

下面我们重点分析一下供应链风险因素的这三种状态。发生态表示风险因素完全偏离了正常的状态，未发生态表示风险因素处于正常状态，而对于临界态，直接描述比较困难，我们给出一个直观的描述方式。临界态其实指的是这一风险因素随时都可能偏离正常状态，这是一个不稳状态。徐绪松和郑小京（2012，2013）对供应链道德风险中的因素以及道德风险的临界状态进行了分析，这一结果以及分析过程可以测定在整个供应链风险系统中风险因素是否处于临界状态。

由于风险影响因素的重要性随着系统状态、环境的变化而不断变化，因此就某一特定的风险因素或风险事件而言都是对应的随机过程，不妨假设这一系统满足下列条件：

(1) 假设在一个有限的时间内条件概率变化过程对所有的 t 是一致平稳的；

(2) 假设动态概率过程是马尔科夫 (Markovian) 的，即满足

$$P(X(t+1) | X(1), X(2), \dots, X(t)) = P(X(t+1) | X(t)) \quad (1)$$

也就是说，未来时刻的概率分布只与当前时刻有关，而与过去历史无关；

(3) 假设相邻时间的条件概率过程是平稳的，

即 $P(X(t+1) | X(t))$ 与时间 t 无关，可以容易得到不同时间的转移概率 $P(X(t+1) | X(t))$ 。

文献 [1-6] 证明供应链风险系统中各个风险因素以及风险基本满足这三个假设，因此可在随机过程的基础上研究供应链风险。除此之外，注意到任意的一个风险因素以及风险事件并不是单独存在着的，而是按照图 1 的网络相互影响，这种相互影响就使得问题更加复杂。鉴于此，我们引入下列动态贝叶斯网络推理模型来描述这一问题。

不失一般性，假设供应链风险贝叶斯网络可以被简化成一些有序排列的链条，按照箭头方向从尾部到头部的顺序对这些节点进行重新排序，得到新的编码，不妨记这一贝叶斯链节点集合为 $\{1, 2, \dots, L\}$ 。令 $M = (Q^{1:L}, D^{1:L-1}, O^{1:L}, \pi^{1:L}, A^{1:L}, B^{1:L}, P^{1:L-1})$ 表示供应链风险系统，其中 $Q^{1:L}, O^{1:L}, D^{1:L-1}$ 分别表示节点 1 到节点 L 的行为状态、观测及节点 1 到节点 $L-1$ 的驻留时间状态的集合。这是一个特殊的动态贝叶斯网络，其状态空间被分解成 L 个行为状态的集合 $Q^l = \{1, 2, 3 | Q^l\}$ 和 $L-1$ 个驻留时间状态的集合 $D^{l-1} = \{d | d \in N \cup \{0\}\}$ ，其中 N 为自然数集。这一模型的参数 Θ 包括初始概率 $\pi^l = \{\pi_{ij}^l\}$ （节点 $l-1$ 在初始时刻状态为 i 条件下，节点 l 状态为 j 的概率）、转移概率 $A^l = \{a_{ijk}^l\}$ （节点 l 在时刻 $t-1$ 上状态为 j ，且其驻留时间为 d ，以及节点 $l-1$ 在时刻 t 状态为 i 条件下，节点 l 在时刻 t 状态为 k 的概率）、观测概率分布 $B^l = \{b_i^l(O_i)\}$ （节点 l 在时刻 t 被观测到状态为 i 的概率分布）以及行为状态的驻留时间分布 $P^{l-1} = \{p_i^{l-1}(d)\}$ （节点 l 时刻 $t-1$ 驻留时间为 d 条件下，在时刻 t 状态为 i 的驻留时间为 d' 的概率），其中 $l=1$ 时， π_{ij}^l 和 a_{ijk}^l 可以退化成 π_j^1 和 a_{jk}^1 ，即 $\Theta = \{\pi^{1:L}, A^{1:L}, B^{1:L}, P^{1:L-1}\}$ 。回顾图 1 描述的供应链风险贝叶斯图，可以发现，这一错综复杂的网络可以被简化成 5 条链状的贝叶斯链，这五条链的长度分别为 12、13、13、14、13。将其最大值定义为供应链风险贝叶斯网络的直径，并用直径描述系统的层数。在本研究中， $L=14$ ，表示供应链在供给管理、需求管理、生产制造管理以及信息管理四个阶段的运作过程中对应的风险因素及风险的影响关系，同时也描述了一个风险因素的波动将会引起下一个风险因素的波动，并且这些因素或风险事件按照一定的概率在未发生态、临界态以及发生态等三种状态中随时间随

机切换。这一模型比较复杂，为了直观地描述这一问题，图 2 给出一个只有三层的动态贝叶斯网络的情况。

从图 1 与图 2 可以看出，对于绝大多数风险因素以及所有的风险事件来说，它们的状态不仅受到这一风险因素自身状态的历史特性影响，而且还受到上一级风险因素状态影响；不仅如此，每一个风险因素的变化过程是一个马尔科夫过程。这种双重特性使得供应链风险变化比较复杂。




图 2 3 层 HDS-DBN 模型

注：这一模型在文献 [13] 中也得到一定的阐述，不过并没有考虑网状的贝叶斯网络的情形，针对供应链风险及其对应动态贝叶斯网络的特征，所构造出来的模型复杂得多。另外，我们关注一种特殊的情况：供应链系统运作过程中，两个弱关系或不相关关系之间是否按照一定的频率发生“共振”现象，这一特殊的现象将在后续的研究中进行分析，其基本的思路就是对于供应链风险的测度按照量子的方式进行，并且按照量子纠缠态的相关理论，在本文所构建的大框架下进行分析，则可以得到，这一研究已在文献 [14] 中给出。

前面说明供应链风险动态贝叶斯网络可以分解成五条不同的链，对于每一条链来说，不妨假设其对应的风险因素或风险事件都是从 1 开始编号，一直到 L 结束（显然，这种编号简化了分析的复杂性，但绝不影响结果），那么在经典概率测度已

知的前提下,这一模型的条件概率分布可以表示如下:

$$P(Q_l^l = j | Q_{l-1}^{l-1} = i) = \begin{cases} \pi_j^l, & l = 1 \\ \pi_{ij}^l, & l = 2, \dots, L \end{cases} \quad (2)$$

$$P(Q_l^l = k | Q_{l-1}^{l-1} = j, Q_{l-1}^{l-1} = i, D_{l-1}^l = d) = \begin{cases} \delta(j - k), & d > 0, l = 1, 2, \dots, L - 1 \\ a_{jk}^l, & d = 0, l = 1 \\ a_{ijk}^l, & d = 0, l = 2, 3, \dots, L - 1 \\ a_{ijk}^L, & l = L \end{cases} \quad (3)$$

$$P(D_l^l = d' | D_{l-1}^l = d, Q_l^l = i) = \begin{cases} p_i^l(d'), & d = 0 \\ \delta(d' - d + 1), & d > 0 \end{cases} \quad (4)$$

$$P(O_l^l | Q_l^l = i) = \sum_{k=1}^{M_l} w_{ik}^l N(O_l^l, \mu_{ik}^l, \Sigma_{ik}^l) \quad (5)$$

其中, $p_i^l(d)$ 是风险因素 l 的状态 $Q^l = i$ 的驻留时间分布, $P(Q_l^l = j | Q_{l-1}^{l-1} = i)$ 表示任意时刻 t 上, 风险因素 $l - 1$ 的状态 $Q^{l-1} = j$ 的条件下风险因素 l 的状态 $Q^l = i$ 的概率, $i = 1, 2, 3$; 显然, 贝叶斯网络中的第一个风险因素发生的概率为 π_j^1 。 $P(Q_l^l = k | Q_{l-1}^{l-1} = j, Q_{l-1}^{l-1} = i, D_{l-1}^l = d)$ 表示在时刻 $t - 1$ 上, 风险因素 l 的状态为 j , 在时刻 t 上, 风险因素 $l - 1$ 状态为 i , 且从 $t - 1$ 时刻开始风险因素 l 状态的持续时间为 d 的条件概率, $\delta(\cdot)$ 是 Delta 函数, a_{ijk}^l 是正实数。 $P(D_l^l = d' | D_{l-1}^l = d, Q_l^l = i)$ 表示时刻 t 风险因素 l 的状态为 i , 从 $t - 1$ 时刻开始风险因素 l 状态持续时间为 d , 且从 t 时刻开始风险因素 l 状态持续时间为 d' 的条件概率。 $N(\cdot, \cdot, \cdot)$ 是高斯分布函数, $M_l^l, w_{ik}^l, \mu_{ik}^l, \Sigma_{ik}^l$ 表示第 i 层观测的概率分布中高斯分布的个数、权重、均值和协方差矩阵。

二、供应链风险贝叶斯网络推理

供应链风险的估计应该包括两个部分, 第一就是在一定风险因素影响下供应链风险发生后所表现出来的规律, 主要包括关键风险因素以及这些关键风险因素变化将导致某一种特定风险发生的可能性以及发生后产生的危害, 这其实就是风险先验估计的主要内容。第二就是在先验的供应链风险发生规律基础上, 确定某一特定供应链状态可能会引起的风险大小。就前一个问题而言, 我们在调查的基础上, 构造出一个供应链贝叶斯网

络, 网络边上的权就表示了上一个风险因素处于某种状态时能够引起下一个因素处于某种状态的概率, 通过推理可以确定出某一因素处于特定状态时可能发生的风险及其可能性大小。不过, 供应链风险贝叶斯图异常复杂, 要想得到比较准确的结论, 首先就需要在这一模型的基础上, 通过数据对模型的各个参数进行有效地估计, 我们称之为贝叶斯网络参数的学习; 然后通过学习好的模型, 估计出供应链风险随机过程意义上的统计规律, 以及后验概率, 以描述供应链风险事件的本质特征。然而, 动态贝叶斯网络模型还能推断出在一组新的供应链风险因素的状态下供应链各个风险出现的情况, 也就是说, 我们获得了供应链风险系统中一组对应的新数据 $P(Q_{m+1} | \Theta)$ 以及 $P(D_{m+1} | \Theta)$, 这里, Q_{m+1} 与 D_{m+1} 是一组新的供应链风险因素所对应的数据, 这一新的数据按照模型预设的规律发生着动态变化。以本文构建的供应链风险动态贝叶斯网络模型为基础, 按照贝叶斯推断的技术确定供应链风险系统中隐变量以及风险事件随机动态变化的情况; Θ 指的是供应链风险动态贝叶斯网络模型的参数。

不妨令 $S_t = (Q_t^1, Q_t^2, \dots, Q_t^L, D_t^1, D_t^2, \dots, D_t^{L-1})$ 表示 t 时刻的状态, $S_{1:T} = (S_1, S_2, \dots, S_T)$ 表示状态序列, $O_t = (O_t^1, O_t^2, \dots, O_t^L)$ 表示 t 时刻的观测数据, $O_{1:T} = (O_1, O_2, \dots, O_T)$ 表示观测序列。值得注意的是, 这里的状态 $S_t = (Q_t^1, Q_t^2, \dots, Q_t^L, D_t^1, D_t^2, \dots, D_t^{L-1})$ 包括了我们构建的动态贝叶斯网络的所有参数, 不仅表示了供应链风险因素以及风险事件的状态, 还包括了其某一特定状态的持续时间。在实际的推理过程中, 我们根据观测的数据对该贝叶斯网络的参数进行估计, 并且记这一参数为 Θ 。显然, 这一参数估计的准确性绝对影响了供应链风险贝叶斯网络推理的可靠性。在给定观测序列时, 可以根据推理算法求解模型的似然值 $P(O_{1:T} | \Theta)$, 以及状态平滑如 $P(S_t | O_{1:T}, \Theta)$ 和 $P(S_t, S_{t+1} | O_{1:T}, \Theta)$ 等。其次, 我们在参数已知的前提下, 可以对这一网络进行推理。本文采用团树算法对 HDS-DBN 模型进行推理。

(一) 一般理论

1. 学习

给定用于训练的观测序列 $O_{1:T}$, HDS-DBN 模

型的参数 Θ 可以通过最大似然法来估计, 即 $\hat{\Theta} = \arg \max_{\Theta} P(O_{1:T}, S_{1:T} | \Theta)$ 。由于状态序 $S_{1:T}$ 列是不能被观测到的, 故需要通过 Expectation-maximization (EM) 算法进行迭代求解:

$$\Theta^{(n+1)} = \arg \max_{\Theta} E \{ \log P(O_{1:T}, S_{1:T} | \Theta) | O_{1:T}, \Theta^{(n)} \} \quad (6)$$

其中, $\Theta^{(n)}$ 是第 n 次迭代结果。通过式 (6) 的迭代计算, 参数可以收敛到一个局部极值点。

根据供应链风险贝叶斯网络的特点, 可以看出这一网络具有串并联共存的混合状态。首先考虑各个风险因素所代表的节点串联的情况。根据贝叶斯网络的基本理论可以知道, 在式 (6) 中, 观测序列 $O_{1:T}$ 和状态序 $S_{1:T}$ 的联合密度如式 (7) 所示:

$$P(O_{1:T}, S_{1:T} | \Theta) = \prod_{t=1}^T \left(\prod_{i=1}^L P(Q_i^t | pa(Q_i^t)) \times P(O_i^t | pa(O_i^t)) \prod_{h=1}^{L-1} P(D_i^h | pa(D_i^h)) \right) \quad (7)$$

其中 $pa(X)$ 表示节点 X 的父节点。

给定 C 个已经训练好的 HDS-DBN 模型 $M_1, M_2, \dots, M_C$, 其中每个模型对应一种情况。给定一个测定状态, 其观测序列为 $O_{1:T}$, 则我们选择 c 作为测试该状态的类别标号, 其中 c 由下式确定

$$c = \arg \max_i P(M_i | O_{1:T}) = \arg \max_i P(O_{1:T} | M_i) P(M_i) \quad (8)$$

式 (8) 中, $P(M_i)$ 是模型 M_i 的先验概率, 可以取为 $1/C$ 。假设 M_i 的参数是 Θ_i , 则 $P(O_{1:T} | M_i) = P(O_{1:T} | \Theta_i)$ 。

其次, 考虑网络中并联存在的情况, 主要考虑某一个风险因素对应的节点有若干个父节点的情况。不妨假定这些父节点的编号为 $pa_i(\cdot)$, 其中 i 表示 I 个父节点中的第 i 个父节点。通过上面的分析可以看出, $pa_i(\cdot)$ 共有三种状态: 发生、临界、未发生, 结合 Expectation-maximization 的算法可知, 观测序列 $O_{1:T}$ 和状态序 $S_{1:T}$ 的联合密度为:

$$P(O_{1:T}, S_{1:T} | \Theta) = \prod_{t=1}^T \left(\sum_{i=1}^I \sum_{j=1}^3 (P(Q_i^t | pa(Q_i^t)) \times P(pa(O_i^t) | O_i^t) \sum_{h=1}^L P(D_i^h | pa(D_i^h))) \right) \quad (9)$$

进一步有

$$P(O_{1:T}, S_{1:T} | \Theta) = P(O_{1:T}, S_{1:T} | \Theta) = \prod_{t=1}^T \left(\sum_{i=1}^I \sum_{j=1}^3 (P(Q_i^t | pa(Q_i^t)) \times P(pa(O_i^t) | O_i^t) \sum_{h=1}^L P(D_i^h | pa(D_i^h))) \right) \times \prod_{t=1}^T \left(\prod_{i=1}^L P(Q_i^t | pa(Q_i^t)) \right)$$

$$\times P(O_i^t | pa(O_i^t)) \prod_{h=1}^{L-1} P(D_i^h | pa(D_i^h)) \quad (10)$$

可以看出, 这一分析的前提是贝叶斯网络参数已知, 因此对其估计是识别这一供应链风险贝叶斯网络特性的关键所在。本文采用最大似然法对其进行估计。对于本文的模型, 定义样本 O_i^t 的特征函数 $X(i, j, k; O_i^t)$ 为 $X(i, j, k; O_i^t) = \begin{cases} 1, & X_i = k, pa(X_i) = j, X_i \in O_i^t; \\ 0, & \text{否则} \end{cases}$ 就局部数据而

言, 定义 $m_{ijk} = \sum_{t=1}^m X(i, j, k; O_i^t)$, 即 m_{ijk} 是数据中满足 $X_i = k$ 和 $pa(X_i) = j$ 的样本的数量, 于是 $\theta_{ijk}^* = \begin{cases} \frac{1}{T} \sum_{t=1}^T m_{ijk} / \sum_{k=1}^{r_i} m_{ijk}, & \text{若 } \sum_{k=1}^{r_i} m_{ijk} > 0, \\ 1/r_i, & \text{其他} \end{cases}$, 且 $\Theta = \{\theta_{ijk}^*\}$ 。

本文根据团树算法将贝叶斯网络进行推理。在推理的过程中, 我们最关心两个问题: 这些风险事件的后验概率分布如何? 当这一风险规律确定之后, 换一组参数, 整个风险事件的特征将是什么样的? 显然, 这两个方面的研究对于我们来说都是非常关键的。下面就针对这两个问题一一进行分析。

令 $\Theta = \{\theta_{ijk}^*\}$, 我们可以知道, $p(\theta | D) \propto \prod_{i=1}^n \prod_{j=1}^{q_i} \prod_{k=1}^{r_i} \theta_{ijk}^{m_{ijk} + \alpha_{ijk} - 1}$ (其中 $i = 1, 2, \dots, n$ 表示贝叶斯网络中节点的编号, $j = 1, 2, \dots, q_i$ 表示节点 X_i 的父节点 $pa(X_i)$ 的个数, $k = 1, 2, \dots, r_i$ 表示节点 X_i 的可能的状态数量), 即后验分布 $P(\theta | O)$ 也是一个乘积狄利克雷分布, 具有全局独立性与局部独立性, 并且 $P(\theta_{ij} | O)$ 是狄利克雷分布 $D[m_{ij1} + \alpha_{ij1}, m_{ij2} + \alpha_{ij2}, \dots, m_{ijr_i} + \alpha_{ijr_i}]$ 。从本质上讲, 给定一个风险因素的序列, 其状态的后验概率表现出了风险因素的内在特性。

2. 推理

现在我们考虑在此规律的基础上, 如果来一个新的样本, 这一新样本能否发生风险或发生风险的可能性有多大。对于一个新的样本观测 O_{m+1} , 可以知道

$$P(O_{m+1} | O) = \int P(O_{m+1} | \Theta) p(\Theta | O) d\Theta = \prod_{t=1}^L \int P(X_t^1, X_t^2, \dots, X_t^L | \Theta) p(\Theta | O) d\Theta = \prod_{t=1}^L P(X_t^i | pa(X_t^i), \Theta) p(\Theta | O) \quad (11)$$

可以推算出

$$P(O_{m+1} | O) = \frac{\prod_{i=1}^n \sum_{j=1}^q \sum_{k=1}^{r_i} \chi(i, j, k; O_{m+1})}{\sum_{k=1}^{r_i} (m_{ijk} + \alpha_{ijk})} \quad (12)$$

其中, 特征函数:

$$\chi(i, j, k; O_{m+1}) = \begin{cases} 1, & X_i = k, pa(X_i) = j, X_i \in O_{m+1} \\ 0, & \text{otherwise} \end{cases}$$

在某一时间点上观测到供应链风险因素的数据基础上, 式(12)给出了有效推断若干时间点上供应链可能出现某种特定风险的概率, 以及可能发生与持续时间特征。

(二) 供应链风险发生与持续时间、可能性大小的评估

为了有效评估供应链风险, 我们对若干个供应链中相关的变量进行了随机抽样, 从而收集了供应链风险系统中涉及到的风险因素以及风险事件数据, 通过数据处理的方式, 对这些数据进行初步分析, 从而得到一些描述性的结果, 确定了对应的供应链风险动态贝叶斯网络模型中的相关参数。根据实际情况, 将这一供应链风险因素以及风险的观测值作为证据, 通过供应链风险贝叶斯网络的学习, 确定这一网络参数的性质, 然后在此基础上输入一个新的变量, 推理在这一新的风险因素下供应链风险可能大小及随时间波动的情况。

按照上面的分析, 我们可以直接利用观测数据 O_i 估计该动态贝叶斯网络的参数 Θ , 然后根据公式(7)、公式(9)对这一供应链风险进行推理, 并利用公式(11)与公式(12)估计特定状态下供应链风险发生与持续时间、可能性等风险序参量的性质。

1. 供应链风险发生可能性

我们根据对所有变量的数据收集与描述性统计, 得到了各个时间点上的风险因素、风险发生的先验概率, 以及各个风险因素之间的条件概率, 然后利用最大似然法估计出模型中所有参数, 并根据一个新的供应链风险状态, 将其输入到供应链风险动态贝叶斯网络模型中, 得到了供应链风险若干风险发生可能性的变化形式。

前文讲过, 供应链风险是一个具有多源、多维、交叉等多种属性的复杂系统, 而文献[14]

中提到道德风险与牛鞭效应最容易发生, 双重边际效应、资金链断裂以及牛鞭效应的影响最大。双重边际效应与供应链核断裂、供应链网络崩溃、物流中断以及资金链断裂之间存在着很大程度的共振现象——即双重边际效应与供应链核断裂、供应链网络崩溃、物流中断以及资金链断裂之间存在着非常微弱的作用, 但它与其他三者之间同时发生的概率较大。因此, 下文将主要以双重边际效应、资金链断裂、道德风险与牛鞭效应等四种风险为例, 分析在这一动态贝叶斯网络的推理下, 这四种风险发生的可能性随时间的变化情况。




图3 四种供应链风险随着时间的变化情况

图3中, 横轴为时间维, 每一单位表示10个单位的真实时间, 纵轴表示风险可能性的大小。实点实线表示道德风险, 空心点实线表示牛鞭效应, 长间隔虚线表示双重边际效应, 点虚线表示资金链断裂。从图3中可以看出, 供应链风险并不是一个稳定的值, 而是随着时间随机波动, 这种变化主要来自于供应链风险因素的随机性以及风险因素之间的相关性, 并且这些风险随着时间延伸均收敛与一个比较稳定的区域。进一步而言, 我们可以看出双重边际效应会随着供应链运作的过程逐渐增大, 而资金链断裂风险则随着时间的变化逐渐降低。这是因为, 随着供应链运作过程的不断进行, 各个节点企业为了片面追求自身利益的最大化, 从而形成供应链系统局部优化的现象, 从而导致这一风险逐步增大, 但随着时间增长, 在风险边际效应递减机制的作用下, 其增长速度降低, 最终使得这一风险趋于一个比较稳定的值。而对于供应链资金链风险来说, 一开始运营的投资量较大, 可能使得某一环节所使用的资金无法保证, 最终导致供应链资金链断裂风险较大, 但是随着时

间推移，供应链运作的各个过程都度过了敏感期，所有的运作都得到了有一定的回报，这时供应链资金断裂的风险就会不断下降，使之趋于另外一个较低的水平。牛鞭效应与道德风险表现出较强的随机性，这与供应链分布式控制的特点以及运作过程中其较为复杂结构的相关因素有极大关系。

进一步，从供应链风险的动态贝叶斯网络模型可以看出，即使供应链风险因素与风险之间的关系是确定的，但由于风险因素的随机性以及随时间的随机波动性，风险大小是不确定的。然而，我们总可以构造一个风险的系统模型对其进行推理，以把握在特定条件下供应链系统中风险的状态及其变化情况。

2. 供应链风险可能发生与持续时间

仍然分析上述的四种风险。由于我们采集的数据中有时间这一变量，因此完全可以通过动态贝叶斯网络对其进行推理，这一过程是在 Genie 平台中实现的，具体的结果如图 4 所示。




图 4 供应链风险持续时间的分布状态

在图 4 中，实线表示道德风险，点虚线表示双重边际效应，短线段组成的虚线表示牛鞭效应，短线段与点组合成的虚线表示资金链断裂。横轴表示可能持续的时间，而纵轴表示可能发生的概率。从图 4 可以看出，这些风险发生持续时间很短时发生的可能性比较高，而当持续时间增长时，其可能发生的概率指数式降低，这一现象非常重要。另外，从图 4 中还可以看出牛鞭效应持续时间的分布情况出现了一个“奇异点”，这主要是因为道德风险的影响因素较为简单，正是由于这种单一的影响因素决定了它的持续时间可能与其他不一致。奇点的出现也比较正常，但是从总体上看，这一奇点可以忽略。

此外，持续时间是与发生时间紧密联系，知道了其中一个就可以得到另外一个的分布形式。这是因为一个时间最初发生时间与消失时间之间的

差值就是这一风险的持续时间。如果我们仅仅考虑风险事件的状态在时间上的分布特征，这一风险发生与持续时间相关的结论就更加容易解释。根据概率的计算方法，不难知道，风险事件发生的时间分布形式也是一条类似的曲线。

三、结论

供应链中存在着若干种类型的风险，他们之间并不独立存在，而是与供应链风险因素相互影响，形成了一个非常复杂的网络。这些供应链风险因素在任何一个时间点上都将随机出现发生、未发生以及临界等三种状态，并且每一种状态是完全独立的。每一种因素的特征将会影响它的下一个因素的状态，这种相互作用使得供应链风险的性质与状态非常复杂。本文构建了一个动态贝叶斯网络模型来描述这一供应链风险的特性，对其可能性大小、发生与持续时间等风险参数进行估计，并且就道德风险、牛鞭效应、双重边际化以及供应链资金链断裂等四种风险进行了研究，认为供应链风险并不是一个稳定的值，而是随着时间随机波动，不过这些风险将随着时间的推移收敛到一个比较确定的区域中。此外，在假定供应链风险因素都只出现发生与未发生两种情况的情形下，这些风险因素以及风险的持续时间的分布特征满足一个指数分布，其幂指数大小为所有风险因素以及风险发生概率的和。

参考文献：

- [1] Christopher S. Tang. Perspectives in supply chain risk management[J]. International of Production Economics, 2006, 103: 451-488.
- [2] Claudia Colicchia and Fernanda Strozzi. Supply chain risk management: a new methodology for a systematic literature review[J]. Supply Chain Management: An International Journal, 2012, 17(4): 403-418
- [3] George A. Zsidisin, Bob Ritchie. Supply Chain Risk Management - Developments, Issues and Challenges [C]. 1-12. George A. Zsidisin, Bob Ritchie, Supply Chain Risk: A Handbook of Assessment, Management, and Performance. Springer Science + Business Media, LLC, 2009.
- [4] Teresa Wu, Jennifer Blackhurst, Vellayappan Chidambaram. A model for inbound supply risk analysis [J].

- Computers in Industry, 2006, 57: 350–365.
- [5] 马建华, 艾兴政, 唐小我. 多源不确定性因素下两阶段动态供应链的风险绩效[J]. 系统工程理论与实践, 2012, 32(6): 1222–1231.
- [6] 李民, 黎建强. 基于模拟方法的供应链风险与成本[J]. 系统工程理论与实践, 2012, 32(3): 580–588.
- [7] Steven A. Melnyk, Alexander Rodrigues, and Gary L. Ragatz. Using Simulation to Investigate Supply Chain Disruptions [C]. 103–122. George A. Zsidisin, Bob Richie, Supply Chain Risk: A Handbook of Assessment, Management, and Performance, Springer Science+Business Media, LLC, 2009.
- [8] Bjørn Egil Asbjørnslett. Assessing the Vulnerability of Supply Chains [C]. 15–34. George A. Zsidisin, Bob Richie, Supply Chain Risk: A Handbook of Assessment, Management, and Performance, Springer Science+Business Media, LLC, 2009.
- [9] Jukka Hallikas and Jari Varis. Risk Management in Value Networks [C]. 35–52. George A. Zsidisin, Bob Richie, Supply Chain Risk: A Handbook of Assessment, Management, and Performance, Springer Science+Business Media, LLC, 2009.
- [10] Mohd Nishat Faisal, D.K. Banwet and Ravi Shankar. Mapping supply chains on risk and customer sensitivity dimensions [J]. Industrial Management & Data Systems, 2006, 106(6): 878–895
- [11] Jennifer V. Blackhurst, Kevin P. Scheibe and Danny J. Johnson. Supplier risk assessment and monitoring for the automotive industry [J]. International Journal of Physical Distribution & Logistics Management, 2008, 38(2): 143–165.
- [12] Archie Lockamy III, Kevin McCormack. Modeling supplier risks using Bayesian networks [J]. Industrial Management & Data Systems, 2012, 112(2): 313–333.
- [13] 杜友田, 陈峰, 徐文立. 基于多层动态贝叶斯网络的人的行为多尺度分析及识别方法[J]. 自动化学报, 2009, 35(3): 225–232.
- [14] 郑小京. 供应链风险评估: 一个贝叶斯-量子决策的推理网络研究范式[J]. 哈尔滨商业大学学报, 2014(6).

Supply Chain Risk Estimation for Happening Probability, Happening and Holding Time: A Framework of Dynamical Bayesian Networks Inference

ZHENG Xiao-jing

(Institute of Business & Economics Research, Harbin University of Commerce, Harbin 150028, China)

Abstract: Supply chain risk has multi-resource, multi-dimensional, transmissible and dynamical characteristics, so it is key to precisely estimating its probability, happening time and holding time. To realize the goal, a dynamical Bayesian networks model of supply chain risk is constructed according to the property of the supply chain risk, then estimates the corresponding parameters by Maximum Likelihood and infers supply chain risks by Bayesian inference tool. It is concluded that supply chain risks will change with time and will be converged into a certain stable interval.

Key words: supply chain risk; probability; happening time; holding time

(责任编辑: 张曦)