

# 基于新息理论的变点检测及其在长输管道 泄漏监测中的应用

李俊花<sup>1</sup> 孙昭晨<sup>1</sup> 崔莉<sup>1</sup> 贾旭<sup>2</sup>

<sup>1</sup>(大连理工大学海岸和近海工程国家重点实验室 大连 116024)

<sup>2</sup>(中国海洋石油总公司 北京 100027)

(E-mail: lzj912@163.com)

**摘要** 在 ESPRT 检测方法的基础上, 结合新息过程给出了一种新的变点检测方法. 利用 ESPRT 方法检测经新息模型产生的新息过程, 实现了模型参数变点的非参数检测, 扩展了 ESPRT 方法在实际应用中的适用范围. 将该方法应用于长输管道泄漏故障监测时, 利用基于 BP 神经网络的非线性时间序列预测方法建立了管道泄漏监测系统的新息模型以及泄漏检测模型. 将上述监测方法应用于实验泄漏水管道, 能在线实时有效地发现泄漏.

**关键词** 序列检测, 新息, 泄漏检测, 管道

**中图分类号** TP206+.3

## Detection of Abrupt Change Based on Innovation Theory and Leak Detection in Pipeline

LI Jun-Hua<sup>1</sup> SUN Zhao-Chen<sup>1</sup> CUI Li<sup>1</sup> JIA Xu<sup>2</sup>

<sup>1</sup>(The State Key Laboratory of Coastal and Offshore Engineering,

Dalian University of Technology, Dalian 116024)

<sup>2</sup>(China National Offshore Oil Corporation, Beijing 100027)

(E-mail: lzj912@163.com)

**Abstract** The paper presents a new detection method of abrupt change based on extended sequential probability ratio test (ESPRT) innovation process. This method can convert a parameter model into a non-parameter model using innovation theory. So, the method can be widely applied to practice in combination with ESPRT. The paper uses nonlinear temporal series based on BP neural network to establish the innovation model and leakage detection model of the pipe. It is proved that the detection method can effectively online detect the leak, using the collected data in the laboratory.

**Key words** Sequential test, innovation, leakage detection, pipeline

## 1 引言

许多实际问题可以用参数模型模拟, 而参数的变化与变点发生的时间有关. 通过检测被考察对象的变点变化来检测系统特征参数变化的方法称为变点检测<sup>[1]</sup>. 变点检测方法已被应用于质量控制、故障检测等领域, 因此有必要对变点检测方法加以研究.

基于二元假设的序列似然比检测 (SPRT)<sup>[2]</sup> 在检测的平均时间和平均数量上达到最优, 但这种方法仅适用于双则一的问题. 基于多元假设的序列似然比检测 (ESPRT)<sup>[3]</sup> 方法

收稿日期 2005-6-20 收修改稿日期 2005-11-30

Received June 20, 2005; in revised form November 30, 2005

将 SPRT 方法推广到多元假设的情形. 但这两种方法都需要事先给出原假设的统计特征参数. 本文将新息理论与 ESPRT 方法结合很好地解决了实际问题中出现的原假设统计参数未知的情况.

通过研究发现当管道中存在泄漏时, 管道中的流体实际上是从一种恒定流状态经过瞬变流过程过渡到另一种瞬变稳定状态, 管道上下游的压力和流量则分别表现为从某一个参数模型突变为另一个参数模型, 因此可以通过变点检测方法识别管道泄漏. 本文将变点检测方法应用于实验水管道, 结果证明了该方法的有效性.

## 2 变点检测

### 2.1 基于二元假设的序列似然比检测 (SPRT)

令:  $\mu_0, \mu_1$  分别表示变点发生前后的统计平均值, 且  $\mu_1 \neq \mu_0$ . 检测模型为

$$H_0: \mu_0, \quad H_1: \mu_1$$

设:  $x_1, x_2, \dots$  为  $X$  的样本观测值,  $p_0(k)$  表示假设  $H_0$  为真时的概率密度,  $p_1(k)$  表示假设  $H_1$  为真时的概率密度.  $j$  时刻的似然比为

$$L(X_j) = \frac{p(X_j|H_1)}{p(X_j|H_0)} = \prod_{i=1}^j \frac{p(x_i|H_1)}{p(x_i|H_0)} = \frac{p(x_j|H_1)}{p(x_j|H_0)} \prod_{i=1}^{j-1} \frac{p(x_i|H_1)}{p(x_i|H_0)} = L(x_j)L(X_{j-1}) \quad (1)$$

为便于计算, 采用对数似然比, 由 (1) 得到  $j$  时刻的递推公式

$$\lambda(j) = \ln L(X_j) = \ln L(x_j) + \ln L(X_{j-1}) = \lambda(j-1) + \ln L(x_j) \quad (2)$$

给定门限值  $\lambda_{NP0} = \ln \frac{\beta}{1-\alpha}$ ,  $\lambda_{NP1} = \ln \frac{1-\beta}{\alpha}$ ,  $\alpha, \beta$  分别为虚报警率和漏报警率.

作出判决: 当  $\lambda(j) > \lambda_{NP1}$  时, 接受假设  $H_1$ ; 当  $\lambda(j) < \lambda_{NP0}$  时, 接受假设  $H_0$ ; 当  $\lambda_{NP0} \leq \lambda(j) \leq \lambda_{NP1}$  时, 不作出任何判断, 继续下一次采样.

### 2.2 基于多元假设的序列似然比检测 (ESPRT)

假定有  $N+1$  个完备且互斥的假设  $H_0, H_1, \dots, H_N$ , 令  $p_i(k)$  表示假设  $H_i$  为真时的概率密度,  $\beta_{ij}$  表示  $H_j$  为真时接受  $H_i$  的概率. 假定有  $N(N+1)$  个门限值  $A_{ij}$ ,  $i, j \in (0, 1, \dots, N)$  且  $i \neq j$ .  $k$  时刻接受  $H_i$  的判断准则为

$$L(X_k) = \frac{p(X_k|H_i)}{p(X_k|H_j)} \geq A_{ij}$$

其中  $A_{ij} = \frac{\beta_{ii}}{\beta_{ij}}$

$$\sum_{k=0}^N \beta_{ki} = 1$$

表示为对数似然比的形式为

$$\lambda_{ij}(k) = \ln L(X_k) = \ln \frac{p(X_k|H_i)}{p(X_k|H_j)} \quad (3)$$

特别地, 给定

$$\lambda_{i0}(k) = \ln \frac{p(X_k|H_i)}{p(X_k|H_0)} \quad (4)$$

则

$$\lambda_{ij}(k) = \lambda_{i0}(k) - \lambda_{j0}(k) \quad (5)$$

上述两种方法在实际应用中需要事先给出原假设的平均值  $\mu_0$ , 但一些实际问题并不能事先确定  $\mu_0$ . 而基于新息理论的变点检测方法实现了原假设的零均化.

### 3 基于新息理论的变点检测

一步前向预测的预测误差称为新息<sup>[5]</sup>, 新息与观测数据之间具有一一对应的关系, 新息序列不会丢失观测序列的任何信息. 假定系统的新息模型如下所示

$$\varepsilon_k = \mathbf{Y}_k - \hat{\mathbf{Y}}_{k|k-1} \quad (6)$$

其中  $\varepsilon$  是新息过程;  $\mathbf{Y}_k$  是  $k$  时刻  $r$  维观测向量;  $\hat{\mathbf{Y}}_{k|k-1}$  表示  $k-1$  时刻的一步前向预测值. 令  $\varepsilon_k^i$  表示假设  $H_i (i \in (0, 1, \dots, N))$  为真时的新息过程. 则  $k$  时刻的对数似然比为:

$$\lambda_{ij}(k) = \ln L(\mathbf{Y}_k) = \ln \frac{p(\mathbf{Y}_k|H_i)}{p(\mathbf{Y}_k|H_j)} = \ln \frac{p(\varepsilon_k|H_i)}{p(\varepsilon_k|H_j)} \quad (7)$$

由新息的定义知道  $\varepsilon_k^i$  的平均值为 0. 假设  $\varepsilon_k^i$  服从平均值为 0, 协方差阵为  $C_k^i$  的正态分布 ( $i \in (0, 1, \dots, N)$ ). 有

$$p(\varepsilon_k|H_i) = \frac{1}{(2\pi)^{r/2} [\det C_k^i]^{1/2}} \exp\left(-\frac{1}{2}(\varepsilon_k^i)^T (C_k^i)^{-1} \varepsilon_k^i\right) \quad (8)$$

令

$$\psi_k^i = \frac{1}{(2\pi)^{r/2} [\det C_k^i]^{1/2}}, \quad \varphi_k^i = (\varepsilon_k^i)^T (C_k^i)^{-1} \varepsilon_k^i$$

上面两式代入 (8) 有

$$p(\varepsilon_k|H_i) = \psi_k^i \exp\left(-\frac{1}{2}\varphi_k^i\right) \quad (9)$$

把 (9) 代入 (7) 得到递推公式

$$\lambda_{i0}(k) = \lambda_{i0}(k-1) + \ln \psi_k^i - \ln \psi_k^0 + \frac{1}{2}(\varphi_k^i - \varphi_k^0) \quad (10)$$

由公式 (5) 求得  $\lambda_{ij}$

算法如下:

- 1) 任一时刻  $k$ , 获得样本的观测值  $Y$
- 2) 根据 (8) 计算  $\lambda_{i0}(k) (i = 1, \dots, N)$ , 进行如下判断
  - 如果  $\lambda_{i0}(k) \leq -\ln A_{0i}$ , 接受假设  $H_0$  并结束检测
  - 如果  $\lambda_{i0}(k) < B_l$ , 令  $\lambda_{i0}(k) = B_l$
  - 如果  $\lambda_{i0}(k) > B_u$ , 令  $\lambda_{i0}(k) = B_u$
- 3) 令  $j = 1$
- 4) 计算  $\lambda_{ij}(k) (i = j+1, \dots, N)$ , 然后进行如下判断
  - 如果  $\lambda_{ij}(k) \leq -\ln A_{ji}$  且  $\lambda_{jl}(k) \geq \ln A_{jl} (l = j-1, \dots, 1, 0)$ , 接受  $H_j$  并结束检测
  - 否则
  - 如果  $j < N$ , 返回 (4) 令  $j = j+1$
  - 如果  $j = N$  且  $\lambda_{Nl}(k) \geq \ln A_{Nl} (l = 0, \dots, N)$ , 接受  $H_N$  并结束检测

否则返回 (1) 令  $k = k + 1$

$B_u, B_l$  是为加快检测而引入的上下界限值<sup>[4]</sup>, 其取值范围分别为:

$$1.5 \ln A_{\max} < B_u < 3.0 \ln A_{\max}, \quad -3.0 \ln A_{\max} < B_l < -1.5 \ln A_{\max}$$

#### 4 管道泄漏监测系统新息模型的构建

实验和理论计算都证明管道发生泄漏前后, 管道入口处的压强会降低, 流量增大, 而出口处的压强也降低, 流量则减小. 因此由上述四个参数的变化情况就能判断管道中是否产生泄漏. 上述四个随机变量的变化可以根据实测样本作变点检测, 但要求给出各状态的统计特征参数 (如变点前各参数的平均值), 这给实时管道泄漏监测带来一定的麻烦. 本文介绍的基于新息理论的变点检测方法避免了上述特征参数并能判断出各随机变量的变化情况. 为了实现该方法在管道泄漏识别中的应用, 首先要构建能够得到管道进出口处流量和压强新息序列的新息模型. 本文采用非线性时间序列 BP 神经网络预测原理建立新息模型.

根据文献 [6] 介绍的非线性时间序列 BP 神经网络预测模型建立的原理, 分别建立管道进出口处流量和压力的神经网络时间序列预测模型

$$\begin{aligned}\hat{Q}_i(t+1) &= QI_w(Q_i(t), Q_i(t-1), \dots, Q_i(t-m_1-1)) \\ \hat{Q}_o(t+1) &= QO_w(Q_o(t), Q_o(t-1), \dots, Q_o(t-m_2-1)) \\ \hat{P}_i(t+1) &= PI_w(P_i(t), P_i(t-1), \dots, P_i(t-m_3-1)) \\ \hat{P}_o(t+1) &= PO_w(P_o(t), P_o(t-1), \dots, P_o(t-m_4-1))\end{aligned}$$

其中  $\hat{Q}_i(t+1), \hat{Q}_o(t+1), \hat{P}_i(t+1), \hat{P}_o(t+1)$  分别表示  $t+1$  时刻管道进出口处流量和压力的预测值;  $QI_w, QO_w, PI_w, PO_w$  分别表示各自神经网络的变换函数, 它们的确定是通过选择适当的各自的神经网络权系数  $w$  实现的;  $Q_i(t), Q_o(t), P_i(t), P_o(t)$  分别表示  $t$  时刻管道进出口处流量和压力的观测值;  $m_1, m_2, m_3, m_4$  分别表示管道进出口流量和压力的预测阶数. 于是得到下面的新息模型

$$\begin{cases} \hat{Y}_{i+1|t} = \begin{pmatrix} QI_w(Q_i(t), \dots, Q_i(t-m_1-1)) \\ PI_w(P_i(t), \dots, P_i(t-m_3-1)) \\ QO_w(Q_o(t), \dots, Q_o(t-m_2-1)) \\ PO_w(P_o(t), \dots, P_o(t-m_4-1)) \end{pmatrix} \\ \varepsilon_{t+1} = Y_{t+1} - \hat{Y}_{t+1|t} \end{cases} \quad (11)$$

#### 5 变点监测方法在管道泄漏识别中的应用

通过管道泄漏监测系统新息模型的建立, 本文将水力参数的变点检测问题转化为对新息序列的变点检测问题. 而对应于各个水力参数的新息序列的变点检测问题实际上是一基于三元假设的似然比检测问题. 具体检测过程为: 首先对管道上下游的压力和流量各自对应的新息分别提出下面三种假设:

$H_0$ : 非恒定流过程发生前管道上下游水力参数对应新息过程的平均值为 0

$H_1$ : 非恒定流过程发生后管道上下游水力参数升高后对应新息过程的平均值为  $\Delta\mu$

$H_2$ : 非恒定流过程发生后管道上下游水力参数降低后对应新息过程的平均值为  $-\Delta\mu$

然后根据公式 (3) 计算似然比函数

$$\lambda_{10}(k) = \ln \frac{p(\varepsilon_k|H_1)}{p(\varepsilon_k|H_0)}, \quad \lambda_{20}(k) = \ln \frac{p(\varepsilon_k|H_2)}{p(\varepsilon_k|H_0)}, \quad \lambda_{21} = \lambda_{20} - \lambda_{10}$$

特别地当新息序列服从正态分布时, 得到上述公式的简化形式为:

$$\lambda_{10}(k) = \lambda_{10}(k-1) + \frac{\Delta\mu}{\sigma^2}(\varepsilon(k) - \frac{\Delta\mu}{2}) \quad (12)$$

$$\lambda_{20} = \lambda_{20}(k-1) - \frac{\Delta\mu}{\sigma^2}(\varepsilon(k) + \frac{\Delta\mu}{2}) \quad (13)$$

最后进行判断:

当  $\lambda_{i0}(k) \leq -\ln A_{0i}$  ( $i = 1, 2$ ) 时接受假设  $H_0$ . 否则如果  $\lambda_{i0}(k) < B_l$ , 令  $\lambda_{i0}(k) = B_l$ , 如果  $\lambda_{i0}(k) > B_u$ , 令  $\lambda_{i0}(k) = B_u$  ( $i = 1, 2$ ).

当  $\lambda_{21}(k) \leq -\ln A_{12}$  且  $\lambda_{10}(k) \geq \ln A_{10}$  时接受假设  $H_1$ .

当  $\lambda_{2l}(k) \geq \ln A_{2l}$  ( $l = 0, 1$ ) 时接受假设  $H_2$ .

上游压力的新息序列接受假设  $H_2$ , 下游压力新息序列接受假设  $H_2$ , 下游流量新息序列接受假设  $H_2$ , 而上游流量新息序列接受假设  $H_1$  时, 即可判断为管道发生泄漏.

## 6 实验算例

已知从无泄漏状态到泄漏状态下管道进出口处流量和压强水头的测量序列, 测量数据采集的时间间隔为 0.01s. 试验管道的长度 48.8m, 直径 53mm.

利用上面介绍的泄漏监测方法对试验水管道进行泄漏识别, 实验是在大连理工大学水力学实验室完成的. 结果见图 1~16.

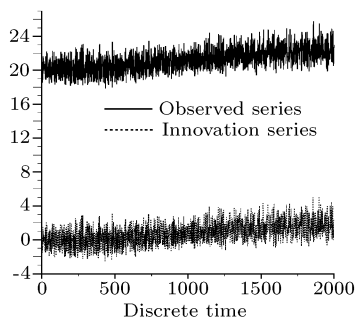


图 1 管道进口实测流量及其新息

Fig. 1 Measured flow rate of pipe at inlet and its innovation




图 2 管道进口实测压强及其新息

Fig. 2 Measured pressure of pipe at inlet and its innovation




图 3 管道出口实测流量及其新息

Fig. 3 Measured flow rate of pipe at outlet and its innovation




图 4 管道出口实测压强及其新息

Fig. 4 Measured pressure of pipe at outlet and its innovation




图 5 进口压强变点检测参数 1  
Fig. 5 The first parameter of detecting abrupt change of the press at inlet




图 6 进口压强变点检测参数 2  
Fig. 6 The second parameter of detecting abrupt change of the press at inlet




图 7 进口压强变点检测参数 3  
Fig. 7 The third parameter of detecting abrupt change of the press at inlet




图 8 出口压强变点检测参数 1  
Fig. 8 The first parameter of detecting abrupt change of the press at outlet




图 9 出口压强变点检测参数 2  
Fig. 9 The second parameter of detecting abrupt change of the press at outlet




图 10 出口压强变点检测参数 3  
Fig. 10 The third parameter of detecting abrupt change of the press at outlet




图 11 进口流量变点检测参数 1  
Fig. 11 The first parameter of detecting abrupt change of flow rate at inlet




图 12 进口流量变点检测参数 2  
Fig. 12 The second parameter of detecting abrupt change of flow rate at inlet




图 13 进口流量变点检测参数 3

Fig. 13 The third parameter of detecting abrupt change of flow rate at inlet




图 14 出口流量变点检测参数 1

Fig. 14 The first parameter of detecting abrupt change of flow rate at outlet




图 15 出口流量变点检测参数 2

Fig. 15 The second parameter of detecting abrupt change of flow rate at outlet




图 16 出口流量变点检测参数 3

Fig. 16 The third parameter of detecting abrupt change of flow rate at outlet

泄漏识别时用到的参数如下:

$$\beta_{01} = \beta_{02} = 0.005, \beta_{10} = \beta_{20} = 0.001, \beta_{12} = \beta_{21} = 0.005, \beta_{00} = 0.998, \beta_{11} = 0.99, \beta_{22} = 0.99$$

$$\ln A_{10} = \ln A_{20} = 6.89, \ln A_{01} = \ln A_{02} = 5.29, \ln A_{12} = \ln A_{21} = 5.28, B_u = 7.6, B_l = -7.6$$

图 1~4 为从实验管道采集的进出口的流量和压力的观测值以及相应的新息序列, 图 5~16 是根据上面给出的参数值以及进出口流量和压力的新息序列计算得到的泄漏检测参数.

图 5~7 为根据进口压力的新息序列计算获得的泄漏参数值, 从图中我们可以看出在前 500 个点左右,  $\lambda_{10}, \lambda_{20}$  都在设定的阈值  $-7.6$  附近波动而  $\lambda_{21}$  在 0 值附近波动; 然后  $\lambda_{10}$  开始下降, 而  $\lambda_{20}$  和  $\lambda_{21}$  开始上升直至到达阈值并停留在阈值附近波动, 根据前面介绍的判断准则得出接受假设  $H_2$  的结论即上游压力降低. 图 11~13 为根据进口流量计算的泄漏参数值, 同样我们从图中可以看出在前 500 多个点左右,  $\lambda_{10}, \lambda_{20}$  都在设定的阈值  $-7.6$  附近波动而  $\lambda_{21}$  在 0 值附近波动; 然后  $\lambda_{10}$  开始上升到设定阈值  $-7.6$ , 而  $\lambda_{20}$  和  $\lambda_{21}$  开始下降直至到达阈值并最终在阈值附近波动, 根据前面介绍的判断准则得出接受假设  $H_1$  即上游流量升高的结论. 同理可以根据图 8~10 的泄漏参数值得出下游压力下降的结论, 而根据图 14~16 的泄漏参数值得出下游流量下降的结论. 综合上面分析的结果得出管道发生泄漏, 这一结论与试验管道存在泄漏的事实完全吻合.

## 7 结论

变点检测实现了对变点参数模型的有效检测. 本文的变点检测方法融入了基于多元假设的似然比检测, 实现了在线实时检测. 通过引入新息过程, 克服了 ESPRT 方法要求已

知原假设统计平均值的局限.

从时间序列的角度出发, 利用 BP 神经网络非线性时间序列预测方法建立了长输管道进出口处水力参数的新息模型以及泄漏检测模型, 为新息模型的建立提供了一种新的方法.

通过引入瞬变稳态的思想将复杂的管道泄漏识别问题转化为管道进出口处水力参数的变点检测, 实现了长输管道泄漏的在线实时检测.

### References

- 1 Michele Basseville, Igor V Nikiforov. Detection of Abrupt Changes: Theory and Application. Englewood Cliffs, N.J.: Prentice-Hall, 1993. 1~528
- 2 Abraham Wald. Sequential Analysis. New York: J. Wiley & Sons Inc., 1947. 1~212
- 3 Armitage P. Sequential analysis with more than two alternative hypotheses and its relation to discriminant function analysis. *Journal of the Royal Statistical Society*, 1950, **B**(12): 137~144
- 4 Chien T T, Adams M B. A sequential failure detection technique and its application. *IEEE Transactions on Automatic Control*, 1977, **22**(5): 750~757
- 5 Simon Haykin. Adaptive Filter Theory. Beijing: Publishing House of Electronics Industry, 2003. 1~731
- 6 Wu J P, Duan F Y. Study non-linear time series forecasting method based on neural networks. *Systems Engineering*, 1997, **15**(5): 61~64

**李俊花** 大连理工大学在读博士生, 研究方向为水力学及河流动力学、健康监测.

(**LI Jun-Hua** Ph. D. candidate at Dalian University of Technology. Her research interests include hydraulics and fluvial dynamics, health monitoring.)

**孙昭晨** 大连理工大学教授、博士生导师, 研究方向为波浪及其建筑物的相互作用、波浪多孔介质的相互作用、海洋环境水力学.

(**SUN Zhao-Chen** Professor of Dalian University of Technology. His research interests include interaction of wave and structure, interaction of wave and porous medium, and ocean environment hydrodynamics.)

**崔 莉** 大连理工大学教授, 研究方向为水力学及河流动力学.

(**CUI Li** Professor of Dalian University of Technology. His research interests include hydraulics and fluvial dynamics.)

**贾 旭** 中国海洋石油总公司研究员, 研究方向为海洋工程.

(**JIA Xu** Professor of China National Offshore Oil Corporation. His research interests include ocean engineering.)