SWU Engineering Journal (2018) 13(2), 153.-165
วารสารวิศวกรรมศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ
ปีที่ 13 ฉบับที่ 2 เดือนพฤษภาคม – สิงหาคม พ.ศ.2561

การทบทวนวิธีวินิจฉัยข้อบกพร่องในระบบควบคุมพลวัต

A Review of Fault Diagnosis in Dynamic Control Systems

เจษฎา สายใจ* เฉลิมภัณฑ์ ฟองสมุทร
อาจารย์ ภาควิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ มหาวิทยาลัยบูรพา
169 ถนนลงหาดบางแสน ตำบลแสนสุข อำเภอเมือง จังหวัดชลบุรี 20131
Jedsada Saijai* Chalermpan Fongsamut
Department of Electrical Engineering, Faculty of Engineering, Burapha University
169 Long Had Bangsaen Rd., Saensuk, Mueang Chonburi, Chonburi 20131
*Corresponding author: Email: jedsada@eng.buu.ac.th

บทคัดย่อ

บทความนี้มีจุดมุ่งหมายในการทบทวนวิธีวินิจฉัยข้อบกพร่องในระบบควบคุมพลวัตเพื่อให้เข้าใจแนวคิดหลักการ ทฤษฎีเบื้องต้น ได้แก่ คำจำกัดความ ชนิดของข้อบกพร่อง รวมถึงความก้าวหน้าของวิธีการและเทคนิคที่ใช้ในการวินิจฉัยข้อบกพร่องแบบต่างๆ ได้แก่ การติดตั้งอุปกรณ์ซ้ำซ้อน การใช้แบบจำลองคณิตศาสตร์ และวิธีวิเคราะห์ข้อมูลและสัญญาณ นอกจากนี้ยังนำเสนอแนวทางประยุกต์และพัฒนาวิธีวินิจฉัยที่ควรมีในอนาคต ซึ่งข้อมูลเหล่านี้สามารถใช้เป็นแนวทางศึกษาและปรับปรุงวิธีวินิจฉัยข้อบกพร่องในระบบควบคุมพลวัตให้มีประสิทธิภาพมากยิ่งขึ้น

คำสำคัญ: การวินิจฉัยข้อบกพร่อง ระบบควบคุมพลวัต อุปกรณ์ซ้ำซ้อน แบบจำลองคณิตศาสตร์ ข้อมูลและสัญญาณ

ABSTRACT

This paper aims to review the techniques for fault diagnosis in dynamic control systems. The basic concept including definition and type of fault is firstly addressed. Following by the current fault diagnosis techniques published in the literatures such as hardware redundancy, model-based, data-driven and signal analysis approach. Discussion and future trend of the fault diagnosis are also presented. This information can be used for improving the fault diagnostic in dynamic control system.

Keyword: Fault diagnosis, dynamic control system, hardware redundancy, model-based, data and signal

1. บทนำ

ข้อบกพร่อง (Fault) หมายถึงสิ่งที่ทำให้ระบบหรืออุปกรณ์ทำงานแตกต่างไปจากค่าปกติ ซึ่งหากปล่อยไว้โดยไม่ได้รับการแก้ไขจะส่งผลให้ระบบหรืออุปกรณ์นั้นเกิดความล้มเหลว (Failure) ไม่สามารถใช้งานได้อีกต่อไป [1-2] จากความต้องการระบบพลวัตที่มีประสิทธิภาพสูง ทำให้มีการพัฒนาระบบควบคุมที่มีความซับซ้อน มีอุปกรณ์ทำงานร่วมกันเป็นจำนวนมากและคาดหวังว่าระบบจะทำงานโดยไม่มีข้อบกพร่องใดๆ แต่ในความเป็นจริงแล้วระบบควบคุมพลวัตไม่สามารถหลีกเลี่ยง

ข้อบกพร่องได้ ดังนั้นการวินิจฉัยและตรวจพบข้อบกพร่องตั้งแต่ช่วงแรกจะช่วยเพิ่มความปลอดภัย (Safety) ความน่าเชื่อถือ (Reliability) ของระบบ รวมถึงช่วยในการวางแผนซ่อมบำรุง โดยเฉพาะการซ่อมบำรุงเชิงพยากรณ์ (Predictive maintenance) ได้อย่างมีประสิทธิภาพ ด้วยเหตุผลดังกล่าวทำให้ระบบวินิจฉัยข้อบกพร่องในระบบควบคุมพลวัตได้รับความสนใจและพัฒนาในช่วงเวลาหลายปีที่ผ่านมา ซึ่งสังเกตได้จากจำนวนงานวิจัยและการใช้งานในภาคอุตสาหกรรมที่เพิ่มขึ้นอย่างต่อเนื่อง [4-7]

บทความนี้จึงมุ่งให้ความรู้เกี่ยวกับวิธีวินิจฉัยข้อบกพร่องต่างๆ ในระบบควบคุมพลวัต โดยนำเสนอเป็น 5 หัวข้อดังนี้ คือ ข้อบกพร่องในระบบควบคุมพลวัต โครงสร้างของระบบวินิจฉัยข้อบกพร่อง เทคนิคการวินิจฉัยข้อบกพร่อง และบทสรุป

2. ข้อบกพร่องในระบบควบคุมพลวัต

โดยทั่วไประบบควบคุมพลวัตประกอบด้วยส่วนต่างๆ คือ อุปกรณ์ทำงาน (Actuator) ตัวรับรู้ (Sensor) และระบบพลวัต (Process) ดังนั้นสามารถจำแนกข้อบกพร่องตามตำแหน่งที่เกิดได้ 3 ส่วน คือ อุปกรณ์ทำงาน (Actuator fault) ตัวรับรู้ (Sensor fault) และระบบพลวัต (Parameter or Structure fault) [1-3] ดังแสดงในรูปที่ 1

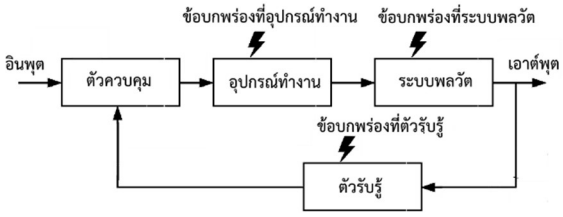

รูปที่ 1 ข้อบกพร่องในระบบควบคุมพลวัต

ถ้าพิจาณาผลต่อการทำงานของระบบพลวัตจะจำแนกข้อบกพร่องได้ 2 รูปแบบ แบบแรกเรียกว่าข้อบกพร่องเสริมค่า (Additive fault) ซึ่งเกิดที่อุปกรณ์ทำงานและตัวรับรู้ มีผลให้อุปกรณ์ทำงานหรือตัวรับรู้ทำงานมากขึ้นหรือน้อยลงกว่าปกติ (Offset, Drift) แบบที่สองเรียกว่าข้อบกพร่องคูณค่า (Multiplicative fault) ซึ่งเกิดที่พารามิเตอร์ของระบบพลวัต มีผลให้โครงสร้างของระบบเปลี่ยนไปจากปกติ [1-3]

ข้อบกพร่องในระบบพลวัตสามารถแทนด้วยปริภูมิสถานะ (State space) [1] ดังสมการ

$$\dot{x} = (A + \Delta A_F)x + (B + \Delta B_F)(u + f_A) \quad (1)$$

$$y = (C + \Delta C_F)x + (D + \Delta D_F)(u + f_A) + f_S \quad (2)$$

โดยที่ f_A, f_S คือข้อบกพร่องแบบเสริมค่าที่อุปกรณ์ทำงานและตัวรับรู้ $\Delta A_F, \Delta B_F, \Delta C_F, \Delta D_F$ คือข้อบกพร่องแบบคูณค่าที่พารามิเตอร์ของระบบพลวัต

นอกจากนี้ยังสามารถแยกข้อบกพร่องในโดเมนเวลาได้ 3 รูปแบบ คือ แบบทันทีทันใด (Abrupt fault หรือ Hard fault) แบบค่อยเป็นค่อยไป (Incipient fault หรือ Soft fault) และแบบไม่สม่ำเสมอ (Intermittent fault) [1-3] ดังแสดงในรูปที่ 2

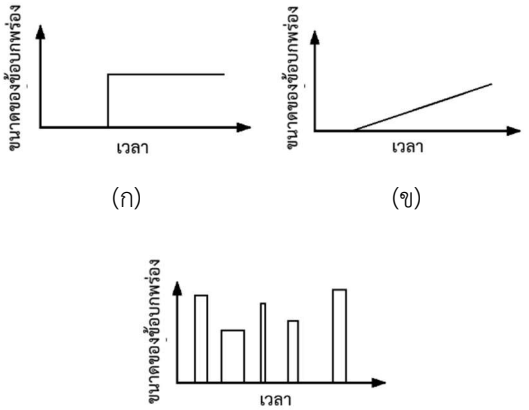

รูปที่ 2 แสดงข้อบกพร่องต่างๆในโดเมนเวลา (ก) ข้อบกพร่องแบบทันทีทัน (ข) ข้อบกพร่องแบบค่อยเป็นค่อยไป (ค) ข้อบกพร่องแบบไม่สม่ำเสมอ

3. โครงสร้างของระบบวินิจฉัยข้อบกพร่อง

ระบบวินิจฉัยข้อบกพร่องในระบบควบคุมพลวัตทำงานตามลำดับขั้นตอนดังนี้คือ การตรวจจับ (Fault Detection) ทำหน้าที่ตัดสินว่ามีข้อบกพร่องเกิดขึ้นใน

ระบบควบคุมพลวัตหรือไม่ ซึ่งเป็นขั้นตอนที่สำคัญที่สุดในระบบวินิจฉัยข้อบกพร่อง [1-2] การแยกแยะ (Fault isolation) ทำหน้าที่ระบุตำแหน่งที่เกิดข้อบกพร่อง และการอธิบายคุณลักษณะ (Fault identification) ทำหน้าที่ให้รายละเอียดเกี่ยวกับข้อบกพร่อง เช่น ขนาด สาเหตุ เป็นต้น ซึ่งขั้นตอนนี้เป็นขั้นตอนเสริมที่อาจจะมีหรือไม่มีในระบบก็ได้ ดังนั้นการวินิจฉัยข้อบกพร่องในระบบควบคุมพลวัตหมายถึงการตรวจจับและการระบุตำแหน่งข้อบกพร่อง (Fault detection and isolation: FDI)

รูปที่ 3 ลำดับการทำงานของระบบวินิจฉัยข้อบกพร่องในระบบควบคุมพลวัต

4. เทคนิคการวินิจฉัยข้อบกพร่อง

การวินิจฉัยข้อบกพร่องมีด้วยกันหลายวิธี ซึ่งหัวข้อนี้จะเสนอเทคนิคที่พบเผยแพร่ในบทความวิชาการรวมถึงการใช้งานจริงในภาคอุตสาหกรรม ดังนี้

4.1 การติดตั้งอุปกรณ์ซ้ำซ้อน (Hardware redundancy)

นิยมใช้วินิจฉัยข้อบกพร่องของอุปกรณ์ทำงานและตัวรับรู้โดยมีหลักการทำงานดังรูปที่ 4

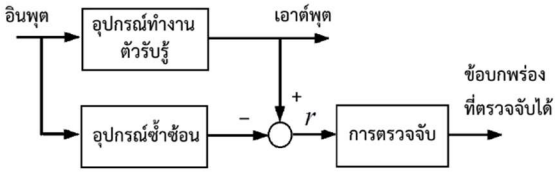

รูปที่ 4 การวินิจฉัยข้อบกพร่องด้วยการติดตั้งอุปกรณ์ซ้ำซ้อน

จากรูปที่ 4 อุปกรณ์ซ้ำซ้อนจะทำงานพร้อมกับอุปกรณ์จริง และตรวจจับข้อบกพร่องจากผลต่างระหว่างอุปกรณ์จริงและอุปกรณ์ซ้ำซ้อนตามเงื่อนไข

$$\begin{aligned} |r| > 0: &\quad \text{fault} \\ |r| = 0: &\quad \text{fault-free} \end{aligned} \tag{3}$$

โดยที่ r คือผลต่างระหว่างอุปกรณ์จริงกับอุปกรณ์ซ้ำซ้อน เรียกว่าตัวแปรเศษเหลือ (Residual)

การวินิจฉัยข้อบกพร่องด้วยวิธีนี้สามารถตรวจจับและระบุตำแหน่งที่เกิดข้อบกพร่องได้ในเวลาเดียวกัน นอกจากนี้ยังมีความน่าเชื่อถือสูงเหมาะสำหรับอุปกรณ์ที่มีความสำคัญ (Major component) เช่น อุปกรณ์ในเครื่องบิน เตาปฏิกรณ์นิวเคลียร์ เป็นต้น แต่มีข้อจำกัดในเรื่องพื้นที่และต้นทุนในการติดตั้ง

4.2 การใช้แบบจำลองคณิตศาสตร์ (Model-based fault diagnosis)

การวินิจฉัยวิธีนี้ใช้แบบจำลองคณิตศาสตร์คำนวณตัวแปรเอาต์พุตแล้วเปรียบเทียบกับเอาต์พุตจริงของระบบ ซึ่งความแตกต่างคือตัวแปรเศษเหลือ จากนั้นใช้เงื่อนไขตามสมการที่ (3) ตัดสินว่าพบข้อบกพร่องในระบบหรือไม่ โดยโครงสร้างของการวินิจฉัยด้วยแบบจำลองคณิตศาสตร์แสดงดังรูปที่ 5

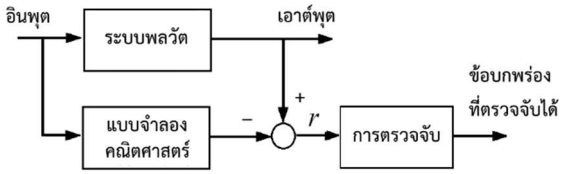

รูปที่ 5 การวินิจฉัยข้อบกพร่องด้วยแบบจำลองคณิตศาสตร์

วิธีสร้างตัวแปรเศษเหลือมีหลายวิธี เช่น วิธีอิงตัวสังเกต (Observer-based) ซึ่งทำงานแบบวงปิด (Closed-loop residual generator) สำหรับแบบจำลองชนิดตายตัว (Deterministic model) นิยมใช้ตัวสังเกตตัวแปรสถานะ (State observer) ตัวสังเกตอินพุตที่ไม่ทราบค่า (Unknown input observer) เป็นต้น [8-10]

ตัวอย่างระบบที่มีข้อบกพร่องตัวรับรู้ในรูปปริภูมิสถานะแบบเวลาไม่ต่อเนื่องดังสมการ

$$x(k) = Ax(k-1) + Bu(k-1) \tag{4}$$

$$y(k) = Cx(k) + D_f f_S(k) \tag{5}$$

เมื่อใช้ตัวสังเกตในการสร้างตัวแปรเศษเหลือจะได้พลวัตของตัวแปรเศษเหลือดังสมการ

$$r(k) = V(y(k) - \hat{y}(k)) = VCe(k) + VD_f f_S(k) \quad (6)$$

$$e(k) = (A - LC)e(k-1) \quad (7)$$

โดยที่ $\hat{y}(k) = C\hat{x}(k)$ คือค่าประมาณตัวแปรเอาต์พุต $e(k) = x(k) - \hat{x}(k)$ คือความผิดพลาดในการประมาณค่าตัวแปรสถานะ (State estimation error) L คือ อัตราขยายตัวสังเกต (Observer gain) และ V คือ น้ำหนักตัวแปรเศษเหลือ (Residual weighting)

จากสมการที่ (6)-(7) ตัวแปรเศษเหลือจะเปลี่ยนตาม f_S เมื่อเลือก L, V ที่ทำให้ $\lim_{k\to\infty} e(k) = 0$

สำหรับแบบจำลองชนิดสุ่ม (Stochastic model) นิยมใช้ตัวกรองคาลมาน (Kalman filter) สร้างตัวแปรเศษเหลือ เมื่อระบบมีสัญญาณรบกวนภายนอกแบบสุ่มและกระจายตัวแบบปกติ (Normal distribution) หรือตัวกรองคาลมานแบบขยาย (Extended Kalmand filter) สำหรับแบบจำลองชนิดสุ่มไม่เชิงเส้น (Nonlinear stochastic model) [11-13]

การสร้างตัวแปรเศษเหลือแบบวงเปิด (Open loop residual generation) ทำได้ด้วยวิธีปริภูมิพาริตี้ (Parity space) [14-16] โดยเลือกอินพุตและเอาต์พุตจำนวน N ค่า สำหรับระบบเชิงเส้นในสมการที่ (4)-(5) จะได้ข้อมูลอินพุตและเอาต์พุตดังสมการ

$$Y_N(k) = H_{o,N}x(k-N) + H_{u,N}U_N(k) + H_{f,N}F_N(k) \quad (8)$$

โดยที่

$$Y_N(k) = \begin{bmatrix} y(k-N) \\ y(k-N+1) \\ \vdots \\ y(k) \end{bmatrix}, U_N(k) = \begin{bmatrix} u(k-N) \\ u(k-N+1) \\ \vdots \\ u(k) \end{bmatrix},$$

$$F_N(k) = \begin{bmatrix} f_S(k-N) \\ f_S(k-N+1) \\ \vdots \\ f_S(k) \end{bmatrix}, H_{o,N} = \begin{bmatrix} C \\ CA \\ \vdots \\ CA^N \end{bmatrix},$$

$$H_{u,N}(k) = \begin{bmatrix} 0 & 0 & \cdots & 0 \\ CB & 0 & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ CA^{N-1}B & \cdots & CB & 0 \end{bmatrix},$$

$$H_{f,N}(k) = \mathrm{diag}(D_f) = \begin{bmatrix} D_f & 0 & \cdots & 0 \\ 0 & D_f & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & D_f \end{bmatrix}$$

จะได้ตัวแปรเศษเหลือจากสมการ

$$\begin{aligned} r_N(k) &= V_N[Y_N(k) - H_{u,N}U_N(k)] \\ &= V_N[Q_N(k)x(k-N) + H_{f,N}F_N(k)] \end{aligned} \quad (9)$$

ดังนั้นต้องออกแบบค่าน้ำหนักตัวแปรเศษเหลือ V_N ที่ทำให้พจน์ $V_N Q_N(k) = 0$ เพื่อให้ตัวแปรเศษเหลือเปลี่ยนค่าตามข้อบกพร่องเท่านั้น

การประมาณค่าพารามิเตอร์ (Parameter estimation) เป็นอีกวิธีหนึ่งที่เหมาะสำหรับข้อบกพร่องที่เกิดขึ้นภายในกระบวนการ โดยตัวแปรเศษเหลือคือผลต่างของพารามิเตอร์จากแบบจำลองคณิตศาสตร์กับค่าประมาณจากสัญญาณอินพุตและเอาต์พุต [17-19] สำหรับระบบเชิงเส้นในสมการที่ (4)-(5) ที่มีข้อบกพร่องของพารามิเตอร์แสดงด้วยสมการ

$$x_f(k) = A_f x_f(k-1) + B_f u_f(k-1) \quad (10)$$

$$y_f(k) = C_f x_f(k) \quad (11)$$

จะได้เวคเตอร์ค่าตัวแปรเอาต์พุตจำนวน N ดังสมการ

$$Y_f(k) = \Psi_f(k)\hat{\Theta}_f(k) + E(k) \quad (12)$$

โดยที่

$$Y_f(k)=\begin{bmatrix} y_f^T(k-N+1) \\ y_f^T(k-N+2) \\ \vdots \\ y_f^T(k) \end{bmatrix}, \quad \hat{\Theta}_f(k)=\begin{bmatrix} \hat{A}_f^T\hat{C}_f^T \\ \hat{B}_f^T\hat{C}_f^T \end{bmatrix}$$

$$\Psi_f^T(k)=\begin{bmatrix} x_f(k-N) & x_f(k-N+1) & \cdots & x_f(k-1) \\ u_f(k-N) & u_f(k-N+1) & \cdots & u_f(k-1) \end{bmatrix}$$

และ $E(k)$ คือความผิดพลาดในการประมาณค่า

เมื่อ $E(k)$ ลู่เข้าสู่ศูนย์จะคำนวณค่าประมาณของพารามิเตอร์ได้จากความสัมพันธ์

$$\hat{\Theta}_f(k)=\Psi_f^{-1}(k)Y_f(k) \qquad (13)$$

และได้ตัวแปรเศษเหลือคือ

$$r(k)=\Theta-\hat{\Theta}_f(k) \qquad (14)$$

โดยที่ $\Theta=\begin{bmatrix} A^TC^T \\ B^TC^T \end{bmatrix}$ คือค่าพารามิเตอร์ปกติของระบบ

ตัวอย่างการวินิจฉัยข้อบกพร่องด้วยการประมาณค่าตัวแปรในเครื่องจักรพันวัสดุ (Winding machine) แสดงในรูปที่ 6

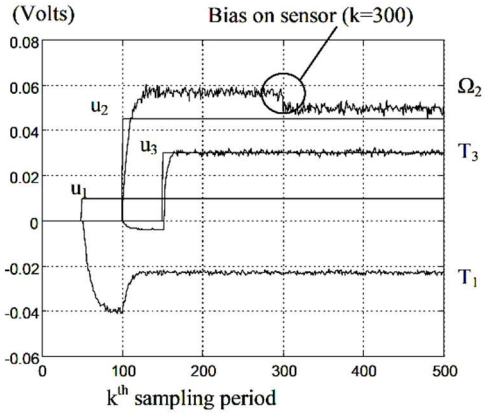

(ก)

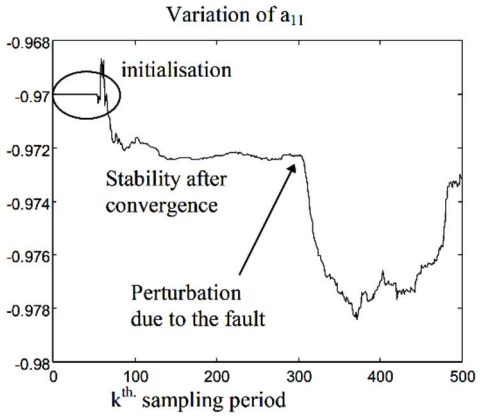

(ข)

รูปที่ 6 ตัวอย่างการวินิจฉัยข้อบกพร่องด้วยการประมาณค่าพารามิเตอร์ [4]

จากรูปที่ 6(ก) และ 6(ข) แสดงถึงการเปลี่ยนค่าของพารามิเตอร์ a_{11} เมื่อเกิดข้อบกพร่องในตัวรับรู้ Ω_2 ที่ลำดับ $\mathrm{k}=300$ ของข้อมูลสุ่ม

การวินิจฉัยข้อบกพร่องด้วยแบบจำลองคณิตศาสตร์สามารถลดพื้นที่และต้นทุนในการติดตั้งอุปกรณ์ซ้ำซ้อนเนื่องจากกระบวนการทั้งหมดทำงานด้วยโปรแกรมคอมพิวเตอร์และยังสามารถนำไปใช้กับระบบที่มีจุดทำงานหลายค่า ทำให้ได้รับความสนใจในเชิงวิชาการและภาคอุตสาหกรรมเป็นอย่างมาก แต่ปัญหาสำคัญของวิธีนี้คือความแม่นยำของแบบจำลองคณิตศาสตร์ เนื่องจากแบบจำลองคณิตศาสตร์ที่อธิบายการทำงานของระบบได้แม่นยำไม่มีอยู่จริงในทางปฏิบัติ ดังนั้นการตัดสินด้วยสมการที่ (3) จึงไม่สามารถใช้ได้และจำเป็นต้องกำหนดค่าขีดเริ่ม (Threshold) ที่เหมาะสมเพื่อตัดสินว่าเกิดข้อบกพร่องขึ้นหรือไม่ [1] และได้เงื่อนไขในการตัดสินใจคือ

$$\begin{aligned} |r| > J_{th}: &\quad \text{fault} \\ |r| \le J_{th}: &\quad \text{fault-free} \end{aligned} \qquad (15)$$

โดยที่ J_{th} คือค่าขีดเริ่ม

การกำหนดค่าขีดเริ่มทำได้ 2 แบบ คือ แบบคงที่ (Fixed threshold) และแบบเปลี่ยนค่า (Adaptive threshold) โดยประยุกต์ใช้ทฤษฎีต่างๆ เช่นทฤษฎีการหาค่าที่เหมาะสม (Optimization) ทฤษฎีควบคุมแบบคงทนและปรับตัว (Robust and adaptive control) เป็นต้น [20-23] ตัวอย่างค่าขีดเริ่มแบบคงที่และแบบเปลี่ยนค่าเพื่อวินิจฉัยข้อบกพร่องในแบบจำลองมาร์คอฟฟ์ (Markov system) แสดงในรูปที่ 7

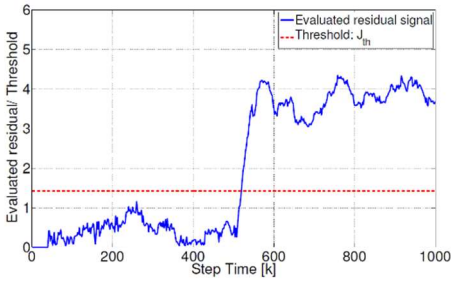

(ก)

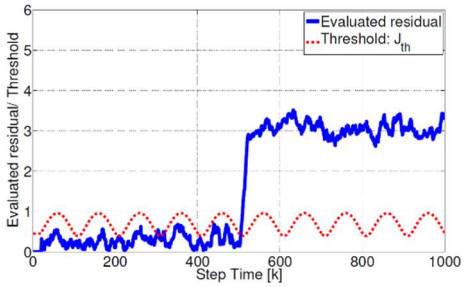

(ข)

รูปที่ 7 ตัวอย่างเปรียบเทียบการตั้งค่าขีดเริ่ม (ก) แบบคงที่ (ข) แบบเปลี่ยนค่า [23]

จากรูปที่ 7 พบว่าเมื่อเกิดข้อบกพร่องที่เวลา $\mathrm{k}=500$ ค่าขีดเริ่มแบบเปลี่ยนค่าจะทำให้ตรวจพบข้อบกพร่องได้เร็วกว่าแบบค่าขีดเริ่มคงที่

นอกจากนี้ยังสามารถปรับปรุงตัวแปรเศษเหลือให้มีความคงทน (Robustness) ต่อความไม่แม่นยำของแบบจำลองหรือสัญญาณรวบกวน แต่ให้มีความไว (Sensitivity) ต่อข้อบกพร่อง [24-26] เช่น การใช้ดัชนี H_∞ / H_- เพื่อหาค่าที่เหมาะสม ตัวอย่างระบบเชิงเส้นซึ่งแสดงด้วยสมการ

$$\dot{x} = (A+\Delta A)x + (B+\Delta B)u + B_f f + B_d d \quad (16)$$

$$y = Cx + D_f f + D_d d \quad (17)$$

โดยที่ $\Delta A, \Delta B$ คือความไม่แม่นยำของแบบจำลอง d คือสัญญาณรบกวน และ f คือข้อบกพร่อง

ขั้นตอนเริ่มจากการออกแบบตัวแปรเศษเหลือด้วยตัวสังเกตดังสมการ

$$\dot{\hat{x}} = (A-LC)\hat{x} + Bu + Ly \quad (18)$$

$$r = V(y - C\hat{x}) \quad (19)$$

จะได้พลวัตของตัวแปรเศษเหลือดังสมการ

$$\begin{aligned}\dot{e} &= (A-LC)e + \Delta Ax + \Delta Bu \\ &\quad + (B_f - LD_f)f + (B_d - LD_d)d\end{aligned} \quad (20)$$

$$r = VCe + VD_f f + VD_d d \quad (21)$$

จากนั้นออกแบบอัตราขยาย L และ V เพื่อหาค่าที่เหมาะสมตามเงื่อนไข

$$\min_{L,V} \frac{\|G_{rd}(s)\|_\infty}{\|G_{rf}(s)\|_-}$$

โดยที่ $G_{rd}(s)$ คือฟังก์ชันถ่ายโอนของตัวแปรเศษเหลือกับสัญญาณรบกวน $G_{rf}(s)$ คือฟังก์ชันถ่ายโอนของตัวแปรเศษเหลือกับข้อบกพร่อง

การใช้แบบจำลองหลายชุด (Multiple model) เป็นอีกแนวทางหนึ่งในการแก้ปัญหาความไม่แม่นยำของแบบจำลองคณิตศาสตร์และการกำหนดค่าขีดเริ่ม [27-29] แบบจำลองนี้ประกอบด้วยแบบจำลองย่อยซึ่งแทนการทำงานแบบปกติและการทำงานเมื่อเกิดข้อบกพร่องต่างๆ โดยใช้ตัวกรองคาลมาลเพื่อประมาณค่าตัวแปรสถานะและความแปรปรวนร่วม (Covariance) แล้วใช้ปรับปรุงความ

น่าจะเป็นของแบบจำลองย่อย (Mode probability) โดยแบบจำลองย่อยที่มีค่าความน่าจะเป็นสูงที่สุดจะแทนการทำงานของระบบในขณะนั้น เรียกว่าการวินิจฉัยด้วยแบบจำลองหลายชุด (Interacting multiple-model fault detection and diagnosis : IMM FDD)

พิจารณาระบบเชิงเส้นแบบสุ่มซึ่งเป็นฟังก์ชันของแบบจำลองย่อย (Mode) $m(k)$ ดังสมการ

$$x(k+1) = A(m(k+1))x(k) + B(m(k+1))u(k) + T(m(k+1))\xi(k) \quad (22)$$

$$y(k) = C(m(k))x(k) + \eta(k) \quad (23)$$

โดยที่ $\xi(k), \eta(k)$ คือสัญญาณรวบกวน

การเปลี่ยนแบบจำลองย่อยจำนวน N ชุด กำหนดโดยความน่าจะเป็นของการเปลี่ยนแบบจำลอง (Transition probability)

$$P\{m_j(k+1) \mid m_i(k)\} = \pi_{ij}(k)\ ;\ \forall m_i, m_j \in S \quad (24)$$

$$\sum_{j=1}^{N} \pi_{ij}(k) = 1\ ;\quad i = 1,2...,N \quad (25)$$

และความน่าจะเป็นที่แบบจำลองย่อย j จะทำงานที่เวลา $k+1$ แทนด้วย

$$P\{m_j(k+1) \mid z(k+1)\} = \mu_j(k+1) \quad (26)$$

โดยที่ $S = \{m_1, m_2, ..., m_N\}$ คือเซทแบบจำลองย่อย และ $P\{\cdot\}$ คือความน่าจะเป็นของแบบจำลองย่อย

วิธี IMM FDD ประกอบด้วย 4 ขั้นตอน ขั้นตอนแรกคือการกำหนดค่าเริ่มต้นของตัวแปรสถานะ ความน่าจะเป็นของแบบจำลองย่อย (Re-initialization) และความแปรปรวนร่วม ขั้นตอนที่ 2 คือการประมาณค่าตัวแปรสถานะและความแปรปรวนร่วมจากค่าเริ่มต้นด้วยตัวกรองคาลมาล (Filtering) ขั้นตอนที่ 3 คือการปรับปรุงค่าตัวแปรสถานะ ความแปรปรวนร่วม และความน่าจะเป็นของแบบจำลองย่อยโดยใช้ค่าเอาต์พุตที่วัดได้ (Updating) และขั้นตอนสุดท้ายคือการตัดสินด้วยการทดสอบสมมุติฐาน (Hypothesis testing) ของค่าความน่าจะเป็นของแบบจำลองย่อยตามเงื่อนไข

$$\mu_j(k+1) = \begin{cases} > \mu_T : H_j : \text{fault } j \text{ occurred} \\ < \mu_T : H_0 : \text{fault free} \end{cases} \quad (27)$$

ตัวอย่างการวินิจฉัยข้อบกพร่องด้วยวิธี IMM FDD ในอุปกรณ์สั่งการสนามแม่เหล็กซ้ำซ้อน (High redundancy actuation) แสดงดังรูปที่ 8

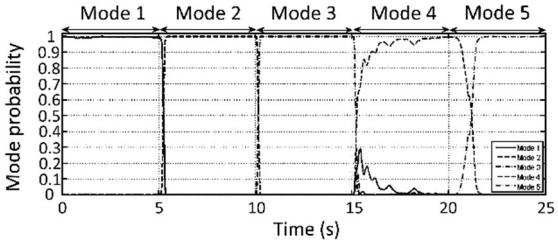

รูปที่ 8 ตัวอย่างการวินิจฉัยข้อบกพร่องแบบ IMM FDD เมื่อ Mode 1 แทนการทำงานปกติ Mode 2 แทนสภาวะความร้อนเกิน 20% Mode 3 แทนสภาวะความร้อนเกิน 50% Mode 4 แทนสภาวะที่อุปกรณ์สั่งการเสียหาย 1 ชุด และ Mode 5 แทนสภาวะที่อุปกรณ์สั่งการเสียหาย 2 ชุด [27]

จากรูปที่ 8 เมื่อความน่าจะเป็นของแบบจำลองย่อย (Mode) มีค่าเท่ากับ 1 จะเกิดข้อบกพร่องตามแบบจำลองย่อยนั้น เช่น ระหว่างเวลา 5 - 10 วินาที ความน่าจะเป็นของแบบจำลองย่อย Mode 2 มีค่าเท่ากับ 1 แสดงว่าเกิดความร้อนเกิน 20%

4.3 การวิเคราะห์ข้อมูลและสัญญาณ (Data driven and signal analysis)

สำหรับระบบควบคุมพลวัตที่มีขนาดใหญ่และซับซ้อนนั้นไม่สามารถหาแบบจำลองคณิตศาสตร์ที่มีความ

แม่นยำเพียงพอเพื่อใช้วินิจฉัยข้อบกพร่องได้ เช่น กระบวนการทางเคมีและปิโตรเคมี กระบวนการกลั่นน้ำมัน ดังนั้นจึงนิยมใช้ข้อมูลที่วัดได้มาวิเคราะห์พารามิเตอร์ในโดเมนเวลา (Time domain analysis) หรือโดเมนความถี่ (Frequency domain analysis)

ในโดเมนเวลาทำการวิเคราะห์จากสัญญาณโดยตรง เช่น ขนาด เฟส ตัวประกอบยอดคลื่น (Crest factor) เป็นต้น หรือใช้วิธีวิเคราะห์และทดสอบทางสถิติ เช่น ค่าเฉลี่ย (Mean) ค่าเบี่ยงแบนมาตรฐาน (Standard deviation) ค่าเฉลี่ยกำลังสอง (Root mean square: RMS) ค่าความโด่ง (Kurtosis) ค่าความเบ้ (Skewness) การทดสอบยอดสะสม (Cumulative sum test : CUMSUM) อัตราส่วนความน่าจะเป็นทั่วไป (Generalized likelihood ratio: GLR) Hotelling's T^2 Q-test และ Square prediction error (SPE) เป็นต้น [30-32] ซึ่งวิธีนี้เหมาะสำหรับการวินิจฉัยที่เวลาคงตัว

ตัวอย่างการวินิจฉัยข้อบกพร่องในหอกลั่น (Distillation unit) ด้วยวิธีทดสอบค่าอัตราความน่าจะเป็นทั่วไป [8] แสดงดังรูปที่ 9

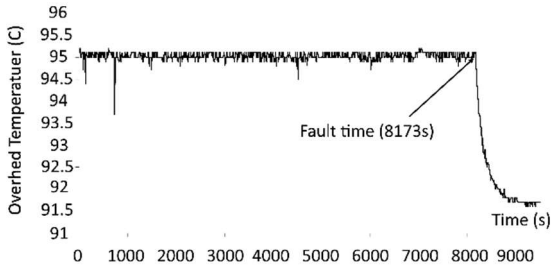

(ก)

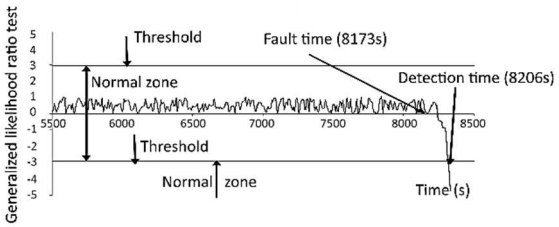

(ข)

รูปที่ 9 ตัวอย่างการวินิจฉัยข้อบกพร่องด้วยการทดสอบอัตราความน่าจะเป็นทั่วไป [6]

จากรูปที่ 9(ก) เกิดข้อบกพร่องที่เวลา 8173 วินาที และสามารถตรวจจับได้ที่เวลา 8206 วินาที ดังรูปที่ 9(ข) โดยสังเกตจากอัตราความน่าจะเป็นทั่วไปที่เปลี่ยนค่าออกจากบริเวณปกติ

สำหรับการวิเคราะห์ในโดเมนความถี่ใช้เทคนิคการแปลงสัญญาณจากโดเมนเวลา เช่น การแปลงฟูรีเย (Fourier transformation การประมาณค่าสเปคตรัมด้วยวิธีเวลช์ (Welch's periodogram) การประมาณค่าสเปคตรัมด้วยวิธีเบอร์ก (Burg's periodogram) เป็นต้น แล้ววิเคราะห์สเปคตรัมความถี่ที่ได้ [33-35] ตัวอย่างการวิเคราะห์ด้วยการประมาณค่าสเปคตรัมกำลังไฟฟ้าวิธีเวลช์และเบอร์กเพื่อวินิจฉัยข้อบกพร่องในตัวนำโรเตอร์ของมอเตอร์ไฟฟ้าเหนี่ยวนำที่ภาระโหลด 70% แสดงดังรูปที่ 10

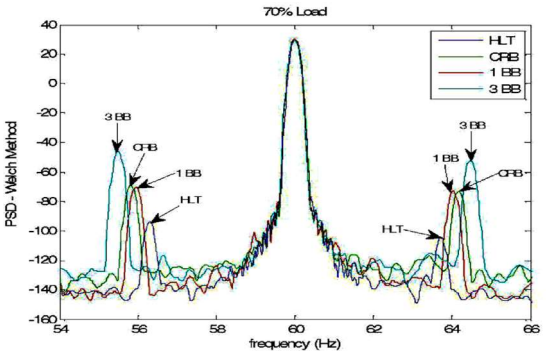

(ก)

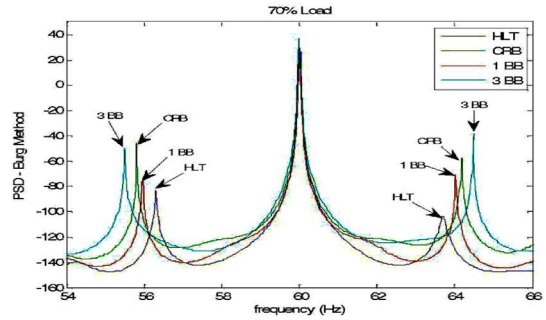

(ข)

รูปที่ 10 ตัวอย่างการวินิจฉัยข้อบกพร่องด้วยการประมาณค่าสเปคตรัม (ก) วิธีเวลช์ (ข) วิธีเบอร์ก
เมื่อ HLT คือมอเตอร์ปกติ CRB คือแท่งตัวนำโรเตอร์ร้าว 1BB และ 3BB คือแท่งตัวนำโรเตอร์หักจำนวน 1 และ 3 แท่ง ตามลำดับ [35]

จากรูปที่ 10(ก) พบว่าการประมาณค่าสเปคตรัมด้วยวิธีเวลช์จะตรวจพบความถี่ข้างเคียงความถี่หลักมูลโดยค่าความห่างและขนาดเพิ่มขึ้นตามความรุนแรงของข้อบกพร่อง คือ มอเตอร์ปกติ แท่งตัวนำโรเตอร์หัก 1 แท่ง แท่งตัวนำโรเตอร์ร้าว และแท่งตัวนำโรเตอร์หัก 3 แท่ง ตามลำดับ แต่การแยกแยะข้อบกพร่องจากแท่งตัวนำหัก 1 แท่ง และแท่งตัวนำร้าวยังไม่ค่อยชัดเจน ในขณะที่รูป 10(ข) แสดงผลจากการประมาณค่าสเปคตรัมด้วยวิธีเบอร์ก พบว่าสามารถแยกแยะข้อบกพร่องจากแท่งตัวนำหัก 1 แท่ง และแท่งตัวนำร้าวได้ดีกว่า

นอกจากนี้ยังสามารถวินิจฉัยข้อบกพร่องโดยการประยุกต์ใช้ทฤษฎีการรู้จำ (Machine Learning) เช่น โครงข่ายประสาทเทียม (Artificial Neural Network : ANN) กระบวนการทางพันธุกรรม (Genetic Algorithm : GA) เป็นต้น [36-38] สำหรับวิธีโครงข่ายประสาทเทียมมีขั้นตอนทั่วไปคือ การเลือกและเก็บค่าตัวแปรอินพุตและเอาต์พุตโดยการป้อนข้อมูลพฤติกรรมของระบบทั้งสภาวะปกติและสภาวะบกพร่องต่างๆ (Data generation and collection) การกำหนดรูปแบบของข้อมูลเพื่อการรู้จำและแยกแยะข้อบกพร่องชนิดต่างๆ (Pattern recognition and classification) วิธีวินิจฉัยนี้จะสามารถตรวจจับและแยกชนิดของข้อบกพร่องได้แต่ต้องใช้ข้อมูลในการเรียนรู้เป็นจำนวนมากและต้องครอบคลุมข้อบกพร่องทั้งหมด ซึ่งข้อมูลข้อบกพร่องบางรูปแบบอาจไม่สามารถวัดได้จริงจากระบบและจำเป็นต้องใช้โปรแกรมจำลองการทำงาน

มิติของข้อมูลเป็นอีกตัวแปรหนึ่งที่ส่งผลต่อการวินิจฉัยข้อบกพร่องด้วยข้อมูล ซึ่งจำนวนมิติที่มากทำให้ใช้เวลามากและเกิดความความซ้ำซ้อนของข้อมูล ดังนั้นก่อนนำข้อมูลไปวิเคราะห์จึงนิยมลดมิติของข้อมูลให้เหลือเท่าที่จำเป็นสำหรับการวินิจฉัยข้อบกพร่อง (Dimensionality reduction) ซึ่งวิธีลดมิติของข้อมูลประกอบด้วยขั้นตอนการเลือกและการดึงลักษณะเฉพาะจากข้อมูลที่วัดได้ (Feature selection and extraction) วิธีที่นิยมใช้ได้แก่ การวิเคราะห์องค์ประกอบหลัก (Principle component analysis: PCA) วิเคราะห์การจำแนกกลุ่มเชิงเส้น (Linear discriminant analysis: LDA) เป็นต้น [39-41] โดยวิธี PCA จะใช้วิธีฉายข้อมูล (Projection) ไปยังปริภูมิย่อย (Subspace) ที่มีมิติต่ำกว่า

พิจารณาข้อมูลของระบบควบคุมพลวัตในสภาวะปกติ $X \in R^{n\times m}$ ซึ่งเก็บจากตัวแปร m ตัว จำนวน n ชุด ขั้นตอนการวิเคราะห์เริ่มจากการคำนวณเมตริกซ์ความแปรปรวนร่วม (Covariance matrix) แล้วทำการกระจายค่าชิงกูล่าร์ (Singular value decomposition: SVD) เพื่อหาค่าลักษณะเฉพาะ (Eigenvalue) ของแต่ละมิติ ดังสมการ

$$\Sigma = \frac{1}{n-1} X^T X = V \Lambda V^T \tag{28}$$

โดยที่ $\Lambda = \mathrm{diag}(\lambda_1, \lambda_2, ..., \lambda_m)$ คือเมตริกซ์ทแยงมุม (Diagonal matrix) ซึ่งมีค่าลักษณะเฉพาะเรียงจากค่ามากไปค่าน้อย นั่นคือ $\lambda_1 \geq \lambda_2 \geq ... \geq \lambda_m \geq 0$ และ $V \in R^{m\times m}$ คือเมตริกซ์ที่ประกอบด้วยเวคเตอร์ลักษณะเฉพาะ (Eigenvector matrix) ที่สอดคล้องกับค่าลักษณะเฉพาะใน Λ

จากนั้นเลือกเวคเตอร์ลักษณะเฉพาะ a ค่าจากเมตริกซ์ V เพื่อสร้างเป็นองค์ประกอบหลักในรูปของเมตริกซ์ถ่ายโอน (Transformation matrix) $P \in R^{m\times a}$ ดังนั้นข้อมูล X สามารถแสดงได้ดังสมการ

$$X = TP^T + E \tag{29}$$

โดยที่ $T \in R^{n\times a}$ คือเมตริกซ์ข้อมูลที่มีมิติเท่ากับองค์ประกอบหลัก a ค่า $P \in R^{m\times a}$ คือเมตริกซ์ถ่ายโอน $E = X - \hat{X}$ คือเมตริกซ์เศษเหลือ เมื่อ $\hat{X}$ คือค่าประมาณของข้อมูล X

ทำการกำหนดค่าขีดเริ่มโดยใช้วิธีทดสอบทางสถิติต่างๆ ตามระดับนัยสำคัญ (Significant level: α) จากนั้นใช้การทดสอบการสถิติกับข้อมูลจริงแล้วเปรียบเทียบกับค่าขีดเริ่มที่กำหนดไว้ เช่นการทดสอบ Hotelling's T^2 ซึ่งแสดงดังสมการ

$$T^2 = xP(\Sigma_a)^{-2}P \qquad (30)$$

โดยที่ $x \in R^{1\times m}$ คือเวคเตอร์ข้อมูลจริง $\Sigma_a \in R^{a\times a}$ คือเมตริกซ์ทแยงมุมตามองค์ประกอบหลัก a ค่า

ตัวอย่างการวิเคราะห์หาข้อบกพร่องของระบบกำจัดน้ำเสียด้วยวิธีวิเคราะห์องค์ประกอบหลัก แสดงดังรูปที่ 11

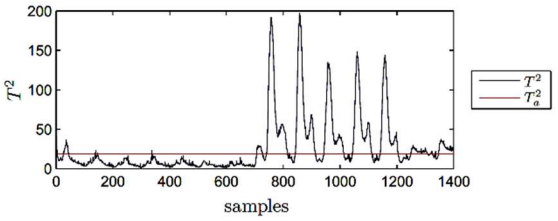

(ก)

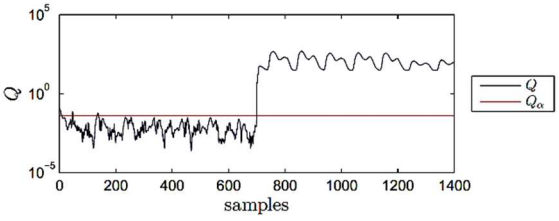

(ข)

รูปที่ 11 การตรวจจับข้อบกพร่องด้วยการวิเคราะห์ตัวประกอบหลัก (ก) T^2-test (ข) Q-test [41]

จากรูปที่ 11 แสดงให้เห็นว่าการทดสอบแบบ T^2-test และ Q-test จะเพิ่มค่ามากขึ้นจนเลยจุดขีดเริ่มเมื่อเกิดข้อบกพร่องในระบบที่ข้อมูลลำดับที่ 700 โดยการทดสอบแบบ Q-test มีอัตราการความถูกต้องมากกว่าการทดสอบแบบ T^2-test

5. สรุป

ระบบวินิจฉัยข้อบกพร่องในระบบควบคุมพลวัตได้รับความสำคัญอย่างต่อเนื่องและถูกนำมาใช้ในภาคอุตสาหกรรมเป็นจำนวนมาก เนื่องจากต้องการเพิ่มความปลอดภัย ความน่าเชื่อถือ และช่วยในการแผนการซ่อมบำรุงรักษาเชิงพยากรณ์ โดยการวินิจฉัยข้อบกพร่องในระบบควบคุมพลวัตที่นิยมใช้ได้แก่การติดตั้งอุปกรณ์ซ้ำซ้อนและการใช้โปรแกรมคอมพิวเตอร์ด้วยแบบจำลองคณิตศาสตร์หรือวิเคราะห์จากข้อมูลและสัญญาณ โดยอุปกรณ์ที่มีความสำคัญมากจะนิยมใช้วิธีติดตั้งอุปกรณ์ซ้ำซ้อน การวินิจฉัยด้วยแบบจำลองคณิตศาสตร์เหมาะสำหรับระบบที่มีแบบจำลองคณิตศาสตร์ที่แม่นยำเพียงพอในขณะที่การวิเคราะห์ข้อมูลหรือสัญญาณเหมาะสำหรับระบบที่มีขนาดใหญ่และซับซ้อนซึ่งการหาแบบจำลองคณิตศาสตร์ทำได้ยากกว่าการเก็บข้อมูล ระบบวินิจฉัยข้อบกพร่องในระบบควบคุมพลวัตยังสามารถนำไปประยุกต์ใช้เป็นหน่วยสำคัญในระบบควบคุมคงทนต่อข้อบกพร่อง (Fault tolerant control: FTC) เพื่อให้ระบบทำงานต่อไปได้ภายใต้ข้อจำกัดแม้ว่าจะเกิดข้อบกพร่อง โดยระบบควบคุมจะใช้ข้อมูลจากระบบวินิจฉัยข้อบกพร่องเพื่อสั่งให้เกิดการเปลี่ยนโครงสร้างหรือวิธีควบคุม ทำให้ผู้ควบคุมมีเวลาในการวางแผนซ่อมบำรุงได้ทันท่วงทีและมีประสิทธิภาพ นอกจากนี้การเข้ามามีบทบาทของโครงข่ายตัวรับรู้แบบไร้สาย (Wireless sensor network) ซึ่งทำหน้าที่ส่งข้อมูลให้กับระบบควบคุมอัจฉริยะต่างๆ เช่น อินเทอร์เน็ตของสรรพสิ่ง (Internet of Things: IoT) โครงข่ายไฟฟ้าอัจฉริยะ (Smart grid) สำนักงานและโรงงานอัจฉริยะ (Smart office and factory) ทำให้เกิดความสะดวกสบาย ลดต้นทุนในการผลิตและแรงงานคน แต่ในขณะเดียวกันระบบควบคุมดังกล่าวก็มีความเสี่ยงเพิ่มขึ้นจากข้อบกพร่องของตัวรับรู้ซึ่งมีอยู่เป็นจำนวนมาก ดังนั้นจึงควรให้ความสำคัญกับระบบวินิจฉัยข้อบกพร่องในตัวรับรู้เพื่อให้เกิดการพัฒนาและรวมเข้าเป็นหน่วยพื้นฐานของระบบอัจฉริยะเหล่านี้

6. เอกสารอ้างอิง

[1] S. X. Ding, *Model-Based Fault Diagnosis Techniques: Design Schemes, Algorithm and Tools*. London, Springer-Verlag, 2013.

[2] R. Isermann, *Fault Diagnosis Systems: An Introduction from Fault Detection to Fault Tolerance.* Heidelberg, Berlin, Springe-Verlag 2006.

[3] L. H Chiang, E. L. Russell and R. D. Braatz, *Fault Detection and Diagnosis in Industrial Systems*. London, Springer-Verlag, 2001.

[4] P. Weber and S. Gentil, "Fault detection using parameter estimation applied to a winding machine," In IAR Annual Conference, Duisburg, Germany, 1997, pp. 1-6.

[5] O. Moseler and R. Isermann, "Application of model-based fault detection to a brushless DC motor," IEEE Trans. Ind. Electron., vol. 47, no. 5, pp. 1015-1020, 2000.

[6] Y. Chetouani, "Change detection in a distillation column based on the generalized likelihood ratio approach," J. Chem. Eng. & Proc. Tech., vol. 2, no. 5, pp. 1-6, 2011.

[7] A. Hwas and R. Katebi, "Nonlinear observer-based fault detection and isolation for wind turbines," The 22nd Mediterranean Conference on Control and Automation (MED), Palermo, Italy, 2014, pp. 870-375.

[8] P. Zhang, S. X. Ding and P. Liu, "A lifting Based approach to oObserver based fFault detection of linear periodic systems," IEEE Trans. Autom. Control, vol. 57, no. 2, pp. 457-462, 2012.

[9] F. Arrichiello, A. Marino and F. Pierri, "Observer-based decentralized fault detection and isolation strategy for networked multirobot systems," IEEE Trans. Control Syst. Technol., vol. 23, no. 4, pp. 1465-1476, 2015.

[10] C. Commault, J. M. Dion, O. Sename and R. Moteyian, "Observer-based fault diagnosis for structured systems," in The 39th IEEE Conference on Decision and Control, Sydney, NSW, Australia, 2000, pp. 4138-4143.

[11] R. Doraiswami and L. Cheded, "Kalman filter for parametric fault detection: an internal model principle-based approach," IET Control Theory Appl., vol. 6, no. 5, pp. 715-725, 2012.

[12] R. Picatoste, M. Butcher and A. Masi, "Use of Extended Kalman Filter in position sensor fault detection for stepper motors," in IECON 2016 - 42nd Annual Conference of the IEEE Industrial Electronics Society, Florence, Italy, 2016, pp. 1548-1553.

[13] I. Alkov and D. Weidemann, "Fault detection with unscented Kalman filter applied to nonlinear differential-algebraic systems," in The 18th International Conference on Methods & Models in Automation & Robotics (MMAR), Miedzyzdroje, Poland, 2013, pp. 166-171.

[14] I. Izadi, S. L. Shah and T. Chen, "Parity space fault detection based on irregularly sampled data," in 2008 American Control Conference, Seattle, WA, USA, 2008, pp. 2798-2803.

[15] H. Wang, Z. Tian, S. Shi and Z. Weng. "A fault detection and isolation scheme based on parity space method for discrete time-delay system," in The 7th World Congress on Intelligent Control and Automation, Chongqing, China, 2008, pp. 6411-6414.

[16] Y. Li and M. Zhong, "Parity space-based fault detection for linear time-varying systems with multiple packet dropouts," in 2009 Fourth International Conference on Innovative Computing, Information and Control (ICICIC), Kaohsiung, China, 2009, pp. 236-239.

[17] E. M. Cimpoesu, B. D. Ciubotaru and D. Stefanoiu, "Fault detection and diagnosis

using parameter estimation with recursive least squares," The 19th International Conference on Control Systems and Computer Science, Bucharest, Romania, 2013, pp. 18-23.

[18] V. Reppa and A. Tzes, "Fault detection and diagnosis based on parameter set estimation," IET Control Theory Appl., vol. 5, no. 1, pp. 69-83, 2011.

[19] T. Jiang, K. Khorasani and S. Tafazoli, "Parameter estimation-based fault detection, isolation and recovery for nonlinear satellite models," IEEE Trans. Control Syst. Technol., vol. 16, no. 4, pp. 799-808, 2008.

[20] A. Q. Khan and S. X. Ding, "Threshold computation for robust fault detection in a class of continuous-time nonlinear systems," 2009 European Control Conference (ECC), Budapest, Hungary, 2009, pp. 3088-3093.

[21] A. Hashemi and P. Pisu, "Adaptive threshold-based fault detection and isolation for automotive electrical systems," The 9th World Congress on Intelligent Control and Automation, Taipei, Taiwan, 2011, pp. 1013-1018.

[22] J. Saijai, S. X. Ding, A. Abdo, B. Shen and W. Damlakhi, "Threshold computation for fault detection in linear discrete-time Markov jump systems," Int. J. Adapt. Control Signal Process., vol. 28, no. 11, pp. 1106-1127, 2014.

[23] J. Saijai, A. Abdo, W. Damlakhi and S. X. Ding, "Fault detection scheme for discrete-time Markov jump linear systems with mode-independent residual," 2012 IEEE International Conference on Control Applications (CCA), Dubrovnik, Croatia, 2012, pp. 1674-1679.

[24] M. Zhong, S. X. Ding, J. Lam and H. Wang, "An LMI approach to design robust fault detection filter for uncertain LTI systems," Automatica, vol. 39, no. 3, pp. 543-550, 2003.

[25] A. Abdo, S. X. Ding, W. Damlakhi and J. Saijai, "Robust fault detection filter design for uncertain switched systems with adaptive threshold setting," 2011 50th IEEE Conference on Decision and Control and European Control Conference, Orlando, FL, USA, 2011, pp. 5467-5472.

[26] S. Zhang, Z. Wang, D. Ding, H. Shu, T. Hayat and A. M. Dobaie, "On Design of Robust Fault Detection Filter in Finite-Frequency Domain with Regional Pole Assignment," IEEE Trans. Circuits Syst. II Express Briefs, vol. 62, no. 4, pp. 382-386, 2015.

[27] J. Davies, H. Tsunashima, R. M. Goodall, R. Dixon, T. Steffen, "Fault detection in high redundancy actuation using an interacting multiple-model approach," IFAC Proc. Volumes, vol. 42, no. 8, pp. 1228-1233, 2008.

[28] Y. Zhang and X. R. Li, "Detection and diagnosis of sensor and actuator failures using IMM estimator," IEEE Trans. Aerosp. Electron. Syst., vol. 34, no. 4, pp. 1293-1313, 1998.

[29] S. Zhao, B. Huang and F. Liu, "Fault detection and diagnosis of multiple-model systems with mismodeled transition probabilities," IEEE Trans. Ind. Electron., vol. 62, no. 8, pp. 5063-5071, 2015.

[30] S. R. Mohanty, A. K. Pradhan and A. Routray, "A cumulative sum-based fault detector for power system relaying application," IEEE Trans. Power Delivery, vol. 23, no. 1, pp. 79-86, 2008.

[31] Y. Vidya Sagar, A. K. Mishra, A. P. Tiwari and S. B. Degweker, "Online fault detection and diagnosis of in-core neutron detectors using generalized likelihood ratio method," IEEE Trans. Nucl. Sci., vol. 62, no. 6, pp. 3311-3323, 2015.

[32] E. A. Sikora, "Detection of bearing damage by statistic vibration analysis (diagnosis using the excess, the concept of crest factor)," 2015

International Conference on Mechanical Engineering, Automation and Control Systems (MEACS), Tomsk, Russia, 2015, pp. 1-5.

[33] S. Singh, A. Kumar and N. Kumar, “Motor current signature analysis for bearing fault detection in mechanical systems,” Procedia Mater. Sci., vol. 6, pp. 171-177, 2014.

[34] J. Burriel-Valencia, R. Puche-Panadero, J. Martinez-Roman, A. Sapena-Bano and M. Pineda-Sanchez, “Short-frequency fourier transform for fault diagnosis of induction machines working in transient regime,” IEEE Trans. Instrum. Meas., vol. 66, no. 3, pp. 432-440, 2017.

[35] L. A. Pereira, D. Fernandes, D. S. Gazzana, F. B. Libano and S. Haffner, “Application of the Welch, Burg and MUSIC Methods to the Detection of Rotor Cage Faults of Induction Motors,” 2006 IEEE/PES Transmission & Distribution Conference and Exposition: Latin America, Caracas, Venezuela, 2006, pp. 1-6.

[36] S. Rajakarunakaran, P. Venkumar, D. Devaraj, K. Surya Prakasa Rao, “Artificial neural network approach for fault detection in rotary system,” Appl. Soft Comput., vol. 8, no. 1, pp. 740-748, 2008.

[37] Z. Peng, P. Wei, Z. Lina and W. Dezhi, “Applications of adaptive genetic algorithm to radar engine fault diagnosis,” 2010 Chinese Control and Decision Conference, Xuzhou, China, 2010, pp. 25-29.

[38] R. J. Patton, J. Chen and G. P. Liu, “Robust fault detection of dynamic systems via genetic algorithms,” First International Conference on Genetic Algorithms in Engineering Systems: Innovations and Applications, Sheffield, UK, 1995, pp. 511-516.

[39] D. Y. Jung, S. M. Lee, Hong-mei Wang, J. H. Kim and S. H. Lee, “Fault detection method with PCA and LDA and its application to induction motor,” J. Cent. South Univ. T., vol. 17, no. 6, pp. 1238-1242, 2010.

[40] X. Zhang, S. Chen, Y. Zhu and W. Yan, “Fault detection and diagnosis for steam turbine based on kernel GDA,” Proceedings of 2011 International Conference on Modelling, Identification and Control, Shanghai, China, 2011, pp. 58-62.

[41] D. Garcia-Alvarez, M. J. Fuente, P. Vega, G. Sainz, “Fault Detection and Diagnosis using Multivariate Statistical Techniques in a Wastewater Treatment Plant,” IFAC Proc. Volumes, vol. 42, no. 11, pp. 952-957, 2009.