

### บทที่ 3

## ตัวควบคุมทำนายแบบจำลองโดยอาศัยข่ายงานระบบประสาท

ตั้งแต่ช่วง ค.ศ. 1980 เป็นต้นมา ตัวควบคุมทำนายแบบจำลอง (model predictive controller) เป็นตัวควบคุมที่ได้รับความนิยมและใช้งานอย่างแพร่หลายในวงการอุตสาหกรรม ซึ่งตัวควบคุมชนิดนี้มีลักษณะพิเศษ คือ สามารถควบคุมกระบวนการที่ให้ผลตอบแทนที่ดี และคงทนต่อความไม่แน่นอนของกระบวนการ ทั้งยังสามารถควบคุมระบบไม่มีเสถียรภาพได้ ตัวควบคุมแบบนี้มีลักษณะการทำงาน คือ การใช้แบบจำลองทำนายผลตอบแทนล่วงหน้าของกระบวนการ เพื่อสังเคราะห์ลำดับของสัญญาณควบคุมที่เหมาะสม เพื่อให้ผลตอบแทนเป็นไปตามที่ได้ออกแบบไว้ [9]

ตัวควบคุมทำนายแบบจำลอง เป็นตัวควบคุมที่อาศัยแบบจำลองของกระบวนการเพื่อทำนายลำดับผลตอบแทนของกระบวนการ สำหรับนำไปใช้ในการสร้างสัญญาณควบคุม โดยพิจารณาจากค่าของฟังก์ชันจุดประสงค์ที่ประกอบด้วยส่วนของความคลาดเคลื่อนระหว่างค่าปรับตั้งและผลตอบแทนที่ได้จากการทำนายด้วยแบบจำลอง และส่วนของสัญญาณควบคุมที่สร้างขึ้น เพื่อสร้างสัญญาณควบคุมที่เหมาะสมที่ทำให้ฟังก์ชันจุดประสงค์นี้มีค่าต่ำสุด

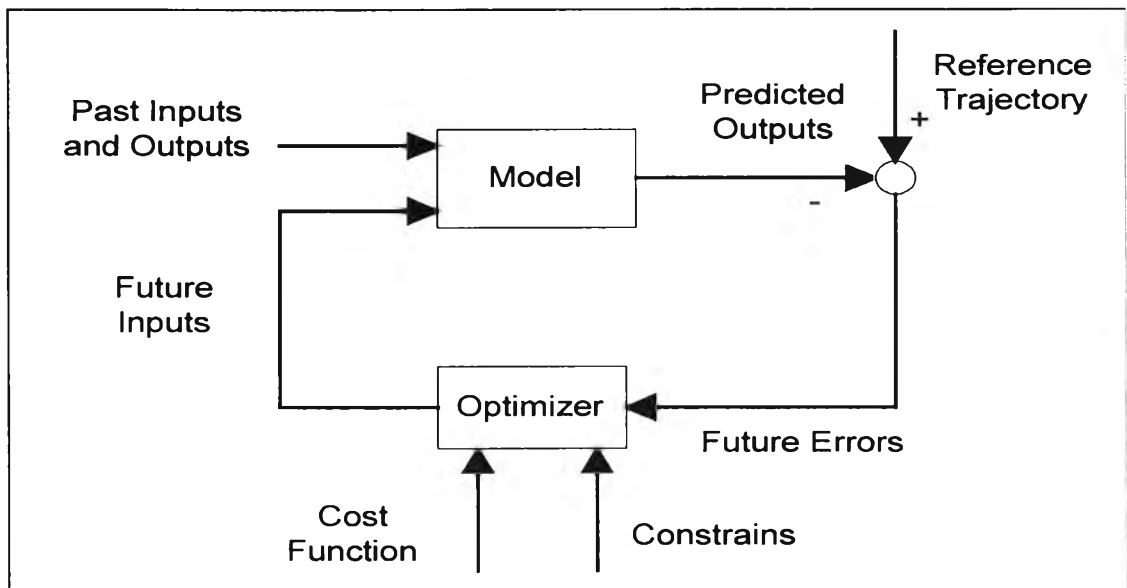
จากการศึกษาทำให้ทราบว่าตัวควบคุมทำนายแบบจำลองสามารถควบคุมกระบวนการที่มีลักษณะพลวัตต่างๆ ได้อย่างกว้างขวาง ทั้งกระบวนการที่มีพลวัตช้า และลักษณะพลวัตที่เร็ว มีความไม่แน่นอนของพารามิเตอร์และค่าประวิงเวลาของกระบวนการได้ดี เช่น การประยุกต์ใช้ตัวควบคุมทำนายแบบจำลองในระบบการผลิตปูนซีเมนต์ เพื่อควบคุมอุณหภูมิของระบบซึ่งมีผลต่อคุณภาพของปูนซีเมนต์ที่ได้ ในการควบคุมเครื่องอบแห้ง เพื่อควบคุมอุณหภูมิของอากาศที่ใช้สำหรับอบผลิตภัณฑ์หรือในการควบคุมแขนกลอัตโนมัติ และมีการนำไปใช้ในการควบคุมอุณหภูมิของน้ำในกระบวนการแลกเปลี่ยนความร้อน ให้ผลการควบคุมดี สามารถกำจัดผลของสัญญาณรบกวนได้ดี จากตัวอย่างที่กล่าวมาส่วนใหญ่เป็นกระบวนการที่มีความไม่แน่นอนสูง ลักษณะพลวัตและค่าประวิงเวลามีการเปลี่ยนแปลงตามจุดทำงาน [8]

ต่อมามีนักวิจัยหลายท่านเสนอแนวคิดที่จะนำข่ายงานระบบประสาทมาสร้างแบบจำลองสำหรับตัวควบคุมชนิดนี้ ซึ่งข่ายงานระบบประสาทมีความสามารถในการจำลองความสัมพันธ์ต่างๆ ได้ดี โดยไม่ต้องใช้สมการทางคณิตศาสตร์ที่ยู่ยากซับซ้อน อาศัยเพียงข้อมูลสัญญาณเข้าและ

สัญญาณออกของกระบวนการ และจากการประยุกต์ใช้แบบจำลองที่สร้างจากข่ายงานระบบประสาทกับตัวควบคุมทำนายแบบจำลองในการควบคุมกระบวนการต่างๆ พบว่าสามารถปรับปรุงประสิทธิภาพของตัวควบคุมทำนายแบบจำลองให้ดีขึ้น ยกตัวอย่างเช่น Draeger, Engell และ Ranke [12] นำข่ายงานระบบประสาทมาใช้ร่วมกับแบบจำลองเชิงเส้น เพื่อชดเชยส่วนที่ไม่เชิงเส้นของกระบวนการสำหรับตัวควบคุมทำนายแบบจำลองในการควบคุมค่าความเป็นกรดเบสในปฏิกิริยาเคมี และจากการเปรียบเทียบกับตัวควบคุม PI พบว่าสามารถกำจัดผลของสัญญาณรบกวนได้ดีกว่าตัวควบคุม PI Su และ McAvoy [37] ได้ศึกษาการนำข่ายงานระบบประสาทไปใช้กับตัวควบคุมทำนายแบบจำลองในการควบคุมระบบหมอกลิ้น พบว่าสามารถกำจัดผลของสัญญาณรบกวนได้ดี Willis, Montague, Massimo, Tham และ Morris [44] ได้ศึกษาการนำข่ายงานระบบประสาทไปใช้กับตัวควบคุมทำนายแบบจำลองในการควบคุมระบบหมอกลิ้น และเปรียบเทียบผลการควบคุมกับตัวควบคุม PI พบว่าให้ผลการควบคุมต่อการเปลี่ยนจุดทำงานและการกำจัดผลของสัญญาณรบกวนดีกว่าตัวควบคุม PI Koivisto, Kimpimaki และ Koivo [24] ศึกษาการใช้โครงสร้างตัวควบคุมทำนายแบบจำลองที่อาศัยข่ายงานระบบประสาทในการควบคุมระบบแลกเปลี่ยนความร้อน พบว่าสามารถควบคุมผลตอบสนองให้เข้าสู่ค่าปรับตั้งได้รวดเร็ว และกำจัดผลของสัญญาณรบกวนได้ดีอีกด้วย

ในบทนี้จะกล่าวถึงลักษณะโดยทั่วไปของตัวควบคุมทำนายแบบจำลอง ลักษณะโดยทั่วไปของข่ายงานระบบประสาทและโครงสร้างการทำนายผลตอบสนองล่วงหน้าของกระบวนการโดยอาศัยข่ายงานระบบประสาท

### 3.1 ตัวควบคุมทำนายแบบจำลอง



รูปที่ 3.1 โครงสร้างตัวควบคุมทำนายแบบจำลอง [1]

ตัวควบคุมทำนายแบบจำลอง [9] (ดูได้จาก [1] เช่นกัน) ซึ่งมีโครงสร้างดังรูปที่ 3.1 เป็นการควบคุมระบบโดยอาศัยแบบจำลองของระบบมาทำนายผลตอบในอนาคต เพื่อคำนวณหาสัญญาณควบคุม ตัวควบคุมแบบนี้ประกอบด้วยส่วนที่สำคัญ 3 ส่วนคือ แบบจำลองของกระบวนการ ฟังก์ชันจุดประสงค์ และกฎการควบคุม โดยทั่วไปการควบคุมทำนายแบบจำลองมีหลายรูปแบบแตกต่างกันไปตามส่วนต่างๆ ของทั้ง 3 ส่วนดังที่กล่าวมาอาศัยแนวคิดหลักดังต่อไปนี้

1. ทำนายผลตอบสนองของกระบวนการจากแบบจำลองในช่วงเวลาหนึ่ง
2. คำนวณลำดับของสัญญาณควบคุมที่ทำให้ฟังก์ชันจุดประสงค์มีค่าน้อยที่สุด โดยฟังก์ชันจุดประสงค์  $J$  มีนิยามดังนี้

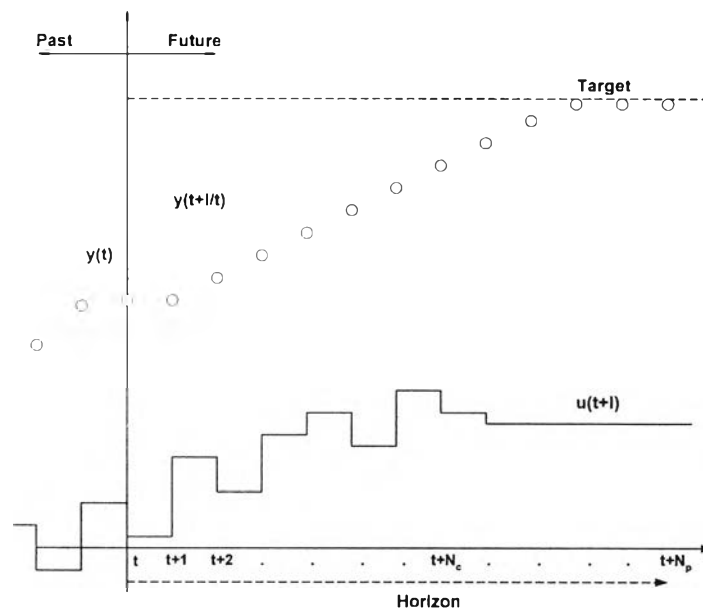
$$J = \frac{1}{2} \sum_{j=N_1}^{N_2} [r(t+j) - y(t+j)]^2 + \frac{1}{2} \lambda \sum_{j=0}^{N_u-1} [\Delta u(t+j)]^2, \quad \Delta u(t) = u(t) - u(t-1) \quad (3.1)$$

โดยที่  $y(t)$  คือ สัญญาณออก  $u(t)$  คือ สัญญาณควบคุม  $r(t)$  คือ สัญญาณอ้างอิง  $\lambda$  คือการถ่วงน้ำหนักสัญญาณควบคุม  $N_1$  คือ เส้นขอบการทำนายต่ำสุด (minimum prediction horizon)  $N_2$

คือ เส้นขอบการทำนายสูงสุด (maximum prediction horizon) และ  $N_c$  คือ เส้นขอบควบคุม (control horizon)

3. ในแต่ละครั้งของการควบคุม สัญญาณควบคุมลำดับแรกที่คำนวณได้จะนำไปใช้กับกระบวนการเท่านั้น

จากแนวคิดหลักข้างต้น มีจุดประสงค์เพื่อควบคุมให้ลำดับของผลตอบสนองในอนาคตของกระบวนการใกล้เคียงกับเป้าหมายที่ต้องการที่สุด ซึ่งแตกต่างจากจุดประสงค์ในการควบคุมของตัวควบคุมแบบพื้นฐานที่ต้องการให้ผลตอบสนองของกระบวนการที่เกิดจากการป้อนสัญญาณควบคุมที่เวลาปัจจุบัน เข้าใกล้เป้าหมายที่ต้องการมากที่สุด



รูปที่ 3.2 แนวคิดของตัวควบคุมทำนายแบบจำลอง [9]


เนื่องจากพารามิเตอร์สำหรับการออกแบบตัวควบคุมแบบนี้มีหลายตัว ดังนั้นการเลือกกำหนดค่าพารามิเตอร์ต่างๆอย่างเป็นระบบจะช่วยในการหาค่าที่เหมาะสมง่ายขึ้น สำหรับระบบที่มีเสถียรภาพมีการศึกษาค่าเริ่มต้นของพารามิเตอร์  $N_1, N_2, N_c$  สำหรับตัวควบคุมที่ทำให้ระบบยังมีเสถียรภาพ [13] ดังนี้ พารามิเตอร์  $N_c$  กำหนดให้เท่ากับ 1 และ  $N_1$  จะขึ้นอยู่กับค่าประวิงเวลา (time delay) หรือ  $d$  ที่น้อยที่สุดของกระบวนการ กำหนดค่า  $N_1$  จากความสัมพันธ์  $N_1 h = d$   $N_2$  จะขึ้นอยู่กับช่วงเวลาขาขึ้นของกระบวนการ (rise time) หรือ  $T_r$  กำหนดค่า  $N_2$  จากความสัมพันธ์  $N_2 h = T_r$  เมื่อ  $h$  คือค่าเวลาการชกตัวอย่าง

### 3.2 ข่ายงานระบบประสาท


ข่ายงานระบบประสาท (neural network) ซึ่งถูกพัฒนาขึ้นเพื่อเลียนแบบความสามารถของระบบประสาททางชีวภาพ (biological neural) โครงสร้างของข่ายงานระบบประสาทรุ่นนั้นมีด้วยกันหลายโครงสร้าง แต่ทุกๆ โครงสร้างก็มีข้อดีที่สำคัญๆ ร่วมกันยกตัวอย่างเช่น [36]

1. คุณลักษณะที่สำคัญที่สุดของข่ายงานระบบประสาทคือ ความสามารถในการประมาณฟังก์ชันต่อเนื่องแบบไม่เชิงเส้น (nonlinear continuous function) ใดๆ ในระดับความแม่นยำที่ต้องการได้ ด้วยคุณลักษณะนี้ข่ายงานระบบประสาทจึงถูกนำไปใช้ในการหาแบบจำลองของระบบไม่เชิงเส้นเพื่อนำไปประยุกต์ใช้ในการสังเคราะห์หาค่าตัวควบคุมต่อไป

2. ข่ายงานระบบประสาทสามารถมีหลายสัญญาณเข้าและหลายสัญญาณออก จึงสามารถนำไปประยุกต์ใช้กับระบบหลายตัวแปร (multivariable system) ได้ง่าย



รูปที่ 3.3 ข่ายงานระบบประสาทแบบหลายชั้นซึ่งมีสองชั้นซ่อนภายใน [29]



รูปที่ 3.4 แผนผังภาพของข่ายงานระบบประสาทแบบหลายชั้นซึ่งมีสองชั้นซ่อนภายใน [29]

ข่ายงานระบบประสาทแบบหลายชั้น (multilayer neural network) ดังแสดงในรูปที่ 3.3 เป็นตัวอย่างหนึ่งของโครงสร้างของข่ายงานระบบประสาท ประกอบไปด้วย ชั้นสัญญาณเข้าหนึ่งชั้น ชั้นสัญญาณออกหนึ่งชั้น และชั้นซ่อนภายในสองชั้น เพื่อให้เข้าใจง่ายขึ้น โครงสร้างในรูปที่ 3.3 เขียนแทนด้วยแผนผังภาพในรูปที่ 3.4 ซึ่งประกอบด้วยเมทริกซ์ถ่วงน้ำหนักสามตัว คือ  $W^1$ ,

$W^2$ ,  $W^3$  และตัวดำเนินการไม่เชิงเส้นในรูปเมทริกซ์แยง  $\Gamma$  ซึ่งสมาชิกใน  $\Gamma$  นี้เป็นฟังก์ชันล็อกซิกมอยด์  $\gamma$  นั่นคือ  $\gamma(x) = \frac{1}{1+e^{-x}}$  แต่ละชั้นของข่ายงานสามารถแสดงได้ด้วยตัวดำเนินการ

$$N_i[u] = \Gamma[W'u] \quad (3.2)$$

และการแปลงจากสัญญาณเข้าไปเป็นสัญญาณออกของข่ายงานระบบประสาทแบบหลายชั้นสามารถเขียนแทนได้ด้วย

$$y = N[u] = \Gamma[W^3\Gamma[W^2\Gamma[W^1u]]] = N_1N_2N_3[u] \quad (3.3)$$

เมทริกซ์ถ่วงน้ำหนัก  $W^1$ ,  $W^2$  และ  $W^3$  จะถูกปรับค่าเพื่อทำให้ค่าของฟังก์ชันจุดประสงค์ของค่าความผิดพลาด ระหว่างสัญญาณออก  $y$  ของเครือข่าย กับสัญญาณออกที่ต้องการ  $y_d$  มีค่าน้อยที่สุด ซึ่งผลของการแปลงโดยใช้ฟังก์ชัน  $N[u]$  นี้ เป็นการแปลงเวกเตอร์หนึ่งๆ ไปเป็นสัญญาณออกหนึ่งๆ ที่อยู่ในเซตของสัญญาณออกที่สอดคล้องกับสัญญาณเข้าที่อยู่ในเซตๆหนึ่ง โดยทั่วไปการแปลงแบบไม่ต่อเนื่อง อาทิเช่น กฎการแปลงแบบใกล้สุด (Nearest Neighbor Rule) ถูกนำมาใช้ในลำดับขั้นสุดท้าย เพื่อแปลงกลุ่มของสัญญาณเข้า ไปเป็นจุดในเซตของสัญญาณออกที่สอดคล้องกับสัญญาณออก และหากมองในรูปของระบบแล้ว โครงสร้างข่ายงานระบบประสาทแบบหลายชั้นนี้เป็นตัวแปลงไม่เชิงเส้นแบบหนึ่งที่มีเมทริกซ์ถ่วงน้ำหนักเป็นพารามิเตอร์

### 3.3 โครงสร้างของตัวทำนายด้วยข่ายงานระบบประสาท

จากความสามารถของข่ายงานระบบประสาทในการประมาณความสัมพันธ์ระหว่างข้อมูลเข้าและข้อมูลออกซึ่งอยู่ในรูปฟังก์ชันที่เวลา  $t$  โดยพิจารณาในระบบเวลาเต็มหน่วย ดังสมการ

$$y(t) = F[y(t-1), \dots, y(t-n), u(t-d), \dots, u(t-d-m)] \quad (3.4)$$

โดย  $d$  คือค่าประวิงเวลา  $m$  และ  $n$  คืออันดับของสัญญาณเข้าและสัญญาณออกที่เป็นข้อมูล ในที่นี้เราสมมติว่าเราทราบค่าการประวิงเวลาแน่นอน เมื่อ  $F(t)$  เป็นฟังก์ชันที่แสดงความสัมพันธ์ระหว่างข้อมูลเข้า  $y(t-1), \dots, y(t-n), u(t-d), \dots, u(t-d-m)$  และข้อมูลออก  $y(t)$  ซึ่งอาจจะเป็นฟังก์ชันเชิงเส้นหรือฟังก์ชันไม่เชิงเส้น

การประมาณผลตอบสนองของกระบวนการล่วงหน้าเพื่อชดเชยผลของการประวิงเวลา โดยตัวทำนายขั้นที่  $d$  (d-step ahead predictor) [41] ซึ่งมีอยู่ 2 วิธี คือ

### 3.3.1 ตัวทำนายแบบเวียนเกิด (recursive predictor)

จากความสามารถของข่ายงานระบบประสาทในการประมาณความสัมพันธ์ระหว่างข้อมูลเข้าและข้อมูลออกซึ่งอยู่ในรูปฟังก์ชันดังที่กล่าวไปแล้วข้างต้น ภายใต้เงื่อนไขที่ว่าตัวประมาณที่อาศัยข่ายงานระบบประสาทสามารถประมาณฟังก์ชันความสัมพันธ์  $F(t)$  ได้ถูกต้อง เราจะนำตัวประมาณฟังก์ชันที่อาศัยข่ายงานระบบประสาทนี้ไปใช้ในการทำนายผลตอบสนองล่วงหน้าของระบบจากฟังก์ชันนี้ เพื่อชดเชยผลของการประวิงเวลา โดยเขียนในรูปสมการของการประมาณล่วงหน้าในเวลา  $t+1, t+2, \dots$  ได้ดังนี้

$$\begin{aligned}\hat{y}(t+1) &= F[y(t), \dots, y(t-n+1), u(t-d+1), \dots, u(t-d-m+1)] \\ \hat{y}(t+2) &= F[\hat{y}(t+1), \dots, y(t-n+2), u(t-d+2), \dots, u(t-d-m+2)]\end{aligned}$$

จนกระทั่งถึงที่เวลา  $t+d$  เมื่อ  $d$  เป็นค่าการประวิงเวลา

$$\hat{y}(t+d) = F[\hat{y}(t+d-1), \dots, \hat{y}(t+d-n), \dots, u(t), \dots, u(t-m)] \quad (3.5)$$

โดยที่  $\hat{y}(t+d-i) = y(t+d-i)$  สำหรับ  $d-i \leq 0$  ( $i=1, \dots, n$ )

เราสามารถประมาณผลตอบสนองของกระบวนการที่มีการประวิงเวลาได้ แต่จำเป็นที่จะต้องอาศัยการคำนวณค่อนข้างมากเนื่องจากต้องทำการคำนวณแบบเวียนเกิด เพื่อประมาณผลตอบสนองล่วงหน้าของกระบวนการ

### 3.3.2 ตัวทำนายแบบไม่เวียนเกิด (non-recursive predictor)

วิธีที่จะใช้ในการประมาณผลตอบสนองของกระบวนการที่มีการประวิงเวลา นอกจากการใช้วิธีแบบเวียนเกิด (recursive predictor) แล้วยังมีวิธีแบบไม่เวียนเกิด (non-recursive predictor) ซึ่งจัดความสัมพันธ์ของข้อมูลเข้าและข้อมูลออกอยู่ในรูปฟังก์ชัน ดังนี้

$$\hat{y}(t+i) = F[y(t), \dots, y(t-n+1), u(t+i-d), \dots, u(t-d-m+1)], \quad i=1, 2, \dots, d \quad (3.6)$$

โดยอาศัยข้อมูลเข้าเป็นสัญญาณออกและสัญญาณเข้าที่สามารถวัดได้จากอดีตถึงเวลาปัจจุบัน ( $t$ ) โดย  $m$  และ  $n$  เป็นอันดับของสัญญาณเข้าและสัญญาณออกที่ใช้เป็นข้อมูลในการประมาณความสัมพันธ์ซึ่งอยู่ในรูปฟังก์ชัน การประมาณฟังก์ชันด้วยวิธีนี้จะทำให้การคำนวณง่ายขึ้น เนื่องจากไม่ต้องคำนวณแบบเวียนเกิด เป็นจำนวน  $d$  ครั้งเพื่อประมาณผลตอบสนองล่วงหน้า แต่โครงสร้างแบบนี้ใช้ข้อมูลในการประมาณฟังก์ชันค่อนข้างมาก และหากจำเป็นที่จะต้องทำการประมาณผลตอบสนองของระบบที่มีการประวิงเวลายาวนาน จะทำให้ขนาดโครงสร้างของข่ายงานระบบ

ประสาทที่ใช้มีขนาดใหญ่ ซึ่งหมายถึงฟังก์ชันที่จะทำการประมาณจะมีความซับซ้อนมากขึ้น การฝึกและการปรับตัวของข่ายงานระบบประสาทจะมีความยุ่งยาก และซับซ้อนมากขึ้นเช่นกัน

ตัวทำนายแบบเวียนเกิดจะทำงานได้ดีแม้จะมีการทำนายในช่วงยาว (long range prediction) ส่วนตัวทำนายแบบไม่เวียนเกิดจะทำงานได้ดีเฉพาะในช่วงการทำนายที่สั้นเท่านั้น แต่จะใช้เวลาในการคำนวณน้อยกว่าตัวทำนายแบบเวียนเกิด เพราะการทำนายแต่ละขั้นเป็นอิสระต่อกัน [38] (ดูได้จาก [1] เช่นกัน) ในการเลือกโครงสร้างของข่ายงานระบบประสาทในการประมาณผลตอบสนองล่วงหน้าของกระบวนการในการทดลองต่อไป จะใช้ตัวทำนายแบบเวียนเกิด เนื่องจากใช้โครงสร้างของข่ายงานระบบประสาทที่เล็กกว่า และมีความสามารถในการทำนายผลตอบสนองในช่วงยาวได้ดี

