

สำนักหอสมุดกลาง พระจอมเกล้าลาดกระบัง

การจำแนกภาพโดยนิรอลเน็ตเวิร์คแบบไม่มีการสอนร่วมกับแบบมีการสอน

รศ.ดร. กิตติ ไพฑูรย์วัฒนกิจ

รัชนี สุภัคพาณิชย์

สุรพล คูนเกย

งมปร.สงทท ๙๕๙๐



T034417

RCH

TK

๗๘๘๒

๙๓

ก๖๗๒ก

เลขหม.....

เลขทะเบียน.....34417.....

วัน, เดือน, ปี- 1 พ.ย. 2542

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

# การจำแนกภาพโดยนิเวศวิทยาแบบไม่มีการสอนร่วมกับแบบมีการสอน

## บทคัดย่อ

ในรายงานนี้เป็นกรนำเสนอวิธีการของการจำแนกวัตถุภายในภาพ โดยใช้หลักการของโครงข่ายประสาทเทียมแบบไม่มีการสอนร่วมกับแบบมีการสอน สำหรับนิเวศวิทยาแบบไม่มีการสอนจะใช้ Self-organization ของ Kohonen และนิเวศวิทยาแบบมีการสอนใช้โครงสร้างแบบ Recurrent โดยใช้การสอนแบบ Back propagation และนำหลักการสร้างความพอใจในขอบเขตที่มีอย่างจำกัดเข้ามารวมไว้ด้วยกัน ทำให้อัลกอริทึมนี้สามารถทำงานในลักษณะแบบขนานได้ซึ่งจะแตกต่างจากอัลกอริทึมแบบเดิมที่อัลกอริทึมจะทำงานในลักษณะแบบลำดับ จากการทำงานที่แตกต่างนั้นทำให้วิธีการที่นำเสนอนี้ มีความสามารถในการสร้างค่าความพอใจสูงสุดโดยรวมได้ และด้วยความสามารถในการเรียนรู้แบบไม่ต้องมีฟังก์ชันเป้าหมายของโครงข่ายประสาทเทียมแบบ Kohonen's self organizing feature map ทำให้ลักษณะโครงสร้างของภาพ นั้นมีการจดจำในรูปของค่าน้ำหนักซึ่งค่าน้ำหนักเหล่านี้จะนำไปเป็นค่าเริ่มต้นให้แก่โครงข่ายประสาทเทียมแบบ Recurrent ที่มีความสามารถในการหาค่าที่ดีที่สุดได้ และด้วยหลักการสร้างความพอใจในขอบเขตที่จำกัด โครงข่ายประสาทเทียมแบบ Recurrent จะมีการเชื่อมต่อถึงกันทั้งหมดด้วยค่าน้ำหนักอีกชุดหนึ่งซึ่งเป็นไปตามวิธีของการสร้างความพอใจในขอบเขตที่จำกัด ดังนั้นโครงสร้างของโครงข่ายประสาทเทียมที่สร้างขึ้นมานี้จะเป็นแบบสามมิติ โดยที่ทุกๆ จุดภายในภาพจะมีตัวแทนที่เป็นโครงข่ายประสาทเทียม Recurrent เท่าๆ กันทุกจุดภาพ โดยที่จำนวนของโครงข่ายประสาทเทียมจะขึ้นอยู่กับความต้องการในการจำแนก และหนึ่งใน Recurrent ของแต่ละจุดภาพที่ให้ค่าเอาท์พุทที่สูงที่สุด จะได้ว่า เป็นตัวแทนของจุดภาพนั้น จากผลการทดลอง อัลกอริทึมนี้สามารถให้ผลลัพธ์ที่น่าพอใจกับภาพที่มีลักษณะการกระจายของระดับเทาแบบต่างๆ กันได้ดี แต่ไม่สามารถทำงานได้ดีกับภาพถ่ายดาวเทียมที่มีลักษณะक्रमเครือมากๆ ได้

## 1. บทนำ

การแบ่งวัตถุภายในภาพ คือ ขั้นตอนที่สำคัญขั้นตอนหนึ่งในขบวนการจดจำคุณลักษณะต่างๆ ของภาพ เพราะถ้าการแบ่งแยกนั้นทำได้ไม่ดีแล้ว ก็จะทำให้การจดจำนั้นมีความผิดพลาดที่มากขึ้นหรือไม่สามารถทำการจดจำได้เลย หลักของการแบ่งแยกวัตถุ นั้น โดยส่วนใหญ่แล้วจะยึดหลักการคุณสมบัติที่เหมือนกันของระดับเทาหรือไม่ ก็ลักษณะของเนื้อภาพเป็นแนวในการแบ่งแยกวัตถุ ในปัจจุบันอัลกอริทึมที่ใช้อยู่จะมีแนวทางในการทำงานกับภาพได้สามแนวทาง คือ

การแบ่งภาพออกเป็นพื้นที่โดยพื้นที่เป็นส่วนเดียวกันหรือมีตัวแทนเป็นตัวแทนเดียวกัน จะมีคุณลักษณะที่เหมือนๆ กัน วิธีการที่สอง คือ การหาความไม่ต่อเนื่องของขอบของวัตถุภายในภาพและทำการเชื่อมต่อเข้าด้วยกันเพื่อให้ได้วัตถุที่มีความสมบูรณ์มากที่สุด และในส่วนวิธีการท้ายสุดก็คือ การแบ่งแยกวัตถุในลักษณะการจำแนกตามระดับเทา ซึ่งในทุกๆ แนวความคิดที่ได้อธิบายมานี้ ความต้องการคือการได้ผลลัพธ์ที่ออกมาแล้วมีความหมายต่อการตีความ ในขบวนการขั้นต่อไป แต่ด้วยข้อจำกัดของอัลกอริทึมที่ทำงานในแบบลำดับ ทำให้ผลลัพธ์ที่ได้มาไม่มีความสัมพันธ์ต่อการทำงานของอัลกอริทึม หรืออธิบายได้ว่าอัลกอริทึมไม่สามารถสร้างค่าตัวแทนต่างๆ ที่ให้แก่วัตถุในภาพนั้น เป็นตัวแทนที่ดีที่สุดของโดยรวมได้นั่นเอง

จากข้อจำกัดของวิธีการในการจำแนกภาพแบบเดิม ทำให้มีการประยุกต์ทฤษฎีต่างๆ เข้ามาแก้ไข และหนึ่งนั้นคือ วิธีการของนิเวรอลเน็ตเวิร์ค หรือ โครงข่ายประสาทเทียมที่มีความสามารถในการเรียนรู้ข้อมูลได้โดยการสอนให้แก่ตัวโครงข่ายนิเวรอล และความสามารถในการทำงานแบบขนาน ทำให้ทฤษฎีได้รับความสนใจในการที่จะประยุกต์ทฤษฎีนี้เข้ามาในงานการจำแนกภาพ และทฤษฎีของนิเวรอลเน็ตเวิร์คนี้ ได้มีการพัฒนามาหลายโมเดลที่มีความสามารถที่แตกต่างกันทำให้การประยุกต์ในการใช้งานทางด้านนี้จึงมีมากขึ้น


สำหรับในรายงานที่นำเสนออยู่นี้เป็นรายงานหนึ่งที่ได้มีการประยุกต์ทฤษฎีนิเวรอลเน็ตเวิร์ค รวมเข้ากับแนวความคิดของการสร้างความพอใจในขอบเขตที่จำกัด เพื่อให้ได้วิธีการจำแนกภาพที่มีความสามารถในการทำงานแบบขนาน และสามารถที่จะสร้างค่าตัวแทนของแต่ละจุดภาพที่ดีที่สุดโดยรวมได้ด้วย โดยได้ใช้โมเดลของนิเวรอลเน็ตเวิร์คสองโมเดล คือ Kohonen's self-organizing feature map ที่มีความสามารถในการเรียนรู้ข้อมูลได้เองโดยไม่ต้องมีฟังก์ชันเป้าหมาย ทำให้ข้อมูลของภาพนั้นได้ถูกจัดเก็บในรูปของค่าน้ำหนัก ซึ่งจะถูกนำมาเป็นค่าเริ่มต้นให้กับโมเดลของ Recurrent นิเวรอลเน็ตเวิร์ค ที่อยู่ภายใต้โครงสร้างของหลักการสร้างความพอใจในขอบเขตที่จำกัด ด้วยคุณสมบัติของ Recurrent นิเวรอลเน็ตเวิร์คนี้สามารถหาค่าที่ดีที่สุดได้นั้นเมื่อทำการรวมเข้ากับการสร้างความพอใจในขอบเขตที่จำกัดที่จะสร้างค่าน้ำหนักขึ้นมาเชื่อมต่อกับทุก Recurrent นิเวรอล และค่าน้ำหนักที่สร้างขึ้นมานั้นก็จะทำงานแบบสมมาตรต่อตำแหน่ง จะทำให้ได้ค่าความพอใจแบบโดยรวมได้

สำหรับในส่วนที่สองของรายงานนี้ เป็นการอธิบายวิธีการในการประยุกต์แนวความคิดของการสร้างค่าความพอใจสูงสุดเข้ากับนิเวรอลเน็ตเวิร์ค และในส่วนที่สามจะเป็นการอธิบายถึงการสร้างค่าน้ำหนักในการเชื่อมต่อระหว่าง Recurrent นิเวรอลเน็ตเวิร์ค และส่วนที่สี่เป็นการอธิบายถึงการลู่ออกของอัลกอริทึม และส่วนท้ายสุดจะเป็นการอธิบายผลการทดลองและสรุปผลการทดลอง

## 2. วิธีการประยุกต์แนวคิดการสร้างความปลอดภัยในขอบเขตจำกัดเข้ากับนิเวศน์เน็ตเวิร์กในงานกรจำแนกภาพ


### 2.1 Recurrent นิเวศน์เน็ตเวิร์ก

โครงสร้างของ Recurrent network นั้นจะต่างจากนิเวศน์เน็ตเวิร์ก แบบทั่วไปที่เป็นการเชื่อมต่อไปข้างหน้า (Feedforward) คือ โหนดในชั้นเดียวกันจะไม่ต่อกันมีแต่ต่อไปยังโหนดของชั้นถัดไปเท่านั้น ซึ่งจะมีรูปแบบดังรูปที่ 1



รูปที่ 1 โครงสร้างแบบ Feedforward

ในกรณีของ Recurrent network โหนดแต่ละโหนดจะต่อกันและยังป้อนเข้าสู่โหนดของตัวเองดังแสดงในรูปที่ 2



รูปที่ 2 โครงสร้างแบบ Recurrent

ในการประยุกต์แนวคิดของการสร้างความพอใจในขอบเขตที่จำกัด หรือที่เรียกย่อๆ ว่า CSP (Constraint Satisfaction Problem) ไปสู่การใช้นิรอลเน็ตเวิร์กนั้น จะต้องรู้ก่อนว่าขบวนการ CSP คือ ขบวนการในการจัดหาตัวแทน หรือ ลาเบล ที่มีอย่างจำกัดให้กับทุกๆ จุดภาพ ได้อย่างเหมาะสมกับภาวะความพอใจสูงสุดหรือการเกิดภาวะของค่าที่ดีที่สุดโดยรวม เพื่อที่ทำให้นิรอลเน็ตเวิร์กทำงานร่วมกับแนวความคิดนี้ได้จะต้องมีการประยุกต์ หรือทำการสร้างโครงสร้างขึ้นมาใหม่ให้ได้เสียก่อน ดังนั้นถ้าเรามีภาพที่มีขนาดเท่ากับ  $n \times n$  และเราต้องการจำแนกภาพนี้ให้อยู่ภายในตัวแทน  $m$  ตัวแทน ดังนั้น เราจะต้องมีการสร้างนิรอลขึ้นมาทั้งหมดเท่ากับ  $n \times n \times m$  หรือสามารถมองเป็นอะเรย์ขนาดสามมิติ โดยจะมีโครงสร้างของเครือข่ายนิรอลคั่งรูปที่ 3 โดยค่า  $(i, j)$  เป็นค่าที่อ้างถึงตำแหน่งของจุดภาพที่  $(i, j)$ ,  $i=1, \dots, n, j=1, \dots, n$

## 2.2 การแปลงค่าพารามิเตอร์ต่างๆของ CSP สู่นิรอลเน็ตเวิร์ก

ในการอธิบายวิธีการทำงานของนิรอลเน็ตเวิร์กให้อยู่ในรูปของ CSP จำเป็นจะต้องทำการแปลงพารามิเตอร์ ของ CSP ให้มีความสอดคล้องกันดังต่อไปนี้


- (1) เซตของวัตถุจะใช้สัญลักษณ์  $O = \{o_i, i=1, \dots, n\}$ , เมื่อ  $n$  คือ จำนวนวัตถุในความหมายของการจำแนกภาพทุกๆ จุดภาพที่จะทำการจำแนก ก็คือ วัตถุ
- (2) เซตของตัวแทนของแต่ละจุดภาพ หรือแต่ละวัตถุจะใช้สัญลักษณ์  $A = \{\lambda_j, j=1, \dots, m\}$  เมื่อ  $m$  เป็นจำนวนตัวแทนของแต่ละจุดภาพที่มีอย่างจำกัด
- (3) เซตของนิรอลใน CSP ในที่อยู่บริเวณที่ใกล้ชิดกันและมีการเชื่อมต่อถึงกันด้วยค่าน้ำหนักเราจะใช้สัญลักษณ์  $\Omega$  โดยที่  $\Omega_i = \{o_i\} \cup \{o_{i_1}, o_{i_2}, \dots, o_{i_p}\}$  เมื่อ  $1 \leq i_1, \dots, i_p \leq n, i \neq i_l$  สำหรับทุกๆ  $1 \leq l \leq p$  ซึ่งก็มีวัตถุบริเวณใกล้เคียง ที่มีจุดศูนย์กลางอยู่ที่มีการเชื่อมต่อด้วยค่าน้ำหนักระหว่างส่วนประกอบเหล่านี้  $\{o_{i_1}, o_{i_2}, \dots, o_{i_p}$  และ  $o_i$
- (4) เซตของค่าน้ำหนักของสองวัตถุในบริเวณใกล้เคียง ที่เชื่อมกันด้วยค่าน้ำหนัก  $\{o_i, o_{i_1}\} \subset \Omega_i$  ที่อยู่บนเซตของตัวแทน  $\{\lambda_j, \lambda_{j_1}\} \subset A$  ได้นิยามไว้ดังนี้

$$A_{ij} : A_i \times A_{i_1} \rightarrow [min, max]$$

เมื่อ  $\Omega_i = \{o_i\} \cup \{o_{i_1}, o_{i_2}, \dots, o_{i_p}\}, 1 \leq i_1, \dots, i_p \leq n, A_i = A_{i_2} = A$  ค่า  $min$  คือ จำนวนจริงที่เป็นลบ และค่า  $max$  นั้นคือจำนวนจริงที่มีค่าเป็นบวก  $A_{ij}(\lambda_j, \lambda_{j_1})$  สามารถที่จะพิจารณา เป็นมาตรวัดที่สะท้อนถึงความเหมาะสมในการที่จะทำการกำหนดตัวแทน  $\lambda_j$  ให้กับวัตถุ  $o_i$  และ  $\lambda_{j_1}$  ให้กับ  $o_{i_1}$  ที่มีกฎเกณฑ์ดังนี้

$$A_{ij}(\lambda_j, \lambda_{j1}) = \begin{cases} \text{มีค่ามาก} & \text{ถ้าตัวแทน } \lambda_j \text{ บนวัตถุ } O_{j1} \\ & \text{สนับสนุนตัวแทน } \lambda_{j1} \text{ บนวัตถุ } O_j \\ \text{มีค่าน้อย} & \text{ถ้าตัวแทน } \lambda_j \text{ บนวัตถุ } O_{j1} \text{ และตัวแทนของ} \\ & \text{วัตถุ } O_j \text{ ไม่สอดคล้องกัน} \\ 0 & \text{ถ้า } O_j \text{ และ } O_{j1} \text{ อีกระยะกัน} \end{cases}$$

เมื่อคำว่า มี *ค่ามาก* คือ จำนวนจริงที่มีค่าเป็นบวก และคำว่ามี *ค่าน้อย* นั้น คือ จำนวนจริงที่มีค่าเป็นลบ



รูปที่ 3 เป็น โครงสร้างของ Recurrent Neural Network ในการทำการแบ่งแยกวัตถุจากภาพ โดยทุก ๆ คอลัมน์มีดัชนีที่  $(i, j)$  จะประกอบด้วยจำนวนนิรอรเท่ากับ  $m$  นิรอร ทำหน้าที่เป็นตัวแทนในขอบเขตที่จำกัดของแต่ละจุดภาพ

### 2.3 การกำหนดสัญลักษณ์

เพื่อให้ง่ายต่อการอธิบายในการแบ่งแยกวัตถุในภาพ เราจะต้องกำหนดสัญลักษณ์เสียก่อน คือ

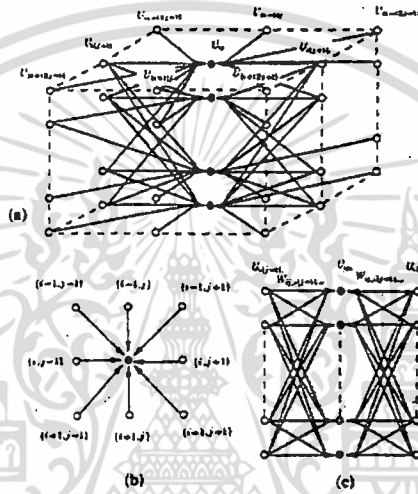
$n \times n$  ขนาดของภาพและจำนวนของวัตถุใน CSP  
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับใช้เพื่อการเรียนการสอนเท่านั้น เมื่ออนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- $m$  จำนวนของตัวแทนที่มีอย่างจำกัด
- $U \dots$   $n \times n \times m$  เป็นอะเรย์ขนาดสามมิติของนิเวศน์เน็ตเวิร์ค
- $U_{ij}$   $m \times 1$  เป็นกลุ่มของเวกเตอร์นิเวศน์เน็ตเวิร์คที่จุดภาพตำแหน่ง  $(i, j)$
- $U_{ijk}$  เป็นส่วนประกอบลำดับที่  $K$  ของ  $U_{ij}$  คือ นิเวศน์เน็ตเวิร์คที่เป็นตัวแทนของเครื่องหมายต่อภาพที่จุดภาพ  $(i, j)$
- $O \dots$   $n \times n \times m$  เป็นอะเรย์ขนาดสามมิติที่แสดงเป็นเอาท์พุทของนิเวศน์เน็ตเวิร์ค  $U \dots$
- $O_{ij}$   $m \times 1$  เป็นเวกเตอร์ที่แสดงเป็นเอาท์พุทของนิเวศน์เน็ตเวิร์ค  $U_{ij}$
- $O_{ijk}$  เป็นส่วนประกอบที่ลำดับที่  $K$  ที่แสดงเป็นค่าความน่าจะเป็นของจุดภาพ  $(i, j)$  ที่จะมีเครื่องหมายลำดับที่  $K$
- $A \dots$   $n \times n \times m$  เป็นอะเรย์ขนาดสามมิติที่แสดงเป็นอินพุทของนิเวศน์เน็ตเวิร์คที่ได้มาจากการป้อนกลับของ  $O \dots$
- $A_{ij}$   $m \times 1$  เป็นเวกเตอร์ที่แสดงเป็นเอาท์พุทของนิเวศน์เน็ตเวิร์ค  $U_{ij}$
- $A_{ijk}$  เป็นส่วนประกอบที่ลำดับที่  $K$  ที่แสดงเป็นค่าความน่าจะเป็นของจุดภาพ  $(i, j)$  ที่จะมีเครื่องหมายลำดับที่  $K$
- $\Omega_{ij}$  เป็นอะเรย์ขนาดสองมิติที่แสดงเป็นค่านำหนักของกลุ่มเพื่อนบ้านของจุดภาพ  $(i, j)$
- $p$  เป็นขนาดของอะเรย์สองมิติของน้ำหนักของเพื่อนบ้าน โดยมีจุดศูนย์กลางอยู่ที่ตำแหน่ง ดังนั้น  $p = |\Omega_{ij}| - 1$
- $N_{ij}$  เป็นอะเรย์ขนาดสามมิติของกลุ่มเพื่อนบ้านที่อยู่รอบ ๆ  $U_{ij}$  โดยมีข้อสังเกต คือ (1)  $\{U_{ijk}, k=1, \dots, m\} \subset N_{ij}$  และ (2)  $\{U_{qrk}, k=1, \dots, m\} \subset N_{ij}$  ถ้า  $(q, r) \neq (i, j)$  และจุดภาพ  $(q, r)$  ในรูปที่ 4 เป็นการแสดงเพื่อนบ้านขนาด  $(p = 3 \times 3 - 1 = 8$  และ  $m = 8)$ , เมื่อ
- $$N_{ij} = \{U_{(i-1)(j-1)}, U_{(i-1)j}, U_{(i-1)(j+1)}, U_{i(j+1)}, U_{(i+1)(j-1)}, U_{(i+1)j}, U_{(i+1)(j+1)}\}$$
- และ
- $$|N_{ij}| = p * m$$
- $H \dots$   $n \times n \times m$  เป็นอะเรย์ขนาดสามมิติที่แสดงเป็นผลบวกของอินพุทจากเพื่อนบ้าน
- $H_{ij}$   $m \times 1$  เป็นเวกเตอร์ที่แสดงเป็นผลบวกของอินพุทจาก  $N_{ij}$  ถึง  $U_{ijk}$  ในรูปที่ 5 เป็นการแสดงความสัมพันธ์ของ  $O_{ijk}, A_{ijk}, H_{ijk}, W_{ij,qr,k,l}$  เป็นค่านำหนักระหว่างนิเวศน์เน็ตเวิร์ค  $U_{qr} \in N_{ij}$  และ  $U_{ijk}$  ซึ่งค่านำหนักนี้จะมีลักษณะที่สมมาตรกัน คือ  $W_{ij,qr,k,l} = W_{qr,ij,l,k}$
- $f(i, j)$  เป็นค่าระดับเทาของจุดภาพ  $(i, j)$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

# สำนักหอสมุดกลาง พระจอมเกล้าลาดกระบัง

- d จำนวนของนิวรอนใน Kohonen's self-organizing feature map. โดยปกติแล้ว  $m = d$
- $I_i$  เป็นนิวรอนลำดับที่  $i$  ใน feature map เมื่อ  $i = 1, \dots, d$
- $N(I_k, r)$  เป็นเพื่อนบ้านของ  $I_k$  โดย  $r$  คือ รัศมีของเพื่อนบ้าน
- $\alpha$  เป็นอัตราการเรียนรู้ของ Feature map
- $w_i$  เป็นค่าน้ำหนักของนิวรอน  $I_i$ , ใน feature map,  $i = 1, \dots, d$



รูปที่ 4 เป็นการแสดงถึงความหมายของบริเวณใกล้เคียงเท่ากับ  $(3 \times 3 - 1) \times 8$  ในรูป (a) เป็นการแสดงความเชื่อมต่อของบริเวณที่ใกล้เคียงกันในรูปสี่เหลี่ยมโดยที่  $p = 8, m = 8$  ในทุก ๆ นิวรอน  $U_{ij}$  จะรับข้อมูลจากนิวรอน  $U_{(i-1)(j-1)}, U_{(i-1)j}, U_{(i-1)(j+1)}, U_{i(j+1)}, U_{(i+1)(j-1)}, U_{(i+1)j}, U_{(i+1)(j+1)}$  (b) เป็นการมองจากด้านบน (c) เป็นการมองแบบตัดขวาง

## 2.4 ขบวนการทำงานของอัลกอริทึม

ขั้นตอนของการทำงานของอัลกอริทึม เริ่มต้นโดยการสร้างค่าเริ่มต้นให้กับระบบโดยใช้นิวรอนเน็ตเวิร์คโมเดลของ Kohonen's self-organizing feature map ที่มีความสามารถในการเรียนรู้ข้อมูลโดยไม่ต้องใช้ฟังก์ชันเป้าหมาย ผลลัพธ์ที่ได้จะเป็นค่าน้ำหนัก ซึ่งเราจะนำมาใช้เป็นค่าเริ่มต้นให้กับระบบ โดยกำหนดให้เป็นค่าเอาท์พุทของ Recurrent นิวรอนเน็ตเวิร์คทุก ๆ ตัวซึ่งทำหน้าที่เป็นตัวแทนให้แก่จุดภาพทุก ๆ จุดภาพ ต่อจากนั้น Recurrent นิวรอนเน็ตเวิร์คจะทำการหาค่าที่ดีที่สุด ในขณะที่เดียวกันค่าทุก ๆ นิวรอนที่เป็นบริเวณใกล้เคียงซึ่งกันและกันก็จะมีการส่งค่าน้ำหนักให้กัน โดยที่ขั้นตอนเหล่านี้จะถูกทำซ้ำ ๆ ไปเรื่อยจนกระทั่งระบบมีการลู่เข้าหาคำตอบหรือมีค่าผิดพลาดน้อยจนรับได้ระบบก็จะหยุดทำงาน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


จากขั้นตอนที่กล่าวไว้ข้างบนนั้น เมื่อนำมาเขียนในทางคณิตศาสตร์ เพื่อที่จะนำไปสร้างเป็น โปรแกรมขึ้นมาได้ก็สามารถที่จะแสดงได้ ดังนี้

$$H \dots = \begin{bmatrix} H_{11} & H_{12} & \dots & H_{1n} \\ H_{21} & H_{22} & \dots & H_{2n} \\ \vdots & \vdots & \dots & \vdots \\ H_{n1} & H_{n2} & \dots & H_{nn} \end{bmatrix} \quad (1)$$

เมื่อ

$$H_{ij} = \begin{bmatrix} H_{ij1} \\ H_{ij2} \\ \vdots \\ H_{ijm} \end{bmatrix} = \begin{bmatrix} \sum_{U_{qrl} \in N_{ij}} W_{ij,qr,1,l} O_{qrl} \\ \sum_{U_{qrl} \in N_{ij}} W_{ij,qr,2,l} O_{qrl} \\ \vdots \\ \sum_{U_{qrl} \in N_{ij}} W_{ij,qr,m,l} O_{qrl} \end{bmatrix}$$

จากการสนับสนุนของเพื่อนบ้านจะมีคุณสมบัติเป็นดังนี้ : (1) ถ้าทั้ง  $O'_{qrl}$  และ  $W_{ij,ar,k,l}$  มีค่าเป็นบวกแล้ว  $O'_{qrl} W_{ij,ar,k,l}$  จะช่วยให้นิวรอล  $U_{ijk}$  มีค่าเป็นบวกมากขึ้น (2) ถ้า  $O'_{qrl}$  มีค่าสูง แต่ค่า  $W_{ij,ar,k,l}$  มีค่าต่ำแล้ว  $O'_{qrl} W_{ij,ar,k,l}$  จะช่วยให้นิวรอลที่  $U_{ijk}$  นั้นมีค่าเป็นลบมากขึ้น (3) ถ้า  $O'_{qrl}$  มีค่าสูงและ  $W_{ij,ar,k,l}$  มีค่าเท่ากับศูนย์แล้ว  $O'_{qrl} W_{ij,ar,k,l}$  จะไม่มีผลต่อ  $U_{ijk}$  โดยที่  $H_{ijk}$  จะเป็นตัวแทนของการสนับสนุนจากบริเวณที่ใกล้เคียงจะมีส่วนร่วมในการปรับค่าระดับการกระตุ้นของนิวรอล  $U_{ijk}$  หลังจากที่ได้รับสัญญาณจากบริเวณใกล้เคียง  $N_{ij}$  ทุก  $O_{ijk}$  จะมีการปรับค่า (Update) ให้เป็นไปตาม  $H_{ijk}$  และ  $A_{ijk}$  ในรายงานนี้  $A_{ijk}$  คือสัญญาณที่ป้อนกลับจาก  $O_{ijk}$  ดังนั้น  $A_{ijk} = O'_{ijk}$  โดยที่ขบวนการปรับค่าของ  $O \dots$  จะเป็นตามขั้นตอนดังนี้



รูปที่ 5 เป็นการแสดงความสัมพันธ์ระหว่าง  $O_{ijk}, A_{ijk}, H_{ijk}$  ได้มาจากการป้อนกลับของสัญญาณ

$$O_{ijk} \text{ และ } H_{ijk} = \sum_{U_{qrl} \in N_{ij}} W_{ij,qr,m,l} O_{qrl}, l=1, \dots, m$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับใช้ภายในเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$O^{t+1} = \begin{bmatrix} O_{11}^{t+1} & O_{12}^{t+1} & \dots & O_{1n}^{t+1} \\ O_{21}^{t+1} & O_{22}^{t+1} & \dots & O_{2n}^{t+1} \\ \vdots & \vdots & \dots & \vdots \\ O_{n1}^{t+1} & O_{n2}^{t+1} & \dots & O_{nn}^{t+1} \end{bmatrix} \quad (2)$$

$$= G \begin{bmatrix} A'_{11} & A'_{12} & \dots & A'_{1n} \\ A'_{21} & A'_{22} & \dots & A'_{2n} \\ \vdots & \vdots & \dots & \vdots \\ A'_{n1} & A'_{n2} & \dots & A'_{nn} \end{bmatrix} \begin{bmatrix} H'_{11} & H'_{12} & \dots & H'_{1n} \\ H'_{21} & H'_{22} & \dots & H'_{2n} \\ \vdots & \vdots & \dots & \vdots \\ H'_{n1} & H'_{n2} & \dots & H'_{nn} \end{bmatrix}$$

เมื่อ

$$A_{ij} = \begin{bmatrix} A_{ij1} \\ A_{ij2} \\ \vdots \\ A_{ijm} \end{bmatrix}, O_{ij} = \begin{bmatrix} O_{ij1} \\ O_{ij2} \\ \vdots \\ O_{ijm} \end{bmatrix}$$

และ G นิยามดังต่อไปนี้

$$O_{ijk}^{t+1} = \frac{\text{Pos}(A'_{ijk} + \Delta A'_{ijk})}{\sum_{l=1}^m \text{Pos}(A'_{ijl} + \Delta A'_{ijl})} \quad (3)$$

เมื่อ

$$\Delta A'_{ijk} = \begin{cases} \delta & \text{if } H'_{ijk} = \max(H'_{ijk}) \\ -\delta & \text{ในกรณีอื่น} \end{cases}$$

$$\text{Pos}(X) = \begin{cases} X & \text{if } X \geq 0 \\ 0 & \text{ในกรณีอื่น} \end{cases}$$

เมื่อ  $\delta$  จำนวนจริงที่มีค่าเป็นบวกน้อย ๆ ขบวนการจะมีการปรับค่า (Update) ของเอาท์พุท  
 ทุกๆ นิวรอลบนฐานของเอาท์พุทของนิวรอลบริเวณใกล้เคียง และค่าเอาท์พุทเก่าที่ผ่านมา ในการ  
 ออกแบบของกฎการปรับค่านี้คือ ยึดหลักการดังนี้ (1) ถ้า  $H'_{ijk}$  มีค่าสูงสุดแล้วจำนวนที่เป็นบวกจะมี  
 การกระจายผลไปยัง  $U_{ijk}$  ด้วย และ  $A'_{ijk}$  มีค่าที่เพิ่มขึ้นด้วย (2) ถ้า  $H'_{ijk}$  มีค่าไม่สูงสุดแล้วจะมีการ  
 กระจายผลไปยัง  $U_{ijk}$  และ  $A'_{ijk}$  ให้มีค่าที่ลดลงในสมการที่ (3) ในส่วนของ

$$\frac{1}{\sum_{l=1}^m Pos(A'_{ijl} + \Delta A'_{ijl})}$$
 เป็นกระบวนการปรับค่าไม่ให้มีค่าเกินกว่าหนึ่ง ดังนั้น ค่าสูงสุดของเอาท์พุท คือ 1 นั่นเอง

## 2.5 เงื่อนไขเริ่มต้น

วิธีการในการกำหนดเงื่อนไขเริ่มต้นนั้นเราจะยึดหลักการแบ่งโดยใช้การกระจายของระดับเทาของภาพที่เป็นอินพุท โดยใช้ Kohonen's self-organizing feature map เป็นแบบจำลองวิเคราะห์การกระจายของระดับเทาของภาพทางอินพุท หรือพูดได้อีกอย่างว่า โครงข่ายจะทำการแยกระดับเทาออกเป็นหลาย ๆ ระดับ ในการทำงานของแบบจำลองนี้จะมีอยู่สองส่วนด้วยกัน คือ ส่วนของการเรียนรู้ (Leaning Phase) และส่วนของการจัดแบ่ง (Categorization Phase) ในส่วนของการเรียนรู้เมื่อค่าระดับเทาของจุดภาพนั้นเข้ามาสู่เน็ตเวิร์คที่เป็นแบบมิติเดียว จะมีนิวรอลอยู่เพียงตัวเดียวเท่านั้นที่จะถือว่าตอบสนองต่ออินพุทที่เข้ามาได้อย่างดีที่สุด ดังนั้น นิวรอลตัวนั้นและบริเวณใกล้เคียงของมันจะมีการปรับค่าน้ำหนักในการคัดเลือกนิวรอลที่ชนะจะใช้หลักของการวัดระยะทางระหว่างค่าของอินพุทกับค่าของน้ำหนักโดยที่สูตรการหาระยะทางมีดังนี้

$$D_{I_l} = \|w_l - f(i, j)\| \quad l = 1, \dots, d$$

โดยสมมติให้

$$D_{I_k} = \min_{l=1, \dots, d} D_{I_l} \quad (4)$$

เมื่อ  $I_k$  เป็นนิวรอลที่ชนะ หลังจากที่ได้ค้นพบนิวรอลที่ชนะแล้ว ค่าน้ำหนักก็จะมีการปรับโดยมีสูตรคำนวณ ดังนี้

$$w_k^{t+1} = w_k^t + \alpha^t (f(i, j) - w_k^t) \quad (5)$$

เมื่อ  $w_k^t$  คือ ค่าน้ำหนักของนิวรอล  $I_k$  ลำดับที่  $k$  ก่อนที่จะมีการปรับค่าใหม่

$w_k^{t+1}$  เป็นค่าน้ำหนักหลังจากมีการปรับเรียบร้อยแล้วและ  $\alpha^t$  (มีค่าระหว่าง 0 กับ 1) เป็นค่าอัตราการเรียนรู้ที่เวลา  $t_k$  ในการปรับค่าน้ำหนักนั้นนอกจากนิวรอลที่ชนะแล้ว นิวรอลในบริเวณใกล้เคียง

เคียงก็จะมีการปรับค่าน้ำหนักใหม่เช่นกัน แต่จะน้อยกว่านิเวรอลที่ชนะ ซึ่งสูตรในการปรับค่าน้ำหนักของนิเวรอลในบริเวณใกล้เคียงมีดังต่อไปนี้

$$w_q^{t+1} = w_q^t + \alpha^t (f(i, j) - w_q^t) \quad (6)$$

เมื่อ  $I_q \in N(I_k, r)$  โดยที่เพื่อนบ้านของนิเวรอลลำดับที่  $k$  สามารถนิยามได้ ดังนี้

$$N(I_k, r) = \left\{ I_q \mid q = (k-r), (k-r+1), \dots, (k-1), (k+1), \dots, (k+r-1), (k+r) \right\}$$

if  $I_q$  exist and  $I_q \neq I_k$

และสูตรในการปรับกฎของการเรียนรู้ มีดังนี้

$$\alpha^{t+1} = K\alpha^t \quad (7)$$

เมื่อ  $K$  เป็นค่าพารามิเตอร์ที่มีขนาดไม่เกิน 1

โดยสรุปขั้นตอนของการปรับค่าน้ำหนักมีดังนี้

- (1) ทำการเริ่มต้นค่าน้ำหนักของ feature map
- (2) สำหรับทุก ๆ จุดภาพ  $(i, j)$  ในภาพที่เป็นอินพุตทำตามขั้นตอน ต่อไปนี้
  - (2.1) หานิเวรอลที่ชนะ  $I_k$  โดยใช้สูตรหาระยะทางในสมการที่ (4)
  - (2.2) ปรับค่าน้ำหนักของนิเวรอลที่ชนะ  $I_k$  โดยใช้สมการที่ (5)
  - (2.3) ปรับค่าน้ำหนักของเพื่อนบ้านของนิเวรอลที่ชนะ  $N(I_k, r)$  โดยใช้สมการที่ (6)

- (3) ปรับค่า  $\alpha$  โดยใช้สมการที่ (7)

(4) ถ้า  $\alpha > \epsilon$  ( $\epsilon$  เป็นค่าตัวเลขจำนวนน้อย ๆ) กลับไปเริ่มที่ขั้นตอนที่สองใหม่ จนกว่าเงื่อนไขเป็นจริง

ต่อไปเป็นการอธิบายในส่วนของ การจัดแบ่ง (Categorization Phase) เป็นขั้นตอนในการกำหนดค่าความน่าจะเป็นแบบไม่มีประสบการณ์ (Prior Probability) โดยยึดหลักการจัดแบ่งตามระดับเทาของจุดภาพที่ทำให้สอดคล้องกับนิเวรอลที่มีเครื่องหมาย  $L$  นั้นเกิด excited โดยการกำหนดจะให้ค่าความน่าจะเป็นมากสำหรับนิเวรอลที่มีเครื่องหมาย  $L$  มากที่สุดและจะน้อยลงไปในบริเวณนิเวรอลที่ใกล้เคียงกัน โดยขั้นตอนที่สามารถที่จะทำการอธิบายได้ ดังนี้

- (1) สำหรับทุก ๆ จุดภาพนั้นทำตามขั้นตอนที่สอง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

(2) กำหนดค่าเริ่มต้นให้กับอินพุตของ  $A_{ijk}^0$  กับทุก ๆ นิวรอนโดยให้สอดคล้องกับการ feature map ที่ได้เกิด excited โดยวิธีการกำหนดค่า มีดังนี้

ถ้า  $\|f(i, j) - w_l\| = \min_l \|f(i, j) - w_l\|$ , แล้ว

$$\begin{cases} A_{ij1}^0 = \frac{v_1}{m} \\ A_{ij2}^0 = \frac{v_2}{m} \\ \vdots \\ A_{ijm}^0 = \frac{v_m}{m} \end{cases} \quad (8)$$

เมื่อ

$$v_1 \geq v_2 \geq \dots \geq v_m \geq 0 \text{ และ } \sum_{i=1}^m v_i = m$$

จากการกำหนดอย่างนี้จะมีเพียงจำนวน  $v_i$  จำนวนน้อยที่ไม่เท่ากับ 0 จำนวนที่  $v_i$  ที่ไม่เท่ากับ 0 เราตั้งชื่อว่า  $s_1$

ถ้า  $\|f(i, j) - w_k\| = \min_l \|f(i, j) - w_l\|$ , แล้ว

$$\begin{cases} A_{ij1}^0 = \frac{y_1}{m} \\ \vdots \\ A_{ij(k-1)}^0 = \frac{y_{k-1}}{m} \\ A_{ijk}^0 = \frac{y_k}{m} \\ A_{ij(k+1)}^0 = \frac{y_{k+1}}{m} \\ \vdots \\ A_{ijm}^0 = \frac{y_m}{m} \end{cases} \quad (9)$$

เมื่อ

$$y_k \geq y_{(k-1)} \geq \dots \geq y_k \geq 0, y_k \geq y_{(k+1)} \geq \dots \geq y_m \geq 0 \text{ และ } \sum_{i=1}^m y_i = m$$

จากการกำหนดอย่างนี้ จะมีเพียงจำนวน  $y_i$  จำนวนน้อยที่ไม่เท่ากับ 0 จำนวนที่  $y_i$  ที่ไม่เท่ากับ 0 เราตั้งชื่อว่า  $s_2$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ถ้า  $\|f(i, j) - w_d\| = \min_i \|f(i, j) - w_i\|$ , แล้ว

$$\begin{cases} A_{ij1}^0 = \frac{z_1}{m} \\ A_{ij2}^0 = \frac{z_2}{m} \\ \vdots \\ A_{ij(m-1)}^0 = \frac{z_{(m-1)}}{m} \\ A_{ijm}^0 = \frac{z_m}{m} \end{cases} \quad (10)$$

เมื่อ

$$z_m \geq z_{m-1} \geq \dots \geq z_1 \geq 0 \text{ และ } \sum_{i=1}^m z_i = m$$

จากการกำหนดอย่างนี้ จะมีเพียงจำนวน  $z_i$  จำนวนน้อยที่ไม่เท่ากับ 0 จำนวนที่  $z_i$  ที่ไม่เท่ากับ 0 เราตั้งชื่อว่า  $s_3$

โดยปกติแล้ว ถ้าต้องการให้เน็ตเวิร์กคู่เข้าอย่างมีเสถียรภาพจะต้องเป็นตามเงื่อนไขสองข้อ คือ ข้อแรก การกำหนดค่าน้ำหนักเริ่มต้นจะต้องไม่เท่ากัน เพราะว่าการเรียนรู้ของของนิวโรลใช้ระยะทางระหว่างค่าน้ำหนักกับค่าระดับเทาของภาพทางอินพุต ดังนั้น จะต้องมียังนิวโรลตัวใดตัวหนึ่งเท่านั้นที่จะเกิด Excited ได้ ข้อที่สอง คือ ค่าของ  $\alpha$  จะต้องลดลงตามเวลาในทางปฏิบัติแล้ว ค่า  $\alpha$  สามารถลดลงอย่างเชิงเส้นได้ โดยที่ขบวนการในการเรียนรู้จะสิ้นสุดโดยอัตโนมัติเมื่อค่า  $\alpha$  เข้าใกล้ศูนย์

### 3. การกำหนดค่าน้ำหนัก

การกำหนดค่าน้ำหนักในระบบก็คือ การสร้างการถ่วงค่าระหว่างนิวโรลในบริเวณที่ใกล้เคียงซึ่งกันและกัน วิธีที่ใช้นี้เป็นวิธีการที่ได้จากการทดลองว่ามีความเหมาะสมผลก็คือ นิวโรลที่เป็นตัวแทนที่เหมือนกันนั้นย่อมจะแสดงผลในทางบวกต่อนิวโรลในบริเวณใกล้เคียงที่เป็นตัวแทนตัวเดียวกันของจุดภาพในบริเวณที่ใกล้เคียง และในทางที่กลับกันนั้นย่อมจะมีผลในทางลบกับตัวแทนอื่น ๆ ต่อบริเวณใกล้เคียงในทางคณิตศาสตร์เขียนได้เป็น

$$W_{ij,qr,k,l} = \frac{1}{p} \left( 1 - 2 \frac{|k-l|}{m} \right) \quad (11)$$

เมื่อ  $W_{ij,qr,k,l}$  เป็นค่าน้ำหนักระหว่างนิวรอนที่ทำหน้าที่เป็นตัวแทนของจุดภาพที่ลำดับ  $k$  ของจุดภาพ  $(i, j)$  กับนิวรอนที่ทำหน้าที่เป็นตัวแทนลำดับที่  $l$  ของจุดภาพ  $(q, r), U_{qr} \in N_{ij}$

#### 4. การรู้เข้าของ Recurrent Neural Network

หลังจากขั้นตอนของอัลกอริทึมผ่านเงื่อนไขเริ่มต้นแล้ว ก็จะถึงขบวนการทำซ้ำของ Recurrent นิวรอนเน็ตเวิร์ค และอัลกอริทึมจะสิ้นสุดลงตามเงื่อนไขต่อไปนี้

$$CE = \|O^{t+1} - O^t\|^2 < \epsilon \quad (12)$$

โดยค่า  $CE$  จะลดลงเรื่อยในกรณีอัลกอริทึมมีการทำซ้ำมากขึ้นจนกระทั่งมีค่าน้อยกว่า  $\epsilon$  ซึ่งเป็นตัวเลขจำนวนน้อยที่ทำหน้าที่ตรวจสอบเงื่อนไขในการจบการทำงานของอัลกอริทึม

#### 5. สรุปขั้นตอนการแบ่งแยกวัตถุในภาพ

ขั้นตอนการแบ่งแยกวัตถุจากภาพมีขั้นตอนโดยสรุปดังนี้

- (1) กำหนดเงื่อนไขเริ่มต้นที่ได้อธิบายไว้ในส่วนที่ 2.5 และกำหนดให้  $H_{jk}^0$  มีค่าเท่ากับศูนย์
- (2) หาค่าน้ำหนักระหว่าง Recurrent นิวรอนโดยใช้สมการที่ (8)
- (3) ตั้งค่า  $t = 0$
- (4) ทำการคำนวณ  $H^t \dots$  โดยใช้สมการที่ (1)
- (5) หา  $O^{t+1}$  โดยใช้สมการที่ (2)
- (6) คำนวณค่า  $CE$  ในสมการที่ (12)
- (7) ถ้าค่า  $CE > \epsilon$  แล้วตั้งค่า  $t = t + 1$  และกลับไปทำงานในขั้นตอนที่ 4 ใหม่ จนกระทั่งเงื่อนไขเป็นจริง

เมื่ออัลกอริทึมสิ้นสุดลง ค่าเอาต์พุตของนิวรอนในแต่ละคอลัมน์จะมีตัวใดตัวหนึ่ง ที่มีค่าสูงสุดและเราก็จะได้ตัวนั้นเป็นตัวแทนให้แก่จุดภาพจุดนั้น

#### 6. ผลลัพธ์ที่ได้จากการทดลอง

เพื่อแสดงความสามารถวิธีการนี้เราได้ทดลองโดยใช้ภาพขนาด  $256 \times 256$  พิกเซล โดยมีข้อมูลขนาด 8 บิต แบบระดับเทาและตั้งค่าพารามิเตอร์ของขบวนการไว้ดังนี้

$$d = m = 8, p = 8$$

$$\alpha = 0.9, r = 1, k = 0.9, \epsilon = 0.1$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$s_1 = s_2 = s_3 = 3$$

$$v_1 = 5, v_2 = 4, v_3 = 1, v_r = 0 \quad \text{สำหรับ} \quad 3 < r \leq m$$


$$y_k = 6, y_{(k+1)} = 2, y_{(k-1)} = 2, y_r = 0 \quad \text{สำหรับ} \quad r \neq k, (k+1), (k-1)$$

$$z_m = 5, z_{(m-1)} = 4, z_{(m-2)} = 1, z_r = 0 \quad \text{สำหรับ} \quad 1 \leq r < (m-2)$$

โดยที่ Kohonen's self-organizing feature map จะประกอบด้วยนิเวรอลจำนวน 8 นิเวรอล แบบมิตติเดียว ดังนั้น จำนวนนิเวรอลที่เป็นแบบ recurrent ทั้งหมดจะเท่ากับ  $256 \times 256 \times 8$  ตัว ภาพที่แสดงไว้นี้เป็นภาพในรูปแบบต่าง ๆ โดยการคัดเลือกภาพที่นำมาแสดงคำนึงถึงการกระจายของระดับเทาว่ามีความแตกต่างกันอย่างไร ภาพที่ทดสอบจะเป็นภาพ ขนาดข้อมูล 8 บิต ในการทดลองจะใช้ภาพที่เป็นแบบสีเทียมหรือ False colour โดยใช้ภาพทั้งจากแถบสีแดง เขียวและน้ำเงิน มารวมกันก่อนที่จะทำการจำแนกภาพ วิธีนี้จะทำให้ขั้นตอนการทำงานทั้งหมดเร็วขึ้นมากแทนที่จะทำทีละภาพ รูปที่ 6(a) เป็นภาพต้นแบบที่มีการกระจายของความเข้มตั้งแต่ 0-255 รูปที่ 6(b)-(h) เป็นผลลัพธ์จากการจำแนกภาพ ปัญหาที่พบก็คือพิกเซลบางค่าจะอยู่ระหว่างกลุ่มซึ่งยากต่อการแยกแยะให้ได้ขนาดว่าอยู่ในกลุ่มไหน ทั้งนี้เปอร์เซ็นต์ของการจำแนกผิดกลุ่มคิดเป็น 10-15% วิธีที่จะลดเปอร์เซ็นต์การผิดพลาดก็ต้องใช้ผู้เชี่ยวชาญในการแยกกลุ่มที่ได้จากผลลัพธ์ที่ได้จากนิเวรอลของ Kohonen ก่อนเพื่อขจัดจำนวนกลุ่มที่ไม่ควรมีให้น้อยลงและจัดการ overlap ของแต่ละกลุ่มให้น้อยที่สุดก่อนที่จะป้อนต้นแบบในการสอนให้แก่ นิเวรอลแบบ Recurrent เพื่อว่าประสิทธิภาพของอัลกอริทึมทั้งระบบจะดีขึ้นในการจำแนกภาพ โดยเฉพาะเปอร์เซ็นต์การจำแนกผิดพลาด




6(a)




6(b)


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



6(c)




6(d)



6(e)



6(f)



6(g)



6(h)

รูปที่ 6(a) เป็นภาพต้นแบบ และ (b)-(h) เป็นผลลัพธ์จากการจำแนกภาพ

## 7. บทสรุป

ในรายงานนี้เป็นการนำเสนอวิธีการในการนำเอาวิธีทฤษฎีนิเวศน์เน็ตเวิร์คมาใช้ในการแบ่งแยกวัตถุออกจากภาพโดยอัตโนมัติ ซึ่งข้อดีของการใช้นิเวศน์เน็ตเวิร์คคือการทำงานแบบขนานทำให้ระบบสามารถแบ่งแยกวัตถุในภาพได้ดีมากขึ้นเพราะเมื่อมีการทำงานอย่างขนานแล้ว การตัดสินใจของนิเวศน์เน็ตเวิร์คแต่ละตัวสามารถที่จะหาค่าที่ดีที่สุดได้ (Global Satisfaction) ด้วยการเชื่อมโยงเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ต่อทุกๆนิเวศด้วยน้ำหนักที่ต่างกัันซึ่งมีความเป็นเหตุผล ในแง่ของการจำแนกวัตถุ เงื่อนไขการเริ่มต้นนั้นได้ใช้โมเดล Kohonen's self-organizing feature map ทำหน้าที่ในการจัดเคอร์รี่ ซึ่งจำนวนของนิเวศมากน้อยมีผลต่อ การแบ่งแยกภาพมากพอสมควรหลังจากนั้นเราจะใช้หลักการของ CSP คือทุกๆพิกเซลคือวัตถุและต้องการสิ่งที่มาแทนวัตถุได้อย่างเหมาะสม เรียกสิ่งทีแทนว่าลาเบล ซึ่งด้วยเหตุนี้เน็ตเวิร์คที่ถูกสร้างขึ้นจาก Recurrent neural network ให้แก่ทุกๆวัตถุจะเท่ากับจำนวนของลาเบลที่ระบบนั้นต้องการและทุกนิเวศจะถูกเชื่อมต่อเข้าด้วยกันโดยใช้ค่าน้ำหนัก ข้อดีของการใช้น้ำหนักของบริเวณใกล้เคียงมาช่วยในการตัดสินใจของนิเวศคือระบบสามารถที่จะทนต่อสัญญาณรบกวนได้สูงขึ้นและมีโอกาสเกิดค่าที่ดีที่สุด (ลาเบล) ของทั้งภาพได้ (Global Optimization) ได้ง่ายกว่าอัลกอริทึมที่ทำงานในแบบลำดับ ข้อเสียของระบบนี้คือการใช้เวลาในการคำนวณที่นาน และการเก็บรายละเอียดไม่ดีพอ สาเหตุเกิดจากการที่นิเวศบริเวณใกล้เคียงส่งผลมากเกินไป

#### เอกสารอ้างอิง

- [1] Wei-Chung Lin, "Constraint Satisfaction Neural Networks for Image Network," Pattern Recognition, Vol. 25, No. 7, pp. 679-693, 1992.
- [2] F. Rosenblatt, "The perceptron : a probabilistic model for information storage and organization in the brain," Psychological Review, Vol. 65, pp. 513-408, 1966.
- [3] Teuvo Kohonen, "Self-organized formation of topologically correct feature maps," Biological Cybernetics, Vol. 43, pp. 59-69, 1982.
- [4] J. J. Hopfield, "Neural networks and physical systems with emergent collective computational ability," Proceedings of the National Academy of Sciences, Vol. 79, pp. 2554-2558, 1982.