

บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 โมบายล์เอเจนต์

นิยาม

เอเจนต์มีคำนิยามไว้หลายความหมายด้วยกัน เช่น

Wooldridge (1997) ได้ให้คำนิยามว่า “เอเจนต์เป็นโปรแกรมที่สมบูรณ์ในตัวเอง โดยรวมเอาการควบคุมการตัดสินใจเกี่ยวกับการกระทำ โดยดูจากวัตถุประสงค์ ซึ่งมีพื้นฐานอยู่บนสิ่งแวดล้อมของตนเอง”

Jennings และ Wooldridge (1995) ได้ให้คำนิยามว่า “เอเจนต์เป็นระบบคอมพิวเตอร์ที่ถูกห่อหุ้ม ซึ่งเหมาะกับสภาพแวดล้อมบางอย่าง มีความยืดหยุ่น และการกระทำที่เป็นแบบอัตโนมัติต่อสิ่งแวดล้อม ซึ่งได้มาจากการออกแบบ”

2.1.1 โครงสร้างการทำงาน

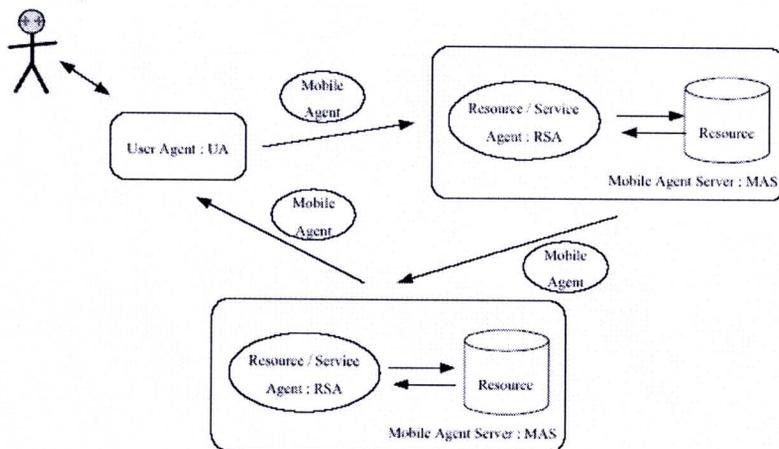
โครงสร้างการทำงานของโมบายล์เอเจนต์โดยทั่วไปแบ่งออกเป็น 4 ส่วน ดังแสดงในรูปที่ 2-1 โดยมีรายละเอียดดังต่อไปนี้

User Agent (UA) ทำหน้าที่เป็นตัวกลางในการติดต่อระหว่างผู้ใช้บริการกับตัวโมบายล์เอเจนต์ โดยเริ่มต้นการทำงานผู้ใช้บริการจะกำหนดลักษณะของข้อมูล ที่ต้องการให้กับ UA และสร้างตัวโมบายล์เอเจนต์ขึ้นมาเพื่อให้สอดคล้องกับสิ่งที่ผู้ใช้บริการต้องการแล้วส่งโมบายล์เอเจนต์ไปประมวลผลยังเซิร์ฟเวอร์ต่างๆ เพื่อให้ได้ข้อมูลที่ต้องการ เมื่อเสร็จสิ้นการประมวลผลแล้วโมบายล์เอเจนต์จะกลับมายัง UA โดย UA จะแปลงข้อมูลที่ได้จากโมบายล์เอเจนต์ให้เป็นรูปแบบที่ผู้ใช้บริการต้องการอีกครั้งหนึ่ง

Mobile Agent Server (MAS) ทำหน้าที่เป็นตัวกลางในการติดต่อระหว่างโมบายล์เอเจนต์และ RSA (Service/Resource Agent) โดยหน้าที่สำคัญคือกำหนดสถานะแวดล้อมต่างๆ ที่เหมาะสมสำหรับการประมวลผลให้กับโมบายล์เอเจนต์ เพื่อให้โมบายล์เอเจนต์ได้ใช้ทรัพยากรที่มีได้อย่างคุ้มค่า และเพื่อให้สามารถทำงานร่วมกับ RSA ได้อย่างมีประสิทธิภาพ

Service/Resource Agent (RSA) เป็นส่วนที่ทำหน้าที่ในการเข้าถึงข้อมูลที่ต้องการในการประมวลผลของโมบายล์เอเจนต์ ซึ่งส่วนใหญ่คือฐานข้อมูลนั่นเอง โดยจะทำงานควบคู่กับ MAS

Mobile Agent (MA) โมบายล์เอเจนต์เป็นโค้ดที่ถูกสร้างขึ้นโดยผู้ใช้บริการ เพื่อไปประมวลผลที่เซิร์ฟเวอร์ แล้วส่งข้อมูลที่ได้กลับไปยังผู้ใช้บริการ



รูปที่ 2-1 โครงสร้างการทำงานของโมบายล์เอเจนต์

2.2 ขั้นตอนวิธีระบบอาณานิคมมด (Ant Colony Algorithm)

เป็นขั้นตอนวิธีการค้นหาซึ่งมีรากฐานมาจากการศึกษาพฤติกรรมกลุ่มของมด (Dorigo et al., 1997; Bonabeau et al., 1999) ขั้นตอนวิธีนี้เหมาะกับการแก้ปัญหาการหาค่าเหมาะที่สุดเชิงการจัด ซึ่งเป็นปัญหาที่มีลักษณะเดียวกับปัญหาการเดินทางของพนักงานขาย หรือ ทีเอสพี โดยมดจะเลือกเดินทางจากเมืองหนึ่งไปยังเมืองถัดไป โดยใช้ข้อมูลระยะทาง และปริมาณฟีโรโมนที่ถูกทิ้งไว้บนเส้นทางระหว่างเมืองต่างๆ ฟีโรโมนเป็นสารชนิดหนึ่งที่ถูกทิ้งไว้บนเส้นทางโดยมดตัวอื่นซึ่งเคยเดิน ผ่านเส้นทางนั้นมาก่อน

ขั้นตอนวิธีนี้ประกอบไปด้วยสามส่วนหลักด้วยกันคือ กฎการเปลี่ยนสถานะ กฎการปรับฟีโรโมนเฉพาะที่ และกฎการปรับฟีโรโมนวงกว้าง ดังนี้

2.2.1 กฎการเปลี่ยนสถานะ (State Transition Rule)

มดจะมีการเดินทางหรือเปลี่ยนสถานะจากเมืองหนึ่งไปอีกเมืองหนึ่ง โดยอาศัยกฎการเปลี่ยนสถานะ กฎนี้ประกอบไปด้วยสองทางเลือกที่เป็นไปได้ นั่นคือ การเลือกสำรวจเพื่อหาผลเฉลยที่เป็นไปได้ใหม่ (exploration) หรือการเลือกผลเฉลยโดยอาศัยความรู้เดิมที่มีอยู่ก่อนแล้ว (exploitation) ให้มด k อยู่ที่ เมือง r เลือกที่จะเปลี่ยนสถานะไปอยู่ที่เมือง s โดย

$$s = \begin{cases} \arg \max_{u \in J_k(r)} \{ [\tau(r,u)] \cdot [\eta(r,u)]^\beta \} & \text{if } q \leq q_0 \\ S & \text{if } q > q_0 \end{cases} \quad \dots(1)$$

เมื่อ q_0 เป็นตัวเลขสุ่มที่มีการกระจายสม่ำเสมอในช่วงศูนย์ถึงหนึ่ง และเป็นความน่าจะเป็นที่จะเลือกจากความรู้เดิมที่มีอยู่ ($0 \leq q_0 \leq 1$) β เป็นเลขยกกำลังสำหรับคำนวณผลคูณระหว่างฟีโรโมน

กับความใกล้ $\tau(r, u)$ แสดงถึงปริมาณฟีโรโมนบนเส้นทางเดินระหว่างเมือง r และ u ส่วน $J_k(r)$ เป็นเซตของเมืองที่มด k ยังไม่เคยเดินทางไปมาก่อน โดยปัจจุบันมดอยู่ที่เมือง r และ s คือเมืองที่จะถูกเลือก ถ้ามด k ตัดสินใจที่จะทำการสำรวจ ความน่าจะเป็นที่มด k ซึ่งอยู่ที่เมือง r จะเลือกเดินทางไปยังเมือง S ซึ่ง $p_k(r, S)$ ถูกกำหนดโดย

$$p_k(r, S) = \begin{cases} \frac{[\tau(r, S)] \cdot [\eta(r, S)]^\beta}{\sum_{u \in J_k(r)} [\tau(r, u)] \cdot [\eta(r, u)]^\beta} & \text{if } S \in J_k(r) \\ 0 & \text{other} \end{cases} \quad \dots(2)$$

จากสมการที่ (1) ถ้ามดเลือกที่จะใช้ความรู้เดิมที่ได้รับมาจากมดตัวอื่นๆ มด จะเลือกเดินทางโดยกำหนดจากเส้นทางที่ให้ผลคุณระหว่างฟีโรโมนกับความใกล้ที่มากที่สุด ในกรณีที่มดเลือกที่จะสำรวจเส้นทางใหม่ จากสมการที่ (2) เส้นทางที่มีผลคุณระหว่างฟีโรโมนกับความใกล้มากเท่าไร ก็มีโอกาที่จะถูกเลือกมากขึ้นเท่านั้น หลังจากที่มีมดทำการเปลี่ยนสถานะ มดจะทิ้งฟีโรโมนจำนวนหนึ่งบนเส้นทางที่เดินผ่าน

2.2.2 กฎปรับเปลี่ยนฟีโรโมนเฉพาะที่ (Local Updating Rule)

หลังจากที่มีมดได้เดินทางจากเมือง r ไปยังเมือง s ระดับฟีโรโมนบนเส้นทางระหว่างเมือง r และ s จะถูกปรับโดยสมการ

$$\tau(r, s) \leftarrow (1 - \rho) \cdot \tau(r, s) + \rho \cdot \Delta\tau(r, s) \quad \dots(3)$$

เมื่อ ρ คือ อัตราการปรับฟีโรโมนเฉพาะที่ ($0 \leq \rho \leq 1$) และ $\Delta\tau(r, s) = \tau_0$ เป็นแฟคเตอร์การปรับฟีโรโมน

2.2.3 กฎปรับฟีโรโมนวงกว้าง (Global Updating Rule)

เมื่อมดทุกตัวในอาณานิคมได้เดินทางครบรอบโดยผ่านครบทุกเมืองแล้ว เส้นทางที่เดินทางได้สั้นที่สุดจะได้รับปริมาณฟีโรโมนเพิ่มเติมอีก ซึ่งกำหนดจากกฎการปรับฟีโรโมนวงกว้างดังสมการ

$$\tau(r, s) \leftarrow (1 - \alpha) \cdot \tau(r, s) + \alpha \cdot \Delta\tau(r, s) \quad \dots(4)$$

กฎการปรับฟีโรโมนทั้งแบบเฉพาะที่และวงกว้าง ซึ่งจะมีความคล้ายคลึงกัน แต่มีข้อแตกต่างเพียงอย่างเดียวคือ ภายหลังจากที่ฟีโรโมนของเส้นทางทุกเส้นทางที่ให้การเดินทางที่สั้นที่สุดมีการระเหยไปจำนวนหนึ่งเส้นทางเหล่านี้จะได้รับฟีโรโมนเพิ่มขึ้นอีกตามส่วนกลับของความยาวของเส้นทางที่ดีที่สุดจากทุกเส้นทาง

2.3 ขั้นตอนวิธีต้นไม้การตัดสินใจ (Decision tree Algorithm)

Decision trees เป็นชื่อเรียกทั่วไปของโมเดลที่สร้างในรูปแบบโครงสร้างต้นไม้ โดยมีขั้นตอนวิธีหลายแบบที่นำมาสร้างเป็น Decision tree ได้ โดยแต่ละขั้นตอนวิธีจะมีโครงสร้างต้นไม้ที่แตกต่างกัน โมเดลขั้นตอนในการสร้าง Decision tree เพื่อใช้จำแนกข้อมูล มีดังนี้

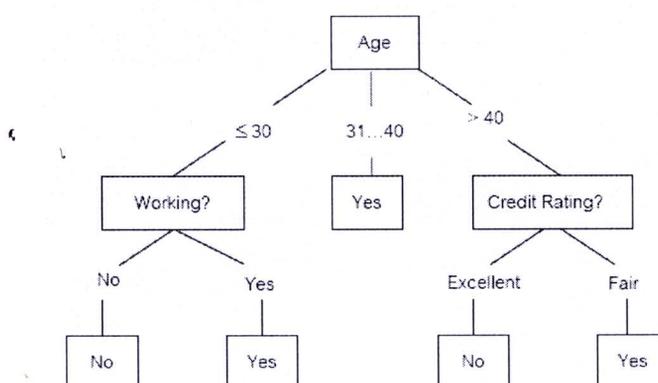
1. เลือกปัจจัยที่ทำหน้าที่เป็น Root node
2. จาก Root node สร้างเส้นทางเชื่อมโยงไปยังโหนดลูก จำนวนเส้นทางเชื่อมจะเท่ากับจำนวนค่าที่เป็นไปได้ทั้งหมดของปัจจัยที่เป็น Root node
3. ถ้าโหนดลูกเป็นกลุ่มของข้อมูลที่อยู่ในคลาสเดียวกันทั้งหมดให้หยุดการสร้าง tree แต่ถ้าโหนดลูกมีข้อมูลของหลายคลาสปะปนกันอยู่ ต้องสร้าง Subtree เพื่อจำแนกข้อมูลต่อไป โดยเลือกปัจจัยมาทำหน้าที่เป็น Root node ของ Subtree และทำซ้ำในขั้นตอนที่ 2

ตารางที่ 2-1 ตัวอย่างข้อมูลในการสร้าง Decision tree

Age	Income	Working	Credit Rating	Product Y
≤ 30	High	No	Fair	No
≤ 30	High	No	Excellent	No
31 ... 40	High	No	Fair	Yes
> 40	Medium	No	Fair	Yes
> 40	Low	Yes	Fair	Yes
> 40	Low	Yes	Excellent	No
31 ... 40	Low	Yes	Excellent	Yes
≤ 30	Medium	No	Fair	No
≤ 30	Low	Yes	Fair	Yes
> 40	Medium	Yes	Fair	Yes
≤ 30	Medium	Yes	Excellent	Yes
31 ... 40	Medium	No	Excellent	Yes
31 ... 40	High	Yes	Fair	Yes
> 40	Medium	No	Excellent	No

จากตารางมี Class labels (Product Y) กำหนดไว้ 2 ค่า คือ Yes, No และ สิ่งที่น่าสนใจคือ อายุ รายได้ การทำงาน และเครดิต โดย

- อายุ แบ่งออกไว้ 3 ค่า คือ อายุต่ำกว่า 30 อายุระหว่าง 31 ถึง 40 และอายุ 40 ปีขึ้นไป
- รายได้ แบ่งออกได้ 3 ค่า คือ High, Medium และ Low
- การทำงาน แบ่งออกได้ 2 ค่า คือ Yes, No
- เครดิต แบ่งออกได้ 2 ค่า คือ Fair, Excellent



รูปที่ 2-2 ตัวอย่าง Decision Tree for “Product Y”

จากตัวอย่างข้างต้น การใช้อายุเป็นตัวแบ่งเริ่มต้น แล้วตามด้วยการทำงาน หรือ เครดิต การใช้ตัวแบ่งแตกต่างกันไป ก็จะได้โครงสร้างที่แตกต่างกันด้วย ทำให้เกิดขึ้นตอนวิธีต่างๆ กันไป

2.4 Support Vector Machines (SVM)

Support Vector Machine หรือ SVM จุดมุ่งหมายที่สำคัญของแนวคิด SVM คือการหาเส้นแบ่ง Hyperplane ซึ่งใช้แบ่งข้อมูลออกเป็นคลาสเพื่อให้ ได้ผลลัพธ์ที่ดี โดยพิจารณาจากสมการเส้นตรง Hyper plane และ SVM จะทำการค้นหาจุดของข้อมูลที่ อยู่ใกล้เส้นแบ่ง Hyper plane ซึ่งจุดนั้นเรียกว่า “Support Vector” มีหลักการดังนี้

1. นำข้อมูลคำนวณหาค่า y ซึ่งค่า $y \in \{-1,1\}$ จากสมการ

$$y = w^T x + b \quad \dots(5)$$

2. คำนวณหาเส้นแบ่ง ซึ่งเรียกว่าเส้น Optimal Hyperplane จากสมการ

$$w^T x + b = 0 \quad \dots(6)$$

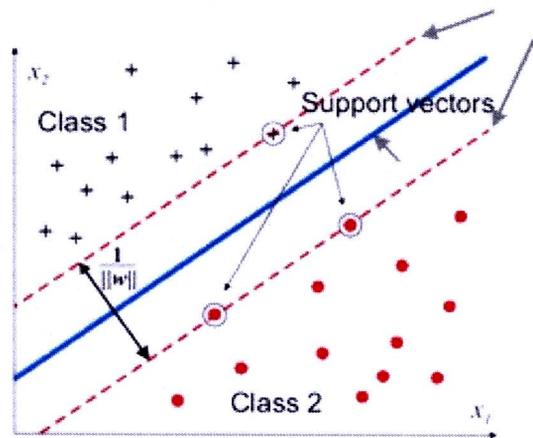
3. ระยะทาง (d) หรือ maximum margin จากเส้นขอบ ณ จุด x_i ไปยัง hyperplane แสดงดังสมการ

$$d = \frac{|w^T x_i + b|}{\|w\|} \quad \dots(7)$$

เมื่อ w คือ เวกเตอร์น้ำหนัก (Weight Vector)

x_i คือ Input

b คือ ค่าคงที่ที่กำหนดขึ้นเพื่อให้เหมาะสมกับการจัดกลุ่ม



รูปที่ 2-3 การแบ่งกลุ่มข้อมูลโดย Support Vector Machines

4. เลือกจุดที่อยู่ใกล้เส้นตรง Optimal Hyperplane ทั้งเหนือเส้นซึ่งเรียกว่า “ขอบล่าง” ซึ่งเป็นขอบล่างสุดของ class ข้อมูลที่อยู่เหนือเส้นตรง Optimal Hyperplane และได้เส้นเรียกว่า “ขอบบน” ซึ่งเป็นขอบบนสุดของ class ข้อมูลที่อยู่ใต้เส้นตรง Optimal Hyperplane เพื่อหาระยะทางระหว่างเส้นขอบทั้งสองโดยจะเลือกเอาค่าระยะทางที่ห่างจากเส้นตรง Optimal Hyperplane ที่น้อยที่สุดเป็นตัวเลือกในการจัดกลุ่มเอกสาร

2.5 การทบทวนวรรณกรรม/สารสนเทศ (Information) ที่เกี่ยวข้อง

Ali และคณะ (2007) ได้นำเสนองานวิจัยเรื่อง Optimizing Mobile Agents Migration Based on Decision Tree Learning โดยศึกษาการเคลื่อนที่ของโมบายล์เอเจนต์บนพื้นฐานของต้นไม้การตัดสินใจ (Decision tree) ภายใต้ข้อมูลการจราจรบนเครือข่าย (Network traffic) ที่เกิดขึ้น ซึ่งทำการวิเคราะห์โดยการจัดกลุ่มข้อมูลการจราจรบนเครือข่ายโดยการใช้ Naïve bayes และการประยุกต์ใช้ขั้นตอนวิธีในการเรียนรู้ต้นไม้ตัดสินใจ (Decision tree learning algorithm) ในการตัดสินใจของโมบายล์เอเจนต์ในการเคลื่อนที่เพื่อให้ได้เส้นทางที่ดีที่สุดจากโหนดหนึ่งไปยังโหนดหนึ่ง พบว่าเมื่อถ้าจำนวนของโหนดและ เอเจนต์มีขนาดเล็ก ประสิทธิภาพในการทำงานของแบบ OSFP ดีกว่าวิธีที่นำเสนอ แต่เมื่อจำนวนของโหนดและเอเจนต์เพิ่มมากขึ้น ประสิทธิภาพในการทำงานของวิธีที่นำเสนอ ดีกว่าแบบ OSFP

Ma และคณะ (2008) ได้นำเสนองานวิจัยเรื่อง Solution to Traveling Agent Problem Based on Improved Ant Colony Algorithm โดยได้นำแนวคิดมาจากมาจาก Basic Ant Algorithm ซึ่งเป็นขั้นตอนวิธีที่เลียนแบบมาจากพฤติกรรมการออกหาอาหารของมด ซึ่งได้ปรับปรุงให้ดีขึ้นเพื่อแก้ปัญหาการเดินทางของเอเจนต์ ซึ่งได้กำหนดกฎในการปรับปรุงฟีโรโมน และจากพฤติกรรมของมดที่นำมาใช้ในการหาเส้นทางของโมบายล์เอเจนต์ เมื่อเวลาผ่านไประยะหนึ่งการสะสมของฟีโรโมนจะมีปริมาณมากในเส้นทางเดียว ดังนั้นจึงนำมาสู่สภาวะการหยุดนิ่ง ทำให้เกิด ปัญหาค่าต่ำสุดเฉพาะที่ (Local minimum) ขึ้น ดังนั้น งานวิจัยนี้จึงได้นำ Mutation Operator มาใช้ในเพื่อแก้ปัญหาที่ช่วย

Zhang และคณะ (2007) ได้นำเสนองานวิจัยเรื่อง An Improved Migration Strategy of Mobile Agent โดยได้นำเอา Support Vector Machine (SVM) มาใช้ในการปรับปรุงกลยุทธ์ในการย้ายการทำงานของโมบายล์เอเจนต์ ซึ่งโดยทั่วไปในการตัดสินใจย้ายการทำงานของโมบายล์เอเจนต์ โดยส่วนใหญ่จะพิจารณาปัจจัยทางด้านซอฟต์แวร์ แต่งานวิจัยนี้ได้นำเอาปัจจัยทางด้านฮาร์ดแวร์มาร่วมในการพิจารณาด้วย ซึ่งวิธีการที่นำเสนอจะเก็บรวบรวมข้อมูลในการทำงานของโมบายล์เอเจนต์ตามโฮสต์ต่างๆ ซึ่งข้อมูลรวมไปถึงพารามิเตอร์ทางด้านฮาร์ดแวร์ และเวลาในการทำงานของโมบายล์เอเจนต์ด้วย และปัญหาที่พบเป็นแบบ multi-classification pattern recognition problem และใช้ SVM ในการแก้ปัญหาและเลือกโฮสต์ในการทำงานให้กับโมบายล์เอเจนต์