

บทที่ 3

ความรู้พื้นฐานที่เกี่ยวข้องกับงานวิจัย

ในบทนี้จะกล่าวถึงองค์ความรู้ที่เป็นพื้นฐานในงานวิจัยนี้ ซึ่งได้แก่ ทฤษฎีที่เกี่ยวข้องกับอีเมล องค์ประกอบของอีเมล ความรู้พื้นฐานเกี่ยวกับทฤษฎีเบย์เซียน (Bayesian Theorem) ความรู้พื้นฐานเกี่ยวกับแผนการตัดสินใจ (Decision Tree) และความรู้พื้นฐานเกี่ยวกับกระบวนการเจเนติกอัลกอริทึม (Genetic Algorithm)

3.1 ทฤษฎีที่เกี่ยวข้องกับอีเมล


3.1.1 ความเป็นมาของอีเมล

บทความ[14] ได้กล่าวว่า อีเมลหรือจดหมายอิเล็กทรอนิกส์ ได้มีการใช้งานมานานแล้ว ตั้งแต่ยุคของเครื่องเมนเฟรมหรือมินิคอมพิวเตอร์ ซึ่งไอบีเอ็มได้พัฒนาระบบที่เรียกว่า PROFS (Professional Office System) ออกมาใช้งาน นอกจากนี้ยังมีระบบ UNIX อีกด้วย ต่อมาหลายค่ายก็ได้พัฒนาระบบอีเมลของตนเองขึ้นมา โดยส่วนใหญ่จะเป็นองค์ประกอบในแอปพลิเคชันที่ทำงานบนระบบเครือข่าย เช่น ไมโครซอฟต์เมล (Microsoft Mail) ของไมโครซอฟต์, ซีซีเมล (CC Mail) ของโลดัส ซึ่งต่างก็ได้ใช้เทคโนโลยีของตนเองและเป็นระบบปิด ดังนั้นการส่งเมลไปยังผู้ใช้ที่มีระบบเมลคนละค่ายกันจึงเป็นเรื่องที่ยุ่งยาก ในยุคต่อมาได้มีระบบเครือข่าย แลน (LAN) และ แวน (WAN) ซึ่งต่างมีมาตรฐานและเป็นระบบเปิดมากขึ้น จึงมีการปรับเปลี่ยนการทำงานของระบบเมลมาเป็นแบบไคลเอนท์-เซิร์ฟเวอร์ (Client-Server) ที่เป็นพื้นฐานที่ใช้กันในระบบยูนิกซ์ (Unix) และมีการพัฒนาอีเมลเซิร์ฟเวอร์ (Email Server) ทั้งในรูปแบบที่เป็นการใช้งานผ่านระบบ LAN หรือ ใช้งานผ่าน modem ที่เชื่อมต่ออยู่กับระบบ WAN ทำให้ผู้ใช้ไม่สามารถมองเห็นและเข้าถึงไฟล์ในฮาร์ดดิสก์บนเครื่องเซิร์ฟเวอร์ได้ ดังนั้นความปลอดภัยของระบบจึงมีมากขึ้น จนในปัจจุบัน ได้พัฒนาขึ้นมาเป็นระบบเวิร์กโฟลว์ (Workflow) ที่ใช้อีเมลเป็นพื้นฐาน

3.1.2 ลักษณะการทำงานของระบบรับ-ส่งอีเมล

การรับ-ส่งอีเมลจะมีลักษณะดังรูปที่ 3.1 โดยเริ่มจากผู้ส่ง (Sender) ทำการสร้าง หรือ เขียนอีเมลขึ้นมาตามวัตถุประสงค์ที่ต้องการ จากนั้นทำการกดปุ่มส่งโดยผ่านโปรโตคอล (Protocol) ส่งไปยังเครื่องเมลเซิร์ฟเวอร์ต้นทาง ดังขั้นตอนที่ 1 จากนั้นเมลเซิร์ฟเวอร์จะส่งไปยังเครื่องที่เป็นรีเลย์โฮสต์ (Relay Host) ต้นทาง เนื่องจากรีเลย์โฮสต์เป็นเครื่องที่สามารถติดต่อกับระบบเครือข่ายภายนอกได้ ดังขั้นตอนที่ 2 (โดยทั่วไปเมลเซิร์ฟเวอร์อาจทำหน้าที่เป็นรีเลย์โฮสต์ในเครื่องเดียวกันก็ได้ ถ้าเป็นเช่นนี้ก็จะไม่มีขั้นตอนที่ 2 เกิดขึ้น) จากรีเลย์โฮสต์ต้นทางเมื่อได้รับเมลมาแล้ว จะติดต่อ


กับรีเลย์โฮสต์ปลายทางเพื่อส่งเมลฉบับนี้ไปดังขั้นตอนที่ 3 และในกรณีเดียวกัน ถ้าเครื่องรีเลย์โฮสต์ปลายทางกับเครื่องเมลเซิร์ฟเวอร์ปลายทางเป็นเครื่องเดียวกันจะไม่มีขั้นตอนที่ 4 เมื่อเมลไปถึงเมลเซิร์ฟเวอร์ปลายทางเรียบร้อยแล้วนั้นคือจบกระบวนการส่งเมล เมื่อผู้รับเช็คเมล ไม่ว่าจะใช้วิธีไหนก็ตามก็จะต้องติดต่อกับเครื่องเมลเซิร์ฟเวอร์ของตนเอง เพื่อนำเมลฉบับนั้นมาอ่าน ในที่นี้เครื่องเมลเซิร์ฟเวอร์หรือเครื่องรีเลย์โฮสต์ก็จะทำหน้าที่เหมือนกับที่ทำการไปรษณีย์นั่นเอง



รูปที่ 3.1 แสดงลักษณะการทำงานของระบบอีเมล

3.1.3 สถาปัตยกรรมของระบบเมล

ทีซีพี/ไอพี (TCP/IP) มีโปรโตคอลที่สนับสนุนการรับ-ส่งอีเมลหลายโปรโตคอล แต่โปรโตคอลที่นิยมใช้ในอินเทอร์เน็ตคือ SMTP (Simple Mail Transport Protocol) หน้าที่ของ SMTP คือการกำหนดกรรมวิธีและแบบแผนการนำส่งข้อความระหว่างผู้รับและผู้ส่ง โดย SMTP อาศัยทีซีพีเพื่อลำเลียงจดหมายผ่านพอร์ต 25 ระบบเมลที่ใช้ในทีซีพี/ไอพี มีองค์ประกอบสองส่วนคือตัวแทนผู้ใช้ (User Agent :UA) หรืออาจจะเรียกว่าตัวแทนผู้ใช้เมล (Mail User Agent : MUA) และตัวแทนขนส่งเมล (MTA :Mail Transfer Agent) ทั้งตัวแทนผู้ใช้และตัวแทนขนส่งเมลเป็นชื่อที่นำมาจากระบบ X.400 ซึ่งเป็นมาตรฐานที่นานาชาติกำหนดไว้เพื่อการนำส่งอีเมล



รูปที่ 3.2 แสดงสถาปัตยกรรมในทีซีพี/ไอพี

จากรูปที่ 3.2 ตัวแทนผู้ใช้งานทำหน้าที่ในการติดต่อกับผู้ใช้เพื่อรับและส่งอีเมล ซึ่งรูปแบบของการติดต่อมี 3 แบบ ดังนี้

1. การติดต่อโดยตรงหรือประมวลผลบนเครื่องที่เก็บเมลบ็อกซ์ (Mailbox) อยู่เลย ซึ่งโปรแกรมที่ใช้ในการรับส่งเมลที่นิยมกันบน Linux/Unix ก็เช่น /bin/mail, mailx, pine, elm เป็นต้น โดยการใช้งานจริงอาจจะด้วยการเทลเน็ต (Telnet) จากเครื่องคอมพิวเตอร์ส่วนบุคคลเข้าไปยังเครื่องที่เป็นเมลเซิร์ฟเวอร์แล้วใช้งานโปรแกรมห้างกล่าวบนเมลเซิร์ฟเวอร์

2. การทำงานแบบไคลเอนท์-เซิร์ฟเวอร์โดยเครื่องที่เป็นเมลไคลเอนท์จะติดต่อกับเครื่องเมลเซิร์ฟเวอร์โดยผ่านโปรโตคอลสำหรับการจัดการโดยเฉพาะ เช่น POP3 (Post Office Protocol version 3) หรือ IMAP 4 (Internet Mail Access Protocol version 4) เพื่อให้ดึงเมลจากเมลบ็อกซ์บนเซิร์ฟเวอร์ไปอ่านได้โดยสะดวกซึ่งโปรแกรมที่นิยมใช้งานเป็นเมลไคลเอนท์ ได้แก่ Microsoft Outlook, Outlook Express, Endora, Netcape Mail เป็นต้น

3. การทำงานแบบเว็บเมล (Web Mail) เป็นการติดต่อระหว่างเว็บเซิร์ฟเวอร์ (Web Server) ที่มีโปรแกรมเว็บเมลติดตั้งอยู่กับเมลเซิร์ฟเวอร์ผ่านโปรโตคอล ที่นิยมใช้กันส่วนใหญ่จะเป็น IMAP ซึ่งเว็บเซิร์ฟเวอร์กับเมลเซิร์ฟเวอร์อาจจะเป็นเซิร์ฟเวอร์ตัวเดียวกันหรือคนละตัวกันก็ได้ โดยโปรแกรมที่เป็นเว็บเมลก็เช่น โปรแกรมที่ติดตั้งอยู่บนเว็บเซิร์ฟเวอร์ของ yahoo.com , hotmail.com เป็นต้น หรือถ้าเป็นโปรแกรมแบบฟรีก็เช่น Horde mail (www.horde.org), OpenWebmail (www.openwebmail.org) , SquirrelMail (www.squirrelmail.org) เป็นต้น โปรแกรมที่เป็นตัวแทนผู้ใช้งานแบบนี้ก็จะหมายถึงเบราว์เซอร์ (Browser) ที่รันอยู่บนเครื่องคอมพิวเตอร์ส่วนบุคคล ที่ใช้ติดต่อกับเมลเซิร์ฟเวอร์ผ่านเว็บเซิร์ฟเวอร์เพื่อดำเนินการในส่วนของการรับและส่งเมล ตัวแทนผู้ใช้งานแบบนี้จะต่างกับแบบที่ 2 คือไม่ต้องมีการใช้โปรโตคอล POP และ IMAP เพราะจะมีตัวกลางที่เป็นเว็บเซิร์ฟเวอร์เป็นตัวใช้งานโปรโตคอลดังกล่าวแทน อาจจะ


กล่าวได้ว่าตัวแทนผู้ใช้เป็นโปรแกรมอำนวยความสะดวกให้ผู้ใช้เขียน แก้ไข และส่งเมล รวมทั้งการเปิดอ่านเมลที่ได้รับ และจัดเก็บเมลเพื่อนำมาใช้ภายหลัง

ตัวแทนขนส่งเมล คือส่วนที่ทำหน้าที่ในการรับและส่งอีเมล โดยจะรับจากตัวแทนผู้ใช้แล้วตรวจสอบว่าผู้รับปลายทางอยู่ในเครื่องเดียวกันหรือไม่ หากอยู่ในเครื่องเดียวกันก็จะส่งเมลนั้นไว้ในเมลบ็อกซ์หรือโฟลเดอร์ที่เก็บเมลของผู้รับนั้น แต่หากอยู่นอกเครื่องจะส่งให้กับอีกกระบวนการหนึ่งเพื่อส่งต่อไปยังเครื่องนั้น ๆ ได้ต่อไป (กระบวนการที่ทำหน้าที่รับส่งเมลข้ามเครื่องนั้นอาจเป็น smtpd ที่ทำหน้าที่คอยแปลงเมลให้อยู่ในรูปของโปรโตคอล SMTP เพื่อให้สามารถส่งผ่านเครือข่ายที่ซีพี/ไอพีได้) ในขณะเดียวกันก็ทำหน้าที่รับเมลที่ส่งเข้ามายังผู้รับในเครื่องนั้น แล้วทำการจัดส่งให้ผู้รับแต่ละคนอย่างถูกต้องด้วย ในส่วนนี้โปรแกรมที่นิยมกันก็เช่น Sendmail, Microsoft Mail, Microsoft Exchange

การจัดแบ่งออกเป็นตัวแทนผู้ใช้และตัวแทนขนส่งเมลมีข้อดีคือ แยกงานของทั้งสองส่วนให้เป็นอิสระจากกัน หน้าที่ของตัวแทนผู้ใช้นั้นการทำงานกับผู้ใช้เพื่อให้ผู้ใช้อ่านเขียนเมลได้อย่างสะดวกโดยไม่ต้องยุ่งเกี่ยวกับการทำงานระดับล่างของโปรโตคอล ตัวแทนขนส่งเมลทำงานตาม SMTP เช่นการตรวจสอบความถูกต้องของที่อยู่ผู้รับผู้ส่ง รวมทั้งการหาเส้นทางและนำส่งเมลไปยังปลายทาง

3.1.4 โปรโตคอล

การที่เครื่องคอมพิวเตอร์ 2 เครื่องจะรับส่งเมลกันได้ หรือผู้ใช้จะโหลดเมลไปอ่านที่เครื่องของตนเองนั้น จำเป็นต้องมีโปรโตคอลที่ใช้คุยกันระหว่างเครื่องทั้งสองคือ SMTP POP3 หรือ IMAP ดังรูปที่ 3.3



รูปที่ 3.3 แสดงโปรโตคอลที่ใช้ในการรับส่งเมล

3.1.4.1 SMTP

SMTP หรือ Simple Mail Transfer Protocol เป็นโปรโตคอลที่ติดต่อกันระหว่างเครื่องที่เป็นโฮสต์กับโฮสต์ โดยโฮสต์ในที่นี้ทำหน้าที่เป็นเมลเซิร์ฟเวอร์หรือผู้ให้บริการอีเมล ซึ่งจะมีกระบวนการที่ทำหน้าที่เป็นตัวแทนขนส่งเมล ทำงานอยู่บนทั้ง 2 ด้าน และรับส่งข้อมูลระหว่างกัน

โดยใช้ SMTP เมื่อได้รับเมลมาแล้วก็จะเก็บเมลเหล่านั้นไว้ในไดเรกทอรีที่เป็นกล่องหรือตู้ไปรษณีย์ในเครื่องนั้น และรอจนกว่าผู้เข้ามาเปิดอ่าน ซึ่งมีได้ 3 วิธีด้วยกันคือ

- ผู้ใช้มีบัญชี (Account) บนเครื่องเมลเซิร์ฟเวอร์ก็สามารถเปิดอ่านได้โดยใช้คำสั่งต่าง ๆ ของ Linux/Unix เช่น mail, pine และเมลที่ถูกอ่านจะถูกย้ายไปเก็บไว้ในเมลบ็อกซ์ของผู้ใช้แทนเมลบ็อกซ์ของระบบได้
- ผู้ใช้อยู่บนเครื่องไคลเอนท์จะต้องโหลดเมลไปไว้ในเครื่องของตัวเองก่อนแล้วจึงเปิดอ่านได้
- ผู้ใช้รับส่งเมลผ่านตัวกลางที่เป็นเว็บเซิร์ฟเวอร์ซึ่งเมลจะยังคงถูกเก็บไว้ที่เครื่องเมลเซิร์ฟเวอร์

การทำงานของ SMTP จะทำหน้าที่ในการกำหนดว่าตัวแทนขนส่งเมลแต่ละตัวจะติดต่อกันได้อย่างไรผ่านทางทีซีพี/ไอพี เมลล์ที่ส่งไปนั้นอาจจะส่งตรงไปยังตัวแทนขนส่งเมลปลายทางเลยหรือว่าผ่านตัวแทนขนส่งเมลหลายเครื่อง (หมายถึงผ่านรีเลย์โฮสต์หลายเครื่อง) โดยผ่านกระบวนการเก็บและส่งต่อ (Store and Forward) ก็ได้เช่นกัน

โปรโตคอล SMTP จะไม่สนใจว่าข้อความในเมลเป็นอะไร แต่จำกัดว่า SMTP สามารถส่งได้แต่ข้อมูลที่เป็นข้อความแอสกี (ASCII) เท่านั้น ไม่สามารถส่งไฟล์ที่เป็นเพลง, หนัง, รูปภาพ หรืออื่น ๆ ได้ ซึ่งถ้าเราต้องการส่งไฟล์เหล่านั้นผ่านทาง SMTP จะต้องแปลงไฟล์เหล่านั้นให้อยู่ในรูปของข้อความเสียก่อนและเมื่อส่งไปถึงปลายทางแล้วค่อยทำการแปลงกลับอีกที

นอกจากการใช้ SMTP เพื่อรับส่งเมลระหว่างเมลเซิร์ฟเวอร์ด้วยกันแล้ว ยังใช้ในขณะที่เป็นไคลเอนท์ส่งเมลไปยังเครื่องที่เป็นเมลเซิร์ฟเวอร์ด้วย

3.1.4.2 POP

POP หรือ Post Office Protocol คือโปรโตคอลที่ออกแบบมาให้ใช้สำหรับการรับเมลจากเครื่องที่เป็นเมลเซิร์ฟเวอร์มายังเครื่องของผู้ใช้ โดยทางฝั่งเซิร์ฟเวอร์จะมีกระบวนการที่เป็น POP เซิร์ฟเวอร์ขณะที่ทางฝั่งผู้ใช้มี POP ไคลเอนท์ซึ่งในบางโปรแกรมที่ผู้ใช้อ่านและเขียนเมลนั้นจะมี POP ไคลเอนท์ฝังอยู่ในตัวอยู่แล้วไม่ได้แยกออกมาเป็นโปรแกรมหนึ่ง เมื่อผู้ใช้เชื่อมต่อไปที่ POP เซิร์ฟเวอร์อีเมลที่อยู่บนเมลเซิร์ฟเวอร์จะถูกส่งมาเก็บไว้ในเครื่องของผู้ใช้เลย ดังนั้นเมื่อผู้ใช้จัดการกับเมล เช่น ลบเมลหรือส่งต่อเมลก็จะทำกับเมลที่อยู่บนเครื่องของผู้ใช้เอง ส่วนเมลบนเมลเซิร์ฟเวอร์จะถูกลบทิ้งไปเมื่อมีการส่งให้ผู้ใช้เรียบร้อยแล้ว เว้นเสียแต่ที่ได้กำหนดเพิ่มเติมไว้ที่โปรแกรมเมลไคลเอนท์ว่าอย่าให้ลบเมลออกจากเซิร์ฟเวอร์ (Leave a copy of message on the server)

ในปัจจุบันโปรโตคอลมีออกมาหลายเวอร์ชัน แต่ที่นิยมกันคือ POP3 ซึ่งก็ยังมีข้อจำกัดในการใช้ คือขณะรับและส่งอีเมล ฝั่งผู้ใช้จะส่งรหัสผ่านของผู้ใช้ในรูปของข้อความไป ทำให้ไม่ปลอดภัย

นักหากมีการเอบดักข้อมูล เพราะฉะนั้น ตอนเซต POP ไคล์แอนท์ เช่น MS outlook หรือโปรแกรมอื่น ๆ ควรจะเลือกใช้งานการเข้าใช้โดยใช้การตรวจสอบรหัสผ่าน (Log on using Secure Password Authentication: SPA) ด้วย แต่ต้องให้เมลล์เซิร์ฟเวอร์มีการสนับสนุนการใช้ SPA ถึงจะใช้งานได้

3.1.4.3 IMAP

IMAP หรือ Internet Message Access Protocol เป็นโปรโตคอลที่เกิดหลัง POP เพื่อแก้ไขข้อจำกัดที่เกิดจาก POP นั่นเอง ทั้งนี้เพราะ POP จะใช้วิธีการโหลดเมลล์ที่อยู่บนเซิร์ฟเวอร์มาเก็บไว้ยังเครื่องคอมพิวเตอร์ส่วนบุคคลของผู้ใช้แล้วลบเมลล์นั้นทิ้ง (แต่ปัจจุบัน POP พัฒนาขึ้น ก็สามารถกำหนดที่เมลล์ไคล์แอนท์ได้ว่าจะให้ลบเมลล์ทิ้งหรือไม่) ทำให้ผู้ใช้นั้นไม่สามารถอ่านเมลล์จากเครื่องคอมพิวเตอร์ส่วนบุคคลเครื่องอื่น ๆ ได้อีก ต้องใช้เครื่องเดิมตลอดซึ่งเป็นปัญหาสำหรับผู้ใช้ที่มีเครื่องคอมพิวเตอร์ส่วนบุคคลทั้งที่บ้านและที่ทำงาน หรือองค์กรที่มีเครื่องให้กับพนักงานไม่ครบทุกคน

การทำงานของ IMAP นั้นจะจัดการเมลล์ที่อยู่บนเซิร์ฟเวอร์ เช่น อ่านหรือเขียนเมลล์ ซึ่งเมลล์เหล่านั้นจะยังคงอยู่บนเซิร์ฟเวอร์ ทำให้ผู้ใช้จะใช้เครื่องคอมพิวเตอร์ส่วนบุคคลเครื่องใดอ่านเมลล์ก็ได้ หรือส่งดาวน์โหลดเมลล์ที่ต้องการมาเก็บในเครื่องพีซีของตนเองเหมือนกับการทำงานของ POP นอกจากนี้ยังสามารถกำหนดเมลล์บ็อกซ์หนึ่ง ๆ ให้กับผู้ใช้หลาย ๆ คนได้ โดยที่ผู้ใช้เหล่านั้นสามารถเปิดเมลล์บ็อกซ์อ่านได้พร้อม ๆ กัน สำหรับในกรณีเว็บเมลล์เครื่องที่เป็นเว็บเซิร์ฟเวอร์ก็จะมี การติดต่อกับเมลล์เซิร์ฟเวอร์โดยผ่านโปรโตคอล IMAP เช่นกัน


3.1.5 คำนิยามของอีเมลล์ขยะ

G. Hulten จาก Msn Safety Team และ J. Godman จาก Microsoft Research [2] ได้แสดงตัวเลขของการสำรวจคำนิยามของอีเมลล์ขยะพบว่า

- 92% เชื่อว่าอีเมลล์ขยะคืออีเมลล์ที่ประกอบไปด้วยเนื้อหาที่เกี่ยวข้องกับสื่อลามกอนาจาร
- 89% เชื่อว่าอีเมลล์ขยะคืออีเมลล์ที่ประกอบไปด้วยเนื้อหาที่เกี่ยวข้องกับข้อเสนอทางการเงินต่างๆ
- 76% เชื่อว่าอีเมลล์ขยะคืออีเมลล์ที่ประกอบไปด้วยเนื้อหาที่เกี่ยวข้องกับการเมืองหรือศาสนา
- 32% จะพิจารณาว่าอีเมลล์เหล่านั้นเป็นอีเมลล์ขยะถ้าหากมันมาจากผู้ส่งซึ่งทำธุรกิจอยู่ ส่วนคำนิยามซึ่งเป็นลักษณะทางกฎหมายกล่าวว่า อีเมลล์ขยะคืออีเมลล์ทางการค้าที่เราไม่ได้ให้ความสนใจจากใครก็ตามที่ไม่มีความสัมพันธ์ทางธุรกิจกันมาก่อน และ [2] ได้ให้คำนิยามว่า อีเมลล์ขยะหมายถึง อีเมลล์ใดๆ ก็ตามที่ใช้ในระบบรายงานให้ทราบ โดยผู้ใช้เหล่านั้นต้องได้รับการทดสอบอย่างใดอย่างหนึ่งแล้วว่าไม่ใช่สแปมเมอร์

3.2 องค์ประกอบของอีเมล

อีเมลประกอบด้วย ส่วนหัวเรื่อง (Header) และส่วนเนื้อเรื่อง (Body) ดังรูปที่ 3.4



รูปที่ 3.4 แสดงตัวอย่างของอีเมลขยะ

3.2.1 ส่วนหัวเรื่อง

จากรูปเราพบว่าส่วนหัวเรื่องประกอบไปด้วยส่วนต่างๆ ดังนี้

1. ส่วน “ได้รับ” (Received) ในส่วนนี้ประกอบไปด้วย รายละเอียดของผู้ส่ง วิธีการที่ใช้ส่ง
2. ส่วน “จาก” (From) ส่วนนี้จะแสดงที่อยู่อีเมลของผู้ส่ง
3. ส่วน “ถึง” (To) ส่วนนี้จะแสดงให้เห็นว่า ผู้ส่งได้ทำการส่งข้อความนี้ไปถึงใครบ้าง
4. ส่วน “วันที่” (Date) แสดงวันที่ที่ส่ง
5. ส่วน “ชื่อเรื่อง” (Subject) ส่วนชื่อเรื่องคือส่วนที่จะแสดงให้เห็นเป็นส่วนแรกก่อนที่ผู้ใช้คลิกเข้าไปจึงจะพบกับส่วนเนื้อหาซึ่งเป็นใจความหลักของอีเมล ชื่อเรื่องจึงเป็นเหมือนส่วนที่ใช้

สำหรับแสดงเนื้อหาโดยสรุปของอีเมลนั่นเอง มีผู้นำส่วนชื่อเรื่องมาเป็นส่วนร่วมในการวิเคราะห์ว่า อีเมลเป็นอีเมลขยะหรืออีเมลดีเป็นจำนวนมาก เนื่องจากชื่อเรื่องก็อาจสื่อความหมายไปถึงเนื้อหาความในอีเมลได้เช่นกัน

6. ส่วน “รหัสข้อความ” (Message ID) แสดงรหัสของข้อความหรืออีเมลนั้นๆ

7. ส่วน “เวอร์ชันเอ็มไอเอ็มอี” (MIME-Version) ชื่อเต็มว่า Multipurpose Internet Mail Extensions เป็นมาตรฐานของรูปแบบของอีเมล

8. ส่วน “ชนิดเนื้อหา” (Content-Type) เป็นส่วนของข้อมูลที่บอกว่าข้อความนี้ถูกแสดงให้ เห็นด้วยวิธีใด โดยทั่วไปแล้วจะเป็นชนิดเอ็มไอเอ็มอี

ในส่วนหัวเรื่องนี้มักถูกนำไปใช้ในการวิเคราะห์อีเมลขยะทางฝั่งเซิร์ฟเวอร์เป็นส่วนใหญ่ เนื่องจากค่อนข้างยุ่งยากและไม่คุ้มค่าที่จะใช้เป็นการส่วนตัวหรือฝั่งลูกค้า แต่สำหรับการวิเคราะห์ ที่ต้องการความถูกต้องและปลอดภัยสูง การกรองที่ฝั่งเซิร์ฟเวอร์จึงต้องเข้มงวดกว่าจึงจำเป็นต้อง รับรู้ข้อมูลที่บ่งบอกถึงที่มาที่ไปของอีเมลเพิ่มเติมในการพิจารณาด้วย

3.2.2 ส่วนเนื้อเรื่อง

ส่วนเนื้อเรื่อง คือส่วนของข้อความที่ผู้ใช้งานอีเมลใช้ติดต่อสื่อสารกัน และเป็นส่วนที่นักวิจัย มักนำมาใช้พิจารณาเนื่องจากง่ายต่อตัวกรองในการเรียนรู้ เนื่องด้วยเหตุนี้อีเมลบางส่วนจึง จำเป็นต้องทำให้เนื้อหาของอีเมลนั้นคลุมเครือเพื่อหลบหนีบรรดาตัวกรองซึ่งมีอยู่มากมาย[2] ได้ จำแนกวิธีต่างๆ ที่ใช้ทำให้อีเมลคลุมเครือ เช่นการทาสีเนื้อหาของอีเมลให้เป็นรูปภาพ (Content in Images) การเพิ่มคำคิที่ไม่ปะติดปะต่อเข้าไปในอีเมล (Good Word Chaff) สุ่มเพิ่มประโยคที่ นำมาจากเมลดี (Content Chaff) เพราะฉะนั้นในบางครั้งการกรองอีเมลโดยพิจารณาจากตัวอักษร อย่างเดียวอาจไม่พอสำหรับอีเมลขยะที่มีหน้าตาแปลกดังที่ได้กล่าวข้างต้น

3.3 ผลกระทบของอีเมลขยะ

ผลกระทบต่อของอีเมลขยะนั้นมีหลายอย่างด้วยกัน โดยที่เห็นได้ชัดมีดังต่อไปนี้

1. สิ้นเปลืองเวลาของผู้ใช้ในการจัดการคัดแยกและลบอีเมลขยะทิ้ง ผลของอีเมลขยะอาจดู ไม่ได้ร้ายแรงอะไรถ้าคุณเป็นผู้ใช้ตามบ้าน เพียงแค่ถ้ามีอีเมลขยะมากคุณก็แค่ลบเมลนั้นทิ้งก็ไม่มีอะไรเกิดขึ้น แต่ถ้าเป็นองค์กรธุรกิจ การที่พนักงานต้องคอยมานั่งลบอีเมลขยะคงไม่ใช่เรื่องที่ น่ายินดีนัก มีผลทำให้การทำงานขององค์กรล่าช้า และส่งผลเสียแก่องค์กรไม่น้อย ตัวอย่างเช่น ถ้า บริษัทหนึ่งให้บริการออนไลน์ แล้วมีการส่งอีเมลขยะมาสักวันละ 100,000 ฉบับ ซึ่งอาจทำให้เมล บ็อกซ์ของบริษัทเต็มส่งผลให้พนักงานแต่ละคนต้องเสียเวลาในการลบเมลขยะเมลละ 2 วินาที ซึ่ง เมื่อมาคิดแล้วเวลารวมที่พนักงานในบริษัทต้องเสียไปกับการลบอีเมลขยะถึง 555 ชั่วโมงในการลบหมด

2. ลื่นเปลี่ยนแบนด์วิธทำให้เมลล์เซิร์ฟเวอร์ต้องเสียแบนด์วิธไปเป็นจำนวนมากพอๆกับขนาดของอีเมลล์ขณะนั้น หากแบนด์วิธมีอยู่อย่างจำกัดก็จะส่งให้อีเมลล์อื่นที่เข้ามาจะต้องใช้เวลาานกว่าปกติหรืออาจจะไม่ได้รับในที่สุด
3. ลื่นเปลี่ยนการประมวลผลของหน่วยประมวลผลกลางที่เมลล์เซิร์ฟเวอร์
4. ลื่นเปลี่ยนเนื้อหาในเมลล์บ็อกซ์ ซึ่งจะมีผลกระทบมากหากเมลล์บ็อกซ์มีการจำกัดเนื้อที่ของผู้ใช้ หากผู้ใช้ทิ้งไว้ไม่ได้มาตรวจสอบบ่อยๆก็จะทำให้เนื้อที่หมดไปได้ หากเป็นอีเมลล์ทางธุรกิจที่สำคัญก็จะทำให้เสียหายต่อธุรกิจได้
5. ส่งผลต่อผู้ให้บริการเซิร์ฟเวอร์ที่มีการตั้งค่าในการรีเลย์ไว้ไม่จำกัดกลุ่มที่แน่นอน คือจะทำให้สแปมเมอร์สามารถใช้เซิร์ฟเวอร์นั้นทำการส่งอีเมลล์ขยะออกไป ซึ่งเมื่อมีการสืบค้นขอของตัวแทนขนส่งเมลล์ (MTA) ก็จะทำให้เซิร์ฟเวอร์นั้นถูกบล็อกทำให้ไม่สามารถส่งอีเมลล์ได้

3.4 ความรู้พื้นฐานเกี่ยวกับทฤษฎีเบย์เซียน (Bayesian Theorem)

ในอดีตอีเมลล์ขยะยังไม่ค่อยจะมีผลกระทบต่อระบบคอมพิวเตอร์มากนัก การกรองอีเมลล์ขยะในอดีตจึงมีการใช้กฎเกณฑ์อย่างง่าย ๆ ในการจำแนก วิธีการที่ใช้เช่น การตั้งกฎในการจำแนกรูปแบบของอีเมลล์ขยะ (Pattern-Matching) โดยมีการตั้งกฎที่ระบุว่าอีเมลล์ลักษณะไหนที่เป็นอีเมลล์ขยะ แต่เนื่องจากในปัจจุบันผู้ส่งอีเมลล์ขยะ สามารถส่งอีเมลล์ขยะที่มีความสามารถในการหลบเลี่ยงตัวกรอง จึงทำให้วิธีการจำแนกรูปแบบของอีเมลล์ขยะเริ่มที่จะไม่มีประสิทธิภาพ เพราะวิธีการนี้เป็นวิธีที่มีการตั้งกฎเกณฑ์ที่ตายตัว ซึ่งเมื่อผู้ส่งอีเมลล์ขยะเปลี่ยนแปลงรูปแบบในการส่งก็จำเป็นต้องเพิ่มกฎใหม่เข้าไปเรื่อยๆ ทำให้ยากต่อการเปลี่ยนแปลงตามความสามารถในการหลบเลี่ยงที่เปลี่ยนไปของผู้ส่งอีเมลล์ขยะ จึงมีการคิดค้นวิธีการในการกรองอีเมลล์ขยะที่มีความสามารถเพิ่มขึ้น โดยมีนาทฤษฎีต่างๆ เข้ามาเพื่อใช้ในการพัฒนาตัวกรองอีเมลล์ขยะเพื่อให้อีเมลล์มีความสามารถที่เพิ่มขึ้น

หนึ่งในวิธีที่ใช้ในปัจจุบันและมีประสิทธิภาพคือการนำการวิเคราะห์ทางสถิติเข้ามามีส่วนช่วยในการเรียนรู้ของอีเมลล์ ซึ่งเป็นวิธีการที่มีประสิทธิภาพในการจำแนกประเภทของอีเมลล์ขยะคือการจำแนกโดยใช้ทฤษฎีเบย์เซียน ตัวกรองอีเมลล์ขยะที่พัฒนาขึ้นโดยใช้ทฤษฎีเบย์เซียนจะมีพื้นฐานของการนำความน่าจะเป็นของอีเมลล์มาคำนวณ ซึ่งเป็นที่วิธีการในการคัดเลือกคีย์เวิร์ดเพื่อนำมาใช้ในการคำนวณ โดยการคัดเลือกคีย์เวิร์ดจะขึ้นกับหลักการในการจำแนกคำ รวมทั้งการตั้งกฎของการจำแนกคำโดยผู้พัฒนาเป็นผู้จัดการ การใช้หลักการทางสถิติมาใช้ในการสร้างตัวกรองเป็นสิ่งที่ค่อนข้างสมเหตุสมผล เพราะว่าความแตกต่างกันระหว่างอีเมลล์ทั่วไปกับอีเมลล์ขยะ ค่อนข้างจะแยกออกจากกันได้ยาก ซึ่งอีเมลล์ขยะทั่วไปจะมีรูปแบบหรือว่าหลักการที่คล้ายคลึงกันกับอีเมลล์ทั่วไป ซึ่งสุดท้ายต้องขึ้นกับผู้ใช้เป็นผู้ระบุว่าอีเมลล์ฉบับไหนที่เป็นอีเมลล์ขยะ หรือว่าอีเมลล์ทั่วไป และผู้ใช้แต่ละคนอาจจะระบุได้แตกต่างกัน ซึ่งอีเมลล์ฉบับหนึ่งเป็นอีเมลล์ขยะของผู้ใช้คนหนึ่ง แต่ในขณะที่ผู้ใช้คนอื่นอาจจะบอกว่าเป็นอีเมลล์ปกติ

จากการที่ผู้ใช้เป็นผู้กำหนดนิยามของอีเมลล์ของตนเองทำให้สังเกตได้ว่าสิ่งหนึ่งที่แตกต่างกันระหว่างอีเมลล์ทั่วไปกับอีเมลล์ขยะก็คือ เนื้อหาที่อยู่ภายในอีเมลล์ วิธีการทางด้านสถิติจะมีข้อเสียก็คือการใช้งานตัวกรองที่สร้างขึ้นจะต้องให้อีเมลล์มีการเรียนรู้ในรูปแบบต่างๆ ซึ่งต้องใช้ระยะเวลาหนึ่งการสอนอีเมลล์ให้แยะระบบตัวกรอง ซึ่งทฤษฎีเบย์เซียนจะมีรายละเอียดดังต่อไปนี้

3.4.1 ทฤษฎีเบย์เซียน

ทฤษฎีเบย์เซียนจะเกี่ยวข้องกับเงื่อนไขและสถิติของเหตุการณ์ A และ B ดังสมการที่ (3.1)

$$\Pr(A | B) = \frac{\Pr(B | A) \Pr(A)}{\Pr(B)} \quad (3.1)$$

เมื่อ

$\Pr(A)$ คือความน่าจะเป็นที่มาก่อน (Prior Probability) หรือค่าความน่าจะเป็นซึ่งมีความสำคัญน้อย (Marginal Probability) ของ A

$\Pr(A | B)$ คือความน่าจะเป็นแบบมีเงื่อนไข (Conditional Probability) ของ A เมื่อให้ B หรือเรียกว่าความน่าจะเป็นที่มาที่หลัง (Posterior Probability) เนื่องจากถูกแปลงหรือเป็นอิสระจากค่าของ B ที่ได้กำหนดไว้

$\Pr(B | A)$ คือความน่าจะเป็นแบบมีเงื่อนไขของ B เมื่อให้ A

$\Pr(B)$ คือความน่าจะเป็นที่มาก่อน (Prior Probability) หรือค่าความน่าจะเป็นซึ่งมีความสำคัญน้อย (Marginal Probability) ของ B ซึ่งกระทำตัวเป็นนอร์มัลไลซิงคอนสแตนท์ (Normalizing Constant) ถอดความทฤษฎีใหม่ได้ดังสมการที่ (3.2)

$$\text{Posterior} = \frac{\text{Likelihood} \times \text{Prior}}{\text{Normalizing Constant}} \quad (3.2)$$

นั่นคือความน่าจะเป็นที่เกิดที่หลังคือสัดส่วนของจำนวนครั้งที่คล้ายกับความน่าจะเป็นที่เกิดขึ้นก่อน ในทางตรงกันข้าม อัตราส่วน $P(B | A) / P(B)$ ในบางครั้งเราจะเรียกว่าความคล้ายมาตรฐาน (Standardized Likelihood) ดังนั้นทฤษฎีนี้จึงถูกถอดความใหม่ได้ดังสมการที่ (3.3)

$$\text{Posterior} = \text{Standardized Likelihood} \times \text{Prior} \quad (3.3)$$

จากนั้นเราจะดิไรฟ์ (Derive) ทฤษฎีโดยเริ่มจากนิยามของความน่าจะเป็นแบบมีเงื่อนไข ความน่าจะเป็นของเหตุการณ์ A เมื่อให้เหตุการณ์ B เป็นไปตามสมการที่ (3.4) คือ

$$P(A|B) = \frac{P(A \cap B)}{P(B)} \quad (3.4)$$

ในทำนองเดียวกัน ความน่าจะเป็นของเหตุการณ์ B เมื่อให้เหตุการณ์ A เป็นไปตามสมการที่ 3.5 คือ

$$P(B|A) = \frac{P(A \cap B)}{P(A)} \quad (3.5)$$

เมื่อนำ 2 สมการนี้มาจัดเรียงใหม่จะเป็นไปตามสมการที่ (3.6) คือ

$$P(A|B)P(B) = P(A \cap B) = P(B|A)P(A) \quad (3.6)$$

หารทั้งสองข้างด้วย $P(B)$ จะได้ทฤษฎีของเบย์จะเป็นไปตามสมการที่ (3.7) คือ

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (3.7)$$

3.4.2 การนำทฤษฎีเบย์เขียนมาใช้ในการกรองอีเมลขยะ

ในการนำทฤษฎีของเบย์มาประยุกต์ใช้กับตัวกรองอีเมลขยะนั้น นิยมใช้ทฤษฎีเบย์อย่างง่าย (Naïve Bayes)[2] ซึ่งบางครั้งเราอาจเรียกว่าเบย์เขียนเทคนิค โดยทฤษฎีเบย์อย่างง่ายนั้นจะมองว่าคำแต่ละคำเป็นอิสระจากกัน

ถ้าต้องการ $P(\text{spam}|\text{mail})$ ซึ่งหมายถึงความน่าจะเป็นที่อีเมลจะเป็นขยะ สามารถหาได้โดยใช้กฎของเบย์ซึ่งคำนวณตามสมการที่ 3.8 โดยที่ค่า $P(\text{ham})$ หรือความน่าจะเป็นของอีเมลดี, $P(\text{spam})$ หรือความน่าจะเป็นของอีเมลขยะ, $P(\text{mail})$ หรือความน่าจะเป็นของอีเมล หาได้จาก สมการที่ (3.9)-(3.11) ตามลำดับ

$$P(\text{spam}|\text{mail}) = \frac{P(\text{mail}|\text{spam}) \times P(\text{spam})}{P(\text{mail})} \quad (3.8)$$

$$P(\text{ham}) = \frac{n\text{MailHam}}{n\text{MailTotal}} \quad (3.9)$$

$$P(\text{spam}) = \frac{n\text{MailSpam}}{n\text{MailTotal}} \quad (3.10)$$

$$P(mail) = P(mail | spam) \times P(spam) + P(mail | ham) \times P(ham) \quad (3.11)$$

จากสมมติฐานความเป็นอิสระที่กล่าวว่า ความน่าจะเป็นของแต่ละตัวเป็นอิสระจากกัน (ข้อสมมติฐานที่ผิด) ทำให้ได้สมการที่ (3.12) และ (3.13)

$$P(mail | spam) \approx P(word_1 | spam) \times P(word_2 | spam) \times \dots \times P(word_n | spam) \quad (3.12)$$

$$P(mail | ham) \approx P(word_1 | ham) \times P(word_2 | ham) \times \dots \times P(word_n | ham) \quad (3.13)$$

อีเมลประกอบด้วยคำหลายๆคำ(Words) เมื่อต้องการทราบว่าอีเมลฉบับใดเป็นอีเมลขยะ จะพิจารณาจากความน่าจะเป็นที่จะเป็นอีเมลขยะของคำแต่ละคำในอีเมลแล้วจึงหาความน่าจะเป็นรวมของอีเมลทั้งฉบับโดยการนำความน่าจะเป็นของคำขยะที่ได้มาคูณกัน เช่นเดียวกัน ถ้าต้องการทราบว่าอีเมลฉบับใดเป็นอีเมลดีให้พิจารณาจากความน่าจะเป็นที่จะเป็นอีเมลดีของคำดีในอีเมลแล้วทำเช่นเดียวกันกับการหาความน่าจะเป็นของอีเมลขยะ


เมื่อได้ความน่าจะเป็นจะเป็นของอีเมลที่จะเป็นอีเมลขยะ $P(mail | spam)$ และความน่าจะเป็นของอีเมลที่จะเป็นอีเมลดี $P(mail | ham)$ ให้นำมาเปรียบเทียบกันถ้าความน่าจะเป็นของฝั่งอีเมลขยะมีค่ามากกว่าให้ตอบว่าเป็นอีเมลที่นำมาทดสอบเป็นอีเมลขยะ ถ้าไม่ก็ตอบว่าเป็นอีเมลดี

3.5 ความรู้พื้นฐานเกี่ยวกับแขนงการตัดสินใจ (Decision Tree)

แขนงการตัดสินใจคือโมเดลสำหรับการทำนายซึ่งใช้ Top-Down Strategy มาใช้ในการค้นหาคำตอบในเส้นทางของคำตอบที่สารทเป็นไปได้อองค์ประกอบของแขนงการตัดสินใจประกอบด้วย

1. โหนด (Node) คือสิ่งที่ถูกทดสอบ หรือเงื่อนไข
2. แขนงหรือกิ่ง (Branches) คือ ผลลัพธ์ที่เป็นไปได้ทั้งหมดของโหนดนั้น

ตัวอย่างของแขนงการตัดสินใจแสดงดังรูปที่ 3.5



รูปที่ 3.5 แสดงตัวอย่างของแขนงการตัดสินใจ

แขนงการตัดสินใจสามารถนำมาประยุกต์เป็นโครงสร้างของกฎได้ เช่น

IF (Condition) THEN (Action)

IF (Condition1) AND (Condition2) THEN (Action)

3.6 ความรู้พื้นฐานเกี่ยวกับเจเนติกอัลกอริทึม

ในปี ค.ศ. 1975 จอห์น ฮอลแลนด์และคณะ [15] จากมหาวิทยาลัยมิชิแกนได้ตีพิมพ์หนังสือการปรับตัวในสิ่งแวดล้อมและระบบเทียม (Adaptation in Natural and Artificial System) ขึ้น ซึ่งเป็นครั้งแรกที่นำแนวความคิดของการเลียนแบบวิวัฒนาการธรรมชาติมาผสมรวมไว้ด้วยกันบนคอมพิวเตอร์ ซึ่งเตรียมสิ่งสำคัญต่าง ๆ ในการวิเคราะห์ปัญหาทางคณิตศาสตร์ เสมือนกับการเลียนแบบการวิวัฒนาการบนคอมพิวเตอร์ และเมื่อไม่นานมานี้งานมากมายที่ได้มาจากการเลียนแบบการวิวัฒนาการบนคอมพิวเตอร์ก็ถูกสร้าง จุดประสงค์เดียวเพื่อความเข้าใจในพันธุกรรม (Genetic) และวิวัฒนาการ (Evolution) หนังสือของฮอลแลนด์แสดง เค้าโครงว่ากระบวนการสามารถใช้ในการแก้ปัญหาในโลกที่แท้จริงได้อย่างไรด้วยเทคนิคของการวิวัฒนาการ ฮอลแลนด์ได้ให้ความหมายของเจเนติกอัลกอริทึมว่า เป็นอัลกอริทึมสำหรับการค้นหาข้อมูลและการค้นหาคำตอบที่ดีที่สุด (Optimization) ซึ่งได้รับแนวคิดมาจากกลไกการคัดเลือกสายพันธุ์ตามธรรมชาติ (Natural Selection) และธรรมชาติทางพันธุกรรม (Natural Genetic) คือสิ่งมีชีวิตใดที่มีความแข็งแรงกว่าย่อมมีโอกาสอยู่รอดได้มากกว่านั้นหมายถึงการมีสายพันธุ์ที่ดีย่อมมีโอกาสจะได้รับกา

คัดเลือกนำมาเป็นต้นแบบ เพื่อถ่ายทอดลักษณะดี ๆ ของสายพันธุ์เหล่านั้นไปยังรุ่นต่อไป มากกว่า มีโอกาสในการอยู่รอดสูง ส่วนสายพันธุ์ที่ไม่ดีก็จะไม่ได้รับการคัดเลือก หรือได้รับการคัดเลือกน้อยกว่า และจะค่อยๆ สูญพันธุ์ไปในที่สุดจนตกลอดกอริทึมได้นำกระบวนการวิวัฒนาการของสิ่งมีชีวิตมาประยุกต์ใช้กับงานด้านปัญญาประดิษฐ์ เพื่อค้นหาคำตอบของปัญหาต่าง ๆ โดยเจเนติกอัลกอริทึมเป็นรูปแบบของเทคนิคการค้นหาซึ่งใช้ในการค้นหาคำตอบจากจำนวนคำตอบที่เป็นไปได้ทั้งหมดของการแก้ปัญหาหนึ่งๆ เพื่อให้ได้คำตอบที่เหมาะสมกับปัญหาโดยอาศัยข้อมูลในการช่วยค้นหา ซึ่งข้อมูลหรือวิธีการที่ใช้จะจำลองมาจากกฎเกณฑ์การคัดเลือกสายพันธุ์ตามธรรมชาตินั่นเอง

เจเนติกอัลกอริทึมมีองค์ประกอบที่สำคัญ 5 องค์ประกอบ ได้แก่

1. นำเสนอปัญหาด้วยรูปแบบโครโมโซม และทางเลือกที่เป็นไปได้ของแต่ละปัญหา
2. วิธีการสร้างประชากรต้นกำเนิด (Initial population) ของทางเลือกที่เป็นไปได้
3. ฟังก์ชันความเหมาะสม (Fitness function) เพื่อให้คะแนนแต่ละทางเลือก
4. เจเนติกโอเปอเรเตอร์ (Genetic Operator) ซึ่งใช้ปรับเปลี่ยนองค์ประกอบของข้อมูลตลอดกระบวนการ
5. ค่าพารามิเตอร์ต่างๆ ซึ่งต้องใช้ในเจเนติกอัลกอริทึม เช่น ขนาดของประชากร ความน่าจะเป็นของการใช้เจเนติกโอเปอเรเตอร์ เป็นต้น

เจเนติกอัลกอริทึมแตกต่างจากวิธีการโดยทั่วไป คือ

1. เป็นวิธีการที่ค้นหาคำตอบภายใต้โครงสร้างของปัญหาอันเกิดจากการเข้ารหัส (Encoding) รูปแบบปัญหา
2. โครงสร้างจากกลุ่มตัวแปรต่างๆ ของปัญหานั้น ไม่ใช่การค้นหาคำตอบจากค่าของกลุ่มตัวแปรนั้นโดยตรง
3. ทำการค้นหาคำตอบจากกลุ่มประชากรคำตอบ (Population) แทนการหาคำตอบใดคำตอบหนึ่ง
4. ทำการค้นหาคำตอบจากผลลัพธ์ของกลุ่มค่าตัวแปรที่เป็นฟังก์ชันเป้าหมาย (Objective Function) ไม่สนใจข้อมูลข่าวสารแวดล้อมอื่นๆ
5. ใช้ความน่าจะเป็น (Probability) ในการค้นหาคำตอบ

3.6.1 พันธุศาสตร์ทางชีววิทยากับเจเนติกอัลกอริทึม

ตามธรรมชาติ สิ่งมีชีวิตแต่ละชนิดจะมีโครงสร้างและพฤติกรรมที่แตกต่างกัน อันเนื่องมาจากสภาพแวดล้อมการดำรงชีวิตที่แตกต่างกัน ลักษณะที่แตกต่างกันนี้มีผลต่ออัตราการมีชีวิตรอดและอัตราการสืบพันธุ์ โดยสิ่งมีชีวิตมีแนวโน้มจะถ่ายทอดคุณลักษณะพิเศษให้กับประชากรรุ่นลูกหลาน (Offspring) และให้กำเนิดสิ่งมีชีวิตที่มีลักษณะพิเศษแตกต่างไปจากเดิมที่มีคุณสมบัติ

เหมาะสม เพื่อให้สามารถดำรงอยู่รอดได้ต่อไปในสภาพแวดล้อมของสิ่งมีชีวิตนั้นๆ ประชากรจะมีแนวโน้มที่จะมีคุณลักษณะที่เหมาะสมต่อการดำรงชีวิตมากกว่ารุ่นบรรพบุรุษ เมื่อเวลาผ่านไปหลายๆ รุ่น (Generation) ของวิวัฒนาการ สิ่งมีชีวิตนั้นก็จะได้สายพันธุ์ใหม่ที่เหมาะสมกับสภาพแวดล้อมมากยิ่งขึ้น ตัวอย่างของวิวัฒนาการเหล่านี้ เช่น มีการสันนิษฐานว่ายีราฟในสมัยโบราณอาจจะมีลำคอไม่ยาวเท่ากับยีราฟในยุคปัจจุบัน ยีราฟดำรงชีวิตด้วยการกินใบไม้ตามยอดไม้ เมื่อจำนวนประชากรยีราฟมีมากขึ้น การแย่งแย่งอาหารเพื่อความอยู่รอดจึงสูงขึ้นตาม ยีราฟตัวที่สามารถกินยอดไม้สูงๆ เท่านั้นจึงจะมีชีวิตอยู่ต่อไป คุณสมบัติที่ดีในการดำรงชีวิตนี้จึงถูกคัดเลือกและถ่ายทอดมายังยีราฟรุ่นลูกหลาน นั่นหมายถึงยีราฟที่คอยาวเท่านั้นที่จะมีโอกาสหาอาหาร และรอดชีวิตสูงกว่ายีราฟคอสั้น

จากที่กล่าวมาข้างต้นว่าเจเนติกอัลกอริทึมเป็นวิธีการที่เลียนแบบมาจากหลักการทางชีววิทยา จึงมีการนำศัพท์ต่างๆ ในด้านพันธุศาสตร์มาประยุกต์ใช้ในกระบวนการเจเนติกอัลกอริทึมดังต่อไปนี้

3.6.1.1 พันธุศาสตร์ทางชีววิทยา

ในแต่ละเซลล์ (Cell) ของสิ่งมีชีวิตจะประกอบไปด้วยหน่วยย่อยที่มีความสำคัญมากอยู่ในนิวเคลียส (Nucleus) ของเซลล์ นั่นคือโครโมโซม (Chromosome) แต่ละโครโมโซมจะประกอบไปด้วยยีนส์ (Genes) ซึ่งเป็นหน่วยเก็บลักษณะต่างๆ ของสิ่งมีชีวิต ภายในยีนส์จะมีค่าแสดงลักษณะต่างๆ หรือแอลลี (Allele) โดยตำแหน่งของยีนแต่ละยีนในโครโมโซมจะเรียกว่าโลคัส (Locus) รูปแบบของยีนส์ที่แตกต่างกันเรียกว่าจีโนไทป์ (Genotype) ส่วนลักษณะภายนอกที่ปรากฏเรียกว่าฟีโนไทป์ (Phenotype) [16]

3.6.1.2 พันธุศาสตร์ทางเจเนติกอัลกอริทึม

สำหรับเจเนติกอัลกอริทึม ตัวแปรของปัญหาจะถูกแปลงให้อยู่ในรูปของสตริง (String) ว่าโครโมโซม ภายในโครโมโซมจะประกอบไปด้วยอักขระ (Character) หรือบิต (Bit) แต่ละตำแหน่งของบิตจะเก็บค่าอักขระ (Character value) หรือค่าของบิต (Bit value) ที่แสดงโครงสร้างของแต่ละโครโมโซมของปัญหาที่แตกต่างกัน สรุปความหมายของคำสำคัญต่างๆ ได้ดังตารางที่ 1

ตารางที่ 3.1 คำสำคัญที่ใช้ในกระบวนการเจเนติกอัลกอริทึม

Natural Genetic Terms	Genetic Algorithm Terms
Chromosome	String
Gene	Feature, Character, Bit
Allele	Feature value, Character value, Bit value
Locus	String position
Genotype	Structure
Phenotype	Decoded structure, Alternative solution

3.6.2 ขั้นตอนการทำงานของเจเนติกอัลกอริทึม

3.6.2.1 การกำหนดรูปแบบโครโมโซม (Chromosome Representation)

การกำหนดปัญหาโดยใช้เจเนติกอัลกอริทึมนั้น จะต้องมีการนำปัญหามาเข้ารหัสข้อมูลให้อยู่ในรูปแบบโครโมโซมที่เหมาะสม เช่น อาจนำเสนอในรูปแบบของเลขฐานสอง เลขจำนวนจริง ตัวอักษร) การสลับลำดับกันในพีชคณิต และแบบทรี (Tree) เป็นต้น สำหรับเจเนติกอัลกอริทึมจะใช้กระบวนการเจเนติกอัลกอริทึมแบบง่าย (Simple Genetic Algorithm) [17] ได้แสดงตัวอย่างการเข้ารหัสแบบไบนารี การเข้ารหัสแบบสลับลำดับ (Permutation Encoding) การเข้ารหัสแบบค่า (Value Encoding) และการเข้ารหัสแบบทรี (Tree Encoding) ดังแสดงในรูปที่ 3.6-3.9 ตามลำดับ

Chromosome A	101100101100101011100101
Chromosome B	111111100000110000011111


รูปที่ 3.6 แสดงการเข้ารหัสแบบไบนารี

Chromosome A	1 5 3 2 6 4 7 9 8
Chromosome B	8 5 6 7 2 3 1 4 9

รูปที่ 3.7 แสดงการเข้ารหัสแบบสลับลำดับ

Chromosome A	1.2324 5.3243 0.4556 2.3293 2.4545
Chromosome B	ABDJEIFJDHDIERJFDLDFLFEGT
Chromosome C	(back), (back), (right), (forward), (left)

รูปที่ 3.8 แสดงการเข้ารหัสแบบค่า



รูปที่ 3.9 แสดงการเข้ารหัสแบบทรี

3.6.2.2 ประชากร (Population)

ประชากรในกระบวนการเจเนติกอัลกอริทึมจะแบ่งออกเป็น 2 กลุ่มคือ ประชากรรุ่นเก่า (Old Population) และประชากรรุ่นใหม่ (New Population) ประชากรรุ่นเก่าจะถูกสร้างขึ้นมาเพื่อที่จะคัดเลือกไปเป็นประชากรรุ่นใหม่ และสำหรับประชากรต้นกำเนิด (Initial Population) ซึ่งเป็นประชากรรุ่นแรกในกระบวนการสามารถทำได้โดยการสุ่มสร้างค่าที่เป็นไปได้ของแต่ละบิตของแต่ละโครโมโซมตามที่ต้องการ

3.6.2.3 กำหนดฟังก์ชันความเหมาะสม (Fitness Function)

การกำหนดฟังก์ชันความเหมาะสมคือ การสร้างฟังก์ชันเพื่อคำนวณหาความเหมาะสมของประชากรว่าเหมาะสมที่จะถูกคัดเลือกมาเพื่อสร้างประชากรรุ่นต่อไปมากน้อยเพียงใด อาจเป็นการวัดจากค่าความเหมาะสมที่สูงสุด (Max) หรือเป็นค่าความเหมาะสมที่ต่ำสุด (Min) ก็ได้ โดยฟังก์ชันความเหมาะสมนั้นจะแตกต่างกันออกไปสำหรับแต่ละปัญหา


3.6.2.4 การวิเคราะห์ค่าความเหมาะสม (Fitness Evaluation)

เป็นขั้นตอนการถอดรหัสโครโมโซม โดยนำค่าที่ได้จากการถอดรหัสนี้ไปแทนค่าในฟังก์ชันความเหมาะสมของปัญหา ผลลัพธ์ที่ได้จากการคำนวณนี้เรียกว่า ค่าความเหมาะสม ซึ่งค่านี้จะเป็นสิ่งที่แสดงว่า แต่ละโครโมโซมมีความเหมาะสมที่จะนำมาใช้แก้ปัญหามากน้อยเพียงใด หรืออาจเปรียบเทียบได้กับค่าความสามารถในการอยู่รอดของแต่ละโครโมโซม และเป็นการกำหนดโอกาสหรือสัดส่วนที่แต่ละโครโมโซมจะถูกคัดเลือกมาเป็นต้นแบบในการให้กำเนิดประชากรรุ่นต่อไป

3.6.2.5 การคัดเลือก (Selection)

เป็นขั้นตอนที่จำลองแบบการคัดเลือกประชากรตามธรรมชาติ เพื่อคัดเลือกโครโมโซมรุ่นเก่าให้เป็นโครโมโซมต้นแบบหรือโครโมโซมพ่อแม่ เพื่อใช้ในการสร้างประชากรรุ่นลูกต่อไป

สำหรับการคัดเลือกทำได้โดยการวัดค่าความเหมาะสมของแต่ละโครโมโซมโดยวิธีใดวิธีหนึ่ง แล้วคัดเลือกโครโมโซมจำนวนหนึ่งที่มีค่าความเหมาะสมเป็นที่น่าพอใจเก็บไว้ ดังตัวอย่างในรูปที่ 3.10 อาจจะคัดเลือกเอาเฉพาะโครโมโซมที่มีค่าความเหมาะสมสูงสุดหรือในบางครั้งอาจเลือกโครโมโซมที่มีค่าความเหมาะสมปานกลางและต่ำบางส่วนเข้ามาด้วย เพราะบางกรณีการนำสายพันธุ์ที่มีค่าปานกลางหรือต่ำมาผสมกันจะสามารถทำให้เกิดสายพันธุ์ที่ดีในรุ่นต่อไปได้



รูปที่ 3.10 แสดงการเลือกโครโมโซมตามค่าความเหมาะสม

การคัดเลือกข้อมูลมีลักษณะเป็นไปตามหลักการที่ว่า การอยู่รอดของสิ่งที่เหมาะสมที่สุด (Survival of the Fittest) [18][19] ถ้าเป็นการวัดค่าความเหมาะสมจากค่าสูงสุด (Maximized Value) ความน่าจะเป็นของของแต่ละโครโมโซม ที่จะได้รับการสุ่มเลือกแต่ละครั้ง (Probability of Value Selection: P_{Si}) จะเป็นไปดังสมการที่ (3.11)

$$P_{Si} = \frac{f_i}{\sum_{i=1}^n f_i} \quad (3.11)$$

เมื่อ ค่าความเหมาะสมของแต่ละทางเลือก (f_i) เทียบกับผลรวมค่าความเหมาะสมทั้งหมด หากเป็นการวัดค่าความเหมาะสมจากค่าต่ำสุด (Minimized Value) ความน่าจะเป็นของแต่ละโครโมโซมที่จะได้รับการสุ่มเลือกแต่ละครั้ง จะเป็นไปดังสมการที่ (3.12)

$$P_{Si} = 1 - \frac{f_i}{\sum_{i=1}^n f_i} \quad (3.12)$$

ดังนั้นสามารถคำนวณค่าความคาดหวังที่จะสุ่มได้ (Expected Value : E) ของแต่ละโครโมโซม เป็นไปดังสมการที่ (3.13)

$$E = P_{Si} \times Popsiz$$
 (3.13)

เมื่อ Popsiz คือขนาดของประชากรทั้งหมด

ในการสุ่มโครโมโซมของเจเนติกอัลกอริทึมแบบง่าย จะใช้แบบจำลองการหมุนวงล้อถ่วงน้ำหนัก (Roulette Wheel) [19] ซึ่งจะกำหนดขนาดของช่องวงล้อตามความน่าจะเป็นที่จะสุ่มได้ในแต่ละครั้ง ของแต่ละโครโมโซมมีวิธีการดังนี้

1. หาค่าความเหมาะสมของแต่ละโครโมโซม
2. หาค่าความน่าจะเป็นที่จะสุ่มได้ในแต่ละครั้งของแต่ละโครโมโซม
3. หาค่าความถี่สะสม (q_i) ของความน่าจะเป็นของแต่ละโครโมโซม ดังสมการที่ (3.14)

$$q_i = \sum_{i=1}^j P_{Si}$$
 (3.14)

4. สร้างเลขสุ่มจำนวนจริง (r) ที่มีค่าอยู่ในช่วง $[0.0, 1.0]$

5. เลือกโครโมโซมลำดับที่ r ซึ่ง r มีค่าอยู่ระหว่าง q_{i-1} และ q_i

จากวิธีดังกล่าวจะเห็นได้ว่า โครโมโซมใดที่มีความน่าจะเป็นที่จะถูกเลือกน้อยๆ จะมีโอกาสถูกเลือกขึ้นมาน้อยเพราะช่องว่างระหว่าง q_{i-1} และ q_i จะแคบมาก ทำให้โอกาสที่ r จะตกช่องนั้นมีน้อย ในทางตรงกันข้าม โครโมโซมใดที่มีความน่าจะเป็นสูง ก็จะมีโอกาสถูกเลือกมากเนื่องจากช่องว่างระหว่าง q_{i-1} และ q_i จะกว้าง ซึ่งสอดคล้องกับที่ได้กล่าวไปแล้วว่า ถ้าความน่าจะเป็นที่จะถูกเลือกมีค่ามาก ก็จะมีโอกาสที่จะถูกเลือกไปเป็นประชากรรุ่นใหม่สูงตามไปด้วย ดังแสดงในตารางที่ 2

ตารางที่ 3.2 ตัวอย่างการใช้แบบจำลองวงล้อถ่วงน้ำหนัก

โครโมโซม	1	2	3	4	5
ค่าความเหมาะสม	8	2	17	7	2
ค่าความน่าจะเป็นที่จะสุ่มได้ในแต่ละครั้ง (P_{Si})	0.22	0.06	0.47	0.19	0.06
ความถี่สะสมค่าความน่าจะเป็น (q_i)	0.22	0.28	0.75	0.94	1.00
สร้างเลขสุ่มจากการหมุนวงล้อแต่ละครั้ง (r)	0.33	0.84	0.45	0.12	0.28
โครโมโซมที่ถูกเลือก	3	4	3	2	1

นอกเหนือจากการคัดเลือกโดยใช้แบบจำลองการหมุนวงล้อถ่วงน้ำหนัก [20] ได้รวบรวมวิธีการอื่นๆ ที่ใช้ในกระบวนการคัดเลือกได้แก่ การคัดเลือกแบบจัดลำดับ (Ranking Selection) การคัดเลือกตามสถานะที่แน่นอน (Steady-State Selection) และการคัดเลือกแบบมีอภิสิทธิ์ (Elitism Selection) ซึ่งเราสามารถเลือกใช้ได้ตามความเหมาะสมในแต่ละงาน

3.6.2.6 การครอสโอเวอร์ (Crossover)


การครอสโอเวอร์คือการนำโครโมโซม 2 โครโมโซม มาทำการตามขั้นตอนต่างๆ ซึ่งจะให้ค่าโครโมโซมใหม่ที่จะนำไปใช้ในการคัดเลือกครั้งต่อไป หรือหมายถึงการนำโครโมโซมสองโครโมโซมมาผสมกันเพื่อให้ได้ค่าโครโมโซมขึ้นมาใหม่นั้นเอง ในขั้นตอนนี้จะพยายามสร้างทางเลือกใหม่เพื่อเป็นคำตอบให้กับปัญหา และปรับปรุงทางเลือกให้ดีขึ้นโดยการครอสโอเวอร์ ซึ่งเจเนติกอัลกอริทึมจะพยายามสร้างทางเลือกที่ดีขึ้นโดยการรวมลักษณะที่ดีของแต่ละโครโมโซมเข้าด้วยกัน โครโมโซมที่มีค่าความเหมาะสมสูงกว่ามักจะถูกลีอกมาทำการครอสโอเวอร์บ่อยครั้งกว่า ส่งผลให้มีโอกาสในการอยู่รอดไปยังรุ่นต่อไปสูงกว่า การครอสโอเวอร์สามารถทำได้หลายวิธี เช่น การครอสโอเวอร์หนึ่งจุด (One Point Crossover) การครอสโอเวอร์สองจุด (Two Point Crossover) และการครอสโอเวอร์หลายจุด (Multiple Point Crossover) ซึ่งมีวิธีการโดยทั่วไปดังนี้

1. ประชากรทั้งหมดจะถูกนำมาจับคู่โดยการสุ่ม ซึ่งจะได้ผลการจับคู่ออกมาทั้งหมด $N/2$ คู่ เมื่อ N คือจำนวนประชากรทั้งหมดในรุ่นนั้นๆ
2. สร้างเลขสุ่มจำนวนจริง (r) ซึ่งมีค่าอยู่ในช่วง $[0.0, 1.0]$ โดยถ้าจำนวนจริงที่สุ่มได้มีค่าน้อยกว่าค่าความน่าจะเป็นในการครอสโอเวอร์ (Probability of Crossover : P_c) แล้วโครโมโซมคู่นั้นก็จะเกิดการครอสโอเวอร์
3. ครอสโอเวอร์โดยแลกเปลี่ยนส่วนของคู่โครโมโซมพ่อแม่ นั้น โดย
 - สุ่มเลือกตำแหน่งที่จะทำการครอสโอเวอร์
 - แลกเปลี่ยนค่าในแต่ละบิตของคู่โครโมโซมพ่อแม่ ตั้งแต่ตำแหน่งที่สุ่มได้จนหมด ซึ่งทำให้เกิดโครโมโซมรุ่นลูกใหม่จำนวน 2 โครโมโซม

การครอสโอเวอร์ในแต่ละรุ่นสามารถทำได้มากกว่า 1 คู่ ขึ้นอยู่กับอัตราค่าความน่าจะเป็นในการครอสโอเวอร์ ซึ่งจำนวนของการครอสโอเวอร์สามารถคำนวณได้ตามสมการที่ 3.15


$$\text{จำนวนของการครอสโอเวอร์} = P_c \times (\text{Popsiz} / 2) \quad (3.15)$$

เมื่อ P_c คือความน่าจะเป็นในการครอสโอเวอร์ และ Popsiz คือขนาดของประชากรในรุ่นนั้นๆ ตัวอย่างการครอสโอเวอร์แบบไบนารี เช่น ถ้าสุ่มตำแหน่งที่จะทำการครอสโอเวอร์ได้เป็นตำแหน่งที่ 4 การแลกเปลี่ยนส่วนของโครโมโซมจะเกิดขึ้นหลังตำแหน่งที่ 5 เรื่อยไปจนถึงตำแหน่งสุดท้าย เกิดโครโมโซมใหม่ขึ้นมา 2 โครโมโซม ดังแสดงในรูปที่ 3.11




รูปที่ 3.11 แสดงกระบวนการครอสโอเวอร์แบบไบนารี

ตัวอย่างการครอสโอเวอร์โครโมโซมแบบตัวอักษรหลังตำแหน่งที่ 3 แสดงดังรูปที่ 3.12



รูปที่ 3.12 แสดงกระบวนการครอสโอเวอร์แบบตัวอักษร

ตัวอย่างการครอสโอเวอร์แบบทรี แสดงดังรูปที่ 3.13



รูปที่ 3.13 การครอสโอเวอร์ของโครโมโซมแบบทรี

3.6.2.7 การมิวเตชัน (Mutation)

การมิวเตชันหรือการผ่าเหล่า เป็นลักษณะของการนำโครโมโซมเก่ามาสุ่มแก้ไขค่าบางค่า เช่น ทำให้ค่าของบางตำแหน่งเปลี่ยนไป โดยทำการกลับบิตเป็นค่าใหม่ในตำแหน่งบิตที่สุ่มได้ ตามค่าความน่าจะเป็นของการมิวเตชันในแต่ละบิต (Probability of Mutation : P_m) ที่กำหนด โดยการมิวเตชันจะทำการสุ่มค่า r ของแต่ละตำแหน่งบิตในแต่ละโครโมโซม โดยถ้าค่า r ณ ตำแหน่งของบิตใดเป็นไปดังสมการที่ (3.16)

$$r \leq P_m \quad (3.16)$$

ค่าของบิต ณ ตำแหน่งนั้นก็จะถูกทำมิวเตชัน จำนวนบิตที่จะถูกทำการมิวเตชันนั้นสามารถคำนวณได้ดังสมการที่ (3.17)

$$\text{จำนวนของการมิวเตชัน} = P_m \times \text{Popsize} \times L \quad (3.17)$$

เมื่อ P_m คือ ความน่าจะเป็นของการมิวเตชัน
 Popsize คือ ขนาดของประชากรในรุ่นนั้นๆ
 L คือ ความยาวของโครโมโซม

ผลจากการมิวเตชัน ทำให้ได้โครโมโซมใหม่ที่มีรูปแบบของโครโมโซมแตกต่างจากเดิม ซึ่งมีโอกาสที่จะเป็นโครโมโซมที่ดีขึ้นหรือเลวลงก็ได้ หากโครโมโซมที่ได้ใหม่เป็นโครโมโซมที่เลวลง คือ มีค่าความเหมาะสมต่ำลง โครโมโซมที่ได้นี้ก็จะถูกคัดออกไปในขั้นตอนการคัดเลือก (Selection) นั่นเอง


วัตถุประสงค์ของการมิวเตชันคือ เพื่อป้องกันการสูญหายของข้อมูล และเพื่อความหลากหลายของข้อมูล สำหรับไบนารีมิวเตชัน เป็นการปรับเปลี่ยนข้อมูล ณ ตำแหน่งที่กำหนดนั้น โดยเปลี่ยนข้อมูลจาก 0 เป็น 1 หรือกลับกัน ตัวอย่างของการทำมิวเตชันแสดงดังรูปที่ 3.14 เป็นการสุ่มเลือกทำมิวเตชัน ณ ตำแหน่งที่ 8



รูปที่ 3.14 แสดงกระบวนการไบนารีมิวเตชัน

3.6.2.8 การสร้างประชากรรุ่นใหม่

ประชากรรุ่นใหม่เป็นกลุ่มโครโมโซมรุ่นลูกที่เกิดจากกระบวนการของวิวัฒนาการต่างๆ ทั้งหมด เริ่มตั้งแต่การวัดค่าความเหมาะสม ทำการคัดเลือก สุ่มเลือกเพื่อนำมาทำครอสโอเวอร์และมิวเตชันตามค่าความน่าจะเป็นที่ได้กำหนดไว้ ซึ่งเมื่อชุดโครโมโซมรุ่นลูกผ่านวิวัฒนาการต่างๆ ดังที่ได้กล่าวไปแล้วนั้นก็จะทำให้เกิดประชากรรุ่นใหม่ โดยที่ประชากรใหม่นี้จะถูกถ่ายทอดกลายเป็นประชากรรุ่นเก่า สำหรับวิวัฒนาการรุ่นถัดไปเช่นเดียวกัน ซึ่งจะเรียกวิวัฒนาการนี้ว่า การถ่ายทอดแบบทั่วไป หรือรีโพรดักชันแบบทั่วไป (General Reproduction) ขบวนการทั้งหมดในการสร้างประชากรสามารถแสดงได้ดังรูปที่ 3.15



รูปที่ 3.15 แสดงกระบวนการสร้างประชากรในรุ่นถัดไป

3.6.2.9 การกำหนดค่าตัวแปรต่างๆ

การกำหนดค่าตัวแปรต่างๆ ในกระบวนการเจเนติกอัลกอริทึมนั้น สามารถแบ่งออกได้เป็น 2 กลุ่ม ได้แก่ ตัวแปรที่ใช้ควบคุมการทำงานและเงื่อนไขการสิ้นสุดการทำงาน

a) ตัวแปรที่ใช้ควบคุมการทำงาน ตัวแปรในกลุ่มนี้ได้แก่

1. การกำหนดขนาดของประชากร (Population Size) จำนวนขนาดของประชากรมีผลกระทบต่อประสิทธิภาพ ความเร็วในการค้นหาคำตอบ และการใช้ทรัพยากรของระบบ ถ้าจำนวนประชากรน้อยเกินไป อาจทำให้ได้คำตอบที่ขาดประสิทธิภาพในการแก้ปัญหาต่างๆ ได้ แต่หากจำนวนประชากรมีมากเกินไปแล้วจะส่งผลให้การทำงานเพื่อค้นหาคำตอบจะต้องใช้เวลาและทรัพยากรมากขึ้น ดังนั้นการกำหนดจำนวนขนาดของประชากรจะต้องมีความเหมาะสม [21]

2. การกำหนดค่าความน่าจะเป็นในการคัดเลือก (Probability of Selection) การสุ่มเลขเพื่อเข้าสู่การคัดเลือกโดยใช้แบบจำลองการหมุนวงล้อถ่วงน้ำหนัก (Roulette Wheel) ถ้าตัวเลขที่สุ่มได้ทำให้เกิดช่วงค่าที่แคบเกินไป หรือกว้างเกินไป อาจทำให้โครโมโซมที่ดีไม่ถูกคัดเลือก หรือทำให้เกิดการคัดเลือกโครโมโซมบางตัวซ้ำๆ แม้ว่าในรุ่นนั้นจะมีประชากรโครโมโซมอื่นๆ อีกก็ตาม

3. การกำหนดค่าความน่าจะเป็นในการครอสโอเวอร์ (Crossover Probability) ที่เหมาะสม เพื่อผลิตโครโมโซมที่มีความหลากหลายในประชากรรุ่นต่อไป การกำหนดค่าความน่าจะเป็นในการครอสโอเวอร์ที่เหมาะสมมีส่วนในการเพิ่มประสิทธิภาพในการค้นหาคำตอบ

4. การกำหนดค่าความน่าจะเป็นในการมิวเตชัน (Mutation Probability) ที่เหมาะสม ซึ่งแต่ละปัญหาก็จะต้องการค่าความน่าจะเป็นในการครอสโอเวอร์และมิวเตชันที่แตกต่างกันไป ดังนั้นจึงควรเลือกใช้ให้เหมาะสมกับแต่ละปัญหา เพื่อให้การค้นหาคำตอบมีประสิทธิภาพมากที่สุด

5. จำนวนรุ่น (Number of Generation) ในการค้นหาคำตอบ

b) เงื่อนไขการสิ้นสุดการทำงาน

โดยปกติการแก้ไขปัญหามักจะเสร็จสิ้นเมื่อได้คำตอบที่ดีที่สุด คือได้โครโมโซมที่มีค่าความเหมาะสมสูงสุด สามารถแก้ไขปัญหาคือเป็นคำตอบที่ดีที่สุดของปัญหานั้นๆ หรือในแนวทางหนึ่ง สามารถกำหนดให้กระบวนการเจเนติกอัลกอริทึมสิ้นสุดการทำงานเมื่อถึงรุ่นสูงสุด (Max Generation) ที่กำหนดไว้ แล้วนำโครโมโซมที่มีค่าความเหมาะสมสูงสุดมาเป็นคำตอบที่ใกล้เคียง

กล่าวโดยสรุป เจเนติกอัลกอริทึมเป็นเทคนิคที่ใช้ในการค้นหาคำตอบ ซึ่งเลียนแบบมาจากกระบวนการวิวัฒนาการทางธรรมชาติที่นำมาประยุกต์ใช้กับคอมพิวเตอร์ เพื่อช่วยแก้ปัญหาในการหาคำตอบต่างๆ ซึ่งพื้นฐานการทำงานเบื้องต้นเป็นเจเนติกอัลกอริทึมแบบง่าย มีรูปแบบโครโมโซมเป็นแบบไบนารี การคัดเลือกใช้แบบจำลองการหมุนวงล้อถ่วงน้ำหนัก การครอสโอเวอร์เป็นการครอสโอเวอร์แบบหนึ่งจุด และมิวเตชันแบบไบนารี ซึ่งสามารถช่วยแก้ปัญหาในการค้นหาคำตอบให้แก่ระบบได้ ในการประยุกต์ใช้เจเนติกอัลกอริทึมกับปัญหาต่างๆ นั้นจะต้องมีการปรับปรุง เปลี่ยนแปลงในบางส่วน เช่น รูปแบบของโครโมโซม ฟังก์ชันความเหมาะสม หรือค่าตัวแปรต่างๆ เพื่อให้เข้ากับรูปแบบของปัญหา และเพื่อให้สามารถค้นหาคำตอบที่ดีที่สุดให้แก่ปัญหานั้น