บทความวิจัย

เพกาซัส: ระบบแนะนำเกมรายบุคคล

จุฑารัตน์ รุ่งวารินทร์* จิติมนต์ อั่งสกุล และ ธรา อั่งสกุล
สาขาวิชาเทคโนโลยีสารสนเทศ สำนักวิชาเทคโนโลยีสังคม มหาวิทยาลัยเทคโนโลยีสุรนารี

* ผู้นิพนธ์ประสานงาน โทรศัพท์ 09 7132 2852 อีเมล: d6020224@g.sut.ac.th DOI: 10.14416/j.kmutnb.2023.07.008
รับเมื่อ 25 พฤษภาคม 2564 แก้ไขเมื่อ 12 กรกฎาคม 2564 ตอบรับเมื่อ 17 สิงหาคม 2564 เผยแพร่ออนไลน์ 12 กรกฎาคม 2566
© 2023 King Mongkut’s University of Technology North Bangkok. All Rights Reserved.

บทคัดย่อ

ปัจจุบัน เกมเป็นสิ่งที่ได้รับความนิยมต่อบุคคลทุกเพศทุกวัย ส่งผลให้อุตสาหกรรมเกมเติบโตอย่างต่อเนื่องและเกมถูกพัฒนาขึ้นมาเป็นจำนวนมาก แต่อย่างไรก็ตาม เกมที่ถูกพัฒนาเหล่านั้นมีความคล้ายคลึงกันมาก ทำให้ผู้เล่นเกมตัดสินใจเลือกซื้อได้ยาก บทความนี้จึงนำเสนอระบบแนะนำเกมที่เหมาะสมกับความชอบเฉพาะของผู้เล่นชื่อเพกาซัส เพกาซัสใช้การแนะนำโดยอ้างอิงเนื้อหาหรือวิเคราะห์จากประวัติของผู้เล่น โดยได้ทำการทดลองออกแบบมอดูลการแนะนำด้วย 2 วิธี ได้แก่ วิธีการหาค่าความคล้ายของโคโซน์ และวิธีการหาค่าน้ำหนักจากความถี่ของแท็กคำ ทั้งนี้เพื่อหาวิธีที่เหมาะสมที่สุดที่จะนำไปใช้ในระบบเพกาซัส ซึ่งการประเมินระบบทำโดยการเปรียบเทียบเกมที่ระบบแนะนำกับเกมที่ผู้เล่นเลือกเล่นจริง ผลการประเมินพบว่า การออกแบบมอดูลการแนะนำด้วยวิธีการคำนวณหาค่าน้ำหนักจากความถี่ของแท็กคำ มีค่าความถูกต้องสูงกว่าวิธีการหาค่าความคล้ายของโคโซน์

คำสำคัญ: ระบบแนะนำรายบุคคล ระบบแนะนำเกม วิธีอ้างอิงเนื้อหา

การอ้างอิงบทความ: จุฑารัตน์ รุ่งวารินทร์, จิติมนต์ อั่งสกุล และ ธรา อั่งสกุล , “เพกาซัส: ระบบแนะนำเกมรายบุคคล,” *วารสารวิชาการพระจอมเกล้าพระนครเหนือ*, ปีที่ 33, ฉบับที่ 3, หน้า 1–10, เลขที่บทความ 233-215106, ก.ค.–ก.ย. 2566.

Research Article

PEGASUS: Personalized Game Suggestion System

Jutarat Rungwarin*, Jitimon Angskun and Thara Angskun
School of Information of Technology, Institute of Social Technology, Suranaree University of Technology, Nakhon Ratchasima, Thailand

* Corresponding Author, Tel. 09 7132 2852, E–mail: d6020224@g.sut.ac.th DOI: 10.14416/j.kmutnb.2023.07.008
Received 25 May 2021; Revised 12 July 2021; Accepted 17 August 2021; Published online: 12 July 2023
© 2023 King Mongkut's University of Technology North Bangkok. All Rights Reserved.

Abstract

Currently, games are very popular among people of all ages and from all walks of life. Consequently, the game industry continues to grow, and new games are being developed in large numbers. However, those developed games are very similar. This makes it difficult for gamers to make purchasing decisions. This article, therefore, presents "Pegasus," a personalized game recommendation system tailored to the specific preferences of players. The Pegasus function is on the basis of content-based recommendations or analysis of a player's game history. The experimental design of the recommendation module was carried out using two methods, i.e. the cosine similarity method and a word tag frequency weighting method. The most suitable method will be used in the Pegasus. The Pegasus system is evaluated by comparing the games recommended by the system with the games the players choose to play. The evaluation results reveal that the recommendation of the word tag frequency weighting method has higher accuracy than the cosine similarity method.

Keywords: Personalized Recommendation System, Game Recommendation System, Content-Based Method

Please cite this article as: J. Rungwarin, J. Angskun, and T. Angskun, "PEGASUS: Personalized game suggestion system," *The Journal of KMUTNB*, vol. 33, no. 3, pp. 1–10, ID. 233-215106, Jul.–Sep. 2023 (in Thai).

1. บทนำ

ปัจจุบันเกมเป็นหนึ่งในความบันเทิงที่ได้รับความนิยมสูง และเป็นอุตสาหกรรมหนึ่งที่สร้างรายได้อย่างมหาศาล [1] นอกจากนั้นเกมยังได้รับการพัฒนาในหลายแพลตฟอร์ม ได้แก่ สมาร์ตโฟน คอนโซล คอมพิวเตอร์ และอุปกรณ์เคลื่อนที่ต่างๆ และยังเป็นที่นิยมในทุกเพศทุกวัย [2] ในอดีตเกมถูกพัฒนาลงบนแพลตฟอร์มคอนโซลและมีรูปแบบการเล่นแบบออฟไลน์ โดยคุณภาพของกราฟิกยังไม่สวยงามนัก เช่น เกมแพ็คแมน (Pac-man) เกมมาริโอ้ (Mario) ในยุคถัดมาเกมเริ่มได้รับการพัฒนาให้มีกราฟิกที่สวยงามมากขึ้น รวมถึงรูปแบบการเล่นที่หลากหลาย เช่น แอ็กชัน วางแผน จำลองสถานการณ์ หลังจากนั้นเกมได้รับการพัฒนาผสมผสานร่วมกับระบบเครือข่ายอินเทอร์เน็ต จึงทำให้เกิดเกมออนไลน์ ซึ่งทำให้เกมมีความสนุกและมีความน่าสนใจจนเกิดความนิยมมากขึ้น [3] เนื่องจากเกมออนไลน์สามารถสร้างสังคมออนไลน์ได้ การเล่นเกมออนไลน์เหล่านี้ ผู้เล่นสามารถเลือกซื้อเกมอย่างสะดวกจากร้านค้าเกมออนไลน์ที่มีอยู่มากมาย เช่น สตีม (Steam) ออริจิน (Origin) ยูเพลย์ (Uplay) อีพิกเกมส์ (Epic Games) ฯลฯ จึงทำให้การเล่นเกมออนไลน์ ได้รับความนิยมมากจนนำไปสู่การแข่งขันกีฬาอีสปอร์ต (E-Sport) โดยใน พ.ศ. 2556 ได้มีการก่อตั้งสหพันธ์อีสปอร์ตนานาชาติ (International e-Sports Federation; IeSF) เพื่อการสนับสนุนและจัดแข่งขันกีฬาอีสปอร์ต และในปี พ.ศ. 2560 ประเทศไทยได้เข้าร่วมสหพันธ์อีสปอร์ตนานาชาติ โดยก่อตั้งสมาคมกีฬาอีสปอร์ตแห่งประเทศไทย (Thailand E-Sports Federation; TESF) [4]

อย่างไรก็ตาม เกมออนไลน์ได้รับการพัฒนาจากหลายบริษัทมีแนวการเล่นที่คล้ายคลึงกันเป็นจำนวนมาก ตัวอย่างเช่น เกมซึ่งมีแนวการเล่นแบบเอาชีวิตรอด อาทิ เกมสมรภูมิของผู้เล่นนิรนาม (PLAYERUNKNOWN'S BATTLEGROUNDS) เกมตำนานเอเพ็กซ์ (Apex Legends) เกมฟอร์ทไนต์แบทเท็ลโรยัล (Fortnite Battle Royale) เกมกฎของการอยู่รอด (Rules of Survival) เกมซึ่งมีแนวการเล่นแบบจำลองสถานการณ์ อาทิ เกมเดอร์ซิม (The Sims) เกมฟาร์มซิมูเลเตอร์ (Farm Simulator) เกมสปอร์ (Spore) เกมแพลเน็ตโคสเตอร์ (Planet Coaster) ซึ่งจะเห็นได้ว่า ในแต่ละเกมมีรูปแบบการเล่นที่คล้ายกันมาก จึงทำให้เกิดปัญหาการตัดสินใจ สับสนต่อการเลือกซื้อเกม ซึ่งเรียกว่า ปฏิทรรศน์ของทางเลือก (Paradox of Choice) [5]

ในอดีตที่ผ่านมามีงานวิจัยที่ศึกษาเกี่ยวกับระบบแนะนำหลายงานวิจัย ซึ่งสามารถแบ่งกลุ่มตามลักษณะของวัตถุประสงค์ของงานวิจัยได้ 4 กลุ่ม ได้แก่ กลุ่มงานวิจัยที่มีวัตถุประสงค์เพื่อแนะนำแท็กคำ กลุ่มงานวิจัยที่มีวัตถุประสงค์เพื่อแนะนำบทความ กลุ่มงานวิจัยที่มีวัตถุประสงค์เพื่อแนะนำภาพยนตร์ และกลุ่มงานวิจัยที่มีวัตถุประสงค์เพื่อแนะนำเกม

กลุ่มงานวิจัยที่มีวัตถุประสงค์เพื่อแนะนำแท็กคำจะนำเสนอแท็กคำที่เหมาะสมสำหรับเว็บไซต์หรือเครือข่ายทางสังคม Lu และคณะ [6] ได้เก็บและวิเคราะห์ข้อมูลจากคำที่อยู่ในยูอาร์แอล (URL) ที่เป็นบุ๊คมาร์ก (Bookmark) จากเว็บ Delicious ด้วยวิธีใช้แท็กคำ ประเมินผลด้วยวิธีการตรวจสอบไขว้ (Cross Validation) แนะนำแบบ Top-5 ผลที่ได้คือ มีค่าความเที่ยงตรง 59% และใช้จำนวนแท็กที่เกี่ยวข้อง 32% จากผู้ใช้โดยตรง มีค่าความเที่ยงตรง 69.45% จากการรวบรวมข้อมูลจาก 31 เว็บเพจ ทั้งนี้ ข้อมูลจากเว็บไซต์มีการเปลี่ยนแปลงตลอดทำให้ค่าความถูกต้องไม่คงที่ งานวิจัยของ Maity และคณะ [7] แนะนำแท็กคำถามที่เหมาะสมบนเว็บสแต็กโอเวอร์โฟลว (Stack Overflow) โดยวิเคราะห์ด้วยการเรียนรู้เชิงลึก (Deep Learning) ที่พัฒนาขึ้นชื่อว่า DeepTagRec วิเคราะห์เปรียบเทียบกับ TagCombine ซึ่งเป็นแบบจำลองมาตรฐาน จากนั้นประเมินด้วยค่า ความเที่ยงตรง และค่าระลึก ใช้ Top-n (n = 3, 5, 10) พบว่า DeepTagRec มีประสิทธิภาพดีกว่า TagCombine งานวิจัยของ Cantador และคณะ [8] ใช้เทคนิคทีเอฟ-ไอดีเอฟ ในการหาค่าน้ำหนักของคำ และปริภูมิเวกเตอร์ ในการวัดความถี่ของคำ โดยเปรียบเทียบหลายแบบจำลองเพื่อหาแบบจำลองที่ดีที่สุดซึ่งพบว่า แบบจำลอง คอส-บีเอ็ม25 (COS-BM25) เป็นแบบจำลองที่ดีที่สุด งานวิจัยของ Subercaze และคณะ [9] นำเสนอวิธีการแนะนำแบบเรียลไทม์ด้วยวิธีแฮชกราฟ (Hash Graph) และใช้ค่าความคล้ายของโคไซน์ ผลการทดลองพบว่า วิธีการ

ดังกล่าวมีค่าความเที่ยงตรง 58%

กลุ่มงานวิจัยเพื่อแนะนำบทความ จะใช้เทคนิคทีเอฟ-ไอดีเอฟ ในการหาค่าน้ำหนักของคำที่ปรากฏในเนื้อหาของบทความ โดยงานวิจัยของ Wang และคณะ [10] ใช้วิธีการตัดข้อความเพื่อหารากศัพท์ และการเลือกคุณลักษณะ (Feature) ซึ่งทำให้ได้ค่าความถูกต้อง 61.37% งานวิจัยของอาชากุลวิสุตและคณะ [11] ใช้วิธีการวิเคราะห์หาความหมายแฝง (Latent Semantic Analysis) การจำแนกกลุ่มด้วยเพื่อนบ้านใกล้สุด (Nearest Neighbor) และขั้นตอนวิธีร็อคชิโอ (Rocchio Algorithm) เพื่อวิเคราะห์ความเกี่ยวข้องของคำ ซึ่งพบว่า เทคนิคเวกเตอร์คำ (Word Vector) มีนัยสำคัญสูงสุดที่ 0.48 งานวิจัยของฟิลลิปและคณะ [12] พบว่าการใช้เทคนิค เทคนิคทีเอฟ-ไอดีเอฟ ในการหาค่าน้ำหนักของคำร่วมกับค่าความคล้ายของโคไซน์ สามารถนำมาใช้กับระบบการแนะนำได้ดีกับวิธีอ้างอิงเนื้อหา (Content-Based) eteren และ Someren [13] นำเสนอการแนะนำบทความเกี่ยวกับวิธีการปรับปรุงบ้านให้กับผู้ใช้ โดยใช้ปริภูมิเวกเตอร์ในการวัดความถี่ของคำ และใช้ค่าความคล้ายของโคไซน์ ผลการทดลองพบว่า ระบบแนะนำนี้สามารถแนะนำบทความที่มีเกี่ยวข้องกันได้มากกว่าครึ่งหนึ่ง แต่คำหนึ่งคำอาจมีได้หลายความหมาย ซึ่งทำให้ผลการแนะนำมีความถูกต้องน้อยลง ผลลัพธ์จะมีความแม่นยำมากขึ้นหากปรับปรุงแบบจำลองปริภูมิเวกเตอร์

กลุ่มงานวิจัยที่มีวัตถุประสงค์ในการแนะนำภาพยนตร์ ใช้วิธีการหาน้ำหนักของคุณลักษณะ ที่แตกต่างกัน งานวิจัยของ Rutkowski และคณะ [14] ใช้การหาน้ำหนักตามกฎของฟัซซี่ (Fuzzy Rules) และใช้โครงสร้างของโครงข่ายประสาทเทียมเชิงลึก (Deep Neural Network; DNN) สำหรับการดึงคุณลักษณะ ร่วมกับเพอร์เซ็ปตรอนหลายชั้น (Multi-Layer Perceptron; MLP) หรือโครงข่ายประสาทเทียมที่มีโครงสร้างเป็นแบบหลายชั้นพบว่า ได้ค่าประสิทธิผล (Effectiveness) 97% งานวิจัยของ Debnath และคณะ [15] หาค่าน้ำหนักด้วยการวิเคราะห์การทดถอยเชิงเส้น (Linear Regression) พบว่าได้คุณลักษณะที่สำคัญ 3 อันดับแรก ได้แก่ ประเภทของภาพยนตร์ ผู้เขียนบทภาพยนตร์ และบริษัทผลิตภาพยนตร์ โดยมีค่าระลึก (Recall) 0.29

ถึงแม้ว่างานวิจัยทั้งสามกลุ่มดังกล่าวข้างต้นจะมิได้มีวัตถุประสงค์สำหรับแนะนำเกมโดยตรง แต่เทคนิคต่างๆ ของงานวิจัยเหล่านั้นสามารถนำมาประยุกต์ใช้ได้ในงานวิจัยนี้ สำหรับกลุ่มงานวิจัยที่มีวัตถุประสงค์ในการแนะนำเกม จะนิยมใช้ปริภูมิเวกเตอร์ (Vector Space) ในการวัดความถี่ของคำ และ ใช้ค่าความคล้ายของโคไซน์ (Cosine Similarity) งานวิจัยของ Yang และคณะ [16] นำเสนอระบบแนะนำเกมรายบุคคลซึ่งพบว่าการแนะนำแบบไฮบริด งานวิจัยของ Meidl และคณะ [17] ใช้วิธีโคคลัสเตอร์ริ่ง (Co-clustering) และทีเอฟ-ไอดีเอฟ (TF-IDF) ในการจัดกลุ่ม คำวิเศษณ์และคำบริบท โดยใช้ความรู้ก่อนประสบการณ์ (A Priori Knowledge) ในการแยกบทวิจารณ์เกมว่าเป็นเชิงบวกหรือเชิงลบ ผลการประเมินพบว่ามีค่าความเที่ยงตรง (Precision) สูงสุด 86% Anwar และคณะ [18] นำเสนอการแนะนำทั่วไปประยุกต์กับวิธีการกรองร่วมกันพบว่า มีค่าคลาดเคลื่อนเฉลี่ยสัมบูรณ์ (Mean Absolute Error; MAE) น้อยที่สุดคือ 0.29 Tao และคณะ [19] ศึกษาวิจัยการแนะนำไอเทมภายในเกม โดยแนะนำจากประวัติของผู้เล่นที่ผู้เล่นเคยซื้อภายในเกม และนำเสนอวิธีการแนะนำด้วยข้อมูลทางสังคมเพิ่มเติมซึ่งพบว่า การแนะนำแบบไฮบริดร่วมกับการมีเพื่อนจำนวน 100 คนขึ้นไป มีค่าความเที่ยงตรงสูงสุด Pathak และคณะ [20] นำเสนอวิธีแนะนำชุดเกมที่มีอยู่และสร้างชุดเกมใหม่ ด้วยขั้นตอนวิธีเชิงละโมบ (Greedy Algorithm) ซึ่งพบว่า แบบจำลองปกติ (Vanilla Model) รวมกับขนาดและชุดสหสัมพันธ์ (Size and Bundle Correlation) มีค่าพื้นที่ใต้โค้ง (AUC) สูงสุด Bertens และคณะ [21] เก็บข้อมูลพฤติกรรมการเล่น การซื้อ ของผู้เล่นจากเกมการ์ดญี่ปุ่นชื่อ Age Of Ishtaria โดยใช้การเปรียบเทียบ 2 วิธี ได้แก่ โครงข่ายประสาทเชิงลึก (Deep Neural Networks; DNN) และ Extremely Randomized Trees (ERT) และใช้การแนะนำด้วย Top-3 พบว่า ค่าความถูกต้องของ ERT ดีกว่า DNN Cheuque และคณะ [22] ใช้ 2 วิธีผสมผสานกัน ได้แก่ Factorization Machines (FM) และ โครงข่ายประสาทเชิงลึก (DeepNN) รวมเรียกว่า DeepFM โดยเปรียบเทียบกับ

แบบจำลองอื่นๆ พบว่า DeepFM แบบไม่ได้วิเคราะห์ความรู้สึก มีค่า MAP, NDCG, Novelty/Diversity สูงสุด

จากการศึกษางานวิจัยที่เกี่ยวข้องพบว่า วิธีอ้างอิงเนื้อหานั้นเป็นที่นิยม เนื่องจากมีค่าประสิทธิผลที่สูง และการแนะนำโดยการใช้วิธีอ้างอิงเนื้อหายังให้ข้อมูลที่แม่นยำ เนื่องจากเป็นข้อมูลที่ได้จากประวัติการเล่นของผู้เล่นเอง นอกจากนี้ยังพบว่า วิธีการที่นิยมในการหาค่าความคล้าย คือ ค่าความคล้ายของโคไซน์ และวิธีการที่นิยมนำมาหาค่าความถี่คือ เทคนิคทีเอฟ-ไอดีเอฟ บทความนี้นำเสนอการพัฒนาระบบแนะนำเกมรายบุคคล มีชื่อเรียกว่า เพกาซัส (PErsonalized GAme SUggestion System; PEGASUS) ซึ่งเป็นระบบแนะนำเกมรายบุคคลซึ่งใช้วิธีอ้างอิงเนื้อหา โดยได้ทำการทดลองออกแบบมอดูลการแนะนำด้วย 2 วิธี ได้แก่ วิธีการหาค่าความคล้ายของโคไซน์ และวิธีการหาค่าน้ำหนักจากความถี่ของแท็กคำ ทั้งนี้เพื่อหาวิธีที่เหมาะสมที่สุดที่จะนำไปใช้ในระบบเพกาซัส

2. วัสดุ อุปกรณ์และวิธีการวิจัย

2.1 สถาปัตยกรรมของระบบเพกาซัส

ระบบเพกาซัส ประกอบด้วยส่วนประกอบ 4 ส่วนหลัก ได้แก่ ส่วนติดต่อกับผู้ใช้งาน ส่วนประมวลผล ส่วนมอดูลแนะนำ และส่วนการประเมินมอดูลการแนะนำ แสดงดังรูปที่ 1

2.1.1 ส่วนติดต่อกับผู้ใช้งาน

ผู้ใช้ต้องเข้าสู่ระบบด้วยบัญชีของสตีม (Steam ID) ผ่านเว็บแอปพลิเคชัน (Web Application) เพื่อให้ระบบเชื่อมต่อกับสตีม และสามารถเรียกใช้บริการสตีมเอพีไอ (Steam API) ได้ จากนั้นระบบจะดึงข้อมูลเกมทั้งหมดในสตีมและข้อมูลการเล่นเกมของผู้ใช้ ซึ่งประกอบด้วย ข้อมูลเกมทั้งหมดของสตีม ได้แก่ รหัสเกม (App-ID) และแท็กคำที่เกี่ยวข้องกับเกม (Tags) และข้อมูลของผู้เล่น ได้แก่ รหัสเกม จำนวนเวลาในการเล่นเกม (Play-Time) และแท็กคำที่เกี่ยวข้องกับเกม (Tags) ตัวอย่างสตีมเอพีไอที่ใช้ในการดึงข้อมูลผู้เล่น เช่น "http://api.steampowered.com/IPlayerService/GetOwnedGames/v0001/?key=<KEY_ID>&steamid=<STEAM_ID>&format=json" สตีมเอพีไอนี้ใช้สำหรับดึงข้อมูลของผู้ใช้

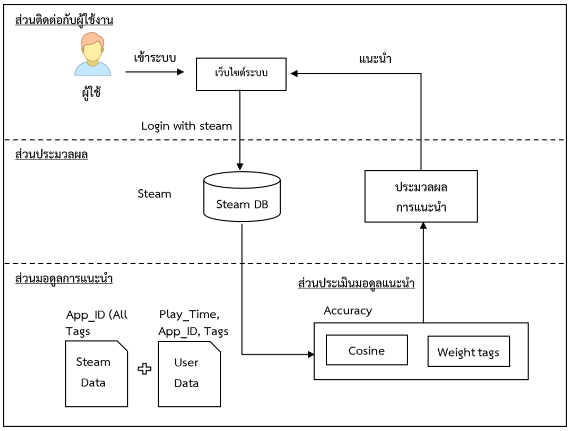

รูปที่ 1 สถาปัตยกรรมของเพกาซัส

สามารถระบุไอดีสตีม (Steamid) ของผู้เล่นได้ ซึ่งเป็นข้อมูลลักษณะของเจสัน (json) ในบทความนี้ใช้ข้อมูลตามที่กล่าวข้างต้นเก็บไว้ในไฟล์ .csv โดยนำข้อมูลเหล่านี้ไปประมวลผลต่อในมอดูลการแนะนำต่อไป

2.1.2 ส่วนประมวลผล

หลังจากที่ผู้ใช้เข้าสู่ระบบด้วยบัญชีของสตีม ระบบจะดึงข้อมูลผู้ใช้ด้วยสตีมเอพีไอเก็บไว้ในฐานข้อมูล เพื่อจะนำไปประมวลผลในส่วนมอดูลแนะนำ และในส่วนนี้จะรับผลประเมินการแนะนำจากมอดูลแนะนำที่เปรียบเทียบมาจาก 2 วิธี จากนั้นเลือกวิธีที่มีค่าความถูกต้องสูงที่สุดมาแนะนำเกมให้กับผู้ใช้

2.1.3 ส่วนมอดูลการแนะนำ

การทำงานของมอดูลการแนะนำได้ประยุกต์ใช้วิธีการแนะนำ 2 วิธีการ ได้แก่

วิธีที่ 1 แนะนำด้วยการใช้ค่าน้ำหนักตามความถี่ของแท็กคำในแต่ละเกม (Weight Tag) โดยรวบรวมข้อมูลเกมทั้งหมดจำนวน 100 เกมต่อผู้เล่น 1 คน จำนวน 30 ผู้เล่น จากนั้นนำเกมทั้ง 100 เกม มาจัดกลุ่ม ด้วยเคมีน (K-Mean) [23] จำนวน 2 กลุ่มตามเวลาการเล่น ได้แก่ กลุ่มที่ 1 เป็นเกมที่ผู้เล่นชอบเล่น และกลุ่มที่ 2 เป็นกลุ่มที่ผู้เล่นไม่ชอบเล่น หลังจากได้เกมในกลุ่มที่ 1 จะนำแท็กคำที่เกี่ยวข้องในกลุ่มนั้นมาคำนวณค่าน้ำหนักของแต่ละแท็กคำตามสมการที่ (1)

วิธีที่ 2 แนะนำด้วยค่าความคล้ายโคไซน์ โดยรวบรวม

ข้อมูลเกมทั้งหมดจำนวน 100 เกมต่อผู้เล่น 1 คน จำนวน 30 ผู้เล่น เช่นเดียวกับวิธีที่ 1 จากนั้นนำเกมที่มีเวลาการเล่นสูงสุดมาคำนวณตามสมการที่ (2)

จากทั้ง 2 วิธีข้างต้น ในบทความนี้ใช้การหาค่าความถูกต้องและเปรียบเทียบว่าวิธีการใดมีความถูกต้องมากกว่า ซึ่งระบบจะเลือกใช้วิธีการดังกล่าวในการทำงานจริง

2.1.4 ส่วนการประเมินมอดูลการแนะนำ

บทความนี้ได้รวบรวมข้อมูลจากสตีมเอพีไอ โดยแบ่งเป็น 2 ส่วน คือ

ส่วนที่ 1 ข้อมูลใช้ในการวิเคราะห์ ได้แก่ ข้อมูลของผู้เล่นเกม และข้อมูลแท็กคำที่เกี่ยวข้องกับเกม โดยใช้กลุ่มตัวอย่างจำนวน 30 คน [24] คนละ 100 เกม

ส่วนที่ 2 ข้อมูลที่ใช้ในการเปรียบเทียบความถูกต้องในการแนะนำเกม ได้แก่ เกมที่ผู้เล่นเคยเล่นในอดีต โดยใช้กลุ่มตัวอย่างจำนวน 100 เกมแรกที่มีจำนวนนาทีการเล่นนานสูงสุด

2.2 การออกแบบมอดูลการแนะนำของระบบเพกาซัส

2.2.1 การเตรียมข้อมูล

บทความนี้ดึงข้อมูลจากสตีมเอพีไอ ด้วยภาษาไพธอน (Python) ได้แก่ ข้อมูลของเกมทั้งหมดบนสตีม ดังแสดงในรูปที่ 2 และข้อมูลเกมของผู้เล่น (เกม 100 เกมแรกที่มีระยะเวลาการเล่นเกมสูงสุด) แท็กคำที่เกี่ยวข้องของเกม 100 เกม เช่น g1, g2, ... , g100 โดยกำหนดให้มีค่า 0 และ 1 ซึ่ง 0 หมายถึง ไม่มีแท็กคำที่เกี่ยวข้อง และ 1 หมายถึง มีแท็กคำที่เกี่ยวข้อง ซึ่งตัวอย่างของแท็กคำ จากนั้นนำเกมทั้ง 100 เกมไปจัดกลุ่ม ของเวลาการเล่น ด้วยเคมีน จำนวน 2 กลุ่ม ได้แก่ กลุ่มที่ 0 เป็นเกมที่ผู้เล่นสนใจเล่นจริง และกลุ่มที่ 1 เป็นกลุ่มที่ผู้เล่นไม่สนใจมากนัก จากนั้นนำแท็กเกมของเกมกลุ่มที่ 0 ไปคำนวณหาค่าน้ำหนักของแท็กคำในขั้นตอนถัดไป

2.2.2 การแนะนำด้วยวิธีใช้เนื้อหา

บทความนี้ได้ศึกษาการแนะนำด้วยวิธีใช้เนื้อหา 2 วิธีการ ได้แก่

วิธีการที่ 1 วิธีการคำนวณค่าความคล้ายจากค่าน้ำหนัก (Weight) ตามความถี่ (Frequency) ของแท็กคำ (Tags) สามารถคำนวณโดยนำผลรวมของค่าความถี่ของแท็กคำนั้นๆ ที่ได้มาจากจัดกลุ่มเกมในกลุ่มที่ 0 คูณด้วยระยะเวลาในการเล่นเกมนั้นๆ หารด้วยจำนวนแท็กคำทั้งหมด จะได้ผลลัพธ์เป็นค่าน้ำหนักของแท็กคำ จากนั้นนำเกมที่ระบบจะแนะนำมาตรวจสอบแท็กคำที่เกี่ยวข้อง เพื่อคำนวณหาคะแนนสูงสุด 5, 10 และ 15 เกมแนะนำ ดังแสดงในสมการที่ (1)

$$Weight\ of\ Tags_i = \frac{\sum\left(FreqTags_i \times Play_time\right)}{AllFreqTags} \qquad (1)$$

หลังจากเสร็จสิ้นขั้นตอนในการคำนวณหาน้ำหนักของแต่ละแท็กคำแล้ว ระบบจะคำนวณคะแนนของเกมทั้งหมดจาก 100 เกม ด้วยค่าน้ำหนักของแท็กคำที่คำนวณไว้ จากนั้นระบบจะแนะนำเกมที่มีคะแนนสูงสุดตามลำดับให้กับผู้เล่นจำนวน 5, 10 และ 15 เกมแรก และนำไปหาค่าความถูกต้องในขั้นตอนถัดไป

วิธีการที่ 2 วิธีการคำนวณค่าความคล้ายของโคไซน์ (Cosine Similarity) [25] ซึ่งสามารถคำนวณโดยนำผลคูณของ 2 เวกเตอร์ แล้วหารด้วยขนาดของทั้งสองเวกเตอร์ โดยระบบเพกาซัสจะนำทุกแท็กคำของเกมที่มีจำนวนเวลาการเล่นสูงสุดเกมแรกเพียง 1 เกม มาเปรียบเทียบกับแท็กคำของเกมทั้งหมด จากนั้นระบบจะแนะนำเกมที่มีแท็กคำที่มีค่าความคล้ายของโคไซน์สูงสุด วิธีการคำนวณค่าความคล้ายของโคไซน์สามารถแสดงดังสมการที่ (2)

$$Cosine\ Similarity = \frac{X \cap Y}{|X|^{1/2} \cdot |Y|^{1/2}} \qquad (2)$$

โดยที่ X, Y คือ ชุดแท็กคำของ X และ Y โดยมีสมาชิกเป็น 0 กับ 1 (เมื่อ 0 หมายถึง ไม่มีความคล้าย และ 1 หมายถึง มีความคล้ายกัน)

หลังจากคำนวณค่าความคล้ายของโคไซน์ จากนั้นระบบจะแนะนำเกมที่มีค่าความคล้ายของโคไซน์สูงสุดตามลำดับให้กับผู้เล่นจำนวน 5, 10 และ 15 เกมแรก และนำไปหาค่าความถูกต้องในขั้นตอนถัดไป

3. ผลการทดลอง

การประเมินระบบเพกาซัสกระทำโดยการเปรียบเทียบวิธีการแนะนำทั้ง 2 วิธี คือ วิธีการแนะนำโดยการใช้ค่าน้ำหนักตามความถี่ของแท็กคำในแต่ละเกมและวิธีการแนะนำด้วยค่าความคล้ายโคไซน์ มาเปรียบเทียบด้วยค่าความถูกต้อง (Accuracy) กับรายการเกมของผู้เล่นจริง จาก 5, 10 และ 15 เกมแนะนำ ซึ่งผลการประเมินในบทความนี้แบ่งออกเป็น 3 ส่วน ดังนี้

3.1 การคำนวณหาค่าความคล้ายด้วยการหาค่าน้ำหนักจากความถี่ของแท็กคำ (Weight Frequency)

เมื่อคำนวณค่าน้ำหนักของแต่ละแท็กคำแล้ว จะได้ผลตัวอย่างค่าน้ำหนักของแท็กคำ ดังตารางที่ 1

ตารางที่ 1 ตัวอย่างค่าความคล้ายของแท็กคำด้วยวิธีการหาค่าน้ำหนักจากความถี่ของแท็กคำ

ลำดับ	แท็กคำ	ค่าน้ำหนักของแท็กคำ
1	Action	4.86
2	Singleplayer	4.57
3	Multiplayer	4.45
4	Adventure	3.75
5	Co-op	3.46

จากนั้นนำค่าคะแนนแท็กคำจากตารางที่ 1 ไปคำนวณกับแท็กคำของเกม 100 เกมที่ผู้เล่นเคยเล่นในอดีต เพื่อคำนวณหาคะแนน (Point) อันดับเกมที่มีคะแนนสูงสุดสำหรับแนะนำผู้เล่น ซึ่งสามารถแสดงได้ดังตัวอย่างผลการแนะนำในตารางที่ 2

ตารางที่ 2 ตัวอย่างการแนะนำเกมด้วยค่าคะแนน (Point) ที่ได้จากการคำนวณค่าความคล้ายของแท็กคำด้วย การหาค่าน้ำหนักจากความถี่ของแท็กคำ

ลำดับ	เกม	คะแนน
1	G1	44.05
2	G2	42.7
3	G3	42.58
4	G4	42.35
5	G5	41.66

3.2 การคำนวณหาค่าความคล้ายของโคโซน์

นำข้อมูลเกมที่มีการเล่นนานสูงสุดของผู้เล่นมาคำนวณกับเกมทั้งหมดบนสตีม ตามสมการที่ (2) จะได้ผลตัวอย่าง ดังตารางที่ 3

ตารางที่ 3 ค่าความคล้ายของแท็กคำด้วยวิธีการหาค่าความคล้ายของโคโซน์

ลำดับ	เกม	ค่าความคล้ายของโคโซน์
1	G1	1
2	G2	0.90
3	G3	0.75
4	G4	0.75
5	G5	0.70

3.3 การเปรียบเทียบความถูกต้องของวิธีวัดความคล้าย

ขั้นตอนการหาค่าความถูกต้องของมอดูลการแนะนำของระบบเพกาซัส ซึ่งใช้วิธีการวัดความคล้ายที่แตกต่างกัน 2 วิธี จะนำไปเปรียบเทียบกับเกมที่ผู้เล่นเคยเล่นจริง ซึ่งสามารถคำนวณตามสมการที่ (3)

$$Accuracy = \frac{SystemRec.}{N} \tag{3}$$

โดยที่ $SystemRec.$ คือ เกมที่ระบบแนะนำได้ตรง
N คือ เกมทั้งหมดที่ผู้เล่นเคยเล่นจริง

ค่าความถูกต้องจะอยู่ระหว่าง 0.00–1.00 หากค่าเข้าใกล้ 1.00 หมายถึง มีความถูกต้องสูงจากการคำนวณของทั้งสองวิธี จะได้รายการเกมที่ระบบเพกาซัสแนะนำเป็นจำนวน 5, 10 และ 15 เกมแนะนำ (Top-5, Top-10, Top-15) จากนั้นนำเกมที่ได้มาคำนวณหาค่าความถูกต้องตามสมการที่ (3) เพื่อนำไปสู่การประเมินระบบเพกาซัสต่อไป ซึ่งผลลัพธ์ของการเปรียบเทียบค่าเฉลี่ยความถูกต้องของการจัดอันดับ 5, 10 และ 15 อันดับแรก จำนวน 30 คน ระหว่างการหาค่าน้ำหนักจากความถี่ของแท็ก และวิธีการหาค่าความคล้ายของโคโซน์ ผลลัพธ์แสดงดังรูปที่ 2 และตารางที่ 4

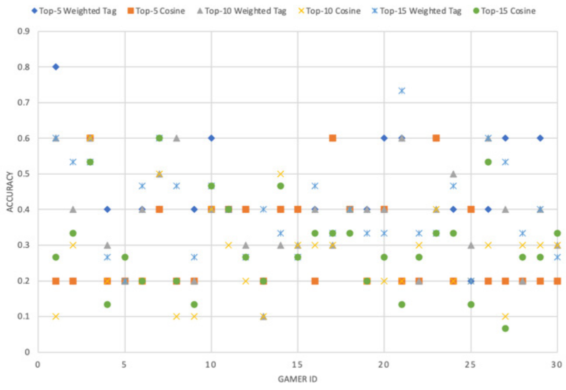

รูปที่ 2 ผลการประเมินความถูกต้อง

ตารางที่ 4 การเปรียบเทียบค่าเฉลี่ยความถูกต้อง ระหว่างการหาค่าน้ำหนักจากความถี่ของแท็ก และวิธีการหาค่าความคล้ายของโคไซน์

ท็อป-เอ็น	ค่าเฉลี่ยความถูกต้อง	
	ความถี่ของแท็กคำ	โคไซน์
Top5	0.41	0.30
Top10	0.38	0.27
Top15	0.40	0.30

จากตารางที่ 4 พบว่า ค่าเฉลี่ยความถูกต้องแบบ Top-5, Top-10 และ Top-15 ของการหาค่าน้ำหนักจากความถี่ของแท็กคำมีค่าสูงกว่าการหาด้วยค่าความคล้ายของโคไซน์ 0.41 และ 0.30 ใน Top-5 0.38 และ 0.27 ใน Top-10 และ 0.40 และ 0.30 ใน Top-15 ตามลำดับ ซึ่งการแนะนำด้วยวิธีการคำนวณจากค่าน้ำหนักจากความถี่ของแท็กคำมีค่าความถูกต้องสูงกว่าการหาด้วยค่าความคล้ายของโคไซน์ ดังนั้นระบบเพกาซัสจึงเลือกใช้วิธีการคำนวณจากค่าน้ำหนักจากความถี่ของแท็กคำในการแนะนำเกมรายบุคคล

4. อภิปรายผลและสรุป

บทความนี้นำเสนอระบบแนะนำเกมที่เหมาะสมกับความชอบเฉพาะของผู้เล่นแต่ละบุคคล เรียกว่าเพกาซัส (PErsonalized GAme SUggestion System; PEGASUS) โดยใช้วิธีอ้างอิงเนื้อหา 2 วิธี ได้แก่ วิธีการหาค่าความคล้ายของโคไซน์ และการหาค่าน้ำหนักจากความถี่ของแท็กคำ ซึ่งใช้ปัจจัยที่เกี่ยวข้องได้แก่ เกม แท็กคำที่เกี่ยวข้อง และเวลาในการเล่นเกม ผลการทดลองพบว่า การแนะนำด้วยการคำนวณจากค่าน้ำหนักจากความถี่ของแท็กคำมีค่าความถูกต้องสูงกว่าการหาด้วยค่าความคล้ายของโคไซน์ ทั้งนี้ วิธีการหาค่าความคล้ายของโคไซน์มีจุดเด่นในการแนะนำเกมอันดับแรกๆ แต่มีความไม่แม่นตรงในลำดับ อื่นๆ เนื่องจากค่าของโคไซน์มีการซ้ำกันทำให้เกิดการเรียงลำดับของเกมต้องดูจาก Top-n จำนวนมาก ซึ่งต้องวิเคราะห์ร่วมกับปัจจัยอื่นเพื่อเพิ่มความถูกต้อง ในขณะที่วิธีการคำนวณจากค่าน้ำหนักจากความถี่ของแท็กคำมีจุดเด่นด้านการแนะนำเกมในทุกลำดับ มากกว่าค่าความคล้ายของโคไซน์

งานวิจัยในอนาคต สำหรับระบบเพกาซัสจะมีการเพิ่มปัจจัยให้มากขึ้น เช่น จำนวนรางวัลภายในเกม การใช้วิธีการแนะนำแบบการกรองร่วมกัน การจัดกลุ่มผู้เล่น และประเภทของเกม เพื่อเพิ่มความถูกต้องในการแนะนำให้มากขึ้น

เอกสารอ้างอิง

[1] Newzoo. (2017, April 20). *Mobile revenues on the rise as Chinese giants continue to grow* [Online]. Available: https://newzoo.com/insights/articles/the-global-games-market-will-reach-108-9-billion-in-2017-with-mobile-taking-42/

[2] Statista. (2020, July). *Age breakdown of video game players in the United States in 2020* [Online]. Available: https://www.statista.com/statistics/189582/age-of-us-video-game-players-since-2010/

[3] IEEE. (2015). *Historic Gaming Timeline* [Online]. Available: https://www.secured-app.com/ieee/historic-gaming-timeline/

[4] Thailand E-Sport Federation. (2019). *History of Thailand E-Sport Federation* [Online] (in Thai). Available: http://www.tesf.or.th/history-of-thailand-e-sport-federation/

[5] B. Schwartz (2007). *Paradox of Choice WHY MORE IS LESS* [Online]. Available From: http://wp.vcu.edu/univ200choice/wp-content/uploads/sites/5337/2015/01/The-Paradox-of-Choice-Barry-Schwartz.pdf

[6] Y. Lu, S. Yu, T. Chang, and J. Y. Hsu, "A Content-Based Method to Enhance Tag Recommendation," in *Proceedings of the Twenty-First International Joint Conference on Artificial Intelligence*, 2009, pp. 2064–2069.

[7] S. K. Maity, A. Panigrahi, S. Ghosh, A. Banerjee, P. Goyal, and A. Mukherjee, "DeepTagRec: A content-cum-user based tag recommendation framework for stack overflow," in *Proceedings of 41st European Conference on IR Research (ECIR), 2019*, pp. 125–131.

[8] I. Cantador, A. Bellogín, and D. Bellogín, "Content-based recommendation in social tagging systems," in *Proceedings of the 4th ACM conference on Recommender systems*, 2010, pp. 237–240.

[9] J. Subercaze, C. Gravier, and F. Laforest, "Real-Time, Scalable, Content-based Twitter users recommendation," *Journal of Web Intelligence*, vol. 14, no. 1, pp. 17–29, 2016.

[10] D. Wang, Y. Liang, D. Xu, X. Feng, and R. Guan, "A content-based recommender system for computer science publications," *Journal of Knowledge-Based Systems*, vol. 157, pp. 1–9. 2018.

[11] T. Achakulvisut, D. E. Acuna, T. Ruangrong, and K. Kording, "Science concierge: A fast content-based recommendation system for scientific publications," *Journal of PLoSS ONE*, vol. 11, no. 7, pp. 1–11, 2016.

[12] S. Philip, P. B. Shola, and A. O. John, "Application of content-based approach in research paper recommendation system for a digital library," *International Journal of Advanced Computer Science and Applications*, vol. 5, no. 10, pp. 37–40, 2014.

[13] R. Meteren and M. V. Someren, "Using content-based filtering for recommendation," in *Proceedings of the Machine Learning in the New Information Age*, 2000, pp. 47–56

[14] T. Rutkowski, J. Romanowski, P. Woldan, P. Staszewski, R. Nielek, and L. Rutkowski, "A content-based recommendation system using neuro-fuzzy approach," presented at the 2018 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE), Rio de Janeiro, Brazil, 8-13 July, 2018

[15] S. Debnath, N. Ganguly, and P. Mitra, "Feature weighting in content based recommendation system using social network analysis," in *Proceedings of the 17th International Conference on World Wide Web*, 2008, pp. 1041–1042.

[16] C. H. Yang, Z. R. Huang, C. S. Lin, and T. H. Tsai, "Text mining on player personality for game recommendation," in *Proceeding of the 4th Multidisciplinary International Social Networks Conference*, 2017, pp. 1–6.

[17] M. Meidl, S Lytinen, and K. Raison, "Using game reviews to recommend games," in *Proceedings of AAAI AIIDE*, 2014, pp. 24–29.

[18] M.S. Anwar, T. Shahzad, Z. Sattar, R. Khan and M. Majid, "A game recommender system using collaborative filtering (GAMBIT)," in *Proceedings 14th International Bhurban Conference on*

Applied Sciences & Technology (IBCAST), 2017, pp. 328–332.

[19] Z. Tao, M. Cheung, J. She, and R. Lam, "Item recommendation using collaborative filtering in mobile social games: A case study," in *Proceeding IEEE 4th International Conference on Big Data and Cloud Computing*, 2014, pp. 293–297.

[20] P. Pathak, K. Gupta, and J. McAuley, "Generating and personalizing bundle recommendations on steam," in *Proceeding SIGIR '17 Proceedings of the 40th International ACM SIGIR Conference on Research and Development in Information Retrieval*, 2017, pp. 1073–1076.

[21] P. Bertens, A. Guitart, P. P. Chen, and A. Perianez, "A Machine-learning item recommendation system for video games," in *Proceedings of IEEE Conference on Computational Intelligence and Games (CIG)*, 2018, pp. 1–4.

[22] G. Cheuque, J. Guzman, and D. Parra, "Recommender systems for online video game platforms: The case of STEAM," in *Proceedings of World Wide Web Conference*, 2019, pp. 763–771.

[23] J. MacQueen, "Some methods for classification and analysis of multivariate observations," in *Proceedings of 5th Berkeley Symposium on Mathematical Statistics and Probability*, 1967, pp. 281–297.

[24] J. Nielsen and T. K. Landauer, "A mathematical model of the finding of usability problems," in *Proceedings of ACM INTERCHI'93 Conference*, 1993, pp. 206–213.

[25] G. Salton and M. J. McGill, *Introduction to modern information retrieval*. Auckland: McGraw-Hill, 1983, pp. 201–215.