

NCCIT 2011



THE 7TH NATIONAL CONFERENCE ON COMPUTING AND INFORMATION TECHNOLOGY

<TECHED-09>

ผศ.อัครวุฒิ ปรมะปญญา

PROCEEDINGS OF NCCIT 2011

THE 7TH NATIONAL CONFERENCE ON COMPUTING AND INFORMATION TECHNOLOGY

11-12 MAY 2011

WWW.NCCIT.NET

FACULTY OF INFORMATION TECHNOLOGY

KING MONGKUT'S UNIVERSITY OF TECHNOLOGY NORTH BANGKOK

VOLUME 1



บทความวิจัย

การประชุมทางวิชาการระดับชาติด้านคอมพิวเตอร์และเทคโนโลยีสารสนเทศ
ครั้งที่ 7

11-12 พฤษภาคม 2554



คณะเทคโนโลยีสารสนเทศ

มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี



THE 7TH NATIONAL CONFERENCE
ON COMPUTING AND INFORMATION
TECHNOLOGY

PROCEEDINGS OF NCCIT 2011

THE 7TH NATIONAL CONFERENCE ON COMPUTING AND INFORMATION TECHNOLOGY

11-12 MAY 2011

FACULTY OF INFORMATION TECHNOLOGY
KING MONGKUT'S UNIVERSITY OF TECHNOLOGY NORTH BANGKOK (KMUTNB)
BANGKOK, THAILAND

WWW.NCCIT.NET



บทความวิจัย

การประชุมทางวิชาการระดับชาติด้านคอมพิวเตอร์และเทคโนโลยีสารสนเทศ
ครั้งที่ 7

11-12 พฤษภาคม 2554



คณะเทคโนโลยีสารสนเทศ
มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

Table of Contents

Message from KMUTNB President	ii
Message from General Chair	iii
Conference Organizers	i
Conference Organization Committee.....	v
Technical Program Committee.....	vi
Keynote Speakers	viii
Technical Program Contents.....	xiii
Invited Papers.....	xxxiv
Regular Papers.....	1
Author Index	498

คำปรารภ

ศาสตราจารย์ ดร.ธีรวุฒิ บุญยโสภณ
อธิการบดี มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ



ปัจจุบันนี้เราไม่สามารถแยกเทคโนโลยีสารสนเทศและการสื่อสาร ออกจากความต้องการในชีวิตประจำวันได้ เนื่องจากมันมีความสำคัญอย่างมากต่อทุกอาชีพ เนื่องจากช่วยอำนวยความสะดวกทางธุรกิจและการพัฒนา ซึ่งไม่เหมือนกับเทคโนโลยีส่วนใหญ่ เนื่องจากเทคโนโลยีสารสนเทศและการสื่อสารเป็นเทคโนโลยีที่ใช้งานได้ทั่วไป ที่จะนำไปสู่พัฒนาการปรับปรุงและประสิทธิภาพทางด้านเศรษฐกิจ ดังนั้น การใช้เทคโนโลยีสารสนเทศและการสื่อสารสำหรับธุรกิจและการค้า ในการพัฒนาประเทศ จึงต้องการความเข้าใจอย่างถ่องแท้

ด้วยความสำคัญและผลที่ได้รับจากเทคโนโลยีสารสนเทศข้างต้น คณะเทคโนโลยีสารสนเทศ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือจึงได้ร่วมมือทางวิชาการจากมหาวิทยาลัยพันธมิตร ได้แก่ มหาวิทยาลัยแห่งรัฐโอกลาโฮมา ประเทศสหรัฐอเมริกา มหาวิทยาลัยเฟิร์นแห่งเมืองฮาเก้น สหพันธ์สาธารณรัฐเยอรมนี มหาวิทยาลัยเคมน์ทซ์ สหพันธ์สาธารณรัฐเยอรมนี มหาวิทยาลัยอีดิชโคเวน ประเทศออสเตรเลีย มหาวิทยาลัยราชภัฏมหาสารคาม มหาวิทยาลัยมหาสารคาม มหาวิทยาลัยโยนก และมหาวิทยาลัยนครราชสีมา เพื่อร่วมกันจัดการประชุมทางวิชาการระดับชาติ ด้านคอมพิวเตอร์และเทคโนโลยีสารสนเทศ ครั้งที่ 7 (NCCIT 2011) ขึ้นระหว่างวันที่ 11-12 พฤษภาคม 2554 ณ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ โดยมีวัตถุประสงค์เพื่อเผยแพร่และแลกเปลี่ยนข่าวสาร วิทยาการ ความรู้ ทักษะและประสบการณ์ จากการค้นคว้าวิจัยและพัฒนาวิชาการด้านคอมพิวเตอร์และเทคโนโลยีสารสนเทศของคณาจารย์ นักศึกษา และประชาชนทั่วไป เพื่อนำเทคโนโลยีด้านคอมพิวเตอร์และสารสนเทศ ไปใช้ประโยชน์อย่างจริงจัง

ขอขอบคุณทุกหน่วยงานและคณะบุคคล ที่มีส่วนสนับสนุนในการจัดการประชุมทางวิชาการในครั้งนี้ ขออวยพรให้การประชุมทางวิชาการ NCCIT 2011 ครั้งนี้ ประสบความสำเร็จบรรลุวัตถุประสงค์ทุกประการ

ธีรวุฒิ บุญยโสภณ

Conference Organizers

King Mongkut's University of Technology
North Bangkok, Thailand
www.kmutnb.ac.th




Oklahoma State University, USA
www.okstate.edu




FernUniversitaet in Hagen, Germany
www.fernuni-hagen.de



Chemnitz University, Germany
www.tu-chemnitz.de



Edith Cowan University, Australia
www.ecu.edu.au



Rajabhat Mahasarakham University
www.rmu.ac.th



Mahasarakham University
www.msu.ac.th



North Bangkok University
www.northbkk.ac.th



Yonok University
www.yonok.ac.th



Institute of Electrical and Electronics Engineers
Thailand Section
www.ieeethailand.org



Conference Organization Committee

Information Contact :

General Chair :

Assoc.Prof.Dr.Monchai Tiantong, KMUTNB

Technical Program Chair :

Prof.Dr.Herwig Unger, FernUni in Hagen, Germany

Conference Treasurer :

Asst.Prof.Dr.Supot Nitsuwat, KMUTNB

Publication Chair :

Asst.Prof.Dr.Anirach Mingkhwan, KMUTNB, IEEE member

Secretary :

Asst.Prof.Dr.Phayung Meesad, KMUTNB

Technical Program Committee

- Prof.Dr.Herwig Unger, FernUni, Germany
 Prof.Dr.Mark Weiser, OSU, USA
 Prof.Dr.Craig Valli, ECU, Australia
 Prof.Dr.Wolfram Hardt, CUT, Germany
 Assoc.Prof.Dr.Wanchai Rivepiboon, CU
 Assoc.Prof.Dr.Viboon Chunkag, KMUTNB
 Assoc.Prof.Dr.Boonwat Attachoo, KMITL
 Assoc.Prof.Dr.Arune Intarapirot, RMUTT
 Assoc.Prof.Dr.Athakorn Kengpol, KMUTNB
 Assoc.Prof.Dr.Sanoe Khunprasert, KMUTNB
 Assoc.Prof.Dr.Nitisuk Sawasdiirakij, NBU
 Assoc.Prof.Dr.Surapan Yimman, KMUTNB
 Assoc.Prof.Dr.Suthep Butdee, KMUTNB
 Assoc.Prof.Dr.Prayoot Akkaraekthalin, KMUTNB
 Assoc.Prof.Udom Jeenpradub, KMUTNB
 Assoc.Prof.Chuleerat Jaruskulchai, KU
 Assoc.Prof.Prasong Praneetpograng, SPU
 Assoc.Prof.Wirat Pongsiri, MSU
 Assoc.Prof.Dr.Somchai Prakan-charoen, KMUTNB
 Assoc.Prof.Dr.Somsak Akatimagul, KMUTNB
 Assoc.Prof.Dr.Somjit Arch-int, KCU
 Asst.Prof.Dr.Phayung Meesad, KMUTNB
 Asst.Prof.Dr.Supot Nitsuwat, KMUTNB
 Asst.Prof.Dr.Sanit teemuangsai, RMU
 Asst.Prof.Dr.Poonsak Kosriyaporn, KMUTNB
 Asst.Prof.Dr.Kuntpong Woraratpanya, KMUTNB
 Asst.Prof.Dr.Charun Sanrach, KMUTNB
 Asst.Prof.Dr.Chaiyapon Thongchaisuratkeul, KMUTNB
 Asst.Prof.Dr.Passakorn Ruengrong, NU
 Asst.Prof.Dr.Kittinuch Chulikawit, MJU
 Asst.Prof.Dr.Winai Bodhisuwan, KU
 Asst.Prof.Dr.Manoon Sriwirat, UBU
 Asst.Prof.Dr.Panpetch Chinintron, RMUT
 Asst.Prof.Dr.Anirat Mingkhwan, KMUTNB
 Asst.Prof.Dr.Prachyanun Nilsook, KMUTNB
 Asst.Prof.Dr.Parinya Sa-nguansat, RSU
 Asst.Prof.Dr.Wittaya Ar-reerach, RMU
 Asst.Prof.Dr.Pitsuttha Ar-reerach, RMU
 Asst.Prof.Dr.Uraiwan Intarayam, RMUTT
 Asst.Prof.Dr.Siriporn Thipkong, RSU
 Asst.Prof.Dr.Wasin Chooprayoon, RSU
 Asst.Prof.Sittiporn Gerdsum-ang, KMUTNB
 Asst.Prof.Burin Rujanapan, Yonok
 Asst.Prof.Narisra Chutinara, SWU
 Dr.Haythem Zorkta, Aleppo University
 Dr.M Muralidhara Rao, Swarnandhra
 Swarnadea Engineering Collage, India
 Dr.Banchong Harangsee, NECTEC
 Dr.Panomkhawn Riyamongkol, NU
 Dr.Punnee Sittidech, NU
 Dr.Passakorn Pratombutr, NECTEC
 Dr.Choochat Haruechaiyasak, NECTEC
 Dr.Apirak Preechayasombhun, TOT
 Dr.Tong Srikacha, TOT
 Dr.Nattavee Utakrit, KMUTNB
 Dr.Noppasak Tantisattayanon, RMUT
 Dr.Somkid Saelee, KMUTNB
 Dr.Jirapan Srisompan, KMUTNB
 Dr.Suksang Kukanok
 Dr.Padej Phomasakha Na Sakolnakorn
 Dr.Woraniti Limpakorn
 Dr.Pairoj Likitthanasate, TOT
 Dr.Banatus Soiraya, KMUTNB
 Dr.Wongkot sriurai, UBU
 Dr.Sumita Nulmeesri, SSRU
 Dr.Sageemas Nawichain, KMUTNB
 Dr.Pudsadee Boonrawd, KMUTNB
 Dr.Thippaya Chintakovid, KMUTNB
 Dr.Cholatip Yawut, KMUTNB
 Dr.Sirapat Boonkrong, KMUTNB
 Dr.Nawaporn Wisitpongphan, KMUTNB
 Dr.Chaiyod Pirak, KMUTNB
 Dr.Soradech krutjohn, KMUTNB
 Dr.Sittiporn Prawatrungrueng, NBU
 Dr.Montean Rattanasiriwongwut, KMUTNB
 Dr.Sakchai Tangwannawit, KMUTNB
 Dr.Maleerat Sodanil, KMUTNB
 Dr.Kamol Limtanyakool, KMUTNB
 Dr.Chatchawin Namman, UBU
 Dr.Wilaiporn Ledmahakiet, RMUT
 Dr.Alisa Kongton, NECTEC
 Dr.Doy Sundarasaradula, TOT
 Dr.Terawat Piboongunon, TOT
 Dr.Noppasak Tantisattayanon, RMUT
 Dr.Khaled Faqih, Al al-Bayt University, Jo
 Dr.Mahmoud Pirhadi, IAU, Ir

List of Abbreviation

CU	Chulalongkorn University
CUT	Chemnitz University of Technology, Germany
ECU	Edith Cowan University, Australia
FernUni.	Fern University in Hagen, Germany
KKU	Khon-Kaen University
KMITL	King Mongkut's Institute of Technology Ladkrabang
KMUTNB	King Mongkut's University of Technology North Bangkok
KU	Kasetsart University
MJU	Maejo University
MSU	Maharakham University
NBU	North Bangkok University
NECTEC	National Electronics and Computer Technology Center
NU	Naresuan University
OSU	Oklahoma State University
RMU	Rajabhat Maharakham University
RMUT	Rajamangala University of Technology
RSU	Rangsit University
SPU	Sripatham University
SWU	Srinakarinwirot University
TOT	Telephone of Thailand
UBU	Ubol Ratchathani University
Yonok	Yonok University

Wednesday May 11, 2011		
8:00-9:00	Registration (Nawamintararachinee Building, KMUTNB)	
9:00-9.30	Opening Ceremony by Prof. Dr. Teravuti Boonyasopon, <i>President of King Mongkut's University of Technology North Bangkok</i>	
9:30-10:30	Invited Keynote Speech by Prof.Dr.Serge Tichkiewitch	
	Topic : Life Cycle Knowledge Management	
10:30-11:00	<i>Coffee Break</i>	
11:00-12:00	Invited Keynote Speech by Dr.-Ing. Gerd Heinz	
	Topic : Interference Networks as a Generalizing Signal Theory between Integral Transformations, Artificial Neural Nets, Optics and Acoustics	
12:00-13:00	<i>Lunch</i>	
13:00-17:00	Parallel Session Presentations	
18:00-22:00	Welcome Dinner	
Room 1		
Session 1 : Data Mining, Knowledge Discovery, and Knowledge Management		
Time/Paper-ID	Title/Author	Page
13.00-13.20 NCCIT2011-03	Data Imputation Estimation Using Product Indicator Approaches of Structural Equation Modeling <i>Narong Phothi and Somchai Prakancharoen</i>	1
13.20-13.40 NCCIT2011-74	Agriculture Bibliographic Data Categorization using Feature Selection Techniques <i>Pilapan Phonarin, Supot Nitsuwat, and Choochart Haruechaiyasak</i>	7
13.40-14.00 NCCIT2011-96	An Information Extraction System for Medical Informatics using Text Mining Techniques <i>Umaporn Saisangchan, Ekamorn Meesomsak, Natthapong Sripadung, Panida Songram, Kaveepoj Bunluawong, and Phatthanapong Wanchantueng</i>	13
14.00-14.20 NCCIT2011-60	Comparative Study of Classification Properties between KNN, Naïve Bays, Decision Tree and Rule-Based <i>Thanyaporn Boonyoung, Aekkarat Lorphichian and Niroot Porngam</i>	19
14.20-14.40 NCCIT2011-100	Comparative analysis, data mining techniques to determine the suitability of the technique for prediction the different data sets and different data models <i>Sajjaporn Waijanya, Thanarak Limjitsomboon and Chayapol Khoonnaret</i>	24

Time/Paper-ID	Title/Author	Page
14.40-15.00	<i>Coffee Break</i>	
15.00-15.20 NCCIT2011-65	A Comparison of Decision Tree, Rule-based, Naïve Bayes and K-Nearest Neighbor for Data Classification <i>Gritya Tongpasuk</i>	30
15.20-15.40 NCCIT2011-27	The Possibility of Using Machine Learning to Predict the Occurrence of Forest Fires in Thailand: A Case Study Chaiphaphum Province <i>Narasak Poophayang, Khamron Sunat, Sirapat Chiewchanwattana, and Ngamnij Arch-int</i>	36
15.40-16.00 NCCIT2011-90	A Comparative Efficiency of Classification with Data Mining Technique <i>Patsakorn Singto, Patamaporn Taophan and Akkrawuthi Paramapuneya</i>	42
16.00-16.20 NCCIT2011-150	A study of related attributes in Vocational Education Institutes and External Quality Assessment with Association Rule Mining <i>Chantima Ekwong, Sageemas Na Wichian, and Choochart Haruechaiyasak</i>	49
16.20-16.40 NCCIT2011-78	Autistic Learning Tracking System : ALTs <i>Nanticha Sondoung, Warunee Rattanaprada, Pichsinee Puttitaweessri, and Chatchada Kaewpruksapimon</i>	55
18.00-22.00	<i>Dinner</i>	
Room 2		
Session 2 : Decision Support and Recommender Systems		
Time/Paper-ID	Title/Author	Page
13.00-13.20 NCCIT2011-223	A Development of Information Recommender for Notebook Purchasing by using Collaborative Filtering Technique and Utility Theory <i>Tanawat Jariyapoom and Chainarong Yensiri</i>	61
13.20-13.40 NCCIT2011-15	Decision Support Systems for Locating Automatic Teller Machine Based on Investment Analysis <i>Santi Teeragul and Rachada Kongkachandra</i>	67
13.40-14.00 NCCIT2011-19	Automatic Priority Heading System using Decision Tree for Improving Screen Reader <i>Jitlada Jermjit and Rachada Kongkachandra</i>	73
14.00-14.20 NCCIT2011-124	The Data Warehouse Health care checkup system for BASF employee analyze the risk of cholesterol by ID3 <i>Asadawut Atising and Sirapat Boonkrong</i>	79

การเปรียบเทียบประสิทธิภาพการจำแนกข้อมูลด้วยเทคนิคการทำเหมืองข้อมูล

A Comparative Efficiency of Classification with Data Mining Techniques

พัศกร สิงห์โต (Patsakorn Singto)¹ อัครวุฒิ ปรมะบุญญา (Akkrawuthi Paramapunya)²

และปฐมภรณ์ เทวพันธ์ (Patamaporn Taophan)³

^{1, 2, 3}ภาควิชาเทคโนโลยีสารสนเทศ คณะเทคโนโลยีสารสนเทศ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
psingto@hotmail.com, akkrawuthi@hotmail.com, patamatt@gmail.com

บทคัดย่อ

งานวิจัยนี้เสนอการเปรียบเทียบประสิทธิภาพการจำแนกข้อมูลด้วยเทคนิคการทำเหมืองข้อมูลด้วย Naive Bayesian, KNN, Rule Base และ Decision Tree โดยเลือกพารามิเตอร์ที่แตกต่างกัน ใช้ชุดข้อมูล Ionosphere, Pima Indians Diabetes, The Insurance Company และ Mushroom จากฐานข้อมูล UCI Machine Learning Repository นำข้อมูลมาวิเคราะห์และทำการเปรียบเทียบประสิทธิภาพโดยเลือกพารามิเตอร์ที่แตกต่างกันในแต่ละเทคนิค

การวัดประสิทธิภาพการจำแนกข้อมูลสามารถวัดได้จากความถูกต้องของการจำแนกในแต่ละชุดข้อมูลด้วยอัลกอริทึมการทำเหมืองข้อมูลที่แตกต่างกัน ผลการทดลองการวัดประสิทธิภาพของแบบจำลองการจำแนกข้อมูลด้วย Unseen Data พบว่า ข้อมูลชนิดนามบัญญัติ (Nominal) ถูกจำแนกได้ประสิทธิภาพดีด้วยอัลกอริทึม Decision Tree, Rule Bas และ K-Nearest Neighbor ตามลำดับ สำหรับข้อมูลชนิดต่อเนื่อง (Continuous Data) มีจำนวนแอตทริบิวต์มากจะถูกจำแนกได้ประสิทธิภาพดีด้วยอัลกอริทึม Rule Base และข้อมูลมีจำนวนแอตทริบิวต์น้อยจะถูกจำแนกได้ประสิทธิภาพดีด้วยอัลกอริทึม K-Nearest Neighbor

คำสำคัญ: เหมืองข้อมูล การจำแนกข้อมูล ค้นไม่การตัดสินใจ เคเนียร์สตันเบอร์ กฎพื้นฐาน นาอ์ฟเบย์เซียน

Abstract

This research proposes to compare the efficiency classification of data mining techniques by Naive Bayesian, KNN, Rule Base, and Decision Tree. Select parameters different set. Use dataset of Ionosphere, Pima Indians Diabetes, The Insurance Company and the

Mushroom from UCI Machine Learning Repository. The data was analyzed and compared the efficiency by choosing the different parameters for each technique.

The efficiency measurement of data classification can be measured form the correctness of the classification of each dataset by algorithms making the difference source. The measurement of the model classification data by unseen data. The result found that the nominal data model was well classified by Decision Tree, Rule Base, and K-Nearest Neighbor, respectively. For continuous data and much attribute was well classified by Rule Base. And K-Nearest Neighbor that was good in efficiency and there is little attribute.

Keyword: Data Mining , Classification Data, Decision Tree, K-Nearest Neighbor, Rule Base, Naïve Bayesian.

1. บทนำ

งานวิจัยนี้เป็นการศึกษาความเหมาะสมของการใช้โมเดลในการทำเหมืองข้อมูลที่มีการจำแนกข้อมูลที่มีมิติสูงและสามารถหาความเหมาะสมของข้อมูลจากการหาเทคนิคต่างๆ โดยใช้ข้อมูลจาก UCI Machine Learning Repository และเลือกข้อมูล 4 ชุด ได้แก่ Ionosphere , Pima Indians Diabetes, The Insurance Company (TIC) 2000 และ Mushroom ใช้เป็นกรณีศึกษา โดยค่าพารามิเตอร์ของชุดข้อมูลที่ถูกเลือกใช้นั้น มีความซ้ำซ้อนและหลากหลาย ทำให้เกิดความแตกต่างของแต่ละชุดข้อมูล ได้แก่ จำนวนแอตทริบิวต์ จำนวนชุดข้อมูล และลักษณะของข้อมูล ผลที่ได้จะสามารถจำแนกกลุ่มข้อมูล ซึ่งการวิจัยครั้งนี้จะใช้เทคนิคการทำเหมืองข้อมูล โดยใช้อัลกอริทึม ได้แก่ Naïve Bayesian, K-Nearest Neighbour, Rule Based และ Decision Tree เพื่อเปรียบเทียบประสิทธิภาพการจำแนกข้อมูล และมีการปรับ

ค่าพารามิเตอร์ที่แตกต่างกัน ทำให้สามารถทราบถึงความเหมาะสมในการใช้การจำแนกข้อมูลประเภทต่างๆได้

2. วัตถุประสงค์ของโครงการ

2.1 เพื่อศึกษาความเหมาะสมของการใช้อัลกอริทึมในการทำเหมืองข้อมูลที่มีการจำแนกข้อมูลที่มีมิติสูง ได้แก่ Naïve Bayesian, KNN, Rule Base และ Decision Tree


2.2 เพื่อศึกษาความเหมาะสมของอัลกอริทึมต่างๆที่นำมาใช้กับข้อมูลที่มีลักษณะแตกต่างกัน

2.3 เพื่อศึกษาการปรับค่าพารามิเตอร์ที่เหมาะสมกับการทดลอง เพื่อให้ได้ผลลัพธ์ที่ดีขึ้น

3. วิจารณ์งานวิจัยหรือทฤษฎีที่เกี่ยวข้อง

3.1 เหมืองข้อมูล (Data Mining)

เป็นกระบวนการกลั่นกรองสารสนเทศ (Information) ที่ซ่อนอยู่ในฐานข้อมูลขนาดใหญ่ (Knowledge Discovery in Database, KDD) เพื่อทำนายแนวโน้ม และพฤติกรรมโดยอาศัยข้อมูลในอดีต และเพื่อใช้สารสนเทศเหล่านี้ในการสนับสนุนการตัดสินใจ โดยรูปแบบที่ใช้ในการทำเหมืองข้อมูลมีหลายรูปแบบด้วยกัน ในแต่ละรูปแบบจะมีวิธีการที่แตกต่างกันออกไป [1]



ภาพที่ 1: กระบวนการ Classification

3.2 การจำแนกข้อมูล (Classification)

เป็นเทคนิคหนึ่งของการทำเหมืองข้อมูลที่ใช้ในการทำ Predictive Modeling ซึ่งมีการทำงานแบบ Supervised Learning กล่าวคือ สามารถสร้างแบบจำลองการจัดหมวดหมู่ได้จาก กลุ่มตัวอย่างของข้อมูลที่ได้กำหนดไว้ก่อนล่วงหน้า และสามารถพยากรณ์ตัวอย่างของข้อมูลที่ได้กำหนดไว้ก่อนล่วงหน้า และสามารถพยากรณ์กลุ่มของรายการที่ยังไม่เคยนำมาจัดหมวดหมู่ได้ด้วย โดยมีกระบวนการและขั้นตอนดังภาพที่ 1 [2]

3.3 นาอิวเบย์ (Naïve Bayesian)

เป็นอัลกอริทึมการจำแนกข้อมูล [3] ที่ใช้หลักความน่าจะเป็นซึ่งอยู่บนพื้นฐานของ Bayes' Theorem เช่นกำหนดให้การเกิดของเหตุการณ์ต่างๆที่ใช้ในการจำแนกกลุ่มนั้นเป็นอิสระต่อกันโดยกำหนดให้

$P(H)$ คือ ความน่าจะเป็นที่จะเกิดเหตุการณ์ H และ

$P(H|E)$ คือความน่าจะเป็นที่จะเกิดเหตุการณ์ H เมื่อเกิดเหตุการณ์ E

จากตัวแปรที่กำหนดและแนวคิดของ Bayes' Theorem นั้นสามารถทำนายเหตุการณ์ที่พิจารณาได้จากการเกิดของเหตุการณ์ต่าง ๆ ได้ดังสมการ

$$P(H|E) = [P(E|H) \times P(H)] / P(E) \quad (1)$$

เช่น การทำนายว่าฝนจะตกเมื่อมีเหตุการณ์มีเมฆดำกำหนดให้

H คือ เหตุการณ์ที่ฝนตก และ

E คือ เหตุการณ์มีเมฆดำ และสามารถทำนายสรุปได้ดังสมการต่อไปนี้

$$P(\text{ฝนตก} | \text{เมฆดำ}) = [P(\text{เมฆดำ} | \text{ฝนตก}) \times P(\text{ฝนตก})] / P(\text{เมฆดำ})$$

กำหนดให้

1) $P(\text{เมฆดำ} | \text{ฝนตก})$ คือ ความน่าจะเป็นที่มีเมฆดำเมื่อฝนตก ซึ่งจะพิจารณาการเกิดเมฆดำเมื่อมีเหตุการณ์ฝนตกเท่านั้น ความน่าจะเป็นนี้สามารถเก็บรวบรวมโดยใช้หลักการทางสถิติ

2) $P(\text{ฝนตก})$ คือ ความน่าจะเป็นที่ฝนจะตก

3) $P(\text{เมฆดำ})$ คือ ความน่าจะเป็นที่มีเมฆดำ

การคำนวณการจำแนกกลุ่มของเหตุการณ์ที่มีการเกิดของเหตุการณ์ต่างๆ ที่ใช้ในการจำแนกกลุ่มมากกว่า 1 ชนิด ได้ดังสมการต่อไปนี้

$$P(H|E_1, E_2, \dots, E_n) = [P(E_1, E_2, \dots, E_n|H) \times P(H)] / P(E_1, E_2, \dots, E_n) \quad (2)$$

เมื่อกำหนดให้เหตุการณ์ $E_1, E_2, \dots, E_n$ คือ เหตุการณ์ n เหตุการณ์ที่ใช้ในการจำแนกกลุ่ม และแต่ละเหตุการณ์ต่างๆที่ใช้ในการจำแนกกลุ่มเป็นอิสระต่อกัน [4]


3.4 เกเนียร์สตันเบอร์ (K-Nearest Neighbor)

เป็นอัลกอริทึมที่ใช้ในการจัดกลุ่มข้อมูลที่อยู่ใกล้กันเข้าด้วยกัน โดย k หมายถึงจำนวนข้อมูลที่นำมาพิจารณา เช่น $k=3$ หมายถึง การพิจารณาข้อมูลจำนวน 3 ชุดที่อยู่ใกล้เคียงจุดที่ต้องการ ประกอบด้วยวิธีการ ดังนี้ 1. กำหนดขนาด k ควรกำหนดเป็นเลขคี่ 2. คำนวณระยะห่างของข้อมูลที่ต้องการพิจารณากับกลุ่มข้อมูลตัวอย่าง 3. จัดเรียงลำดับของระยะห่างและเลือกพิจารณาชุดข้อมูลที่ใกล้จุดที่ต้องการพิจารณาตามจำนวน k ที่กำหนด 4. พิจารณาข้อมูลจำนวน k ชุด และสังเกตว่ากลุ่ม (Class) ไหนที่ใกล้จุดที่พิจารณาเป็นจำนวนมากที่สุด 5. กำหนดกลุ่มให้กับจุดที่พิจารณา ดังภาพที่ 2 กำหนด $k = 3$ ประกอบด้วย Class (+), Class (○) และจุดพิจารณาคือ ● ดังนั้นข้อมูลที่อยู่ใกล้ ● ที่สุดจำนวน 3 ชุด คือ

+ + เท่ากับ 2

○ เท่ากับ 1

ดังนั้น จึงจัดกลุ่มให้จุดที่พิจารณา ● ให้เป็น Class (+) [5]



ภาพที่ 2: การกระจายตัวของ K-Nearest Neighbor

3.5 กฎพื้นฐาน (Rule based)

กฎพื้นฐาน [6] หรือ rule-based คือ เทคนิคสำหรับการแยกประเภทของระเบียบ โดยการใช้รูปแบบกฎ "if...then..." ซึ่งกฎที่นำมาสร้างโมเดลจะถูกนำเสนอ ในรูปแบบการเชื่อมต่อกัน เช่น $R = (r_1 \vee r_2 \dots \vee r_j)$ โดยที่ R คือ กลุ่มของกฎ และ r_i คือ กฎที่ใช้แยกหรือกฎแต่ละอัน แต่ละกฎที่ใช้แยกสามารถอธิบายโดยสมการที่ (3)

$$r_i : (\text{เงื่อนไข}) \rightarrow y_i \quad (3)$$

ด้านซ้ายมือของกฎมักเรียกว่า Rule antecedent หรือ precondition ซึ่งจะมีการเชื่อมต่อกับ attribute set: ดังแสดงในสมการที่ (4)


$$\text{Condition} = \{ (A_1 \text{ op } v_1) \wedge (A_2 \text{ op } v_2) \wedge (A_k \text{ op } v_k) \} \quad (4)$$

ที่ (A_i, v_i) คือ คู่ของ attribute และค่า และ op คือ ตัวปฏิบัติการแบบตรรกะที่ถูกเลือกจาก set $\{=, \neq, <, >, \leq, \geq\}$ ในขณะที่ทางด้านขวามือของกฎเรียกว่า rule consequent ซึ่งจะใช้ทำนาย class y_i [7]

3.6 ต้นไม้การตัดสินใจ (Decision Tree)

ต้นไม้การตัดสินใจเป็น เทคนิคที่ค่อนข้างแพร่หลาย เนื่องจากการตัดสินใจแบบโครงสร้างต้นไม้ เป็นลักษณะที่ทำให้เข้าใจได้ง่าย วิธีนี้คือกระบวนการในการจัดแบ่งข้อมูล (Classification) โดยใช้โครงสร้างของต้นไม้ในการเขียนอธิบายการประมวลผล โดยจำลองกิ่งก้านสาขาของต้นไม้เป็นหลัก โดยแตกจากรากทางซ้ายมือ แตกกิ่งอยู่ทางขวามือแตกกิ่งไปเรื่อย ๆ จนครบเงื่อนไขทั้งหมดและกิ่งสุดท้ายของทุกกิ่งคือกิจกรรมที่ต้องกระทำ เมื่อเป็นตามเงื่อนไขนั้น [8]

อัลกอริทึมพื้นฐานของการสร้างต้นไม้ตัดสินใจ คือ Greedy Algorithm โดยจะสร้างต้นไม้ จากบนลงล่างแบบวนซ้ำ (Recursive) ด้วยวิธีการแบ่งปัญหาใหญ่เป็นปัญหาย่อย (Divide-and-Conquer) ซึ่งรูปแบบของต้นไม้ จะประกอบด้วยโหนดแรกสุดที่เรียกว่า Root Node จาก Root Node ก็จะแตกออกเป็นโหนดลูก และที่โหนดลูกก็จะมีลูกของตัวเอง ซึ่งโหนดในระดับ สุดท้ายจะเรียกว่า Leaf Node ดังภาพที่ 3



ภาพที่ 3: รูปแบบต้นไม้ตัดสินใจ

จากภาพที่ 3 จะเห็นว่า จาก Root Node จนถึง Leaf Node จะมีเพียงเส้นทางเดียวเท่านั้น ซึ่งเส้นทางนี้จะอธิบายถึงกฎที่ใช้

สำหรับการจัดหมวดหมู่ของแต่ละกลุ่ม ซึ่งในแต่ละ Leaf Node นั้นอาจเป็นกลุ่มเดียวกัน ซึ่งเกิดจากเหตุผล ที่แตกต่างกันได้

แต่ละอัลกอริทึมก็ได้นิยามค่าความดีของคุณสมบัติแตกต่างกันไป อัลกอริทึม CART นิยามความดีของคุณสมบัติ โดยใช้ค่าสัมประสิทธิ์จีนิ (Gini) แต่ที่แพร่หลายที่สุดคือการ ใช้ค่ามาตรฐานเกน (Gain criterion) ของอัลกอริทึม ID3 [9] และ C4.5 [10] ซึ่งได้จากการคำนวณโดยอาศัยทฤษฎีสารสนเทศ (Information Theory) และค่าเอนโทรปี (Entropy)

4. ขั้นตอนการดำเนินงาน

4.1 การเตรียมข้อมูล

ในการวิจัยครั้งนี้ ผู้วิจัยได้เลือกใช้ข้อมูลจาก UCI Machine Learning Repository จำนวน 4 ชุดข้อมูลเป็นกรณีศึกษา ได้แก่ Ionosphere ข้อมูลการวัดสัญญาณชั้นบรรยากาศนอกโลก เป็นข้อมูลชนิดต่อเนื่อง (Continuous Data) ประกอบด้วยแบบข้อมูลชั้นบรรยากาศ 351 รายการ แต่ละรายการมี 34 แอททริบิวต์ เพื่อตรวจสอบว่าสัญญาณดีหรือไม่ดี Pima Indians Diabetes ข้อมูลโรคเบาหวานของชาวอินเดีย เป็นข้อมูลชนิดต่อเนื่อง ประกอบด้วยแบบของโรคเบาหวาน 768 รายการ แต่ละรายการมี 8 แอททริบิวต์ เพื่อแสดงว่าเป็นหรือไม่เป็นโรคเบาหวาน The Insurance Company (TIC) ข้อมูลลูกค้าที่เป็นเจ้าของกรรมกรรม เป็นข้อมูลชนิดนามบัญญัติ (Nominal Data) ประกอบด้วยแบบข้อมูลลูกค้า 9822 รายการ แต่ละรายการ 85 แอททริบิวต์ เพื่อตรวจสอบว่าได้รับสิทธิการมีหรือไม่มีรถบ้าน และ Mushroom ข้อมูลลักษณะของเห็ดเป็นข้อมูลชนิดนามบัญญัติ ประกอบด้วยแบบข้อมูลเห็ด 8124 รายการ 23 แอททริบิวต์ เพื่อแสดงว่าเป็นเห็ดมีพิษหรือไม่มีพิษ และได้นำข้อมูลมาทำการ Cleaning ตัวแปรที่เกิดจากความผิดพลาดในการใส่ข้อมูล และได้ตัดรายการข้อมูลที่ไม่สมบูรณ์ออกไป หลังจากนั้น ทำการลดทอนหรือแบ่งกลุ่มตัวแปรสร้างกลุ่มตัวแปรตามใหม่ตามความเหมาะสม จัดรูปแบบชุดข้อมูลให้อยู่ในรูปแบบ Comma Separate Value File (csv file) แต่ละชุดข้อมูลและจำนวนอินสแตนซ์ มีจำนวนแอททริบิวต์ ดังตารางที่ 1 และแต่ละชุดข้อมูลทำการสุ่มแบ่งข้อมูลออกเป็น 2 ส่วน ได้แก่ ข้อมูลฝึกสอน (Training Set) 66% และ ข้อมูลทดสอบ (Test Set) 34% ดังตารางที่ 2

ตารางที่ 1: ตารางแสดงรายละเอียดแอททริบิวต์

Data set	No. of Instance	No. of Attb.	No. of Nominal Attb.	No. of Numeric Attb.	Missing Values	No. of Class
Ionosphere	351	34	0	34	None	2
Pima Indians Diabetes	768	8	0	8	None	2
The Insurance Company (TIC)	9,822	85	85	0	None	2
Mushroom	8,124	23	23	0	2480	2

ตารางที่ 2: จำนวนรายการข้อมูลชุดฝึกสอน และชุดทดสอบ

Data set	No. of Pattern Training Set for Class			No. of Pattern Test Set for Class			No. of Pattern Total for Class	
	1	2	Tot	1	2	Tot	1	2
Ionosphere	138	93	231	87	33	120	225	126
Pima Indians Diabetes	321	185	506	179	83	262	500	268
The Insurance Company (TIC)	5474	348	5822	3762	238	4000	9236	586
Mushroom	2548	2818	5366	1368	1390	2758	3916	4208

ตารางที่ 3: จำนวนแอททริบิวต์ในแต่ละชุดข้อมูลตามวิธีการประเมินค่าแอททริบิวต์

Attribute Evaluator	Ionosphere	Pima Indians Diabetes	The Insurance Company	Mushroom
Original	34	8	85	23
CfsSubset	13	4	10	5
ChiSquared	20	3	14	12
InfoGain	17	-	13	-
Symmetrical Uncert	18	5	15	-
SVM	-	5	-	-
Consistency Subset	7	-	-	5
OneR	18	3	80	-
ReliefF	19	5	42	12
GainRatio	-	4	16	7
Filtered	21	4	-	12

จากการนำชุดข้อมูลมาประเมินค่าแอทริบิวต์ด้วยวิธีการประเมินค่าแอทริบิวต์ที่เหมาะสม ทำให้ได้ชุดข้อมูลเพิ่มมากขึ้น ดังนี้ Ionosphere มีจำนวน 9 ชุด Pima Indians Diabetes มีจำนวน 9 ชุด The Insurance Company (TIC) มีจำนวน 8 ชุด และ Mushroom มีจำนวน 7 ชุด ดังตารางที่ 3

4.2 การออกแบบโมเดลเพื่อทำการทดลอง

ผู้วิจัยได้ทำการออกแบบโมเดล โดยทำการปรับค่าพารามิเตอร์ให้กับอัลกอริทึม Decision Tree, Rule Base, Naïve Bayesian และ K-Nearest Neighbor ดังตารางที่ 4-7

ตารางที่ 4: ค่าพารามิเตอร์ของอัลกอริทึม K-Nearest Neighbor

No.	KNN	distanceFunction	dontNormalize
1	1	EuclideanDistance	FALSE
2	3	EuclideanDistance	FALSE
3	1	EuclideanDistance	TRUE
4	3	EuclideanDistance	TRUE
5	1	ManhattanDistance	FALSE
6	3	ManhattanDistance	FALSE

ตารางที่ 5: แสดงค่าพารามิเตอร์ของอัลกอริทึม Rule Base

No.	Min NumObj	Reduced ErrorPruning	unpruned	useMDL Correction
1	2	FALSE	FALSE	TRUE
2	2	TRUE	FALSE	TRUE
3	1	FALSE	FALSE	TRUE
4	3	FALSE	FALSE	TRUE
5	2	FALSE	FALSE	FALSE
6	3	FALSE	FALSE	FALSE
7	2	TRUE	FALSE	FALSE
8	3	TRUE	FALSE	FALSE
9	2	FALSE	TRUE	FALSE
10	4	FALSE	TRUE	FALSE

ตารางที่ 6: แสดงค่าพารามิเตอร์ของอัลกอริทึม Decision Tree

No.	minNum Object	Reduced ErrorPruning	unpruned	useMDL Correction
1	2	FALSE	FALSE	TRUE
2	2	TRUE	FALSE	TRUE
3	1	FALSE	FALSE	TRUE
4	3	FALSE	FALSE	TRUE
5	3	FALSE	FALSE	FALSE
6	2	TRUE	FALSE	FALSE
7	3	TRUE	FALSE	FALSE
8	2	FALSE	TRUE	FALSE
9	4	FALSE	TRUE	FALSE

ตารางที่ 7: แสดงค่าพารามิเตอร์ของอัลกอริทึม Naive Bayesian

No.	debug	displayModel InOldFormat	useKernel Estimator	useSupervised Discretization
1	FALSE	FALSE	FALSE	FALSE
2	FALSE	FALSE	TRUE	FALSE
3	FALSE	FALSE	FALSE	TRUE
4	TRUE	TRUE	FALSE	FALSE
5	TRUE	TRUE	TRUE	FALSE
6	TRUE	TRUE	FALSE	TRUE

4.3 การดำเนินการฝึกสอนระบบ

การฝึกสอนระบบโดยการนำชุดข้อมูลฝึกสอนที่เตรียมไว้แต่ละชุดเข้าทำฝึกสอนระบบในแต่ละอัลกอริทึมด้วยพารามิเตอร์ที่แตกต่างกัน ดังตารางที่ 4-7 โดยให้แต่ละชุดข้อมูลได้เข้าฝึกสอนระบบทุกเทคนิคและทุกพารามิเตอร์

4.4 วิธีการทดสอบระบบ

การทดสอบระบบโดยการนำข้อมูลชุดทดสอบที่เตรียมไว้แต่ละชุดมาดำเนินการทดสอบระบบในแต่ละอัลกอริทึมด้วยพารามิเตอร์ที่แตกต่างกัน และประเมินประสิทธิภาพการจำแนกข้อมูลของระบบด้วยค่าความถูกต้อง (Accuracy)

5. ผลการดำเนินงาน

5.1 ผลการทดสอบ

เป็นการวัดประสิทธิภาพการจำแนกข้อมูลของแต่ละโมเดลด้วยค่าความถูกต้องของการทดสอบระบบด้วยเทคนิคการทำเหมืองข้อมูล 4 เทคนิคที่มีพารามิเตอร์ที่แตกต่างกันกับข้อมูลแต่ละชุด มีผลการทดสอบ ดังตารางที่ 8 - 11

ตารางที่ 8: ค่าความถูกต้องการจำแนกด้วยเทคนิค K-Nearest Neighbour จาก 198 โมเดล

Evaluate Attribute		Num attrib.	Parameter Pattern		
			2	4	5
Ionosphere	SymmetricalUncert	18	93.33	93.33	97.50
	Filtered	13	92.50	94.17	94.17
	Original	8	71.37	69.47	73.66
Pima	GrainRatioEval	5	84.73	66.79	71.76
Indians	CfsSubset	4	72.14	67.56	66.79
The Diabetes	CfsSubset	10	93.58	93.78	92.05
Insurance	OneR	80	93.35	93.23	90.13
Company	InfoGainAttrib	13	93.33	93.58	90.73
Mushroom	Original	25	100	100	100
	ChiSquaredAttrib	12	100	100	100
	Consistency	5	100	100	100

ตารางที่ 9: ค่าความถูกต้องการจำแนกด้วย Naïve Bayesian จาก 198 โมเดล

Evaluate Attribute		Num attb.	Parameter Pattern		
			1	4	5
Ionosphere	SymmetricalUncert	18	87.50	87.50	91.67
	Filtered	13	92.50	92.50	<u>97.50</u>
Pima Indians Diabetes	Original	8	77.10	77.10	73.66
	GrainRatioEval	5	75.95	75.95	76.34
	CfsSubset	4	77.86	<u>77.86</u>	73.28
The Insurance Company	CfsSubset	10	<u>92.53</u>	92.53	92.40
	OneR	80	77.53	77.53	83.85
	InfoGainAttrib	13	86.30	86.30	87.68
Mushroom	Original	23	95.03	95.03	95.03
	ChiSquaredAttrib	12	94.74	94.74	94.74
	Consistency	5	<u>98.66</u>	<u>98.66</u>	<u>98.66</u>

ตารางที่ 10: ค่าความถูกต้องการจำแนกด้วย Decision Tree จาก 297 โมเดล


Evaluate Attribute		Num	Parameter Pattern		
		attb.	2	3	5
Ionosphere	SymmetricalUncert	18	<u>97.50</u>	92.50	90.83
	Filtered	13	95.83	92.50	<u>97.50</u>
Pima Indians Diabetes	Original	8	72.90	67.56	<u>77.10</u>
	GrainRatioEval	5	72.90	73.28	75.57
	CfsSubset	4	72.90	72.52	69.85
Insurance	CfsSubsetEval	10	94.05	94.05	94.05
	OneR	80	93.93	<u>94.35</u>	93.90
	InfoGainAttrib	13	94.05	94.05	94.05
Mushroom	Original	23	100	100	100
	ChiSquaredAttrib	12	100	100	100
	Consistency	5	100	100	100

ตารางที่ 11: ค่าความถูกต้องการจำแนกด้วย Rule Base จาก 330 โมเดล

Evaluate Attribute		Num attb.	Parameter Pattern		
			1	2	3
Ionosphere	SymmetricalUncert	18	92.50	90.83	91.67
	Filtered	13	98.33	95.83	98.33
Pima Indians Diabetes	Original	8	71.76	72.52	70.61
	GrainRatioEval	5	72.52	71.76	72.52
	CfsSubset	4	<u>76.72</u>	75.95	75.95
The Insurance Company	CfsSubset	10	93.93	<u>94.05</u>	93.78
	OneR	80	91.50	93.48	90.40
	InfoGainAttrib	13	93.75	93.05	<u>94.05</u>
Mushroom	Oiginal	23	100	100	100
	ChiSquaredAttrib	12	100	100	100
	Consistency	5	100	100	100

5.2 วิเคราะห์วิจารณ์ เปรียบเทียบ อภิปรายผลการทดลอง

จากตารางที่ 8-11 ค่าความถูกต้องการจำแนกด้วยเทคนิคการทำเหมืองข้อมูล 4 เทคนิคในแต่ละชุดข้อมูล เทคนิคที่เหมาะสมกับข้อมูลแต่ละชุดตามผลของค่าความถูกต้องที่สูงที่สุด คือ เทคนิค Rule Base กับข้อมูล Ionosphere คัดเลือกแอททริบิวต์แบบ Filtered ปรับค่าพารามิเตอร์แบบที่ 1 และ 3 เท่ากับ 98.33% เทคนิค K-Nearest Neighbour ข้อมูล Pima Indians Diabetes คัดเลือกแอททริบิวต์แบบ GrainRatioEval ปรับค่าพารามิเตอร์แบบ 2 เท่ากับ 84.73% เทคนิค Decision Tree ข้อมูล The Insurance Company คัดเลือกแอททริบิวต์แบบ OneR ปรับค่าพารามิเตอร์แบบที่ 3 เท่ากับ 94.35% และ เทคนิค Rule Base, Decision Tree และ K-Nearest Neighbour ข้อมูล Mushroom ใช้แอททริบิวต์ที่มีเริ่มต้นจากชุดข้อมูล และใช้พารามิเตอร์เริ่มต้นของเทคนิคเหมืองข้อมูลเท่ากับ 100%



ภาพที่ 5: เปรียบเทียบความถูกต้องของการจำแนกในแต่ละชุดข้อมูล

6. สรุป

จากการเปรียบเทียบประสิทธิภาพการจำแนกข้อมูลด้วยอัลกอริทึมการทำเหมืองข้อมูล 4 อัลกอริทึม ได้แก่ Decision Tree, Rule Base และ K-Nearest Neighbour และ Naïve Bayesian กับชุดข้อมูล 4 ชุด คือ ข้อมูลชนิดนามบัญญัติ (Nominal) จำนวน 2 ชุด และข้อมูลชนิดต่อเนื่อง (Continuous Data) จำนวน 2 ชุด จากฐานข้อมูล UCI Machine Learning Repository ได้สร้างโมเดลการจำแนกข้อมูลด้วยอัลกอริทึมต่างๆ โดยการปรับค่าพารามิเตอร์ที่เหมาะสม และเลือกแอททริบิวต์ที่มีผลต่อการเปลี่ยนแปลงคลาสมากที่สุด โดยวัดประสิทธิภาพการจำแนกข้อมูลด้วยโมเดลที่แตกต่างกัน จากค่าความถูกต้อง แสดงดังภาพที่ 5 พบว่า ข้อมูลชนิดนามบัญญัติ


(Nominal) คือ The Insurance Company และ Mushroom ถูกจำแนกได้ประสิทธิภาพดีด้วยอัลกอริทึม Decision Tree พารามิเตอร์ที่ 3, Rule Base พารามิเตอร์ที่ 2 K-Nearest Neighbour พารามิเตอร์ที่ 4 และ Naïve Bayesian พารามิเตอร์ที่ 1-4 โดยทุกชุดได้คัดเลือกแอทริบิวต์ด้วยวิธี cfsSubset สำหรับข้อมูลชนิดต่อเนื่อง (Continuous Data) อัลกอริทึม Rule Base พารามิเตอร์ที่ 3 จำแนกข้อมูลได้ประสิทธิภาพดี ด้วยจำนวนแอทริบิวต์มากคัดเลือกแอทริบิวต์ด้วยวิธี Filtered และอัลกอริทึม K-Nearest Neighbour พารามิเตอร์ 2 จำแนกข้อมูลได้ประสิทธิภาพดีกับจำนวนแอทริบิวต์ไม่มากและคัดเลือกแอทริบิวต์ด้วยวิธี GrainRatioEval

จากการวิเคราะห์ผล สามารถสรุปผลได้ว่า อัลกอริทึม K-Nearest Neighbour เหมาะกับข้อมูลมีแอทริบิวต์ไม่มาก และจะดีที่สุดกับข้อมูลที่มีแอทริบิวต์ที่เหมาะสมมากที่สุดด้วยวิธีการประเมินค่าแอทริบิวต์ GrainRatioEval อัลกอริทึม Rule Base เหมาะกับข้อมูลมีแอทริบิวต์มาก และจะดีที่สุดกับข้อมูลที่เหมาะสมด้วยวิธีการประเมินค่าแอทริบิวต์ Filtered อัลกอริทึม Decision Tree เหมาะกับข้อมูลชนิดนามบัญญัติ และจะดีที่สุดกับข้อมูลที่มีแอทริบิวต์ที่เหมาะสมที่สุดด้วยวิธีการประเมินค่าแอทริบิวต์ CfsSubset อัลกอริทึม Naive Bayesian จากผลการทดลองไม่ปรากฏว่าเหมาะสมกับลักษณะข้อมูลชนิดใดชัดเจน การศึกษาในครั้งนี้ต่อไปผู้วิจัยมุ่งศึกษาเทคนิคการทำเหมืองข้อมูลกับข้อมูลที่รวบรวมภายในประเทศเพื่อสามารถค้นหาคำตอบที่ต้องการทราบต่อไป

เอกสารอ้างอิง

- [1] อุกฤษ บังฉิม. การประยุกต์ใช้เทคนิคการทำเหมืองข้อมูลในการทำนายระดับน้ำสูงสุด. วิทยานิพนธ์วิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมทรัพยากรน้ำ คณะวิศวกรรมศาสตรบัณฑิตวิทยาลัยมหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี, 2546.
- [2] พยูน พาณิชย์กุล. การพัฒนาระบบดาต้าไมน์นิ่งโดยใช้ Decision Tree. โครงการพัฒนาระบบงาน ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาเทคโนโลยีสารสนเทศ แขนงวิชาวิทยาการสารสนเทศ สถาบันเทคโนโลยีพระจอมเกล้าคุณทหารลาดกระบัง, 2548.
- [3] ภรณ์ยา อามฤตรัตน์ เดช ธรรมศิริ วาทีนี นุ้ยเพียน ณรงค์ โพธิ์ทราวุฒิ แสงศิริ ผศ.ดร.พยุ่ง มีสัง. “การเปรียบเทียบประสิทธิภาพการคัดเลือกและจำแนกข้อมูลด้วยวิธีการทางเครือข่ายประสาทเทียม”. in *The 5th National Conference on Computing and Information Technology*. (5)2009:112.
- [4] Ian H. Witten and Eibe Frank, *Data Mining: Practical Machine Learning Tools and Techniques*, Second Edition, Morgan Kaufmann publishers: Canada, 2005.
- [5] Sun Lee Band, Hyung Jeong Yang and Jae Dong Yang, “Automatic Document Categorization Based on k-NN and Object-Based Thesauri”. *Springer Lecture Notes in Computer Science, Volume 3246/2004*, pp. 101-112
- [6] Pang-Ning Tan, Michael Steinbach, and Vipin Kumar. *Introduction to Data Mining*. Addison Wesley. 2005:146,207-208.]
- [7] กาญจนา แสงทองพัฒนา. “การจำแนกประเภทเว็บเพจโดยใช้ลักษณะเด่นบนตัวจำแนกแบบเบย์อย่างง่ายที่ทำงานร่วมกัน”, วิทยานิพนธ์, บัณฑิตวิทยาลัยมหาวิทยาลัยเกษตรศาสตร์. 2543 :1-2.
- [8] Barry de Ville, *Decision Trees for Business Intelligence and Data Mining: Using SAS Enterprise Mine*, SAS Publishing, 2006.
- [9] Quinlan, J. R. “Induction of decision tree”, *Machine Learning*, Vol. 1, pp.81-106, 1986.
- [10] Quinlan, J. R, “C4.5: Programs for Machine Learning”, San Mateo, CA: Morgan Kaufmann, 1993.

- [4] Rajeev, K. and S.C. Soham, "Precise static type analysis for object oriented programs". *SIGPLAN Not.*, 2007. 42(2): p. 17-26.
- [5] Logozzo, F., *Cibai:* "An Abstract Interpretation-Based Static Analyzer for Modular Analysis and Verification of Java Classes in Verification, Model Checking, and Abstract Interpretation". 2007, *Springer Berlin / Heidelberg*. p. 283-298.
- [6] Tal, L., et al., "Putting static analysis to work for verification: A case study", in *Proceedings of the 2000 ACM SIGSOFT international symposium on Software testing and analysis*. 2000, ACM: Portland, Oregon, United States.
- [7] Logozzo, F., "Separate Compositional Analysis of Class-Based Object-Oriented Languages in Algebraic Methodology and Software Technology". 2004, *Springer Berlin / Heidelberg*. p. 334-348.
- [8] Payet, É. and F. Spoto, "Magic-Sets Transformation for the Analysis of Java Bytecode in Static Analysis". 2007, *Springer Berlin / Heidelberg*. p. 452-467.
- [9] Fausto, S., "Nullness Analysis in Boolean Form", in *Proceedings of the 2008 Sixth IEEE International Conference on Software Engineering and Formal Methods*. 2008, IEEE Computer Society.
- [10] Tsutomu, S. and M. Munehiro, "BDD representation for incompletely specified multiple-output logic functions and its applications to functional decomposition", in *Proceedings of the 42nd annual conference on Design automation*. 2005, ACM: Anaheim, California, USA.
- [11] Cabodi, G. and M. Murciano, "BDD-Based Hardware Verification Formal Methods for Hardware Verification". Vol. 3965/2006. 2006: *Springer Berlin / Heidelberg*. 30.
- [12] Eijk, C.A.J.v., "A BDD-based verification method for large synthesized circuits". *Integr. VLSI J.*, 1997. 23(2): p. 131-149.
- [13] Liu, Y., et al., "Binary decision diagram with minimum expected path length", in *Proceedings of the conference on Design, automation and test in Europe*. 2001, IEEE Press: Munich, Germany.
- [14] Rudiger, E., G. Wolfgang, and D. Rolf, "Combination of Lower Bounds in Exact BDD Minimization", in *Proceedings of the conference on Design, Automation and Test in Europe - Volume 1*. 2003, IEEE Computer Society.



- KING MONGKUT'S UNIVERSITY OF TECHNOLOGY, BANGKOK, THAILAND
- OKLAHOMA STATE UNIVERSITY, USA
- FERN UNIVERSITY IN HAGEN, GERMANY
- CHEMNITZ UNIVERSITY OF TECHNOLOGY, GERMANY
- EDITH COWAN UNIVERSITY, AUSTRALIA



