

ระบบตรวจจับและจำแนกอุบัติเหตุทางจราจรแบบอัตโนมัติ
ด้วยเวฟเล็ตและฟัซซีลอจิก

AUTOMATIC TRAFFIC INCIDENT DETECTION AND CLASSIFICATION SYSTEM
USING WAVELET AND FUZZY LOGIC



T138761



จารสพัฒน หล้าอินเชื้อ

JARASPAT LA-INCHUA

วพ.
จ159ร
2558

b.....
i.....

เลขทะเบียน 138761
รับเดือนปี 16 ต.ค. 2558

12718440

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชาวิศวกรรมโทรคมนาคม
คณะวิศวกรรมศาสตร์
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
พ.ศ.2558

KMITL-2015-EN-M-010-101

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

AUTOMATIC TRAFFIC INCIDENT DETECTION AND CLASSIFICATION SYSTEM
USING WAVELET AND FUZZY LOGIC



A THESIS SUBMITTED IN PARTIAL FULFILLMENT
OF THE REQUIREMENT FOR THE DEGREE OF
MASTER OF ENGINEERING IN TELECOMMUNICATIONS ENGINEERING
FACULTY OF ENGINEERING
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG
2015

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



COPYRIGHT 2015

FACULTY OF ENGINEERING

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

คณะวิศวกรรมศาสตร์
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
ใบรับรองวิทยานิพนธ์

หัวข้อวิทยานิพนธ์ ระบบตรวจจับและจำแนกอุบัติเหตุการจราจรแบบอัตโนมัติด้วยเวฟเล็ตและฟัซซีลอจิก
Thesis Title Automatic Traffic Incident Detection and Classification System Using Wavelet and Fuzzy Logic
นักศึกษา นางสาวจรัสพัฒน์ หล้าอินเชื้อ
รหัสประจำตัว 56601271
ปริญญา วิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชา วิศวกรรมโทรคมนาคม
อาจารย์ที่ปรึกษาวิทยานิพนธ์ ผศ.ดร.ศรวัฒน์ ชิวปรีชา
อาจารย์ที่ปรึกษาวิทยานิพนธ์ (ร่วม) ดร.สุทธิพงษ์ รัชชยพงษ์
หมายเลขวิทยานิพนธ์ KMITL-2015-EN-M-010-101

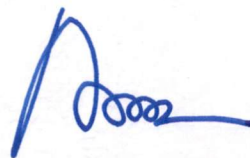
คณะกรรมการสอบวิทยานิพนธ์		ลายมือชื่อ
รศ.ดร.ยุทธพงษ์	รังสรรค์เสรี	
ดร.สถาพร	พรหมวงศ์	
ศ.ดร.ประยูทธ	อัครเอกฉาลิน	
ดร.สุทธิพงษ์	รัชชยพงษ์	
ผศ.ดร.ศรวัฒน์	ชิวปรีชา	

วัน / เดือน / ปี ที่สอบ วันพุธที่ 15 กรกฎาคม พ.ศ. 2558 เวลา 14.00-16.00 น.

สถานที่สอบ ณ อาคารเฉลิมพระเกียรติใหม่ ห้อง HM-304

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

คณะวิศวกรรมศาสตร์ รับรองแล้ว



(รองศาสตราจารย์ ดร. คมสัน มาลีสี)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

วันที่ 15 กรกฎาคม พ.ศ. 2558

หัวข้อวิทยานิพนธ์	ระบบตรวจจับและจำแนกอุบัติเหตุทางจราจรแบบอัตโนมัติด้วยเวฟเล็ทและพีซซีลอจิก
นักศึกษา	นางสาวจรัสพัฒน์ หล้าอินเชื้อ
รหัสนักศึกษา	56601271
ปริญญา	วิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชา	วิศวกรรมโทรคมนาคม
พ.ศ.	2558
อาจารย์ที่ปรึกษาวิทยานิพนธ์	ผศ.ดร. ศรววัฒน์ ชิวปรีชา
อาจารย์ที่ปรึกษาวิทยานิพนธ์ (ร่วม)	ดร.สุทธิพงษ์ ธีชัยพงษ์

บทคัดย่อ

วิทยานิพนธ์นี้ได้นำเสนอระบบตรวจจับและจำแนกอุบัติเหตุทางจราจรแบบอัตโนมัติด้วยเทคนิคการประมวลผลสัญญาณและปัญญาประดิษฐ์ เพื่อตรวจจับอุบัติเหตุที่มีลักษณะแบบ Lane blocking ซึ่งเป็นปัญหาหลักที่ทำให้การจราจรเกิดการติดขัดเมื่อมีอุบัติเหตุดังกล่าวเกิดขึ้น ระบบที่นำเสนอนี้ได้ใช้ระบบอนุমানตรระกลุ่มเคลื่อนบนฐานโครงข่ายปรับตัวได้ เพื่อปกป้องสภาพจราจรที่ปกติและสภาพจราจรที่ผิดปกติ โดยข้อมูลอินพุตที่นำมาใช้กับระบบเป็นข้อมูลเชิงมหภาคซึ่งก็คือค่าความเร็วเฉลี่ย และข้อมูลเชิงจุลภาคซึ่งก็คือค่าเบี่ยงเบนมาตรฐานของเวลาระหว่างการเข้าถึง ข้อมูลอินพุตที่ใช้งานจะมีลักษณะแบบ Hybrid Microscopic-Macroscopic Model เนื่องจากข้อมูลทางจราจรมีความผันผวนของข้อมูลอยู่มาก ทางผู้วิจัยจึงได้นำการแปลงเวฟเล็ทเติมหน่วยมาใช้กับข้อมูลก่อนนำข้อมูลที่ได้เป็นข้อมูลอินพุตให้กับระบบอนุমানตรระกลุ่มเคลื่อนบนฐานโครงข่ายปรับตัวได้ ซึ่งการแปลงเวฟเล็ทเติมหน่วยมีข้อดีคือ ช่วยลดสัญญาณรบกวนและช่วยสกัดคุณลักษณะเด่นของข้อมูลออกมา นอกจากนี้วิธีการเสียงข้างมากถูกนำมาประยุกต์ใช้กับผลลัพธ์ที่ได้จากระบบอนุমানตรระกลุ่มเคลื่อนบนฐานโครงข่ายปรับตัวได้ เพื่อช่วยเพิ่มค่าอัตราตรวจจับ (DR) ให้กับระบบ ระบบที่นำเสนอนี้ใช้ข้อมูลทางจราจรที่อยู่บนพื้นฐานของโปรแกรมจำลองทางด้านวิศวกรรมจราจร Aimsun สำหรับประสิทธิภาพของระบบที่นำเสนอเพื่อตรวจจับและจำแนกอุบัติเหตุแบบ Lane blocking จะถูกนำเสนอในวิทยานิพนธ์นี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Thesis Title	Automatic Traffic Incident Detection and Classification System Using Wavelet and Fuzzy Logic
Student	Ms.Jarapat La-inchua
Student ID.	56601271
Degree	Master of Engineering
Program	Telecommunications Engineering
Year	2015
Thesis Advisor	Asst.Prof.Dr.Sorawat Chivapreecha
Thesis Co-Advisor	Dr.Suttipong Thajchayapong

ABSTRACT

This thesis presents an Automatic Traffic Incident Detection and Classification System Using Signal Processing and Artificial Intelligence Techniques to detect a lane-blocking traffic incident that usually causes of traffic congestion. The proposed system uses ANFIS to identify traffic status as normal and abnormal. Macroscopic and microscopic traffic variables, namely, mean speed and standard deviation of inter-arrival time are used as inputs to the Adaptive Network-Based Fuzzy Inference System (ANFIS). As traffic variables have many fluctuations which are considered as noisy signals, discrete wavelet transform (DWT) as used for de-noising and also extracting features from noisy signals. Furthermore, the majority voting is also applied to the outputs of ANFIS in order to increase detection rate. Finally, based on simulation results, the performance of the proposed detection and classification system for lane-blocking traffic incidents will be shown.

กิตติกรรมประกาศ

วิทยานิพนธ์เรื่องระบบตรวจจับและจำแนกอุบัติเหตุการจราจรแบบอัตโนมัติด้วยเวฟเล็ตและฟัซซีลอจิก (Automatic Traffic Incident Detection and Classification System Using Wavelet and Fuzzy Logic) ข้าพเจ้าขอขอบคุณผู้ช่วยศาสตราจารย์ ดร.ศรวิวัฒน์ ชิวปรีชา อาจารย์ที่ปรึกษา ที่คอยให้คำแนะนำเกี่ยวกับกระบวนการทำวิจัย ช่วยดูแลให้ความช่วยเหลืออยู่เสมอ ให้คำปรึกษาเมื่อเกิดปัญหาขึ้นระหว่างการทำวิทยานิพนธ์นี้ และให้ความรู้รวมถึงทักษะทางด้านกระบวนการคิดการทำงาน และคอยส่งเสริมทักษะในด้านต่างๆ จนทำให้งานวิจัยนี้สำเร็จไปได้ด้วยดี ขอขอบคุณ ดร.สุทธิพงษ์ รัชชพงษ์ อาจารย์ที่ปรึกษาร่วมและนักวิจัยศูนย์เทคโนโลยีอิเล็กทรอนิกส์และคอมพิวเตอร์แห่งชาติ (NECTEC) ที่คอยให้คำปรึกษา คำแนะนำเกี่ยวกับกระบวนการทำวิจัย ตลอดจนเป็นผู้ชี้แนะแนวทางในการทำวิจัยนี้และคอยเอื้อเพื่อข้อมูลงานทางด้านจราจร ขอขอบคุณพีทีทีทิงซ์ ทริโอต์ป๊ะและพีจีเอสยู จงอุดมการณ์ ที่คอยให้ความช่วยเหลือเกี่ยวกับการใช้งานทางด้านโปรแกรมจำลองทางด้านวิศวกรรมจราจร Aimsun รวมทั้งให้คำแนะนำและความรู้ทางด้านวิศวกรรมขนส่ง (Transportation Engineering) นอกจากนี้ขอขอบคุณโครงการทุนสถาบันบัณฑิตวิทยาศาสตร์และเทคโนโลยีไทยหรือทุน TGIST โดยสำนักงานพัฒนาวิทยาศาสตร์และเทคโนโลยีแห่งชาติ (สวทช.) ที่สนับสนุนทุนการศึกษาตามสัญญาทุนเลขที่ TGIST 01-56-027 รวมทั้งได้ให้โอกาสเข้าร่วมงานกับนักวิจัยจาก สวทช. และได้ช่วยผลักดันให้มีผลงานทางวิชาการที่มีคุณภาพ ขอขอบพระคุณคุณแม่ที่คอยให้กำลังใจ คอยสนับสนุนและทำให้ผ่านอุปสรรคทั้งหมดมาได้ สุดท้ายขอขอบคุณพี่ๆ เพื่อนๆ ที่คอยช่วยเหลือและให้กำลังใจเสมอมา

นางสาวจรัสพัฒน์ หล้าอินเชื้อ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ

หน้า

บทคัดย่อภาษาไทย.....	I
บทคัดย่อภาษาอังกฤษ.....	II
กิตติกรรมประกาศ.....	III
สารบัญ.....	IV
สารบัญตาราง.....	VI
สารบัญรูป.....	VIII

บทที่ 1 บทนำ.....	1
1.1 ความเป็นมาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของการศึกษา.....	4
1.3 ขอบเขตงานวิจัย.....	4
1.4 รายละเอียดของวิทยานิพนธ์.....	5

บทที่ 2 ความรู้พื้นฐานที่เกี่ยวข้องกับงานวิจัย.....	6
2.1 หลักการเกี่ยวกับวิศวกรรมจราจร.....	6
2.1.1 ข้อมูลจราจรเชิงมหภาค (Macroscopic traffic variable).....	6
2.1.2 ข้อมูลจราจรเชิงจุลภาค (Microscopic traffic variable).....	7
2.1.3 นิยามของอุบัติเหตุทางจราจรและหลักการในการจัดการอุบัติเหตุจราจร.....	9
2.2 โปรแกรมการจำลองทางด้านวิศวกรรมจราจร (Aimsun).....	12
2.3 การแปลงเวฟเล็ต (Wavelet Transform).....	13
2.4 ระบบอนุมานตรรกะคลุมเครือ (Fuzzy Inference System: FIS).....	16
2.4.1 แนวคิดพื้นฐานเกี่ยวกับระบบอนุมานตรรกะคลุมเครือ.....	16
2.4.2 การประยุกต์ใช้งานของระบบอนุมานตรรกะคลุมเครือ.....	17
2.5 โครงข่ายประสาทเทียม (Artificial Neural Network: ANN).....	22
2.6 ระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (Adaptive Neuro Fuzzy Inference System: ANFIS).....	29

บทที่ 3 การออกแบบและการคำนวณ.....	33
3.1 ข้อมูลที่นำมาใช้กับระบบ	33
3.1.1 ข้อมูลจากโปรแกรมจำลองทางด้านวิศวกรรมจราจร Aimsun.....	33
3.1.2 การกำหนดลักษณะของอุบัติเหตุที่เกิดขึ้น.....	39
3.1.2.1 แบบ 1 Lane blocking.....	39
3.1.2.2 แบบ 2 Lane blocking.....	39
3.1.2.3 แบบ 3 Lane blocking.....	40

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ (ต่อ)

	หน้า
3.2 หลักการออกแบบและหลักการทำงานโดยรวมของระบบที่นำเสนอ.....	40
3.2.1 ระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้ระบบอนุมานตรรกะ คลุมเครือ.....	40
3.2.2 ระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้ระบบอนุมานตรรกะ คลุมเครือและวิธีการเสียงข้างมาก.....	45
3.2.3 ระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้การแปลงเวฟเล็ตเต็มหน่วย และระบบอนุมานตรรกะคลุมเครือร่วมกับวิธีการเสียงข้างมาก.....	47
3.2.4 ระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้การแปลงเวฟเล็ตเต็ม หน่วยและระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ ร่วมกับวิธีการเสียงข้างมาก.....	53
3.2.5 ระบบตรวจจับและจำแนกอุบัติเหตุทางจราจรแบบอัตโนมัติ โดยใช้ การแปลงเวฟเล็ตเต็มหน่วยและระบบอนุมานตรรกะคลุมเครือบน ฐานโครงข่ายปรับตัวได้ร่วมกับวิธีการเสียงข้างมาก.....	57
3.3 วิธีการประเมินประสิทธิภาพของระบบ.....	58
3.3.1 คำนวณหาค่า DR (Detection Rate).....	58
3.3.2 การคำนวณหาค่า MTTD (Mean Time to Detect).....	59
บทที่ 4 ผลการทดลองและอภิปรายผล.....	63
4.1 ข้อมูลที่นำมาใช้กับระบบ.....	63
4.2 ผลของการแปลงเวฟเล็ตเต็มหน่วย.....	64
4.3 ผลการเปรียบเทียบวิธีการทางปัญญาประดิษฐ์ (Artificial Intelligence).....	66
4.3.1 ระบบอนุมานตรรกะคลุมเครือ (Fuzzy Inference System: FIS).....	66
4.3.2 ระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (ANFIS).....	71
4.4 ผลการเปรียบของระบบที่นำเสนอ.....	73
4.5 ผลของการจำแนกอุบัติเหตุทางจราจร.....	75
บทที่ 5 สรุปผล.....	78
5.1 สรุปผลการทดลอง.....	78
เอกสารอ้างอิง.....	79
ภาคผนวก.....	81
ประวัติผู้เขียน.....	89

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญตาราง

ตารางที่		หน้า
3.1	เงื่อนไขของการเกิดอุบัติเหตุ [5].....	39
3.2	กฎของฟัซซี่ (Fuzzy rules) ของระบบที่นำเสนอใน [6].....	48
3.3	กฎของฟัซซี่ (Fuzzy rules) ของระบบที่นำเสนอใน [7].....	54
4.1	DR และ MTTD ของ 1 Lane blocking โดยใช้ขนาดหน้าต่าง 5 samples ของระบบอนุमानตรรกะคลุมเครือ.....	66
4.2	DR และ MTTD ของ 1 Lane blocking โดยใช้ขนาดหน้าต่าง 7 samples ของระบบอนุमानตรรกะคลุมเครือ.....	67
4.3	DR และ MTTD ของ 2 Lane blocking โดยใช้ขนาดหน้าต่าง 5 samples ของระบบอนุमानตรรกะคลุมเครือ.....	67
4.4	DR และ MTTD ของ 2 Lane blocking โดยใช้ขนาดหน้าต่าง 7 samples ของระบบอนุमानตรรกะคลุมเครือ.....	67
4.5	DR และ MTTD ของ 3 Lane blocking โดยใช้ขนาดหน้าต่าง 5 samples ของระบบอนุमानตรรกะคลุมเครือ.....	68
4.6	DR และ MTTD ของ 3 Lane blocking โดยใช้ขนาดหน้าต่าง 7 samples ของระบบอนุमानตรรกะคลุมเครือ.....	68
4.7	DR และ MTTD ของ 1 Lane blocking โดยใช้ขนาดหน้าต่าง 3 samples ของระบบอนุमानตรรกะคลุมเครือที่ใช้การแปลงเวฟเล็ตเต็มหน่วย.....	69
4.8	DR และ MTTD ของ 1 Lane blocking โดยใช้ขนาดหน้าต่าง 5 samples ของระบบอนุमानตรรกะคลุมเครือที่ใช้การแปลงเวฟเล็ตเต็มหน่วย.....	69
4.9	DR และ MTTD ของ 2 Lane blocking โดยใช้ขนาดหน้าต่าง 3 samples ของระบบอนุमानตรรกะคลุมเครือที่ใช้การแปลงเวฟเล็ตเต็มหน่วย.....	70
4.10	DR และ MTTD ของ 2 Lane blocking โดยใช้ขนาดหน้าต่าง 5 samples ของระบบอนุमानตรรกะคลุมเครือที่ใช้การแปลงเวฟเล็ตเต็มหน่วย.....	70
4.11	DR และ MTTD ของ 3 Lane blocking โดยใช้ขนาดหน้าต่าง 3 samples ของระบบอนุमानตรรกะคลุมเครือที่ใช้การแปลงเวฟเล็ตเต็มหน่วย.....	70
4.12	DR และ MTTD ของ 3 Lane blocking โดยใช้ขนาดหน้าต่าง 5 samples ของระบบอนุमानตรรกะคลุมเครือที่ใช้การแปลงเวฟเล็ตเต็มหน่วย.....	71
4.13	DR และ MTTD ของ 1 Lane blocking โดยใช้ขนาดหน้าต่าง 3 samples ของระบบอนุमानตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (ANFIS).....	71
4.14	DR และ MTTD ของ 1 Lane blocking โดยใช้ ขนาดหน้าต่าง 5 samples ของระบบอนุमानตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (ANFIS)	72
4.15	DR และ MTTD ของ 2 Lane blocking โดยใช้ ขนาดหน้าต่าง 3 samples ของระบบอนุमानตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (ANFIS)	72
4.16	DR และ MTTD ของ 2 Lane blocking โดยใช้ ขนาดหน้าต่าง 5 samples ของระบบอนุमानตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (ANFIS)	72

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญตาราง (ต่อ)

ตารางที่		หน้า
4.17	DR และ MTTD ของ 3 Lane blocking โดยใช้ขนาดหน้าต่าง 3 samples ของระบบอนุमानตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (ANFIS).....	73
4.18	DR และ MTTD ของ 3 Lane blocking โดยใช้ขนาดหน้าต่าง 5 samples ของระบบอนุमानตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (ANFIS).....	73
4.19	การเปรียบเทียบผลลัพธ์ของระบบที่นำเสนอ.....	74
4.20	การจำแนกลักษณะของอุบัติเหตุการณแบบ 1 Lane blocking ของระบบอนุमानตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (ANFIS).....	75
4.21	การจำแนกลักษณะของอุบัติเหตุการณแบบ 2 Lane blocking ของระบบอนุमानตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (ANFIS).....	76
4.22	การจำแนกลักษณะของอุบัติเหตุการณแบบ 3 Lane blocking ของระบบอนุमानตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (ANFIS).....	76
4.23	ผลลัพธ์ของการจำแนกลักษณะของอุบัติเหตุการณสำหรับระบบอนุमानตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (ANFIS).....	77



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญรูป

รูปที่		หน้า
1.1	อัลกอริธึมในการตรวจจับและจำแนกลักษณะของสภาพจราจรที่ผิดปกติที่ นำเสนอใน [1].....	1
1.2	อัลกอริธึมในการตรวจจับและจำแนกลักษณะของสภาพจราจรที่ผิดปกติที่ นำเสนอใน [4].....	2
1.3	การนำตรรกะคลุมเครือมาใช้กับข้อมูลทางจราจรที่นำเสนอใน [5].....	3
2.1	Inter-arrival time ในกระแสจราจร.....	9
2.2	อุบัติเหตุรถเสียบนสะพานวงแหวนอุตสาหกรรม.....	10
2.3	หลักการจัดการอุบัติเหตุจราจร.....	11
2.4	การจัดการที่เกิดเหตุ.....	12
2.5	หน้าตาการทำงานของโปรแกรมจำลองทางด้านวิศวกรรมจราจร Aimsun.....	13
2.6	ลักษณะของสัญญาณเวฟเล็ดแบบต่างๆ.....	14
2.7	โครงสร้างของชุดตัวกรองสัญญาณเวฟเล็ดเต็มหน่วย.....	15
2.8	การแปลงเวฟเล็ดแบบเต็มหน่วยโดยอาศัยโครงสร้างต้นไม้แบบทวิภาค 3 ระดับ...	15
2.9	ตรรกะแบบจริงเท็จ (บูลีนลอจิก) กับตรรกะแบบฟัซซี (ฟัซซีลอจิก).....	16
2.10	ความไม่แน่นอน (Uncertainty).....	17
2.11	โครงสร้างพื้นฐานของการอนุมานตรรกะคลุมเครือแบบ Mamdani-style.....	19
2.12	โครงสร้างพื้นฐานของการอนุมานตรรกะคลุมเครือแบบ Sugeno-style.....	21
2.13	ส่วนประกอบของเซลล์ประสาทของมนุษย์.....	22
2.14	สถาปัตยกรรมของโครงข่ายประสาทเทียมโดยทั่วไป.....	23
2.15	แผนภาพของเซลล์ประสาท.....	24
2.16	Activation Functions ของเซลล์ประสาท.....	25
2.17	โครงสร้างของการเรียนรู้แบบแพร่ย้อนกลับ (Back propagation).....	27
2.18	สถาปัตยกรรมของระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้.....	29
3.1	หน้าตาการทำงานของโปรแกรมจำลองทางด้านวิศวกรรมจราจร Aimsun.....	37
3.2	หน้าตาของการตั้งค่าลักษณะของถนน.....	37
3.3	หน้าตาการทำงานของ Traffic state.....	38
3.4	หน้าตาการทำงานของ Traffic demand.....	39
3.5	หน้าตาการบันทึกข้อมูลลงฐานข้อมูล Microsoft Access.....	40
3.6	ข้อมูลที่ถูกบันทึกลงฐานข้อมูล Microsoft Access.....	40
3.7	ลักษณะข้อมูลที่นำมาใช้กับระบบสำหรับอุบัติเหตุแบบ 1 Lane blocking.....	41
3.8	ลักษณะข้อมูลชุดเรียนรู้ที่นำมาใช้กับระบบสำหรับอุบัติเหตุแบบ 1 Lane blocking.....	42
3.9	สภาพจราจรแบบ 1 lane-blocking.....	42
3.10	สภาพจราจรแบบ 2 lane-blocking.....	42
3.11	สภาพจราจรแบบ 3 lane-blocking.....	43

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญญรูป (ต่อ)

รูปที่		หน้า
3.12	ระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้ระบบอนุมานตรรกะคลุมเครือ.....	44
3.13	การพล็อตแบบกระจายของอุบัติเหตุแบบ 1 Lane blocking.....	44
3.14	การพล็อตแบบกระจายของอุบัติเหตุแบบ 2 Lane blocking.....	45
3.15	การพล็อตแบบกระจายของอุบัติเหตุแบบ 3 Lane blocking.....	45
3.16	ฟังก์ชันความเป็นสมาชิกของอินพุท (Input membership function).....	46
3.17	ฟังก์ชันความเป็นสมาชิกของค่าความเร็วเฉลี่ย (Mean speed).....	46
3.18	ฟังก์ชันความเป็นสมาชิกของค่าเบี่ยงเบนมาตรฐานของเวลาในขณะที่ยานต์กำลังเข้ามาในพื้นที่ถนนที่กำหนด (Std. inter-arrival time).....	47
3.19	ฟังก์ชันความเป็นสมาชิกของเอาต์พุท (Output membership function).....	47
3.20	ระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้ระบบอนุมานตรรกะคลุมเครือและวิธีการเสียงข้างมาก.....	48
3.21	Blocking window ขนาด 5 samples และ 7 samples.....	49
3.22	ระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้การแปลงเวฟเล็ตเต็มหน่วยและระบบอนุมานตรรกะคลุมเครือร่วมกับวิธีการเสียงข้างมาก.....	50
3.23	โครงสร้างของชุดตัวกรองสัญญาณ (Filter bank analysis).....	51
3.24	เวฟเล็ตแม่ชนิด Daubechies-2.....	51
3.25	โครงสร้างของชุดตัวกรองสัญญาณแบบ 1 ระดับ.....	52
3.26	ฟังก์ชันความเป็นสมาชิกของ Approximation coefficient ของค่าความเร็วเฉลี่ย.....	53
3.27	ฟังก์ชันความเป็นสมาชิกของ Approximation coefficient ของค่าเบี่ยงเบนมาตรฐานของเวลาในขณะที่ยานต์กำลังเข้ามาในพื้นที่ถนนที่กำหนด.....	53
3.28	ฟังก์ชันความเป็นสมาชิกของเอาต์พุท (Output membership function) สำหรับการแปลงเวฟเล็ตเต็มหน่วย.....	54
3.29	Blocking window ขนาด 5 samples และ 7 samples.....	55
3.30	ระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้การแปลงเวฟเล็ตเต็มหน่วยและระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ร่วมกับวิธีการเสียงข้างมาก.....	56
3.31	การทำงานในโหมดการฝึกหัด (Training mode).....	57
3.32	ฟังก์ชันสี่เหลี่ยมคางหมู (Trapezoid membership function).....	57
3.33	ฟังก์ชันความเป็นสมาชิกของ Approximation coefficient ของค่าความเร็วเฉลี่ย สำหรับระบบที่ใช้ ANFIS เป็นกลไกหลัก.....	58
3.34	ฟังก์ชันความเป็นสมาชิกของ Approximation coefficient ของค่าเบี่ยงเบนมาตรฐานของเวลาในขณะที่ยานต์กำลังเข้ามาในพื้นที่ถนนที่กำหนด สำหรับระบบที่ใช้ ANFIS เป็นกลไกหลัก.....	59
3.35	การทำงานในโหมดการทำงาน (Working mode).....	59
3.36	หลักการดำเนินงานโดยรวมของระบบระบบตรวจจับและจำแนกอุบัติเหตุทาง	

เอกสารนี้เป็นทรัพย์สินทางปัญญาที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญรูป (ต่อ)

รูปที่		หน้า
3.37	การจำแนกลักษณะอุบัติเหตุการ.....	61
4.1	ลักษณะข้อมูลที่นำมาใช้กับระบบที่นำเสนอสำหรับอุบัติเหตุการแบบ 1 Lane blocking	63
4.2	ลักษณะข้อมูลที่นำมาใช้กับระบบที่นำเสนอสำหรับอุบัติเหตุการแบบ 2 Lane blocking.....	64
4.3	ลักษณะข้อมูลที่นำมาใช้กับระบบที่นำเสนอสำหรับอุบัติเหตุการแบบ 3 Lane blocking.....	64
4.4	ลักษณะข้อมูลที่ได้จากการแปลงเวฟเล็ดเติมหน่วยสำหรับอุบัติเหตุการแบบ 1 Lane blocking.....	65
4.5	ลักษณะข้อมูลที่ได้จากการแปลงเวฟเล็ดเติมหน่วยสำหรับอุบัติเหตุการแบบ 2 Lane blocking.....	65
4.6	ลักษณะข้อมูลที่ได้จากการแปลงเวฟเล็ดเติมหน่วยสำหรับอุบัติเหตุการแบบ 3 Lane blocking.....	66



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

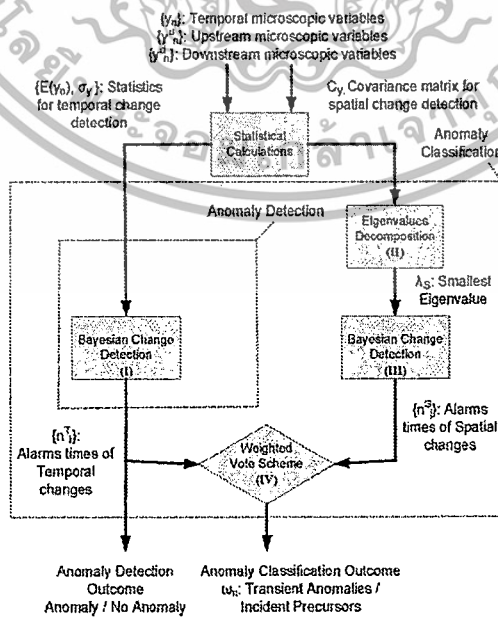
บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

เป็นที่ทราบกันดีว่าปัญหาการเกิดอุบัติเหตุทางจราจร (Traffic incident) บนท้องถนนเป็นสาเหตุหลักที่สำคัญที่ทำให้เกิดปัญหาการจราจรติดขัด (Traffic jam) โดยเฉพาะอย่างยิ่งในเมืองใหญ่ และโดยธรรมชาติแล้วการเกิดอุบัติเหตุทางจราจรเป็นสิ่งที่ไม่สามารถคาดการณ์ได้ล่วงหน้า (Non-recurrent congestion) ซึ่งสามารถนำไปสู่การก่อให้เกิดปัญหาความล่าช้าในการเดินทางเนื่องจากรถติด รวมทั้งก่อให้เกิดการสิ้นเปลืองพลังงานเชื้อเพลิงโดยเปล่าประโยชน์ สำหรับงานวิจัยที่เกี่ยวข้องกับการตรวจจับอุบัติเหตุอย่างอัตโนมัติ (Automatic Incident Detection) ได้มีการพัฒนาและปรับปรุงมาอย่างต่อเนื่องในระยะเวลากว่า 30 ปี ในต่างประเทศ โดยเฉพาะในประเทศสหรัฐอเมริกาและกลุ่มประเทศยุโรป แต่กระนั้นสำหรับประเทศไทยลักษณะงานวิจัยและระบบตรวจจับอุบัติเหตุทางจราจรดังกล่าวยังถือว่าเป็นเรื่องใหม่และเพิ่งเริ่มมีกลุ่มนักวิจัยทางด้านวิศวกรรมจราจรได้ทำการศึกษาถึงความเป็นไปได้ในการนำเทคโนโลยีดังกล่าวมาประยุกต์ใช้ในประเทศ โดยในทางปฏิบัติข้อมูลที่เกิดจากการตรวจวัดสภาพทางจราจรจะถูกพิจารณาเป็นข้อมูลหรือสัญญาณแบบเวลาไม่ต่อเนื่อง (Discrete-time signal) ซึ่งเทคนิคทางด้านวิศวกรรมประมวลผลสัญญาณและปัญญาประดิษฐ์จะเป็นประโยชน์อย่างมากในการนำข้อมูลทางจราจรมาทำการประมวลผลเพื่อการแจ้งสถานะของสภาพจราจรบนท้องถนนว่ามีความปกติ/หรือผิดปกติอย่างไร และยังสามารถจำแนกลักษณะของอุบัติเหตุที่เกิดขึ้นได้

จากการศึกษาวิจัยที่ได้นำเสนอใน [1] ซึ่งได้นำเสนออัลกอริธึมในการตรวจจับและจำแนกลักษณะของสภาพจราจรที่ผิดปกติ (Anomalies) แสดงได้ดังรูปที่ 1.1 โดยใช้ข้อมูลเชิงจุลภาคบนพื้นฐานของการคำนวณเชิงสถิติ (Statistical)




รูปที่ 1.1 อัลกอริธึมในการตรวจจับและจำแนกลักษณะของสภาพจราจรที่ผิดปกติที่นำเสนอใน [1]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาค้นคว้าเท่านั้น ไม่อนุญาตให้นำไปเผยแพร่โดยไม่ได้รับอนุญาต

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 1.1 แสดงแผนผังของอัลกอริธึมในการตรวจจับและจำแนกลักษณะของสภาพจราจรที่ผิดปกติที่น่าเสนอใน [1] ซึ่งจะอาศัยการวิเคราะห์การเปลี่ยนแปลงของข้อมูลเชิงตำแหน่ง-เชิงเวลา (Spatiotemporal) ในรูปแบบของแบบจำลองตามทฤษฎีของเบย์ (Bayesian theorem) ในลักษณะการเปลี่ยนแปลงค่าความแปรปรวน (Variance) สำหรับการตรวจจับความผิดปกติ (Anomalies detection) ซึ่งจะมีวิธีการที่ค่อนข้างซับซ้อนโดยเฉพาะสำหรับการนำไปประยุกต์ใช้งานแบบเวลาจริง (Real-time)


ในงานวิจัยที่คล้ายกันได้มีการนำเทคนิคทางด้านปัญญาประดิษฐ์มาใช้เป็นกลไกหลักในการตรวจจับอุบัติเหตุที่ผิดปกติได้ถูกนำเสนอใน [2-7] ซึ่งมีงานวิจัยใน [2-3] นำโครงข่ายประสาทเทียม (Artificial neural network: ANN) มาใช้ในการตรวจจับการเกิดอุบัติเหตุทางจราจร แต่ข้อมูลทางจราจรจำนวนมากจำเป็นที่จะต้องถูกนำมาใช้ในกระบวนการสอน (Training) ของโครงข่ายประสาทเทียม ทำให้มีงานวิจัยที่น่าเสนอใน [4] ได้นำการแปลงเวฟเล็ตเพิ่มเติมหน่วยมาใช้ร่วมกับโครงข่ายประสาทเทียมในการตรวจจับและจำแนกอุบัติเหตุทางจราจร



รูปที่ 1.2 อัลกอริธึมในการตรวจจับและจำแนกลักษณะของสภาพจราจรที่ผิดปกติที่น่าเสนอใน [4]

จากรูปที่ 1.2 แสดงแผนผังของอัลกอริธึมในการตรวจจับและจำแนกลักษณะของสภาพจราจรที่ผิดปกติที่น่าเสนอใน [4] จะเห็นได้ว่ากลไกหลักของอัลกอริธึมจะใช้โครงข่ายประสาทเทียมโดยมีข้อดีคือสามารถเรียนรู้จัดจำรูปแบบของสัญญาณได้ (Pattern recognition) แต่ก็มีข้อเสียคือไม่สามารถอธิบายได้ว่าโครงข่ายประสาทเทียมมีการตัดสินใจเพื่อให้ได้มาซึ่งคำตอบอย่างไร ทำให้มีเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

งานวิจัยใน [5] ได้นำเสนออัลกอริธึมที่ใช้ในการตรวจจับอุบัติเหตุทางจราจรบนพื้นฐานของระบบอนุมานตรรกะคลุมเครือ (Fuzzy Inference System: FIS) แทนการใช้โครงข่ายประสาทเทียม ซึ่งสามารถตัดสินใจเพื่อให้ได้มาซึ่งคำตอบสำหรับข้อมูลที่มีความคลุมเครือได้ โดยสามารถแสดงการนำตรรกะคลุมเครือมาใช้กับข้อมูลทางจราจรได้ดังรูปที่ 1.3



รูปที่ 1.3 การนำตรรกะคลุมเครือมาใช้กับข้อมูลทางจราจรที่นำเสนอใน [5]

จากรูปที่ 1.3 ในการนำตรรกะคลุมเครือมาใช้กับข้อมูลทางจราจรที่นำเสนอใน [5] จะเห็นได้ว่าลักษณะของข้อมูลบางส่วนจะสามารถแบ่งหมวดหมู่ของความเป็นปกติ (Normal) กับผิดปกติ (Abnormal) ได้ แต่ก็มีข้อมูลบางส่วนที่ซ้อนทับกันอยู่ทำให้แบ่งหมวดหมู่ได้ยาก เมื่อนำตรรกะคลุมเครือซึ่งจะช่วยในการตัดสินใจภายใต้ความไม่แน่นอนของข้อมูล โดยใช้หลักการเลียนแบบวิธีความคิดของมนุษย์ เมื่อนำไปใช้งานจริงก็จะทำให้ระบบมีความเป็นเหตุเป็นผลในการตัดสินใจเพื่อตรวจจับและบ่งบอกสภาพจราจรได้ นอกจากนี้งานวิจัยที่นำเสนอก่อนหน้านี้ใน [6-7] ก็ได้นำระบบอนุมานตรรกะคลุมเครือมาใช้ในการตรวจจับสภาพจราจรที่ปกติ/ผิดปกติด้วย แต่ในการเลือกใช้จำนวนของตัวแปรจราจรที่นำมาใช้กับระบบก็มีผลต่อประสิทธิภาพของระบบด้วย โดยงานวิจัยที่นำเสนอใน [5] ได้เลือกใช้ตัวแปรทางจราจรเป็นอินพุตจำนวน 4 ตัว ทำให้ระบบมีความซับซ้อนในการประมวลผลมากกว่า ดังนั้นในงานวิจัยที่ได้นำเสนอนี้และงานวิจัยที่นำเสนอก่อนหน้านี้ใน [6-7] จะใช้ตัวแปรทางจราจรเป็นอินพุตเพียง 2 ตัวเท่านั้น และงานวิจัยที่นำเสนอนี้ได้พัฒนาต่อยอดจากงานวิจัยที่นำมาก่อนหน้านี้ [6-7] โดยปรับเปลี่ยนกลไกหลักของระบบซึ่งระบบจะสามารถเรียนรู้จากลักษณะของข้อมูล (Learning from data) ทำให้ระบบสามารถปรับตัวได้ รวมทั้งได้มีการประยุกต์ใช้การแปลงเวฟเลตเติมหน่วย (Discrete wavelet transform: DWT) มาช่วยในการสกัดคุณลักษณะเด่นของข้อมูล (Feature extraction) ออกจากข้อมูลต้นฉบับซึ่งมีความผันผวนของข้อมูลอยู่มาก (Fluctuation) และช่วยลดสัญญาณรบกวน (De-noising) ที่ปะปนเข้ามา กับสัญญาณต้นฉบับได้ถูกนำเสนอไว้ในเอกสาร [8-9] ซึ่งในการนำการแปลงเวฟเลตเติมหน่วยมาใช้กับระบบที่นำเสนอจะเป็นระบบตรวจจับและจำแนกอุบัติเหตุในโดเมนเวฟเลตโดยไม่มีการสังเคราะห์กลับ (Synthesis) เพื่อ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ลดความซับซ้อนของระบบเนื่องจากจำนวนข้อมูลลดลงจะต่างจากงานวิจัยใน [4] ที่พิจารณาข้อมูลที่ถูกแปลงเวฟเล็ตเต็มหน่วยและทำการสังเคราะห์ข้อมูลกลับให้อยู่ในโดเมนเวลา

ดังนั้นงานวิจัยนี้จึงมุ่งเน้นไปที่การนำเสนอระบบเพื่อตรวจจับและจำแนกอุบัติเหตุทางจราจรบนท้องถนนอย่างอัตโนมัติเพื่อการบริหารจัดการสำหรับหน่วยงานที่เกี่ยวข้องอันจะนำไปสู่การแก้ไขเพื่อบรรเทาปัญหาการจราจรที่เกิดขึ้นตามเมืองใหญ่ในประเทศโดยเฉพาะกรุงเทพมหานคร การตรวจจับการเกิดอุบัติเหตุบนท้องถนนได้อย่างทันท่วงที่จะช่วยทำให้เจ้าหน้าที่และหน่วยงานที่เกี่ยวข้องสามารถบริหารจัดการและดำเนินการขจัดปัญหาที่เกิดขึ้นได้อย่างเร็วที่สุดก่อนที่การอุบัติการณ์ดังกล่าวจะนำไปสู่ปัญหาการจราจรติดขัด โดยระบบที่นำเสนอในงานวิจัยนี้ใช้เทคนิคทางด้านปัญญาประดิษฐ์ (Artificial Intelligence) ของระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (Adaptive Neuro Fuzzy Inference System: ANFIS) ร่วมกับเทคนิคทางด้านการประมวลผลสัญญาณ (Signal processing) คือการแปลงเวฟเล็ตเต็มหน่วย (Discrete Wavelet Transform: DWT) ในการบ่งบอกสภาพจราจรที่ปกติและสภาพจราจรที่ผิดปกติ สำหรับการจำแนกอุบัติเหตุทางจราจรจะพิจารณาลักษณะสัญญาณของข้อมูลด้วยการหาค่าระดับอ้างอิง (Threshold) และจำแนกลักษณะของอุบัติเหตุแบบ Lane blocking ได้ 3 แบบคือ 1 Lane blocking, 2 Lane blocking และ 3 Lane blocking

1.2 วัตถุประสงค์ของการศึกษา

- 1) นำเสนอหลักการออกแบบและสร้างระบบตรวจจับและจำแนกอุบัติเหตุทางจราจรแบบอัตโนมัติที่สามารถนำไปประยุกต์ใช้งานในการบริหารจัดการจราจรได้ในแบบเวลาจริงสำหรับหน่วยงานที่เกี่ยวข้อง เพื่อใช้ในการวางแผน แก้ไขและบรรเทาปัญหาที่เกิดจากอุบัติเหตุทางจราจรซึ่งจะนำไปสู่ปัญหาการจราจรติดขัด
- 2) เพื่อศึกษาและนำความรู้เทคนิคทางด้านประมวลผลสัญญาณโดยใช้การแปลงเวฟเล็ตเต็มหน่วยซึ่งจะช่วยสกัดเอาคุณลักษณะเด่นชัดของข้อมูลให้ปรากฏออกมาและช่วยลดสัญญาณรบกวนจากสัญญาณต้นฉบับได้
- 3) เพื่อศึกษาและนำความรู้เทคนิคทางด้านปัญญาประดิษฐ์มาใช้ในการออกแบบและสร้างระบบตรวจจับสภาพจราจรที่เกิดขึ้น
- 4) ศึกษาวิธีการในการจำแนกอุบัติเหตุทางจราจรแบบอัตโนมัติด้วยวิธีการทางการประมวลผลสัญญาณร่วมกับการพิจารณาลักษณะสัญญาณของข้อมูล

1.3 ขอบเขตงานวิจัย

เพื่อบ่งบอกสภาพจราจรที่ปกติ/ผิดปกติ และจำแนกลักษณะอุบัติเหตุทางจราจรแบบ Lane blocking โดยใช้ทั้งข้อมูลเชิงจุลภาค (Microscopic Traffic Variables) และข้อมูลเชิงมหภาค (Macroscopic Traffic Variables) หรือที่เรียกว่าเป็นแบบผสม (Hybrid Micro-Macro Analysis) โดยข้อมูลดังกล่าวได้มาจากจากโปรแกรมจำลองทางด้านวิศวกรรมจราจร Aimsun ซึ่งข้อดีของการใช้ข้อมูลเชิงจุลภาคเป็นข้อมูลที่มีความไวของอัตราการเปลี่ยนแปลง (Sensitivity) สูง ทำให้สามารถบ่งบอกสภาพจราจรที่ผิดปกติได้อย่างรวดเร็วและทันท่วงทีก่อนที่ความผิดปกติต่างๆ จะก่อให้เกิดปัญหาการจราจรติดขัด และข้อดีของข้อมูลเชิงมหภาคคือเป็นข้อมูลที่ได้มาจากการตรวจจับอัตราการไหลและการวิ่งบนถนนของรถยนต์ ซึ่งจะใช้ในวิเคราะห์ร่วมกับข้อมูลเชิงจุลภาคโดยข้อมูลจราจรดังกล่าวเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จะถูกแปลงเวฟเล็ทเต็มหน่วย โดยอาศัยโครงสร้างการแปลงด้วยชุดตัวกรองสัญญาณ (Filter bank) ผลลัพธ์ที่ได้จะถูกนำไปตัดสินใจในการบ่งบอกสภาพจราจรที่ปกติ/ผิดปกติ โดยใช้ระบบอนุमानตรระคะคลุมเครือบนฐานโครงข่ายปรับตัวได้วิธีการเสียงข้างมาก เพื่อหาลักษณะที่ปกติ (Normal) และผิดปกติ (Abnormal) ของสภาพจราจรที่เกิดขึ้น และระบบจะทำการจำแนกลักษณะของอุบัติเหตุการณ์ที่เกิดขึ้นด้วย โดยใช้หลักการพิจารณาลักษณะสัญญาณของข้อมูลด้วยการหาค่าระดับอ้างอิง (Threshold)

1.4 รายละเอียดของวิทยานิพนธ์

วิทยานิพนธ์นี้ได้แบ่งเนื้อหาออกเป็น 5 บทด้วยกัน คือ

บทที่ 1 กล่าวถึงความเป็นมาของงานวิจัยและความสำคัญของปัญหา วัตถุประสงค์ของการศึกษา ขอบเขตงานวิจัยและรายละเอียดของวิทยานิพนธ์

บทที่ 2 กล่าวถึงหลักการและทฤษฎีที่เกี่ยวข้องกับวิศวกรรมจราจร หลักการและทฤษฎีในการแปลงเวฟเล็ทเต็มหน่วย รวมถึงหลักการและทฤษฎีที่เกี่ยวข้องกับปัญญาประดิษฐ์ซึ่งถูกนำมาใช้ในวิทยานิพนธ์ฉบับนี้

บทที่ 3 กล่าวถึงหลักการในการออกแบบระบบที่นำเสนอในวิทยานิพนธ์ รวมถึงอธิบายถึงขั้นตอนการทำงานที่เริ่มต้นจากกระบวนการในการแปลงเวฟเล็ทเต็มหน่วยแล้วนำผลลัพธ์ที่ได้เข้าสู่การตัดสินใจด้วยเทคนิคทางด้านปัญญาประดิษฐ์ และเพื่อให้ระบบที่นำเสนอมีประสิทธิภาพในการทำงานมากขึ้น จึงได้ทำการออกแบบวิธีการเสียงข้างมากมาใช้งานร่วมกับเทคนิคทางด้านปัญญาประดิษฐ์ เพื่อเพิ่มความถูกต้องในการตัดสินใจของระบบ และกล่าวถึงวิธีการจำแนกลักษณะอุบัติเหตุการณ์ที่ระบบสามารถตรวจจับได้

บทที่ 4 กล่าวถึงผลของการทดสอบระบบที่นำเสนอด้วยข้อมูลจราจรที่ได้จากโปรแกรมจำลองทางด้านวิศวกรรมจราจร รวมถึงวิเคราะห์และประเมินผลเพื่อเปรียบเทียบกับงานวิจัยที่ถูกนำเสนอใน [5-7] ซึ่งสามารถประเมินประสิทธิภาพของระบบโดยพิจารณาค่าอัตราการตรวจจับอุบัติเหตุการณ์ของระบบ (Detection Rate: DR) และค่าเฉลี่ยของผลรวมเวลาที่สามารถตรวจจับอุบัติเหตุการณ์ได้ (Mean Time to Detection: MTTD) และยังคงกล่าวถึงผลของการจำแนกอุบัติเหตุการณ์ทางจราจร

บทที่ 5 กล่าวถึงข้อสรุปเนื้อหาของวิทยานิพนธ์ ผลการทดสอบของระบบที่นำเสนอและแนวทางในการพัฒนาระบบต่อไป

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 2

ความรู้พื้นฐานที่เกี่ยวข้องกับงานวิจัย

สำหรับบทนี้จะกล่าวถึงหลักการและทฤษฎีที่เกี่ยวข้องกับวิศวกรรมจราจรรวมถึงอธิบายถึงนิยามของอุบัติเหตุทางจราจรและหลักการจัดการอุบัติเหตุจราจร โปรแกรมที่ใช้ในการจำลองสภาพ หลักการและทฤษฎีในการแปลงเวฟเล็ดเต็มหน่วย และหลักการทฤษฎีที่เกี่ยวข้องกับปัญญาประดิษฐ์ซึ่งถูกนำมาใช้ในวิทยานิพนธ์ฉบับนี้

2.1 หลักการเกี่ยวกับวิศวกรรมจราจร

ในหัวข้อนี้จะอธิบายถึงลักษณะข้อมูลจราจรเชิงมหภาค (Macroscopic traffic variable) และข้อมูลเชิงจุลภาค (Microscopic traffic variable) นิยามของตัวแปรจราจรต่างๆ รวมถึงตัวแปรจราจรที่นำมาใช้เป็นข้อมูลอินพุตให้กับระบบที่นำเสนอและนิยามของอุบัติเหตุจราจรกับหลักการในการจัดการอุบัติเหตุจราจร

2.1.1 ข้อมูลจราจรเชิงมหภาค (Macroscopic traffic variable)

แบบจำลองเชิงมหภาค (Macroscopic models) ถูกนำเสนอโดย Lighthill และ Whitham [9] นำเสนอขึ้นในปี ค.ศ. 1955 ซึ่งลักษณะเหมือนกับแบบจำลองการไหลของของเหลว (Fluid flow model) โดยสมการอนุพันธ์ที่ใช้จะทำการอธิบายการไหลของกระแสจราจร (Traffic flow) ค่าเฉลี่ยความเร็วของยานทั้งหมดที่ครอบครองช่วงถนนที่พิจารณาในช่วงเวลาที่กำหนด (Space mean speed) และความหนาแน่น (Density) นอกจากนี้ยังอาศัยหลักการของการอนุรักษ์การไหลของกระแสจราจร ซึ่งกล่าวไว้ว่า “จำนวนของยานพาหนะที่เข้าไปในแต่ละส่วนของถนนจะเท่ากับที่ออกมาตลอดช่วงของคาบเวลาที่กำหนด” โดยในทางคณิตศาสตร์สามารถแสดงได้ด้วยสมการของความต่อเนื่อง (Continuity equation) ดังนี้

$$\frac{\partial \rho(x,t)}{\partial t} + \frac{\partial q(x,t)}{\partial x} = c \quad (2.1)$$

โดย $\rho(x,t)$ คือ ความหนาแน่นของถนนแต่ละเลน (Density per lane) ที่ตำแหน่ง x และเวลา t

$q(x,t)$ คือ กระแสจราจรของถนนแต่ละเลน (Traffic flow per lane) ที่ตำแหน่ง x และเวลา t

และ $c = \frac{\text{การไหลเข้าของกระแสจราจรจากทางลาด} - \text{การไหลออกของกระแสจราจรจากทางลาด}}{\text{ความยาวของถนนบริเวณที่สนใจ}}$

ซึ่ง $c = 0$ เมื่อไม่มีทั้งการไหลเข้าและการไหลออกของกระแสจราจรจากทางลาด

จากความสัมพันธ์ $q = v\rho$ ดังนั้นจะได้ว่า

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$q(x,t) = v(x,t)\rho(x,t) \quad (2.2)$$

โดย $v(x,t)$ จะเรียกว่าความเร็วของยานพาหนะทั้งหมดที่ครอบครองช่วงถนนที่พิจารณาในช่วงเวลาที่กำหนดที่ตำแหน่ง x และเวลา t และนอกจากนั้นยังสามารถแสดงความสัมพันธ์ที่เรียกว่าความสัมพันธ์ทางพลวัตของความเร็วและความหนาแน่นได้ดังนี้

$$v(x,t) = f[\rho(x,t)] \quad (2.3)$$

แบบจำลองเชิงมหภาคจะทำการจำลองการไหลของกระแสจราจรในลักษณะเป็นกลุ่มก้อนทั้งหมด (จากแนวคิดของพลศาสตร์ของไหล) และอยู่บนพื้นฐานของสมการอนุพันธ์ของความต่อเนื่อง (Differential equation of continuity) ซึ่งเป็นฟังก์ชันของพารามิเตอร์ 3 ตัว คือ

1. กระแสจราจร (Traffic Flow, q)
2. ความเร็ว (Speed, v)
3. ความหนาแน่น (Density, ρ)

สำหรับงานวิจัยที่นำเสนอนี้ได้เลือกใช้ตัวแปรทางจราจรที่เป็นข้อมูลเชิงมหภาค ซึ่งก็คือความเร็ว (Speed) โดยจะใช้เป็นค่าเฉลี่ยของความเร็ว (Mean speed) โดยเป็นค่าเฉลี่ยความเร็วของยานพาหนะที่ครอบครองช่วงถนนที่พิจารณาในช่วงเวลาที่กำหนด

2.1.2 ข้อมูลจราจรเชิงจุลภาค (Microscopic traffic variable)

แบบจำลองเชิงจุลภาค (Microscopic models) จะจำลองความเป็นพลวัต (Dynamics) ของแต่ละผู้ขับขี่ยานพาหนะเป็นรายเดี่ยวๆ โดยแบบจำลอง “Car-Following” [12] ได้นำเสนอขึ้นเป็นแบบจำลองเชิงจุลภาคในยุคแรกๆ ซึ่งใช้ความเร่ง (Acceleration) ของยานพาหนะเป็นพารามิเตอร์อิสระ (Independent parameter) สำหรับสมการการเคลื่อนที่ของยานพาหนะ ทั้งนี้เพราะว่าความเร่งเป็นพารามิเตอร์ที่ถูกควบคุมโดยผู้ขับขี่ยานพาหนะ (Driver-controlled parameter) ซึ่งสามารถแทนการตอบสนองของผู้ขับขี่ที่มีต่อ ระยะห่างระหว่างยานพาหนะ (Space headways) ได้

โมเดลเหล่านี้จะแสดงความเร่งของยานพาหนะแต่ละคัน, α ที่ถูกหน่วงโดยเวลาการเกิดปฏิกิริยาของผู้ขับขี่, τ ได้ในรูปแบบฟังก์ชันของ

$$\dot{v}_\alpha(x,t+\tau) = f\left(v_\alpha(x,t), \Delta v_\alpha(x,t), \frac{1}{s_\alpha(x,t)}\right) \quad (2.4)$$

โดย $v_\alpha(x,t)$ = ความเร็วของยานพาหนะ α ที่ตำแหน่ง x และเวลา t

$\Delta v_\alpha(x,t)$ = ความเร็วของยานพาหนะ α ที่สัมพันธ์ (Relative) กับยานพาหนะคันก่อนหน้า $\alpha-1$ ที่ตำแหน่ง x และเวลา t โดย

$$\Delta v_\alpha(x,t) = v_\alpha(x,t) - v_{\alpha-1}(x,t) \quad (2.5)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$s_\alpha(x, t)$ = ระยะห่างของยานพาหนะ α ที่ตำแหน่ง x และเวลา t ซึ่งนิยามโดย

$$s_\alpha(x, t) = x_{\alpha-1}(x, t) - x_\alpha(x, t) \quad (2.6)$$

โดย x_α เป็นตำแหน่ง (Position) ของยานพาหนะ α และ $x_{\alpha-1}$ เป็นตำแหน่งของยานพาหนะคันก่อนหน้า $\alpha-1$ แต่สำหรับอัตราการชะลอตัว (Deceleration rate) จะถูกสมมติให้เป็นฟังก์ชันของ $\Delta v_\alpha(x, t)$ เพียงอย่างเดียว คือ

$$-\dot{v}_\alpha(x, t + \tau) = f[\Delta v_\alpha(x, t)] \quad (2.7)$$

ในการที่จะทำให้แบบจำลองเชิงจุลภาคข้างต้นมีความสมจริงมากขึ้น ได้มีการนำเสนอโมเดล “Optimal velocity” โดยที่นิยามไว้ว่า “ความเร็วมากที่สุด (Collision-free) ที่ยานพาหนะสามารถคงไว้ (Maintain) ภายใต้ความหนาแน่นของจราจรสูงสุด” ซึ่งได้มาจากการเพิ่มการไหลของจราจร (การหาค่าการไหลของจราจรที่มากที่สุด) ที่ถูกกำหนดโดยสมการ

$$q(x, t) = v(x, t)\rho(x, t) \quad (2.8)$$

ซึ่ง $\rho(x, t)$ คือ ความหนาแน่นของจราจร ดังนั้นจะได้ความเร็ว $v(x, t)$ ที่เหมาะสมโดยความเร็วสูงสุดเป็นฟังก์ชันของระยะห่างของยานพาหนะ α ซึ่งจะทำให้การลดความเร็วเมื่อระยะห่างของยานพาหนะมีค่าต่ำและเพิ่มความเร็วเมื่อระยะห่างของยานพาหนะมีค่ามาก

Bando et al. (1995) ได้นำเสนอการกำหนดโมเดล “Optimal velocity” ซึ่งได้ทำการพิจารณาเวลาการเกิดปฏิกิริยาของผู้ขับขี่ (τ) และผลต่างในความเร็วของยานพาหนะ α ใดๆ กับความเร็วสูงสุดของยานพาหนะนั้นๆ เพื่อที่จะทำการกำหนดค่าความเร่งของยานพาหนะจากความสัมพันธ์ของความเร็วและความหนาแน่น ที่ถูกตั้งสมมติฐานที่ว่า การตอบสนองของยานพาหนะที่ถูกหน่วงโดยปฏิกิริยาของผู้ขับขี่ τ สามารถแสดงเป็นฟังก์ชันของระยะห่างระหว่างยานพาหนะดังนี้

$$v_\alpha(x, t + \tau) = V[s_\alpha(x, t)] \quad (2.9)$$

ซึ่ง $V[s_\alpha(x, t)]$ เป็นฟังก์ชันความเร็วสูงสุดและ τ จะถูกสมมติว่ามีค่าน้อยกว่า 1 นาที โดยการกระจายของอนุกรมเทเลอร์ (Taylor's series) และทำการตัดเทอมที่ 2 และเทอมของ High-order ทั้งสมการด้านบนข้างต้นสามารถแสดงได้เป็น

$$v_\alpha(x, t) + \dot{v}_\alpha(x, t)\tau = V[s_\alpha(x, t)] \quad (2.10)$$

จัดรูปสมการใหม่ จะได้ว่าความเร่งของยานพาหนะ α คือ


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$\dot{v}_\alpha(x,t) = \frac{V[s_\alpha(x,t)] - v_\alpha(x,t)}{\tau} \quad (2.11)$$

บนพื้นฐานของ Numerical simulation ของความเร็วของยานพาหนะที่สูงสุด ซึ่งเป็นฟังก์ชันของ Space headway โดยใช้ข้อมูลจราจรจริงและการพิจารณา Boundary conditions (Bando et al. 1995) จึงได้นำเสนอ Empirical equation สำหรับความเร็วของยานพาหนะสูงสุดคือ:

$$V[s_\alpha(x,t)] = \tanh[s_\alpha(x,t) - 2] - \tanh(-2) \quad (2.12)$$

การอธิบายลักษณะการเคลื่อนที่ของยวดยานที่ค่อยลงมาระดับรถแต่ละคันที่วิ่งอยู่ในกระแสจราจร หรือในระดับจุลภาค (Microscopic descriptors) นั้น จะใช้ช่วงห่าง (Headway) หรือ Inter-arrival time ในการอธิบายลักษณะของกระแสจราจร แสดงได้ดังรูปที่ 2.1



รูปที่ 2.1 Inter-arrival time ในกระแสจราจร

2.1.3 นิยามของอุบัติเหตุทางจราจรและหลักการในการจัดการอุบัติเหตุจราจร

อุบัติเหตุจราจร (Traffic incident) หมายถึง เหตุการณ์ใดๆ ที่เกิดขึ้นบนทางอันจะทำให้ระดับความปลอดภัยในการให้บริการลดลงหรือทำให้การจราจรเกิดความล่าช้า เช่น รถเสีย อุบัติเหตุรถชน สิ่งของบรรทุกตกหล่น วัตถุกีดขวางการจราจร สภาพอากาศเลวร้าย กิจกรรมบำรุงรักษาทางต่างๆ ซึ่งมีระดับความรุนแรงต่างกันตั้งแต่รถจอดเสียบนไหล่ทางแต่ไม่กีดขวางการจราจรไปจนถึงอุบัติเหตุรุนแรง รถบรรทุกพลิกคว่ำ หรือวัตถุอันตรายรั่วไหลบนไหล่ทาง อันทำให้ลดระดับการให้บริการ การจัดการอุบัติเหตุจราจรในประเทศไทยยังมีบางขั้นตอนที่ไม่สมบูรณ์หรือขาดแนวทางปฏิบัติที่เป็นมาตรฐานจึงทำให้การจัดการอุบัติเหตุล่าช้า เกิดแถวคอยยาวส่งผลกระทบต่อผู้ใช้ทางยกตัวอย่างเช่นมีเหตุกรณีรถเทรลเลอร์จอดเสียบนสะพานวงแหวนอุตสาหกรรม แสดงได้ดังรูปที่ 2.2 ทำให้กีดขวางการจราจรเป็นเวลานานเนื่องจากการเคลื่อนย้ายทำได้ยาก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 2.2 อุบัติเหตุรถเสียบนสะพานวงแหวนอุตสาหกรรม

จากรูปที่ 2.2 อุบัติเหตุรถเสียบนสะพานวงแหวนอุตสาหกรรม โดยอุบัติเหตุดังกล่าวเกิดขวาง 3 ช่องทางจราจรในช่วงเวลาเร่งด่วนเช้า ซึ่งเป็นเวลาที่ประชาชนเดินทางไปทำงานต้องใช้เจ้าหน้าที่ปฏิบัติงานจำนวนมากในการตั้งกรวยยางและป้ายแจ้งเตือน ศูนย์ควบคุมวงแหวนฯ ได้ขอกำลังเจ้าหน้าที่ตำรวจเพื่อช่วยจัดการจราจรด้วยและได้ประสานงานหน่วยรถยก ทำให้การเคลื่อนย้ายออกจากช่องจราจร โดยใช้เวลานานถึง 2 ชั่วโมง 30 นาที ในการเคลียร์พื้นที่จะเห็นได้ว่าใช้เวลาในการจัดการอุบัติเหตุจราจรค่อนข้างมาก ทำให้การจราจรบนสะพานวงแหวนอุตสาหกรรมในช่วงเช้าติดขัดอย่างมาก ก่อให้เกิดความสูญเสียทางด้านเศรษฐกิจ สังคม สิ่งแวดล้อม ต่อผู้ใช้ทางและชุมชนข้างเคียง ดังนั้นการรับรู้และตอบสนองต่ออุบัติเหตุอย่างรวดเร็วและมีประสิทธิภาพเพื่อการจราจรกลับสู่สภาพปกติเร็วที่สุดจึงจำเป็นอย่างยิ่ง เพื่อลดผลกระทบที่อาจจะเกิดขึ้นให้น้อยที่สุด

สำหรับหลักการในการจัดการอุบัติเหตุจราจรประกอบด้วยกิจกรรมต่างๆ เริ่มจากการรับทราบเหตุทั้งจากการตรวจจับโดยผู้ควบคุมระบบหรือการแจ้งเหตุจากผู้ใช้ทาง จากนั้นผู้ควบคุมตรวจสอบความถูกต้อง วิเคราะห์ ประเมินความรุนแรง เลือกแนวทางการตอบสนองและสั่งการเพื่อเริ่มดำเนินการตอบสนองเหตุการณ์ที่เกิดขึ้น หลังจากนั้นต้องดำเนินการต่างๆ ต่อไปพร้อมกัน ทั้งการแจ้งข่าวแก่ผู้ใช้ทางและผู้เกี่ยวข้อง การจัดการที่เกิดเหตุ การจัดการจราจรในพื้นที่และบริเวณข้างเคียงรวมถึงการจัดการจราจรให้สามารถใช้งานได้บางส่วนและเคลื่อนย้ายหรือเคลียร์พื้นที่ที่เกิดเหตุซึ่งแสดงได้ดังรูปที่ 2.3 ทั้งนี้การดำเนินการดังกล่าวจะต้องยึดหลักความปลอดภัยและความสะดวกรวดเร็วเพื่อให้การจราจรกลับคืนสู่สภาพปกติให้เร็วที่สุด ลดความเสี่ยงที่จะเกิดอุบัติเหตุซ้ำขึ้นได้อีก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.3 หลักการจัดการอุบัติเหตุจราจร


โดยในแต่ละขั้นตอนของการจัดการอุบัติเหตุจราจรสามารถอธิบายได้ดังนี้

- 1) การรับทราบเหตุ (Detection) กระบวนการที่หน่วยงานต่างๆ ที่เกี่ยวข้องได้รับทราบเหตุ ทั้งจากผู้ประสบเหตุหรือผู้พบเห็นเหตุจากช่องทางต่างๆ อาทิเช่น จากหมายเลขโทรศัพท์ฉุกเฉินของหน่วยตำรวจ จากหมายเลขโทรศัพท์ฉุกเฉินของหน่วยกู้ภัย จากกล้องตรวจการจราจร CCTV (Closed Circuit Television Camera) จากเครื่องตรวจจับความเร็วอัตโนมัติหรือรถผู้ประสบเหตุที่มีเทคโนโลยีขั้นสูง เช่น เมื่อถูกลมนิรภัยทำงานจะส่งข้อมูลไปยังหน่วยงานรับแจ้งเหตุ
- 2) การตรวจสอบเหตุ (Verification) หลังจากที่มีการรับทราบเหตุแล้ว ผู้ควบคุมศูนย์จะทำการตรวจสอบเหตุ เพื่อให้ทราบถึงตำแหน่งที่เกิดเหตุ ระดับความรุนแรง รวมถึงจำนวนผู้บาดเจ็บและผู้เสียชีวิต
- 3) การตอบสนอง (Response) ศูนย์ควบคุมทางจราจรตอบสนองอย่างเหมาะสมตามลักษณะเหตุต่างๆ โดยนโยบายของการตอบสนองจะต้องตอบสนองอย่างรวดเร็วและมีประสิทธิภาพลดระยะเวลาตั้งแต่เกิดอุบัติเหตุจราจรจนถึงจัดการพื้นที่ ช่วยเหลือผู้ประสบเหตุให้ทันต่อการรักษาและลดโอกาสที่จะเกิดอุบัติเหตุซ้ำ
- 4) การแจ้งข่าวให้แก่ผู้ใช้ทาง (Motorist information) การแจ้งข่าวแก่ผู้ใช้ทางสามารถแจ้งได้หลายช่องทาง เช่น วิทยุกระจายเสียง ป้ายข้อความปรับเปลี่ยนได้ (VMS) ทางโทรศัพท์มือถือและอินเทอร์เน็ต ผู้ใช้ทางจะต้องได้รับข่าวสารจนกว่าการจราจรจะกลับคืนสู่สภาพปกติ
- 5) การจัดการที่เกิดเหตุ (Site management) การจัดการอุบัติเหตุใดๆ บริเวณที่เกิดเหตุมีวัตถุประสงค์เพื่อให้มั่นใจว่าผู้ประสบภัยหรือผู้ใช้ทางมีความปลอดภัย ลดผลกระทบต่อการจราจร บริเวณที่เกิดอุบัติเหตุ ยานพาหนะสามารถวิ่งผ่านสถานที่ที่เกิดเหตุได้และเพื่อลดโอกาสการเกิดอุบัติเหตุซ้ำ แต่ยังคงเก็บหลักฐานไว้ตรวจสอบต่อไปได้ดังรูปที่ 2.4 มีการตั้งกรวยยาง ป้ายเตือนและจอตกรถกู้ภัยนั้นอย่างเป็นระเบียบ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จราจร Aimsun มีความสามารถในการจำลองการเกิดอุบัติเหตุการจราจรสามารถจำลองระบบควบคุมการจราจรได้และระบบที่ให้ความสำคัญกับระบบขนส่งสาธารณะการใช้เครื่องมือทางการจราจร เช่น สัญญาณไฟจราจร เครื่องตรวจจับ ป้ายปรับเปลี่ยนข้อความ (VMS - Variable Message Signs) เป็นต้น การประเมินผลกระทบที่มีต่อสิ่งแวดล้อมที่เกิดจากการปล่อยมลภาวะและการใช้พลังงาน การให้รายละเอียดของผลลัพธ์ในเชิงสถิติ เช่น อัตราการไหลความเร็ว ระยะเวลาในการเดินทาง เป็นต้น

โปรแกรมจำลองทางด้านวิศวกรรมจราจร Aimsun สามารถจำลองสภาพจราจรเชิงมหภาค (Macroscopic traffic variable) และเชิงจุลภาค (Microscopic traffic variable) ซึ่งผลลัพธ์ที่ได้จากการจำลองสภาพจราจรจะเป็นข้อมูลทางสถิติ โดยหน้าต่างการทำงานของโปรแกรมจำลองทางด้านวิศวกรรมจราจร Aimsun แสดงได้ดังรูปที่ 2.5

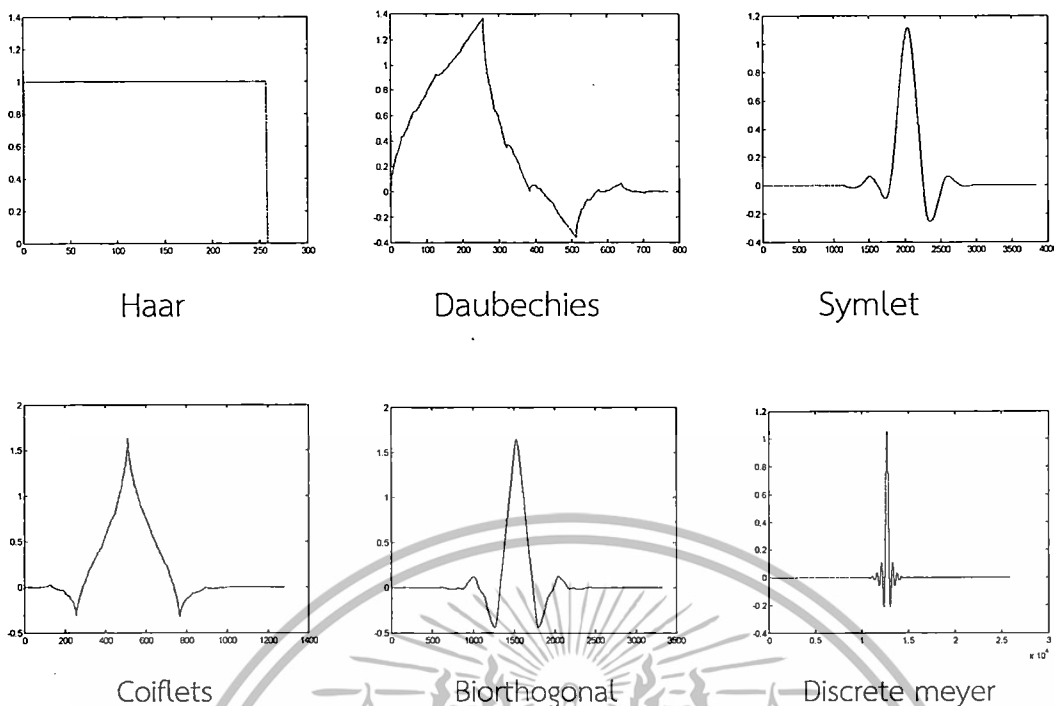


รูปที่ 2.5 หน้าต่างการทำงานของโปรแกรมจำลองทางด้านวิศวกรรมจราจร Aimsun

2.3 การแปลงเวฟเลต (Wavelet Transform)

การแปลงเวฟเลต (Wavelet Transform) เป็นกระบวนการทางคณิตศาสตร์วิธีหนึ่งที่ใช้ในการอธิบายโครงสร้างของระบบสัญญาณที่ประกอบด้วยสัญญาณเฉพาะหลายๆสัญญาณมารวมกันเป็นสัญญาณหนึ่ง โดยสัญญาณเฉพาะนี้จะเป็นรูปคลื่นเล็กๆที่เรียกว่า “เวฟเลต” ซึ่งจะเป็นรูปคลื่นที่มีการเปลี่ยนแปลงอย่างต่อเนื่อง (Oscillatory) และขนาดของคลื่นจะลดลงสู่ศูนย์อย่างรวดเร็ว โดยรูปแบบสัญญาณของเวฟเลตนั้นจะมีรูปแบบต่างๆ ดังรูปที่ 2.6

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.6 ลักษณะของสัญญาณเวฟเล็ตแบบต่างๆ

การแปลงเวฟเล็ตของสัญญาณจะแสดงในรูปของผลรวมสัญญาณองค์ประกอบความถี่ต่ำ (Low frequency) และองค์ประกอบความถี่สูง (High frequency) ในระดับต่างๆ โดยจะมีค่าสัมประสิทธิ์เวฟเล็ตในองค์ประกอบความถี่แต่ละระดับ ดังนั้นในการอธิบายสัญญาณใดๆ ด้วยการแปลงเวฟเล็ตจึงทำได้โดยอธิบายฟังก์ชันที่เป็นฟังก์ชันต้นกำเนิดที่เรียกว่า เวฟเล็ตแม่ (Mother Wavelet) โดยที่สัญญาณที่ได้จากการแปลงเวฟเล็ตจะเกิดจากการปรับสเกล (Scale ; a) หรือการแสดงการยืดหรือหดตัวของเวฟเล็ตแม่ นั่นเอง ส่วนการเลื่อนตำแหน่ง (Translation or Shifting ; b) จะเป็นการแสดงตำแหน่งบนแกนเวลา โดยจะสามารถเขียนสมการของเวฟเล็ตได้ดังนี้

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (2.13)$$


- เมื่อ $\psi(t)$ คือ ฟังก์ชันของเวฟเล็ตแม่ที่มีการปรับสเกล
 a คือ พารามิเตอร์ของการปรับสเกล (Scaling)
 b คือ พารามิเตอร์การเลื่อนตำแหน่ง (Shifting)

เมื่อนำสัญญาณใดๆ มาผ่านกระบวนการแปลงเวฟเล็ตก็เปรียบเหมือนการแตกสัญญาณนั้นให้ออกมาดังรูปของเวฟเล็ตแม่ที่การปรับสเกลและตำแหน่งที่แตกต่างกันไป ซึ่งรูปแบบของการแปลงเวฟเล็ต โดยทั่วไปนั้นสามารถแบ่งออกได้เป็น 2 แบบ คือการแปลงเวฟเล็ตแบบต่อเนื่อง (Continuous Wavelet Transform) และการแปลงเวฟเล็ตแบบเต็มหน่วย (Discrete Wavelet Transform)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

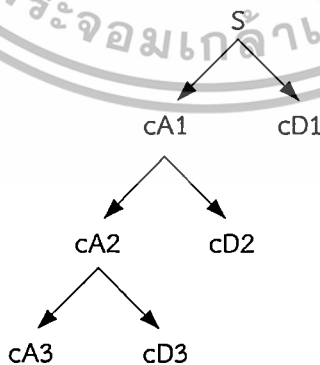
สำหรับงานวิจัยที่นำเสนอนี้ได้เลือกใช้วิธีการแปลงเวฟเล็ตเติมหน่วยมาช่วยลดความผันผวนของตัวแปรทางจราจร

ในการแปลงเวฟเล็ตแบบเติมหน่วย (Discrete Wavelet Transform: DWT) จะเป็นการแปลงเวฟเล็ตรูปแบบหนึ่งที่มีลักษณะการวิเคราะห์โดยพัฒนารูปแบบการปรับสเกลและการเลื่อนตำแหน่งในลักษณะเป็นช่วงๆ ไม่ต่อเนื่องกัน ซึ่งการแปลงเวฟเล็ตเติมหน่วยที่นำเสนอในระบบนี้จะใช้วิธีการวิเคราะห์ชุดตัวกรองสัญญาณ (Filter bank analysis) จะทำการแยกสัญญาณต้นแบบจากชุดตัวกรองสัญญาณ ออกเป็น 2 ส่วน คือส่วนที่มีความถี่ต่ำกับส่วนที่มีความถี่สูง โดยจะใช้ตัวกรองความถี่ต่ำผ่าน (Lowpass Filter) สำหรับแยกองค์ประกอบส่วนที่ความถี่ต่ำ (Approximation coefficient) และใช้ตัวกรองความถี่สูงผ่าน (Highpass Filter) สำหรับแยกองค์ประกอบความถี่สูง (Detail coefficient) โดยสัญญาณที่ได้มานั้นจะผ่านอัตราสุ่มลง (Down Sampling) ด้วย 2 ซึ่งจะทำให้ผลลัพธ์จากการวิเคราะห์ลดลงครึ่งหนึ่ง ซึ่งโครงสร้างของชุดตัวกรองสัญญาณ แสดงได้ดังรูปที่ 2.7



รูปที่ 2.7 โครงสร้างของชุดตัวกรองสัญญาณเวฟเล็ตเติมหน่วย

สามารถเรียกโครงสร้างของการแปลงเวฟเล็ตลักษณะนี้ว่ามีโครงสร้างต้นไม้แบบทวิภาค (Dyadic Tree Structure) ซึ่งรูปที่ 2.8 ได้แสดงการแปลงเวฟเล็ตแบบเติมหน่วยโดยอาศัยโครงสร้างดังกล่าว



รูปที่ 2.8 การแปลงเวฟเล็ตแบบเติมหน่วยโดยอาศัยโครงสร้างต้นไม้แบบทวิภาค 3 ระดับ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เมื่อกำหนดให้

cDn คือ ค่าสัมประสิทธิ์ของสัญญาณองค์ประกอบความถี่สูง (Detail Coefficients)

cAn คือ ค่าสัมประสิทธิ์ของสัญญาณองค์ประกอบความถี่ต่ำ (Approximation Coefficients)

n คือ ค่าระดับความละเอียดซึ่งจะเป็นเลขจำนวนเต็ม ตั้งแต่ $1, 2, \dots, \infty$


ข้อดีของการแปลงเวฟเลตเต็มหน่วยมีด้วยกัน 3 ประการหลักที่ถูกพิจารณาเพื่อนำมาใช้งานในที่นี้ คือ

1. การดึงคุณลักษณะเด่นของข้อมูลออกมา (Feature extraction)
2. ลดสัญญาณรบกวนลง (De-noising) อันจะทำให้ความผันผวนของข้อมูลลดลงด้วยส่งผลให้กระบวนการตัดสินใจโดยระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้มีความถูกต้องมากยิ่งขึ้น
3. ช่วยลดจำนวนของข้อมูลลงทำให้ช่วยลดภาระในการประมวลผลของระบบลงได้ด้วยอันเป็นคุณลักษณะเด่นของการแปลงเวฟเลตเต็มหน่วยที่ถูกนำไปประยุกต์ใช้งานด้าน Data compression

2.4 ระบบอนุมานตรรกะคลุมเครือ (Fuzzy Inference System: FIS)

2.4.1 แนวคิดพื้นฐานเกี่ยวกับระบบอนุมานตรรกะคลุมเครือ

ระบบอนุมานตรรกะคลุมเครือ (Fuzzy Inference System) หรือตรรกะแบบฟัซซี (Fuzzy logic) เป็นเทคนิคแบบหนึ่งในแขนงของงานวิจัยทางด้านปัญญาประดิษฐ์หรือ Artificial Intelligence (AI) ซึ่งนำมาใช้เป็นเครื่องมือที่ช่วยในการตัดสินใจภายใต้ความไม่แน่นอนของข้อมูล และใช้หลักเหตุผลที่คล้ายการเลียนแบบวิถีความคิดที่ซับซ้อนของมนุษย์ ตรรกะแบบฟัซซีมีลักษณะที่พิเศษกว่าตรรกะแบบจริงเท็จ (Boolean logic) โดยจะมีการต่อขยายในส่วนของความจริง (Partial true) โดยค่าความจริงจะอยู่ในช่วงระหว่างจริง (Completely true) กับเท็จ (Completely false) ส่วนตรรกศาสตร์เดิมจะมีค่าเป็นจริงกับเท็จเท่านั้นดังรูปที่ 2.9



รูปที่ 2.9 ตรรกะแบบจริงเท็จ (Boolean logic) กับตรรกะแบบฟัซซี (Fuzzy logic)

ความเป็นฟัซซี (Fuzziness) มีชื่อเรียกว่า มัลติวาลานซ์ (Multivalance) ซึ่งมีค่าที่ความเป็นสมาชิกมากกว่า 2 ค่า และแตกต่างกับไบวาลานซ์ (Bivalance) ที่มีความเป็นสมาชิกเพียง 2 ค่า ฟัซซีเซต (Fuzzy set) เป็นเครื่องมือทางคณิตศาสตร์ที่สื่อถึง “ความไม่แน่นอน (Uncertainty)” ซึ่งหากเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

กำหนดว่า คนที่อ้วนคือคนที่มีน้ำหนักมากกว่า 75 กิโลกรัม คอมพิวเตอร์จะให้ผลว่าคนที่มีน้ำหนัก 74.50 กิโลกรัม ไม่จัดเป็นคนที่อ้วนจะสร้างและกำหนดรูปแบบ (Modeling) ของลักษณะความไม่แน่นอนที่เป็นความคลุมเครือ ความไม่ตายตัว รวมถึงความขาดข้อมูลบางส่วน โดยทฤษฎีของฟัซซีเซต จะใช้ลักษณะความหมายตัวแปร (Linguistic) มากกว่าปริมาณ (Quantitative) ของตัวแปร เช่น การหาความหมายของ “คนที่อ้วน” จะไม่สามารถนิยามค่าความอ้วนที่ตรงกันและระบุเป็นหนึ่งเดียว (Identical) สำหรับคนที่อ้วน นาย ก. จะให้ความหมายของ “คนอ้วน” หมายถึงคนที่มีน้ำหนักมากกว่า 70 กิโลกรัม นาย ข. ให้ความหมายว่าเป็นคนที่มีน้ำหนักมากกว่า 75 กิโลกรัม ซึ่งทั้งสองคนต่างแสดงความหมายของคำว่าคนที่อ้วนโดยเปรียบเทียบและในมุมมองของตัวเองตามน้ำหนักของตน ในการทำงานในมุมมองแบบฐานสอง (Binary sense) จะได้ผลเป็น ใช่ หรือ แต่จะเห็นว่าบุคคลนี้เป็นคนอ้วนน้ำหนักเกือบจะ 75 กิโลกรัม และถึงแม้ว่าบุคคลนี้จะมีน้ำหนัก 75 กิโลกรัม แต่หากพิจารณาจากกลุ่มคนที่มีน้ำหนักเฉลี่ย 90 กิโลกรัม บุคคลนี้ก็อาจจะไม่จัดอยู่ในกลุ่มคนที่อ้วน แสดงให้เห็นว่าความอ้วนไม่ได้มีลักษณะความไม่แน่นอนแบบสุ่ม จากการศึกษาปัญหาทั่ว ๆ ไปจะแสดงถึงรูปแบบลักษณะการกระจายของปัญหา

รูปที่ 2.10 เป็นการแสดงให้เห็นว่าแนวทางในการตัดสินใจของปัญหาทั้งหมดมีเพียงส่วนน้อยที่เป็นสิ่งที่แน่นอน (Certainty) ที่เหลือคือสิ่งที่ไม่แน่นอนซึ่งประกอบด้วยความไม่แน่นอนที่มีลักษณะแบบสุ่ม และความไม่แน่นอนที่มีลักษณะเป็นฟัซซี หรือคลุมเครือ ซึ่งมีมากกว่าร้อยละ 40 เพราะปัญหาส่วนมากเกี่ยวข้องกับการตัดสินใจของมนุษย์ซึ่งจะตัดสินใจตามพื้นฐานความคิดของตนเป็นหลัก



รูปที่ 2.10 ความไม่แน่นอน (Uncertainty)

ฟัซซีจะสร้างวิธีทางคณิตศาสตร์ที่แสดงถึงความคลุมเครือ ความไม่แน่นอนของระบบ ที่เกี่ยวข้องกับความคิดความรู้สึกของมนุษย์ เมื่อพิจารณาส่วนประกอบต่างๆ ในความไม่แน่นอนเพื่อกำหนดเงื่อนไขในการตัดสินใจ (Decision making) โดยอาศัยเซตของความไม่เป็นสมาชิก (Set membership)

2.4.2 การประยุกต์ใช้งานของระบบอนุมานตรรกะคลุมเครือ

ประกอบด้วย 4 ขั้นตอนหลักดังนี้

1) Fuzzification คือ ส่วนที่แปลงข้อมูลจาก Crisp input เพื่อกำหนดขนาดของฟัซซีเซต (Fuzzy set) หรือที่เรียกว่าเป็นตัวแปรภาษา (Linguistic)

2) Rule evaluation คือ ส่วนของการกำหนดวิธีการควบคุม ซึ่งได้จากผู้เชี่ยวชาญในรูปแบบของชุดข้อมูลที่เป็นกฎของภาษา (Linguistic rule)

เอกสารนี้เป็นเอกสารสงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3) Aggregation of the rule outputs คือ กระบวนการในการตรวจสอบข้อเท็จจริงและกฎเพื่อใช้ในการตีความหาเหตุผล เป็นเหมือนกลไกสำหรับควบคุมการใช้ความรู้ในการแก้ไขปัญหา

4) Defuzzification คือ ส่วนที่แปลงข้อมูลจากฟัซซีเซต (Fuzzy set) ที่เป็นตัวแปรทางภาษาให้เป็น Crisp output

โดยการอนุมานด้วยระบบฟัซซี (Fuzzy inference) ที่นิยมใช้คือ

- Mamdani-style

โดยปกติส่วนมากจะใช้เทคนิควิธีการของ Mamdani ในการอนุมานตรรกะคลุมเครือ ซึ่งในปี 1995 Professor Ebrahim Mamdani จากมหาวิทยาลัยลอนดอน สร้างระบบการอนุมานได้เป็นครั้งแรก ซึ่งนำไปควบคุมเครื่องจักรไอน้ำและหม้อน้ำ โดยเขาได้กำหนดพารามิเตอร์ต่างๆ เช่น ฟัซซีเซตและกฎของฟัซซีจากประสบการณ์ของผู้ดูแลเครื่องจักรไอน้ำและหม้อน้ำ

ยกตัวอย่างเช่น 2 อินพุต 1 เอาท์พุท และประกอบไปด้วย 3 กฎ

Rule: 1

IF x is A3
OR y is B1
THEN z is C1

Rule: 2

IF x is A2
AND y is B2
THEN z is C2

Rule: 3

IF x is A1
THEN z is C3

Rule: 1

IF *project_funding* is *adequate*
OR *project_staffing* is *small*
THEN *risk* is *low*

Rule: 2


IF *project_funding* is *marginal*
AND *project_staffing* is *large*
THEN *risk* is *high*

Rule: 3

IF *project_funding* is *inadequate*
THEN *risk* is *high*

ซึ่ง x , y และ z (*project_funding*, *project_staffing* และ *risk*) คือตัวแปรทางภาษา (Linguistic variable) ส่วน A1, A2 และ A3 (*adequate*, *marginal* และ *inadequate*) คือ ตัวแปรทางภาษาที่กำหนดจากฟัซซีเซตของข้อมูล x (*project_funding*) สำหรับ B1 และ B2 (*small* และ *large*) คือ ตัวแปรทางภาษาที่กำหนดจากฟัซซีเซตของข้อมูล y (*project_staffing*) และในส่วนของ C1, C2 และ C3 (*low*, *normal* และ *high*) คือ ตัวแปรทางภาษาที่กำหนดจากฟัซซีเซตของข้อมูล z (*risk*) โดยโครงสร้างพื้นฐานของการอนุมานตรรกะคลุมเครือแบบ Mamdani-style สำหรับตัวอย่างข้างต้นแสดงได้ดังรูปที่ 2.11

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.11 โครงสร้างพื้นฐานของการอนุมานตรรกะคลุมเครือแบบ Mamdani-style [10]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- Sugeno-style

สำหรับการอนุมานแบบ Mamdani-style ผลลัพธ์จะต้องถูกคำนวณแบบการหาจุดศูนย์กลาง (Centre of gravity) ซึ่งจะมีความซับซ้อนในการคำนวณและใช้เวลาในการคำนวณนาน ดังนั้นระบบอนุมานแบบ Sugeno-style จะอาศัยการคำนวณแบบ Singleton จะใช้เป็นการหาค่าฟังก์ชันสมาชิกของกฎตามลำดับ สำหรับวิธีการนี้ถูกนำเสนอขึ้นครั้งแรกโดย Michio Sugeno (Zadah of Japan) ในปี 1985 [10] ระบบอนุมานตรรกะคลุมเครือแบบ Sugeno-style จะมีความคล้ายกับวิธีการแบบ Mamdani-style โดยความแตกต่างของแบบ Sugeno จะมีการเปลี่ยนแปลงเฉพาะลำดับของกฎฟัซซีและได้มีการเลือกใช้ฟังก์ชันทางคณิตศาสตร์ของตัวแปรอินพุตมาใช้แทนฟัซซีเซต ซึ่งจะมีรูปแบบของกฎดังนี้


IF x is A
 OR y is B
 THEN z is $f(x,y)$

ซึ่ง x , y และ z คือตัวแปรทางภาษา ส่วน A และ B คือฟัซซีเซตของข้อมูล x และ y โดย $f(x,y)$ คือ ฟังก์ชันทางคณิตศาสตร์ ซึ่งส่วนมากจะนิยมใช้ zero-order Sugeno fuzzy model มาประยุกต์ใช้กับกฎของฟัซซี ดังนี้

IF x is A
 OR y is B
 THEN z is k

โดยค่า k เป็นค่าคงที่ ในกรณีนี้ผลลัพธ์ที่ได้จากแต่ละกฎของฟัซซีจะเป็นค่าคงที่ กล่าวคือผลของฟังก์ชันสมาชิก (Membership function) จะถูกแทนด้วยแท่งเดี่ยว (Singleton spikes) แสดงได้ดังรูปที่ 2.12 แสดงกระบวนการของระบบอนุมานตรรกะคลุมเครือสำหรับ zero-order Sugeno fuzzy model เมื่อพิจารณาเปรียบเทียบระบบอนุมานแบบ Mamdani และ Sugeno จะเห็นได้ว่าวิธีการและขั้นตอนการทำงานมีความคล้ายคลึงกันอย่างเห็นได้ชัด มีเพียงแต่เฉพาะกฎที่ให้ผลลัพธ์เป็นแท่งเดี่ยวในวิธีการอนุมานแบบ Sugeno เท่านั้น

โดยโครงสร้างพื้นฐานของการอนุมานตรรกะคลุมเครือแบบ Sugeno-style จะสามารถแสดงได้ดังรูปที่ 2.12




รูปที่ 2.12 โครงสร้างพื้นฐานของการอนุมานตรรกะคลุมเครือแบบ Sugeno-style [10]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.5 โครงข่ายประสาทเทียม (Artificial Neural Network: ANN)

โครงข่ายประสาทเทียมหรือที่เรียกกันว่า Artificial Neural Networks (ANN) เป็นแบบจำลองแบบหนึ่งในแขนงของงานวิจัยทางด้านปัญญาประดิษฐ์หรือ Artificial Intelligence (AI) โดยมีการอ้างอิงมาจากการทำงานของเซลล์ประสาทในสมองของมนุษย์แต่ในโครงข่ายของเซลล์ประสาทในสมองของมนุษย์จริงมีขั้นตอนการทำงานที่ซับซ้อนกว่ามาก แต่กระนั้นโครงข่ายประสาทเทียมก็ยังสามารถที่จะนำมาใช้ประโยชน์ได้จริงในงานด้านวิทยาการคอมพิวเตอร์และวิศวกรรมโดยทั่วไป โครงข่ายประสาทเป็นหนึ่งในเทคนิคของการทำเหมืองข้อมูล (Data mining) คือโมเดลทางคณิตศาสตร์ สำหรับประมวลผลสารสนเทศด้วยการคำนวณแบบคอนเนคชันนิสต์ (Connectionist) เพื่อจำลองการทำงานของโครงข่ายของเซลล์ประสาทในสมองมนุษย์ ด้วยวัตถุประสงค์ที่จะสร้างเครื่องมือซึ่งมีความสามารถในการเรียนรู้การจดจำรูปแบบ (Pattern recognition) และการสร้างความรู้ใหม่ (Knowledge extraction) เช่นเดียวกับความสามารถที่มีในสมองมนุษย์

แนวคิดเริ่มต้นของเทคนิคนี้ได้มาจากการศึกษาโครงข่ายไฟฟ้าชีวภาพ (Bioelectric network) ในสมอง ซึ่งประกอบด้วย เซลล์ประสาท หรือ "นิวรอน" (Neurons) และ "จุดประสานประสาท" (Synapses) แต่ละเซลล์ประสาทประกอบด้วยปลายในการรับกระแสประสาท เรียกว่า "เดนไดรต์" (Dendrite) ซึ่งเป็นอินพุตและปลายในการส่งกระแสประสาทเรียกว่า "แอกซอน" (Axon) ซึ่งเป็นเหมือนเอาต์พุตของเซลล์ เซลล์เหล่านี้ทำงานด้วยปฏิกิริยาไฟฟ้าเคมี เมื่อมีการกระตุ้นด้วยสิ่งเร้าภายนอกหรือกระตุ้นด้วยเซลล์ด้วยกัน กระแสประสาทจะวิ่งผ่านเดนไดรต์เข้าสู่นิวเคลียสซึ่งจะเป็นตัวตัดสินใจว่าต้องกระตุ้นเซลล์อื่นๆ ต่อหรือไม่ ถ้ากระแสประสาทแรงพอ นิวเคลียสก็จะกระตุ้นเซลล์อื่น ๆ ต่อไปผ่านทางแอกซอนของมันในสมองของมนุษย์นั้นจะประกอบไปด้วยเซลล์ประสาท ประมาณ 10^{11} ตัว โดยที่เซลล์ประสาทหนึ่งๆ จะมีการเชื่อมโยงต่อไปยังเซลล์ประสาทอื่นๆ อีกประมาณ 10^4 ตัว และเวลาที่ใช้ในการแลกเปลี่ยนข้อมูลระหว่างเซลล์ประสาทนั้นจะอยู่ในหลัก 10^{-3} วินาที โดยการทำงานของ เซลล์ประสาทในสมองมนุษย์นั้นจะมีลักษณะการประมวลผลแบบขนานขั้นสูงอีกด้วย (Highly parallel processing) จึงทำให้มนุษย์สามารถทำการเรียนรู้และจดจำหน้าที่ของตัวเองได้ภายในเวลาเพียงไม่กี่วินาที



รูปที่ 2.13 ส่วนประกอบของเซลล์ประสาทของมนุษย์

ซึ่งนักวิจัยส่วนใหญ่ในปัจจุบันเห็นตรงกันว่าโครงข่ายประสาทเทียมมีโครงสร้างแตกต่างจากโครงข่ายในสมอง แต่ก็ยังเหมือนสมองในแง่ที่ว่าโครงข่ายประสาทเทียมคือการรวมกลุ่มแบบขนานของหน่วยประมวลผลย่อยๆ และการเชื่อมต่อนี้เป็นส่วนสำคัญที่ทำให้เกิดสติปัญญาของโครงข่าย เมื่อพิจารณาขนาดแล้วสมองมีขนาดใหญ่กว่าโครงข่ายประสาทเทียมอย่างมาก รวมทั้งเซลล์ประสาทยังมี

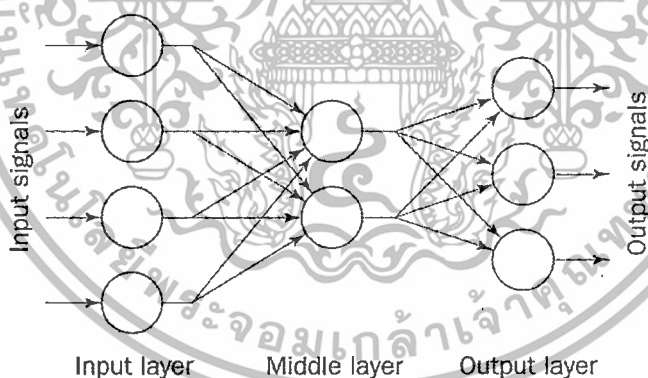
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ทางการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ความซับซ้อนกว่าหน่วยย่อยของโครงข่าย อย่างไรก็ตามที่หน้าที่สำคัญของสมอง เช่น การเรียนรู้ยังคงสามารถถูกจำลองขึ้นอย่างง่ายด้วยโครงข่ายประสาทนี้

เป้าหมายหลักของการนำเอาโครงข่ายประสาทเทียมมาใช้ในการงานด้านวิศวกรรมและวิทยาการคอมพิวเตอร์นั้นคือการพัฒนากระบวนการเรียนรู้ของเครื่องจักรหรือที่เรียกกันว่า Machine Learning ให้มีประสิทธิภาพสูง การนำโครงข่ายประสาทเทียมมาใช้งานแบ่งเป็น 2 ขั้นตอนหลัก คือ ขั้นตอนการฝึกหัด (Training) หรือเรียนรู้ (Learning) และขั้นตอนการทดสอบ (Testing) หรือใช้งานจริง (working) โดยในขั้นตอนของการ Training นั้นยังสามารถแบ่งออกได้เป็น 2 กลุ่มหลัก คือ

1. การเรียนรู้แบบมีครูสอน (Supervised Learning Algorithm)
2. การเรียนรู้แบบไม่มีครูสอน (Unsupervised Learning Algorithm)


สำหรับสถาปัตยกรรมของโครงข่ายประสาทเทียมจะมีการเชื่อมโยงเซลล์ประสาทเทียมจำนวนหนึ่งเข้าด้วยกันเป็นโครงข่ายประสาทเทียม โดยจะสามารถเชื่อมโยงแบบใดก็ได้โดยไม่มีขอบเขตจำกัด แต่อย่างไรก็ตามในทางปฏิบัติแล้วเทคนิคการเรียนรู้ของโครงข่ายประสาทเทียมมักจะถูกออกแบบมาให้ใช้งานได้กับสถาปัตยกรรมโครงข่ายประสาทเทียมที่มีลักษณะเฉพาะเท่านั้น ซึ่งสถาปัตยกรรมโครงข่ายประสาทเทียมที่พบทั่วไปจะมีลักษณะหลักๆ คือ มีการจัดเซลล์ประสาทเทียมเป็นชั้นๆ (Layer) ชั้นที่รับข้อมูลเข้าเรียกว่า ชั้นอินพุท (Input layer) ชั้นที่ผลิตผลคำตอบของโครงข่าย เรียกว่า ชั้นเอาต์พุท (Output layer) ส่วนชั้นที่มีส่วนในการช่วยทำการประมวลผลอยู่ภายในเรียกว่า ชั้นกลาง (Middle layer) หรือชั้นซ่อน (Hidden layer) ในโครงข่ายประสาทเทียมอาจมีได้หลายชั้น โดยสถาปัตยกรรมของโครงข่ายประสาทเทียมโดยทั่วไปจะแสดงได้ดังรูปที่ 2.14



รูปที่ 2.14 สถาปัตยกรรมของโครงข่ายประสาทเทียมโดยทั่วไป

สำหรับพื้นฐานการคำนวณของเซลล์ประสาทแต่ละเซลล์จะแสดงแผนภาพได้ดังรูปที่ 2.15

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.15 แผนภาพของเซลล์ประสาท

ตามแบบจำลองที่นำเสนอโดยแม็คคัลลอค (McCulloch) และพิตส์ (Pitts) ซึ่งถือเป็นแบบจำลองของเซลล์ประสาทยุคแรกในปี 1943 โดยมีหลักการง่ายในการรวมอินพุตพร้อมทั้งค่าน้ำหนักประสาท แล้วนำไปเปรียบเทียบกับค่าระดับอ้างอิง (Thresholding) ซึ่งถ้าผลรวมมีค่ามากกว่าค่าระดับอ้างอิง เอาท์พุทของนิวรอนจะให้ค่าเป็น 1 ถ้าผลรวมมีค่าไม่ถึงค่าระดับอ้างอิง เอาท์พุทของนิวรอนจะมีค่า 0 ในการนำเสนอได้มีการแสดงถึงความสามารถในการคำนวณทางคณิตศาสตร์ได้ดังนี้

$$X = \sum_{i=1}^n x_i w_i \quad (2.14)$$

โดยจะเรียก X ว่าค่าน้ำหนักสุทธิของอินพุตในนิวรอน

จากนั้นพิจารณาต่อดังนี้ (ซึ่งถือเป็นฟังก์ชันถ่ายโอน (Transfer function) หรือที่นิยมเรียกว่า “Activation function”)

$$Y = \begin{cases} +1 & \text{if } X \geq \theta \\ -1 & \text{if } X < \theta \end{cases} \quad (2.15)$$


โดย θ เรียกว่าค่าระดับอ้างอิง (Threshold) และ Y คือเอาท์พุทที่ได้จากนิวรอน

ซึ่ง “Activation function” ดังกล่าวนี้นี้จะเรียกว่าฟังก์ชันซิกนัม (Sigmoid function) หรือ Sign function ดังนั้นจะสามารถแสดงเอาท์พุทที่แท้จริงของเซลล์ประสาทที่ใช้ “Sign activation function” ได้ดังนี้

$$Y = \text{sign} \left[\sum_{i=1}^n x_i w_i - \theta \right] \quad (2.16)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Activation Function ที่นิยมใช้แสดงดังนี้



รูปที่ 2.16 Activation Functions ของเซลล์ประสาท

ต่อมาในช่วงปี 1958 แฟรงค์ โรเซนแบลทต์ (Frank Rosenblatt) ได้นำเสนออัลกอริทึมที่มีการเรียนรู้ โดยเป็นวิธีการเรียนรู้ที่ง่ายสำหรับโครงข่ายประสาทเทียมที่เรียกว่าเพอร์เซ็ปตรอน (Perceptron) ซึ่งมีโครงสร้างที่คล้ายคลึงกับแบบจำลองแมคคัลลอค (McCulloch) และพิตส์ (Pitts) ในการนำไปประยุกต์ใช้กับการแก้ปัญหาทางด้านการจดจำรูปแบบ (Pattern recognition) นอกจากนี้โรเซนแบลทต์ได้พิสูจน์ว่ากฎการเรียนรู้ที่ได้นำเสนอนั้นจะลู่เข้าสู่ค่าน้ำหนักประสาทของโครงข่ายได้อย่างถูกต้องเสมอ (นั่นคือสามารถฝึกสอนโครงข่ายจนกระทั่งเรียนรู้และใช้งานได้) การเรียนรู้ของโครงข่ายไม่มีความซับซ้อนและเป็นไปอย่างอัตโนมัติ นอกจากนั้นยังได้แสดงถึงตัวอย่างพฤติกรรมของระบบของโครงข่าย ที่สามารถเรียนรู้จากข้อผิดพลาดของตัวเองได้ โดยจะสามารถแบ่งออกเป็นโครงข่ายประสาทเทียมแบบหนึ่งหน่วย (Single-layer perceptron) และโครงข่ายประสาทเทียมแบบหลายชั้น (Multi-layer perceptron)

ขั้นตอนสำหรับการเรียนรู้ของโครงข่ายประสาทเทียมแบบหนึ่งหน่วย (Single-layer perceptron)

Step 1: Initialization

กำหนดค่าน้ำหนักเริ่มต้น (Weight initial) w_1, w_2, \dots, w_n และค่าระดับอ้างอิง (Threshold) θ ให้มีค่าแบบสุ่ม (Random) ในช่วง $[-0.5, 0.5]$

Step 2: Activation

ทำการเริ่มกระบวนการทำงานโดยการนำข้อมูลอินพุต $x_1(p), x_2(p), \dots, x_n(p)$ และเอาต์พุตเป้าหมาย (Desired output) $Y_d(p)$ มาทำการคำนวณหาค่าเอาต์พุตจริง (Actual output) ที่รอบ $p = 1$ โดยใช้สมการดังนี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$Y(p) = \text{step} \left[\sum_{i=1}^n x_i(p) w_i(p) - \theta \right] \quad (2.17)$$

โดย n คือจำนวนของอินพุตและ “Step” หมายถึงให้ใช้ Step activation function

Step 3: Weight Training

ทำการปรับค่าน้ำหนักของโครงข่ายดังสมการ

$$w_i(p+1) = w_i(p) + \Delta w_i(p) \quad (2.18)$$

โดยค่า $\Delta w_i(p)$ คือค่าน้ำหนักที่จะต้องปรับที่รอบ p และสามารถที่จะหาค่าได้โดยกฎที่เรียกว่ากฎเดลต้า (Delta rule) ดังนี้

$$\Delta w_i(p) = \alpha \times x_i(p) \times e(p) \quad (2.19)$$

ซึ่ง α เรียกว่าอัตราการเรียนรู้ (Learning rate) และจะมีค่าเป็นค่าคงที่ที่เป็นค่าบวกและมีขนาดน้อยกว่า 1 ส่วน $e(p)$ ซึ่งจะเรียกว่าเป็นค่าความผิดพลาด (Error signal) สามารถหาค่าได้ดังนี้

$$e(p) = Y_d(p) - Y(p) \quad (2.20)$$


โดย $Y_d(p)$ คือเอาต์พุตเป้าหมาย (Desired output) และ $Y(p)$ คือเอาต์พุตจริง (Actual output)

Step 4: Iteration

ทำการเพิ่มจำนวนรอบ p ไปอีก 1 จากนั้นกลับไปทำในขั้นตอนที่ 2 และทำกระบวนการทั้งหมดซ้ำจนกระทั่งระบบเข้าสู่สภาวะลู่เข้า (Convergence)

สำหรับโครงข่ายประสาทเทียมแบบหลายชั้น (Multi-layer perceptron) โดยจะอธิบายถึงวิธีการเรียนรู้แบบแพร่ย้อนกลับ (Back propagation) ซึ่งกระบวนการเรียนรู้จะมีทั้งแบบป้อนข้อมูลไปข้างหน้า (Feedforward pass) และแบบป้อนข้อมูลย้อนกลับ (Backward pass) สามารถแสดงโครงสร้างได้ดังรูปที่ 2.17

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.17 โครงสร้างของการเรียนรู้แบบแพร่ย้อนกลับ (Back propagation)

ขั้นตอนสำหรับการเรียนรู้ของโครงข่ายประสาทเทียมแบบหลายชั้น (Multi-layer perceptron) สำหรับวิธีการเรียนรู้แบบแพร่ย้อนกลับ (Back propagation)

Step1: Initialization

กำหนดค่าน้ำหนักเริ่มต้น (Weight initial) w_1, w_2, \dots, w_n และค่าระดับอ้างอิง (Threshold) θ ให้มีค่าแบบสุ่ม (Random) ให้อยู่ในช่วง

$$\left(-\frac{2.4}{F_i}, +\frac{2.4}{F_i} \right) \quad (2.21)$$

โดย F_i คือจำนวนอินพุตทั้งหมดในโครงข่าย

Step2: Activation

ในการเริ่มกระบวนการทำงานของวิธีการแพร่ย้อนกลับของโครงข่ายจะเริ่มจากการนำข้อมูลอินพุตและเอาต์พุตเป้าหมาย (Desired outputs) $y_{d,1}(p), y_{d,2}(p), \dots, y_{d,l}(p)$ มาคำนวณเพื่อหาเอาต์พุตที่แท้จริง (Actual output) ของนิวรอนในชั้นซ่อน (Hidden layer) ดังนี้

$$y_j(p) = \text{sigmoid} \left[\sum_{i=1}^n x_i(p) \times w_{ij}(p) - \theta_j \right] \quad (2.22)$$

โดย n คือจำนวนอินพุตของนิวรอน j ในชั้นซ่อน

จากนั้นคำนวณหาเอาต์พุตที่แท้จริง (Actual output) ของนิวรอนในชั้นซ่อน ดังนี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$y_k(p) = \text{sigmoid} \left[\sum_{j=1}^m x_{jk}(p) \times w_{jk}(p) - \theta_k \right] \quad (2.23)$$

โดย m คือจำนวนอินพุตของนิวรอน k ในชั้นเอาต์พุต (Output layer)

Step3: Weight Training

ทำการปรับค่าน้ำหนักในกระบวนการแพร่ย้อนกลับของโครงข่ายป้อนข้อมูลย้อนกลับ (Backward pass) โดยจะพิจารณาค่าความผิดพลาดร่วมกับนิวรอนเอาต์พุต

(1) เริ่มจากคำนวณค่าความผิดพลาดเกรเดียนต์สำหรับนิวรอนในชั้นเอาต์พุต (Output layer)

$$\delta_k(p) = y_k(p) \times [1 - y_k(p)] \times e_k(p) \quad (2.24)$$

โดย $\delta_k(p)$ คือ ค่าความผิดพลาดเกรเดียนต์สำหรับนิวรอน k

$y_k(p)$ คือ เอาต์พุตของนิวรอน k ที่รอบ p

และ $e_k(p) = y_{d,k}(p) - y_k(p)$

จากนั้นคำนวณหาค่าน้ำหนักที่จะต้องทำการปรับค่าน้ำหนักดังนี้

$$\Delta w_{jk}(p) = \alpha \times y_j(p) \times \delta_k(p) \quad (2.25)$$

และทำการปรับค่าน้ำหนักที่นิวรอนเอาต์พุตดังนี้

$$w_{jk}(p+1) = w_{jk}(p) + \Delta w_{jk}(p) \quad (2.26)$$

(2) คำนวณหาค่าความผิดพลาดเกรเดียนต์สำหรับนิวรอนในชั้นซ่อน (Hidden layer)

$$\delta_j(p) = y_j(p) \times [1 - y_j(p)] \times \sum_{k=1}^l \delta_k(p) \times w_{jk}(p) \quad (2.27)$$

โดย $\delta_j(p)$ คือ ค่าความผิดพลาดเกรเดียนต์สำหรับนิวรอน j

$y_j(p)$ คือ เอาต์พุตของนิวรอน j ที่รอบ p

จากนั้นคำนวณหาค่าน้ำหนักที่จะต้องทำการปรับค่าน้ำหนักดังนี้

$$\Delta w_{ij}(p) = \alpha \times x_i(p) \times \delta_j(p) \quad (2.28)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

และทำการปรับค่าน้ำหนักที่นิวรอนชั้นซ่อนดังนี้

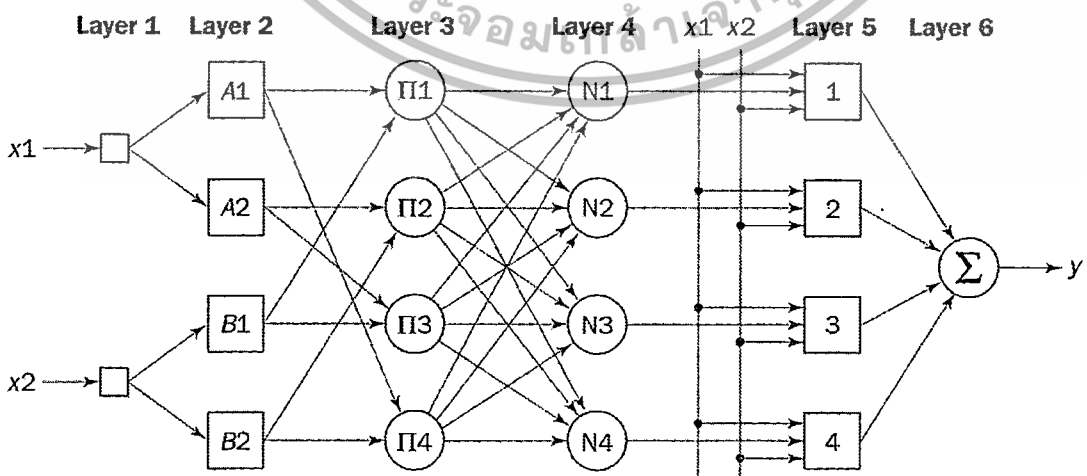
$$w_{ij}(p+1) = w_{ij}(p) + \Delta w_{ij}(p) \quad (2.29)$$

Step4 : Iteration

ทำการเพิ่มจำนวนรอบ p ไปอีก 1 จากนั้นกลับไปทำในขั้นตอนที่ 2 และทำกระบวนการทั้งหมดซ้ำจนกระทั่งค่าความผิดพลาดถึงเกณฑ์ที่กำหนดไว้

2.6 ระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (Adaptive Neuro Fuzzy Inference System: ANFIS)

ระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (Adaptive Neuro Fuzzy Inference System: ANFIS) เป็นเทคนิคทางปัญญาประดิษฐ์ (Artificial Intelligence: AI) รูปแบบหนึ่ง ซึ่งเป็นรูปแบบการทำงานร่วมกันของระบบอนุมานตรรกะคลุมเครือ (Fuzzy Inference System: FIS) และโครงข่ายประสาทเทียม (Artificial Neural Network) โดยที่การทำงานเพียงอย่างเดียวของตรรกะคลุมเครือหรือโครงข่ายประสาทเทียมนั้นจะไม่สามารถแก้ไขปัญหาเฉพาะบางอย่างได้อย่างเช่นโครงข่ายประสาทเทียมจะมีคุณสมบัติในการเรียนรู้ (Learning) ที่ไม่สามารถอธิบายถึงการได้มาของสิ่งที่ตัดสินใจได้ ในขณะที่ตรรกะคลุมเครือสามารถให้เหตุผลที่เลียนแบบการตัดสินใจของมนุษย์ ซึ่งเป็นการเรียนรู้ที่ได้จากข้อมูลและมีคุณสมบัติของการใช้งานเพื่ออธิบายการตัดสินใจด้วยกฎของตรรกะคลุมเครือ แต่ระบบของตรรกะคลุมเครือเองก็ไม่มีความสามารถในการเรียนรู้กฎโดยอัตโนมัติจากข้อมูลคือไม่สามารถปรับตัวได้เมื่อลักษณะของข้อมูลมีการเปลี่ยนแปลง จะเห็นได้ว่ามีข้อจำกัดเกิดขึ้นในระบบอนุมานตรรกะคลุมเครือและโครงข่ายประสาทเทียม ทำให้มีผู้คิดค้น [13] นำเทคนิคกระบวนการทางด้านปัญญาประดิษฐ์มาใช้งานร่วมกัน กลายเป็นระบบประสานอัจฉริยะ (Hybrid Intelligent System: HIS) นั่นก็คือระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ หรือ ANFIS หลักการทำงานของระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ มีโครงสร้างแสดงได้ดังรูปที่ 2.18



รูปที่ 2.18 สถาปัตยกรรมของระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 2.18 แสดงโครงสร้างของระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ หรือ ANFIS ซึ่งกำหนดให้มี 2 อินพุท โดยแต่ละอินพุทแบ่งออกเป็นฟัซซีเซตได้คือ สำหรับอินพุทที่ 1 แบ่งฟัซซีเซตออกเป็น A_1 และ A_2 ส่วนอินพุทที่ 2 แบ่งฟัซซีเซตออกเป็น B_1 และ B_2 ซึ่งโครงสร้างของระบบอนุมานตรรกะคลุมเครือดังกล่าวถูกออกแบบมาบนพื้นฐานของ Sugeno Fuzzy Model โดยมีการกำหนดกฎ (Rules) ขึ้นมาในรูปแบบ ดังนี้

If x_1 is A_1
 And x_2 is A_2
 ...
 And x_m is A_m
 Then $y = f(x_1, x_2, \dots, x_m)$

โดย x_1, x_2, \dots, x_m เป็นตัวแปรอินพุท และ A_1, A_2, \dots, A_m เป็นฟัซซีเซต

ถ้าฟังก์ชัน y เป็นค่าคงที่ จะเรียกรูปแบบระบบว่าเป็น “zero-order Sugeno fuzzy model” แต่ถ้าฟังก์ชัน y เป็นสมการในอันดับที่ 1 (First-order) ซึ่งเป็นสมการเชิงเส้นจะเรียกว่า “First-order Sugeno fuzzy model” โดยรูปแบบมาตรฐานของระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้นำเสนอใน [14] จะเป็นรูปแบบนี้คือ

$$y = k_0 + k_1x_1 + k_2x_2 + \dots + k_mx_m \quad (2.30)$$

และสามารถแบ่งโครงสร้างออกได้เป็น 6 เลเยอร์ ตามรูปแบบของโครงข่ายประสาทเทียมแบบป้อนข้อมูลไปข้างหน้า (Feed-forward neural network) ดังที่จะอธิบายตามตัวอย่างต่อไปนี้

สมมติรูปแบบระบบของระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ที่ประกอบด้วย 2 อินพุท คือ x_1 และ x_2 ซึ่งแต่ละอินพุทประกอบด้วย 2 ฟัซซีเซตและมี 1 เอาท์พุท คือ y ด้วยเหตุนี้ในการสร้างระบบจะประกอบไปด้วยกฎจำนวนทั้งสิ้น 4 กฎ ดังนี้

กฎที่ 1:

If x_1 is A_1
 And x_2 is B_1
 Then $y = f_1 = k_{10} + k_{11}x_1 + k_{12}x_2$

กฎที่ 3:

If x_1 is A_2
 And x_2 is B_1
 Then $y = f_3 = k_{30} + k_{31}x_1 + k_{32}x_2$

กฎที่ 2:

If x_1 is A_2
 And x_2 is B_2
 Then $y = f_2 = k_{20} + k_{21}x_1 + k_{22}x_2$

กฎที่ 4:

If x_1 is A_1
 And x_2 is B_2
 Then $y = f_4 = k_{40} + k_{41}x_1 + k_{42}x_2$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดย k_{i0}, k_{i1} , และ k_{i2} เป็นผลลัพธ์ของพารามิเตอร์สำหรับกฎข้อที่ i (Consequent parameters of rule i)

ซึ่งการทำงานในแต่ละเลเยอร์แสดงได้ดังนี้

(1) Layer 1: Input Layer

เป็นการดำเนินการของข้อมูลอินพุตภายนอกที่เข้ามาเพื่อผ่านไปยังเลเยอร์ 2 ดังสมการที่ 2.31

$$y_i^{(1)} = x_i \quad (2.31)$$

โดย i เป็น Index ของนิเวรอนที่ i

(2) Layer 2: Fuzzification Layer

เป็นชั้นพารามิเตอร์ของการแบ่งฟัซซีเซต (Fuzzy set) สำหรับข้อมูลอินพุตที่ถูกป้อนให้กับระบบ โดยเป็นการหาค่าฟัซซี (Fuzzification) จากข้อมูลอินพุต (x) ผ่านทางฟังก์ชันความเป็นสมาชิก $\mu_{A_i}(x)$ ดังสมการที่ 2.32

$$y_i^{(2)} = \mu_{A_i}(y_i^{(1)}) \quad (2.32)$$

เมื่อ $y_i^{(2)}$ เป็นฟังก์ชันสมาชิกของ A_i โดยฟังก์ชันความเป็นสมาชิก $\mu_{A_i}(x)$ ใน Jang's model นำเสนอไว้โดยจะใช้ฟังก์ชันระฆังคว่ำหรือที่เรียกว่า "Bell activation function" ซึ่งกำหนดได้ดังสมการต่อไปนี้

$$y_i^{(2)} = \frac{1}{1 + \left(\frac{y_i^{(1)} - a_i}{c_i} \right)^{2b_i}} \quad (2.33)$$

โดย a_i, b_i , และ c_i เป็นพารามิเตอร์ที่ใช้ควบคุมจุดกึ่งกลาง (Center) ความกว้าง (Width) และความชัน (Slope) ของฟังก์ชันระฆังคว่ำตามลำดับ

(3) Layer 3: Rule Layer

ทำหน้าที่คำนวณหาค่าความจริงหรือที่เรียกว่า Firing strength ของกฎในแต่ละนิเวรอนโดยพื้นฐานผลลัพธ์ที่ได้จากชั้นนี้จะเกิดจากตัวดำเนินการทางคณิตศาสตร์ (Operator) "Product" แสดงได้ดังนี้

$$y_i^{(3)} = \prod_{j=1}^m x_{ji}^{(3)} \quad (2.34)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ยกตัวอย่างเช่นการหาค่าของเอาต์พุตของชั้น Rule layer สำหรับกฎในนิวรอนที่ 1 (Π_1) จะได้ว่า

$$y_1^{(3)} = y_1^{(2)} \times y_3^{(2)} = \mu_1 \quad (2.35)$$

โดย μ_1 เรียกว่า Firing strength หรือค่าความจริง (Truth value) ของกฎข้อที่ 1

(4) Layer 4: Normalization Layer

ในเลเยอร์นี้จะทำหน้าที่รับข้อมูลอินพุตจากนิวรอนทั้งหมดใน Rule layer จากนั้นทำการคำนวณหาค่านอมอลไลซ์ค่า Firing strength

$$y_i^{(4)} = \frac{\mu_i}{\sum_{j=1}^n \mu_j} = \bar{\mu}_i \quad (2.36)$$

ยกตัวอย่างเช่น

$$y_1^{(4)} = \frac{\mu_1}{\mu_1 + \mu_2 + \mu_3 + \mu_4} = \bar{\mu}_1 \quad (2.37)$$

(5) Layer 5: Defuzzification Layer

ทำหน้าที่คำนวณผลลัพธ์ของค่าน้ำหนัก (Weighted consequent value) ของกฎข้อที่กำหนด โดยมีการนำค่าอินพุต x_1, x_2 มาใช้ในการคำนวณร่วมด้วย

$$y_i^{(5)} = \bar{\mu}_i \left[k_{i0} + \sum_{j=1}^m k_{ij} x_j \right] \quad (2.38)$$

(6) Layer 6: Summation Neuron

เป็นการรวมเอาต์พุตทั้งหมดที่ได้จากนิวรอนใน Defuzzification Layer เพื่อสร้างเอาต์พุตทั้งหมดของระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ y

$$y = \sum_{i=1}^{2m} y_i^{(5)} \quad (2.39)$$

สำหรับระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้จะเรียนรู้เพื่อกำหนดกฎ (คือการปรับค่า k ต่างๆ) และทำการปรับค่าฟังก์ชันสมาชิก (Membership function) ซึ่งกลไกการเรียนรู้ของระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (ANFIS Training Algorithm) จะใช้การเรียนรู้ของอัลกอริทึมแบบผสม (Hybrid Learning Algorithm) ที่ประกอบด้วยการประมาณเอกสตรัคชันเป็นเอกสตรัคชันและขั้นตอนการปรับปรุงค่าฟังก์ชันสมาชิก เพื่อการค้นหาค่าที่เหมาะสม เมื่ออยู่ในขั้นตอนการคำนวณค่าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ค่ากำลังสองน้อยสุด (Least-squares estimator) และวิธีการหาค่าเกรเดียนต์ (Gradient descent method) มีทั้งแบบป้อนข้อมูลไปข้างหน้า (Feedforward pass) (ผลลัพธ์ของค่าน้ำหนักจะถูกกำหนดโดยใช้การประมาณค่ากำลังสองน้อยสุด) และแบบป้อนข้อมูลย้อนกลับ (Backward pass) ซึ่งในส่วนของการป้อนข้อมูลย้อนกลับได้ประยุกต์ใช้อัลกอริทึมการแพร่กระจายแบบย้อนกลับ (Back-propagation algorithm)

เนื่องจากระบบอนุมานแบบ Sugeno-style ที่ใช้นี้เอาท์พุท y เป็นฟังก์ชันเชิงเส้น (Linear function) ดังนั้นจากค่าที่กำหนดสำหรับสมาชิกของพารามิเตอร์และชุดข้อมูลที่ใช้เรียนรู้ P (Input-output pattern) จะสามารถเขียนสมการเชิงเส้นจำนวน P สมการ ในเทอมของผลลัพธ์สำหรับพารามิเตอร์ได้ดังนี้

$$f = y_i^{(s)} \quad (2.40)$$

ซึ่งสามารถเขียนให้อยู่ในรูปแบบของเมตริกซ์ได้คือ

$$\mathbf{y}_d = \mathbf{A}\mathbf{k} \quad (2.41)$$

โดย \mathbf{y}_d เป็น $P \times 1$ สำหรับเวกเตอร์ของเอาท์พุทเป้าหมาย (Desired output)

$$\mathbf{y}_d = \begin{bmatrix} y_d(1) \\ y_d(2) \\ \vdots \\ y_d(p) \\ \vdots \\ y_d(P) \end{bmatrix} \quad (2.42)$$

\mathbf{A} คือเมตริกซ์ขนาด $P \times n(1+m)$

$$\mathbf{A} = \begin{bmatrix} \bar{\mu}_1(1) & \bar{\mu}_1(1)x_1(1) & \cdots & \bar{\mu}_1(1)x_m(1) & \cdots & \bar{\mu}_n(1) & \bar{\mu}_n(1)x_n(1) & \cdots & \bar{\mu}_1(1)x_m(1) \\ \bar{\mu}_1(2) & \bar{\mu}_1(2)x_1(2) & \cdots & \bar{\mu}_1(2)x_m(2) & \cdots & \bar{\mu}_n(2) & \bar{\mu}_n(2)x_n(2) & \cdots & \bar{\mu}_1(1)x_m(1) \\ \vdots & \vdots & \cdots & \vdots & \cdots & \vdots & \vdots & \cdots & \vdots \\ \bar{\mu}_1(p) & \bar{\mu}_1(p)x_1(p) & \cdots & \bar{\mu}_1(p)x_m(p) & \cdots & \bar{\mu}_n(p) & \bar{\mu}_n(p)x_n(p) & \cdots & \bar{\mu}_1(1)x_m(1) \\ \vdots & \vdots & \cdots & \vdots & \cdots & \vdots & \vdots & \cdots & \vdots \\ \bar{\mu}_1(P) & \bar{\mu}_1(P)x_1(P) & \cdots & \bar{\mu}_1(P)x_m(P) & \cdots & \bar{\mu}_n(P) & \bar{\mu}_n(P)x_n(P) & \cdots & \bar{\mu}_1(1)x_m(1) \end{bmatrix}$$

และ \mathbf{k} คือ เวกเตอร์ขนาด $n(1+m) \times 1$ ของผลลัพธ์พารามิเตอร์ที่ไม่ทราบค่า

$$\mathbf{k} = [k_{10} \ k_{11} \ k_{12} \ \dots \ k_{1m} \ k_{20} \ k_{21} \ k_{22} \ \dots \ k_{2m} \ \dots \ k_{n0} \ k_{n1} \ k_{n2} \ \dots \ k_{nm}]^T \quad (2.43)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดยปกติแล้วถ้าจำนวนชุดสมการ P ในกระบวนการเรียนรู้มีมากกว่าจำนวนผลลัพธ์ของพารามิเตอร์ $n(1+m)$ ทำให้ระบบสมการเกิดกรณีของจำนวนสมการมากกว่าจำนวนตัวไม่ทราบค่า (Over-determined problem) สามารถแก้ปัญหาโดยใช้วิธีซูโดอินเวอร์ส (Pseudo-inverse technique) ดังสมการที่ 2.34

$$\mathbf{k}^* = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{y}_d \quad (2.44)$$

เมื่อผลลัพธ์ของกฎได้ถูกสร้างขึ้นจะสามารถคำนวณเวกเตอร์ผลลัพธ์ \mathbf{y} และกำหนดเวกเตอร์ความผิดพลาด e ได้คือ

$$e = y_d - y \quad (2.45)$$

สำหรับอัลกอริธึมการแพร่กระจายแบบย้อนกลับ (Back-propagation algorithm) จะถูกนำมาใช้ในกระบวนการป้อนข้อมูลย้อนกลับ (Backward pass) และพารามิเตอร์ก่อนหน้าจะถูกอัปเดตโดยกฎลูกโซ่ (Chain rule)

เมื่อมีการอัปเดตค่าน้ำหนักเพื่อหาค่าคงที่ที่พิจารณาสำหรับแก้ไขพารามิเตอร์ a ของ Bell activation function ในนิวรอน A_i จะได้กฎลูกโซ่ดังนี้

$$\Delta a = -\alpha \frac{\partial E}{\partial a} = -\alpha \frac{\partial E}{\partial a} \times \frac{\partial e}{\partial y} \times \frac{\partial y}{\partial (\mu_i f_i)} \times \frac{\partial (\mu_i f_i)}{\partial \bar{\mu}_i} \times \frac{\partial \bar{\mu}_i}{\partial \mu_i} \times \frac{\partial \mu_i}{\partial \mu_{A1}} \times \frac{\partial \mu_{A1}}{\partial a} \quad (2.46)$$

ซึ่ง α คือ อัตราการเรียนรู้ (Learning rate) และ E คือค่าความผิดพลาดสำหรับเอาท์พุทของระบบอนุกรมตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้

$$E = \frac{1}{2} e^2 = \frac{1}{2} (y_d - y)^2 \quad (2.47)$$

ดังนั้นจะได้

$$\Delta a = -\alpha (y_d - y) (-1) f_i \times \frac{\bar{\mu}_i (1 - \bar{\mu}_i)}{\mu_i} \times \frac{\mu_i}{\mu_{A1}} \times \frac{\partial \mu_{A1}}{\partial a} \quad (2.48)$$

หรือ

$$\Delta a = \alpha (y_d - y) f_i \bar{\mu}_i (1 - \bar{\mu}_i) \times \frac{1}{\mu_{A1}} \times \frac{\partial \mu_{A1}}{\partial a} \quad (2.49)$$

ซึ่งเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$\frac{\partial \mu_{A1}}{\partial a} = -\frac{1}{\left[1 + \left(\frac{x1-a}{c}\right)^{2b}\right]^2} \times \frac{1}{c^{2b}} \times 2b \times (x1-a)^{2b-1} \times (-1) \quad (2.50)$$

$$= \mu_{A1}^2 \times \frac{2b}{c} \times \left(\frac{x1-a}{c}\right)^{2b-1} \quad (2.51)$$

ในส่วนของพารามิเตอร์ b และ c สามารถหาได้จากสมการที่ 2.45 ด้วยเช่นกัน



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 3

การออกแบบและการคำนวณ

ในบทนี้จะกล่าวถึงข้อมูลอินพุตที่นำมาใช้กับระบบและการออกแบบระบบที่นำเสนอซึ่งก็คือระบบตรวจจับและจำแนกอุบัติเหตุทางจราจรบนท้องถนนอย่างอัตโนมัติ โดยใช้เทคนิคทางด้านการประมวลผลสัญญาณ (Signal processing) ก็คือการแปลงเวฟเลตเต็มหน่วย (Discrete Wavelet Transform: DWT) และนำเทคนิคทางด้านปัญญาประดิษฐ์ (Artificial intelligence) มาใช้ในการตัดสินใจเพื่อให้ได้มาซึ่งคำตอบ สำหรับบ่งบอกสภาพจราจรที่ปกติ (Normal) และผิดปกติ (Abnormal) รวมถึงระบบจะสามารถจำแนกลักษณะอุบัติเหตุทางจราจรที่เกิดขึ้นได้ โดยจำแนกออกเป็น 3 แบบคือ 1 Lane blocking, 2 Lane blocking และ 3 Lane blocking ซึ่งในการแจ้งสถานะและลักษณะของสภาพจราจรบนท้องถนนจะช่วยทำให้เจ้าหน้าที่และหน่วยงานที่เกี่ยวข้องสามารถบริหารจัดการและดำเนินการขจัดปัญหาที่เกิดขึ้นได้อย่างเร็วที่สุดก่อนที่การอุบัติเหตุดังกล่าวจะนำไปสู่ปัญหาการจราจรติดขัด

3.1 ข้อมูลที่นำมาใช้กับระบบ


ในการเลือกใช้ข้อมูลอินพุตของระบบจะใช้ข้อมูลจราจร ซึ่งได้จากโปรแกรมจำลองทางด้านวิศวกรรมจราจร Aimsun [11] โดยข้อมูลที่ถูกนำมาใช้เป็นข้อมูลอินพุตให้กับระบบที่นำเสนอจะเป็นค่าความเร็วเฉลี่ย (Mean speed (ในหน่วยของ km/h)) และค่าเบี่ยงเบนมาตรฐานของเวลาในขณะที่รถยนต์กำลังเข้ามาในพื้นที่ถนนที่กำหนด (Std. inter-arrival time (ในหน่วยของ s)) โดยในหัวข้อนี้ได้กล่าวถึงการกำหนดลักษณะของสภาพจราจรและลักษณะของอุบัติเหตุที่เกิดขึ้น

3.1.1 ข้อมูลจากโปรแกรมจำลองทางด้านวิศวกรรมจราจร Aimsun

ข้อมูลอินพุตของระบบที่นำเสนอจะสามารถออกแบบได้ดังนี้


1) กำหนดลักษณะของสภาพจราจร ซึ่งงานวิจัยนี้ได้อ้างอิงจากผลงานวิจัยใน [5] โดยกำหนดให้มีความยาวของถนน 500 เมตร ลักษณะถนนเป็นทางเดินรถทางเดียวแบบฟรีเวย์ (Freeway) 3 ช่องจราจร

2) ค่าความเร็วเฉลี่ยสูงสุดหรือความเร็วอิสระ (Free flow speed) 105 km/h และมีค่ากระแสการไหลของจราจร (Traffic flow) 3,000 veh/h โดยหน้าตาการทำงานของโปรแกรมจำลองวิศวกรรมจราจร Aimsun แสดงได้ดังรูปที่ 3.1



รูปที่ 3.1 หน้าต่างการทำงานของโปรแกรมจำลองทางด้านวิศวกรรมจราจร Aimsun


3) โดยคลิกไอคอน  หมายเลข 1 ในรูปที่ 3.1 เพื่อสร้างถนนตามขนาดที่ได้กำหนดไว้ ซึ่งได้กำหนดลักษณะของถนนเป็นแบบฟรีเวย์ (Freeway) และค่าความเร็วเฉลี่ยสูงสุดหรือความเร็วอิสระ (Free flow speed) เท่ากับ 105 km/h ของถนนที่ต้องการใช้งาน โดยดับเบิลคลิกที่ถนนที่สร้างขึ้นในหมายเลข 3 จะมีหน้าต่างขึ้นดังรูปที่ 3.2




รูปที่ 3.2 หน้าต่างของการตั้งค่าลักษณะของถนน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4) คลิกขวาที่รูปถนนหมายเลข 3 ในรูปที่ 3.1 เลือก Number of lanes -> 3 จะได้จำนวนช่องจราจรของถนนตามที่ได้กำหนดไว้

5) คลิกไอคอน  หมายเลข 2 ในรูปที่ 3.1 เพื่อติดตั้งเส้นอ้างอิงรถเคลื่อนที่เข้า-ออก จากถนน โดยติดตั้ง 2 สถานีตามรูปถนนหมายเลข 3

6) คลิกหมายเลข 4 ในรูปที่ 3.1 เลือก Traffic state -> State car

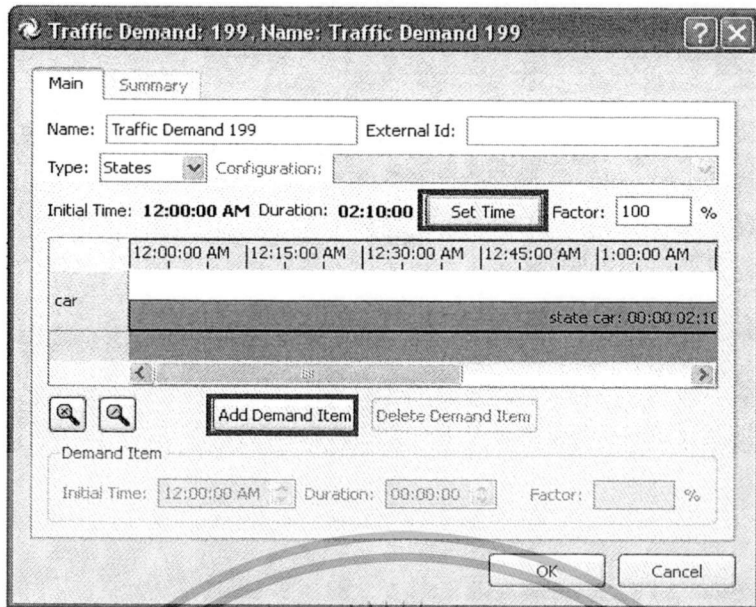


รูปที่ 3.3 หน้าต่างการทำงานของ Traffic state

จากรูปที่ 3.3 หน้าต่างการทำงานของ Traffic state โดยกำหนดชนิดของยานพาหนะจะเลือก Vehicle type: car กำหนดค่ากระแสการไหลของจราจร (Traffic flow) เท่ากับ 3,000 veh/h กำหนดช่วงเวลาของการจำลองสภาพจราจรทั้งหมด 7,800 วินาที หรือ 2 ชั่วโมง 10 นาทีและเก็บข้อมูลทุกๆ 30 วินาที ซึ่งอ้างอิงได้จากงานวิจัยใน [5]

7) คลิกหมายเลข 5 ในรูปที่ 3.1 เลือก Traffic demand -> Traffic demand 199 จะได้นหน้าต่างดังรูปที่ 3.4

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.4 หน้าต่างการทำงานของ Traffic demand

จากรูปที่ 3.4 หน้าต่างการทำงานของ Traffic demand กำหนดเวลาเริ่มต้นและช่วงเวลาทั้งหมดที่จะใช้ในการจำลองสภาพจราจร เพื่อกำหนดช่วงเวลาที่จะให้ยานพาหนะแต่ละชนิดเคลื่อนที่ตามช่วงเวลาต่างๆ


8) คลิกหมายเลข 7 ในรูปที่ 3.1 เลือก Traffic management -> Traffic condition เพื่อกำหนด เงื่อนไขของการเกิด Incident โดยกำหนดช่วงห่างของ 2 Incident ห่างกัน 12 นาที ตามตารางที่ 3.1

ตารางที่ 3.1 เงื่อนไขของการเกิดอุบัติเหตุ [5]

ครั้งที่เกิดอุบัติเหตุ	ระยะห่างจากจุดรถเข้า (m)	ระยะทางของการเกิดอุบัติเหตุ (m)	เวลาเริ่มเกิดอุบัติเหตุ (s)	ช่วงเวลาที่เกิดอุบัติเหตุ (s)
1	150	30	360	360
2	150	30	1080	360
3	150	30	1800	360
4	270	30	2520	360
5	270	30	3240	360
6	270	30	3960	360
7	270	30	4680	360
8	340	30	5400	360
9	340	30	6120	360
10	340	30	6840	360

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

9) คลิกหมายเลข 6 ในรูปที่ 3.1 เลือก Scenarios -> Dynamic scenario 201 เพื่อทำการจำลองสภาพจราจร และบันทึกข้อมูลลงฐานข้อมูล Microsoft Access ดังรูปที่ 3.5




รูปที่ 3.5 หน้าต่างการบันทึกข้อมูลลงฐานข้อมูล Microsoft Access

จากรูปที่ 3.5 แสดงหน้าต่างในการเลือกเก็บข้อมูลในฐานข้อมูล โดยเลือกบันทึกข้อมูลจราจรที่ได้จากโปรแกรมจำลองวิศวกรรมจราจร Aimsun ด้วยโปรแกรม Microsoft Access จะแสดงได้ดังรูปที่ 3.6

rid	tfrom	to	ctype	Flow	density	spd1	spd2	hspd1	hspd2	ttc
214	0	30	0	3240	11.0925689467208	104.043049226756	6.14434453201294	103.691375732422	6.081147954940796	34.71
214	30	60	0	3480	11.4818525814331	104.733540942383	5.83092534146729	104.423049326750	5.69679737091064	34.47
214	60	90	0	3000	10.1820201873779	100.967350463867	6.13039583928223	100.610679626465	6.15607309341431	35.78
214	90	120	0	3000	9.66542053222656	106.969627380371	6.77433415603618	106.558364686164	6.61995887756348	33.78
214	120	150	0	3960	11.8434725952148	101.594367980957	8.57008647918701	100.88179779527	8.47853660583496	35.68
214	150	180	0	2830	9.04883289337158	105.121655833789	7.38923740326963	104.688507080078	7.18517589569092	34.38
214	180	210	0	2400	6.91577482223511	110.681251525379	7.20299100875834	110.233299255371	7.02701044082642	32.65
214	210	240	0	2400	8.38225269317627	104.837415161133	5.57763814926147	104.614189147949	5.44331741333008	34.41
214	240	270	0	3120	10.8985948526222	102.746406555176	8.06781768798228	102.129035949707	7.94045114517212	35.24
214	270	300	0	3000	8.59829125823975	106.257751464844	7.92191505432129	105.670951643262	7.87450265884399	34.06
214	300	330	0	2040	6.81578779220581	102.151710516254	6.55059003239956	101.753807067871	6.36306762695313	35.37
214	330	360	0	2400	7.16574287414551	104.091939697266	6.42574644088745	103.710395812938	6.20746326445533	34.7
214	360	390	0	1200	9.71541404724121	96.4965209960938	19.0376224517822	93.0227432250977	17.9760875701904	38.70
214	390	420	0	1920	21.5305576324463	61.9063110351563	12.1957302093506	59.5120887756348	11.9367151260376	60.49
214	420	450	0	2040	27.9463958740234	40.3751525878906	4.20613581771831	39.9519157409663	4.11206007003784	90.10
214	450	480	0	2160	37.3951797489352	31.8810424804688	2.13240497016907	31.74355101013184	2.07426309585571	113.4
214	480	510	0	2040	43.92766935251465	27.1630821223027	1.83223378658235	27.0474510192271	1.76848411560059	133.0
214	510	540	0	2040	49.5102844238281	22.8801136016046	1.42798662185669	22.7931976318359	1.4075179079437	157.9
214	540	570	0	2160	48.6103973388672	19.3591971588135	1.53476428955996	19.4733963012695	1.50166773795682	184.8
214	570	600	0	2040	49.1769943237305	17.4258480072021	1.68931186199198	17.2660304443359	1.6570230224274	208.4
214	600	630	0	2040	49.5269470214844	15.7276840209961	1.41782235703883	15.6047811506179	1.3848739662442	230.6

รูปที่ 3.6 ข้อมูลที่ถูกบันทึกลงฐานข้อมูล Microsoft Access

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.8 ลักษณะข้อมูลชุดเรียนรู้ที่นำมาใช้กับระบบสำหรับอุบัติเหตุการแบบ 1 Lane blocking

3.1.2 การกำหนดลักษณะของอุบัติเหตุการที่เกิดขึ้น

ลักษณะของอุบัติเหตุการที่เกิดขึ้นสามารถสร้างได้จากโปรแกรมจำลองทางด้านวิศวกรรมจราจร Aimsun โดยทางผู้วิจัยได้กำหนดลักษณะของอุบัติเหตุการได้ 3 รูปแบบ คือ

3.1.2.1 แบบ 1 Lane blocking

ลักษณะอุบัติเหตุการแบบ 1 Lane blocking จะเกิดขึ้นใน 1 ช่องจราจร ดังรูปที่ 3.9




รูปที่ 3.9 สภาพจราจรแบบ 1 lane-blocking

จากรูปที่ 3.9 แสดงลักษณะสภาพจราจรแบบ 1 Lane blocking ซึ่งกรณีในการเกิดอุบัติเหตุการ เช่น อุบัติเหตุทางถนน หรือมีการข่มทางเกิดขึ้น เป็นต้น โดยมีการปิดถนน 1 ช่องจราจร ซึ่งในการจำลองสภาพจราจรก็ได้มีการจำลองโดยปิดช่องจราจรทั้งช่องซ้าย ช่องกลาง และช่องขวา แต่ลักษณะอุบัติเหตุการแบบ 1 Lane blocking นี้ไม่ว่าจะมีการปิดช่องทางจราจรที่ช่องทางใด ยานพาหนะที่เคลื่อนที่เข้ามาจะมีช่องทางในการหลบหลีกได้ 2 ช่องทางจราจร ทำให้ลักษณะข้อมูลที่ได้จะมีความผันผวนของข้อมูลอยู่มาก

3.1.2.2 แบบ 2 Lane blocking

ลักษณะอุบัติเหตุการแบบ 2 Lane blocking จะเกิดขึ้นใน 2 ช่องจราจร ดังรูปที่ 3.10



รูปที่ 3.10 สภาพจราจรแบบ 2 lane-blocking

จากรูปที่ 3.10 แสดงลักษณะสภาพจราจรแบบ 2 Lane blocking ซึ่งกรณีในการเกิดอุบัติเหตุการ เช่น อุบัติเหตุทางถนน หรือมีการข่มทางเกิดขึ้น เป็นต้น โดยมีการปิดถนน 2 ช่องจราจร แม้ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ซึ่งในการจำลองสภาพจราจรก็ได้มีการจำลองโดยปิดช่องจราจรทั้ง 2 ช่องทางจราจรชิดซ้ายและ 2 ช่องทางจราจรชิดขวา ทำให้ยานพาหนะที่เคลื่อนที่เข้ามาจะมีช่องทางในการหลบหลีกได้เพียง 1 ช่องทางจราจร ทำให้ลักษณะข้อมูลที่ได้ทั้งค่าความเร็วเฉลี่ย (Mean speed) ของยานพาหนะลดลงอย่างเห็นได้ชัดและค่าเบี่ยงเบนมาตรฐานของเวลาระหว่างการเข้าถึง (Standard deviation of inter-arrival time) ก็เพิ่มขึ้นอย่างเห็นได้ชัดด้วยเช่นกันและลักษณะของข้อมูลก็ยังมีควมผันผวนอยู่บ้าง เพราะยังมียานพาหนะเคลื่อนที่ผ่านช่องจราจรที่ไม่ได้ถูกปิดกั้นไปได้บ้าง

3.1.2.3 แบบ 3 Lane blocking

ลักษณะอุบัติเหตุแบบ 3 Lane blocking จะเกิดขึ้นใน 3 ช่องจราจร ดังรูปที่ 3.11



รูปที่ 3.11 สภาพจราจรแบบ 3 lane-blocking

จากรูปที่ 3.11 แสดงลักษณะสภาพจราจรแบบ 3 Lane blocking ซึ่งกรณีในการเกิดอุบัติเหตุ เช่น อุบัติเหตุทางถนน ปิดถนนเพื่อรอขบวนเสด็จ เป็นต้น โดยมีการปิดถนนทั้ง 3 ช่องจราจร ซึ่งในการจำลองสภาพจราจรก็ได้มีการจำลองโดยปิดช่องจราจรทั้ง 3 ช่องทางจราจรชิด ทำให้ยานพาหนะที่เคลื่อนที่เข้ามาจะไม่มีช่องทางในการหลบหลีกได้ ทำให้ลักษณะข้อมูลที่ได้ทั้งค่าความเร็วเฉลี่ย (Mean speed) ของยานพาหนะลดลงอย่างเห็นได้ชัดและค่าเบี่ยงเบนมาตรฐานของเวลาระหว่างการเข้าถึง (Standard deviation of inter-arrival time) ก็เพิ่มขึ้นอย่างเห็นได้ชัดด้วยเช่นกัน จนยานพาหนะที่เคลื่อนที่เข้ามายังบริเวณที่เกิดอุบัติเหตุหยุดนิ่ง


3.2 หลักการออกแบบและหลักการทำงานโดยรวมของระบบที่นำเสนอ

สำหรับหัวข้อที่ 3.1 ได้อธิบายถึงที่มาของข้อมูลจราจรที่นำมาใช้เป็นข้อมูลอินพุตให้กับระบบ ซึ่งในหัวข้อนี้จะนำเสนอหลักการออกแบบระบบตรวจจับและจำแนกอุบัติเหตุทางจราจรแบบอัตโนมัติที่นำเสนอในงานวิจัยนี้

3.2.1 ระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้ระบบอนุมานตรรกะคลุมเครือ

สำหรับหัวข้อนี้จะอธิบายวิธีการออกแบบปัญญาประดิษฐ์ที่ถูกเลือกใช้ให้เป็นกลไกหลักของระบบเพื่อช่วยในการตัดสินใจ ซึ่งจะกล่าวถึงงานที่นำเสนอก่อนหน้านี้ใน [6-7] โดยกลไกหลักที่เลือกใช้คือระบบอนุมานตรรกะคลุมเครือ (Fuzzy Inference System: FIS) หรือที่เรียกกันว่าฟัซซีลอจิก (Fuzzy logic) สำหรับระบบอนุมานตรรกะคลุมเครือจะเป็นเครื่องมือที่ช่วยในการตัดสินใจภายใต้ความไม่แน่นอนของข้อมูลและใช้หลักเหตุผลที่คล้ายการเลียนแบบวิถีความคิดที่ซับซ้อนของมนุษย์ เนื่องจากข้อมูลจราจรมีความผันผวนของข้อมูลอยู่มาก ทำให้ข้อมูลมีลักษณะไม่แน่นอนจึงยากต่อการตัดสินใจและระบบที่นำเสนอนั้นต้องการบ่งบอกสภาพจราจรว่าปกติหรือผิดปกติหรือไม่ โดยจะสามารถแสดงผลของระบบได้ดังรูปที่ 3.12

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

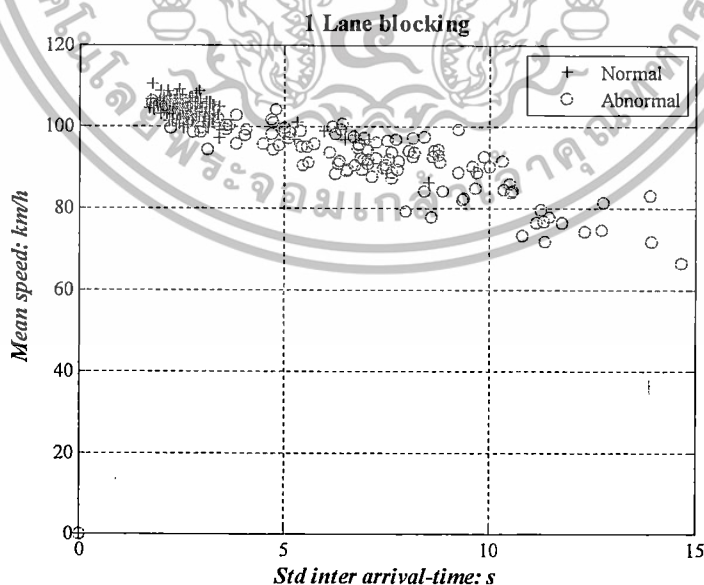


รูปที่ 3.12 ระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้ระบบอนุมานตรรกะคลุมเครือ

จากรูปที่ 3.12 แสดงระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้ระบบอนุมานตรรกะคลุมเครือมาใช้เป็นกลไกหลักในการตัดสินใจเพื่อให้ได้มาซึ่งคำตอบ เพื่อบ่งบอกสภาพจราจรที่ปกติ/ผิดปกติ ทำให้ระบบอนุมานตรรกะคลุมเครือเป็นตัวช่วยในการตัดสินใจที่ดี แต่เนื่องจากระบบอนุมานตรรกะคลุมเครือไม่สามารถเรียนรู้จากข้อมูลได้จึงจำเป็นต้องใช้ผู้เชี่ยวชาญในการกำหนดค่าพารามิเตอร์ต่างๆ ซึ่งในนำระบบอนุมานตรรกะคลุมเครือมาใช้งานนั้นจะต้องทำการออกแบบฟังก์ชันความเป็นสมาชิก (Membership function) และกฎของฟัซซี (Fuzzy rule) โดยสามารถพิจารณาได้จากข้อมูลได้

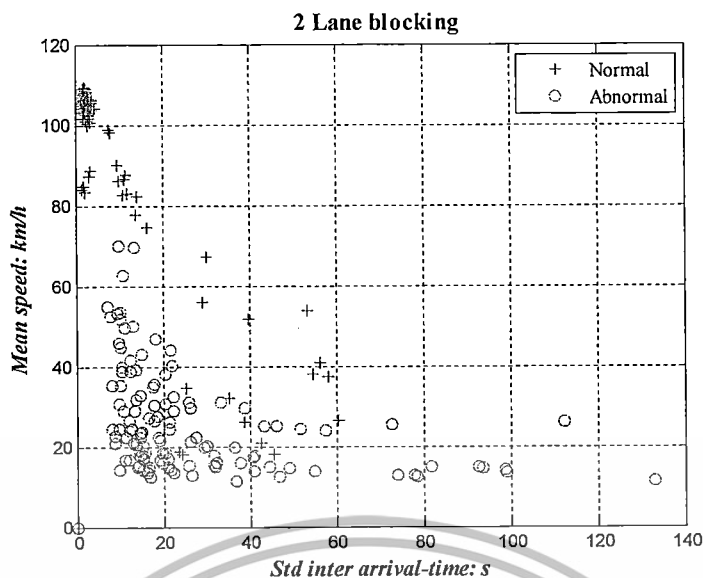
สำหรับการออกแบบฟังก์ชันความเป็นสมาชิก (Membership function)

ในการออกแบบฟังก์ชันความเป็นสมาชิกควรนำข้อมูลมาพล็อตแบบกระจาย (Scatter plot) เพื่อทำการวิเคราะห์ลักษณะข้อมูล โดยแสดงการพล็อตแบบกระจายของอุบัติเหตุแบบ 1 Lane blocking, 2 Lane blocking และ 3 Lane blocking ดังรูปที่ 3.13, 3.14 และ 3.15 ตามลำดับ




รูปที่ 3.13 การพล็อตแบบกระจายของอุบัติเหตุแบบ 1 Lane blocking

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.14 การพล็อตแบบกระจายของอุบัติเหตุการแบบ 2 Lane blocking




รูปที่ 3.15 การพล็อตแบบกระจายของอุบัติเหตุการแบบ 3 Lane blocking

จากรูปที่ 3.13, 3.14 และ 3.15 จะสามารถพิจารณาข้อมูลเพื่อแบ่งช่วงของฟังก์ชันความเป็นสมาชิกของอินพุท (Input Membership function) ซึ่งในงานวิจัยนี้ได้พิจารณาอินพุทก็คือค่าความเร็วเฉลี่ย (Mean speed) และค่าเบี่ยงเบนมาตรฐานของเวลาในขณะที่รถยนต์กำลังเข้ามาในพื้นที่ถนนที่กำหนด (Std. inter-arrival time) ในโดเมนของเวลา (Time domain)


จากการพิจารณาพบว่าค่าความเร็วเฉลี่ย (Mean speed) ควรแบ่งช่วงของฟังก์ชันความเป็นสมาชิกของอินพุท (Input membership function) ออกเป็น 3 ฟังก์ชันเซต คือ {Small Medium Large} และค่าเบี่ยงเบนมาตรฐานของเวลาในขณะที่รถยนต์กำลังเข้ามาในพื้นที่ถนนที่กำหนด (Std. inter-arrival time) ควรแบ่งช่วงของฟังก์ชันความเป็นสมาชิกของอินพุท (Input membership function) ออกเป็น 3 ฟังก์ชันเซต คือ {Small Medium Large} อย่างไรก็ตามการแบ่งช่วงของฟังก์ชันความเป็นสมาชิกของอินพุท (Input membership function) นี้จำเป็นต้องพิจารณาถึงลักษณะของข้อมูลและลักษณะของฟังก์ชันความเป็นสมาชิกของอินพุท (Input membership function) ที่ใช้ในการสร้างแบบจำลองการจราจรด้วย

function) ออกเป็น 4 ฟังก์ชันเซต คือ {Small Medium Large Very-large} และแต่ละฟังก์ชันเซตจะต้องมีการเลือกใช้ฟังก์ชันความเป็นสมาชิกโดยจะขึ้นอยู่กับข้อมูลนั้นๆ ซึ่งมีอยู่หลายชนิด เช่น ฟังก์ชันสามเหลี่ยม (Triangle function) ฟังก์ชันสี่เหลี่ยมคางหมู (Trapezoid function) ฟังก์ชันซิกมอยด์ (Sigmoid function) ฟังก์ชันเกาส์เซียน (Gaussian function) เป็นต้น โดยในงานวิจัยนี้ได้เลือกใช้ฟังก์ชันความเป็นสมาชิกเป็นรูปสี่เหลี่ยมคางหมู เนื่องจากการกำหนดระดับความเป็นสมาชิก (Degree of membership function) ของฟังก์ชันสี่เหลี่ยมคางหมูจะมีค่าอยู่ระหว่าง 0 และ 1 โดยจะมีความเป็นสมาชิกของค่าตอบที่แน่นอนได้อยู่หลายค่า ซึ่งฟังก์ชันความเป็นสมาชิกของอินพุต (Input membership function) สามารถออกแบบให้มีลักษณะได้ดังรูปที่ 3.16



รูปที่ 3.16 ฟังก์ชันความเป็นสมาชิกของอินพุต (Input membership function)

ซึ่งจะได้ฟังก์ชันความเป็นสมาชิก (Membership function) ของค่าความเร็วเฉลี่ย (Mean speed) ดังนี้



รูปที่ 3.17 ฟังก์ชันความเป็นสมาชิกของค่าความเร็วเฉลี่ย (Mean speed)


จากรูปที่ 3.17 ฟังก์ชันความเป็นสมาชิกของค่าความเร็วเฉลี่ย ซึ่งแบ่งเป็น 3 ฟังก์ชันเซต คือ

- 1) Small มีค่าอยู่ในช่วง [0 0 15 40]
- 2) Medium มีค่าอยู่ในช่วง [35 45 60 75]

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ไว้เพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3) Large มีค่าอยู่ในช่วง [65 90 120 120]

และจะได้ฟังก์ชันความเป็นสมาชิก (Membership function) ของค่าเบี่ยงเบนมาตรฐานของเวลาในขณะที่รถยนต์กำลังเข้ามาในพื้นที่ถนนที่กำหนด (Std. inter-arrival time) ดังนี้




รูปที่ 3.18 ฟังก์ชันความเป็นสมาชิกของค่าเบี่ยงเบนมาตรฐานของเวลาในขณะที่รถยนต์กำลังเข้ามาในพื้นที่ถนนที่กำหนด (Std. inter-arrival time)

จากรูปที่ 3.18 ฟังก์ชันความเป็นสมาชิกของค่าเบี่ยงเบนมาตรฐานของเวลาในขณะที่รถยนต์กำลังเข้ามาในพื้นที่ถนนที่กำหนด ซึ่งแบ่งเป็น 4 ฟัซซีเซต คือ

- 1) Small มีค่าอยู่ในช่วง [0 0 3 5]
- 2) Medium มีค่าอยู่ในช่วง [3 7 12 16]
- 3) Large มีค่าอยู่ในช่วง [13 17 23 27]
- 4) Very large มีค่าอยู่ในช่วง [22 28 250 250]

ในส่วนของเอาต์พุตที่ได้จากระบบอนุมานตรรกะคลุมเครือจะเป็นแบบ Mamdani คือ ผลลัพธ์ที่ได้จะถูกคำนวณเพื่อหาจุดศูนย์กลาง (Center of Gravity: COG) ดังนั้นฟังก์ชันความเป็นสมาชิกของเอาต์พุต (Output membership function) จะสามารถแบ่งออกเป็น 2 ฟัซซีเซต คือ {Normal Abnormal} ดังนี้



รูปที่ 3.19 ฟังก์ชันความเป็นสมาชิกของเอาต์พุต (Output membership function)

จากรูปที่ 3.19 ฟังก์ชันความเป็นสมาชิกของเอาต์พุต ซึ่งแบ่งเป็น 2 ฟัซซีเซต คือ

- 1) Normal มีค่าอยู่ในช่วง [0 0 60 80]
- 2) Abnormal มีค่าอยู่ในช่วง [75 80 100 100]

สำหรับการออกแบบกฎของฟัซซี (Fuzzy rules)

ในการออกแบบกฎของฟัซซีสามารถแสดงได้ดังตารางที่ 3.2

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


ตารางที่ 3.2 กฎของฟัซซี (Fuzzy rules) ของระบบที่นำเสนอใน [6]

Mean Speed \ Std. inter arrival time	Small	Medium	large
Small	Abnormal	Abnormal	Normal
Medium	Abnormal	Abnormal	Abnormal
Large	Abnormal	Abnormal	Abnormal
Very-large	Abnormal	Normal	Abnormal

ซึ่งในการกำหนดจำนวนกฎของฟัซซี (Fuzzy rule) ขึ้นอยู่กับการกำหนดจำนวนฟัซซีเซตของสมาชิกของอินพุตแต่ละอินพุต ซึ่งจะได้เท่ากับ $m \times n$ โดยที่ m คือจำนวนฟัซซีเซตของค่าความเร็วเฉลี่ย (Mean speed) และ n คือจำนวนฟัซซีเซตของค่าเบี่ยงเบนมาตรฐานของเวลาในขณะที่รถยนต์กำลังเข้ามาในพื้นที่ถนนที่กำหนด (Std. inter-arrival time) สำหรับงานวิจัยที่นำเสนอใน [6] นี้สามารถกำหนดกฎของฟัซซีได้ทั้งหมด 12 กฎ ดังตารางที่ 3.2

3.2.2 ระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้ระบบอนุมานตรรกะคลุมเครือและวิธีการเสียงข้างมาก

ในหัวข้อ 3.2.1 ที่กล่าวมานั้นได้อธิบายถึงวิธีการออกแบบระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้ระบบอนุมานตรรกะคลุมเครือ ซึ่งในหัวข้อนี้จะอธิบายถึงการนำระบบที่นำเสนอดังกล่าวมาใช้ร่วมกับวิธีการเสียงข้างมาก (Majority voting) แสดงแผนผังได้ดังรูปที่ 3.20




รูปที่ 3.20 ระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้ระบบอนุมานตรรกะคลุมเครือและวิธีการเสียงข้างมาก

สำหรับวิธีการเสียงข้างมากจะถูกนำมาพิจารณาเพื่อเพิ่มประสิทธิภาพในการตรวจจับอุบัติการณ์ของระบบให้มีความถูกต้องมากยิ่งขึ้นและใช้เวลาในการตรวจจับอุบัติการณ์น้อย ซึ่งจะสามารถคำนวณออกมาเป็นค่าอัตราการตรวจจับอุบัติการณ์ของระบบหรือที่เรียกว่า Detection Rate (DR) และค่าเฉลี่ยของผลรวมเวลาที่ระบบสามารถตรวจจับอุบัติการณ์ได้หรือที่เรียกว่า Mean Time to Detection (MTTD) โดยจะกล่าวถึงในหัวข้อสุดท้ายของบทนี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาค้นคว้าเท่านั้น เมื่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สำหรับการออกแบบวิธีการเสียงข้างมาก (Majority voting)

จากงานวิจัยที่นำเสนอก่อนหน้านี้ใน [6] ได้ออกแบบวิธีการเสียงข้างมาก ซึ่งจะพิจารณาข้อมูลโดยวิธีการเลื่อนของหน้าต่างเป็นแบบบล็อกหรือที่เรียกว่า Blocking window ที่มีขนาดหน้าต่าง 5 samples และ 7 samples ซึ่งวิธีการนี้จะให้ผลลัพธ์ก็ต่อเมื่อมีเสียงข้างมากของคำตอบภายในขนาดหน้าต่างๆ นั้น ซึ่งแสดงได้ดังรูปที่ 3.21



ก. Blocking window ขนาด 5 samples ข. Blocking window ขนาด 7 samples

รูปที่ 3.21 Blocking window ขนาด 5 samples และ 7 samples


จากรูปที่ 3.21 แสดงวิธีการเสียงข้างมากแบบ Blocking window ขนาด 5 samples และ 7 samples จะเห็นว่าผลลัพธ์ที่ได้จะไม่ได้แสดงทุกจุดของข้อมูล โดยผลลัพธ์ที่ได้จากหน้าต่างขนาด 5 samples จำเป็นต้องมีคำตอบเป็น 3 ใน 5 และผลลัพธ์ที่ได้จากหน้าต่างขนาด 7 samples จำเป็นต้องมีคำตอบเป็น 4 ใน 7 ของขนาดหน้าต่างนั้นๆ

แต่กระนั้นเพื่อเพิ่มค่าอัตราการตรวจจับอุบัติเหตุ (DR) ในขณะที่ค่าเฉลี่ยของผลรวมเวลาที่ระบบสามารถตรวจจับอุบัติเหตุได้ (MTTD) มีค่าใกล้เคียงกับระบบที่นำเสนอใน [6] และไม่เปลี่ยนแปลงมากนักทำให้ผู้วิจัยพัฒนาต่อยอดโดยนำเทคนิคการประมวลผลสัญญาณ (Signal processing) ซึ่งก็คือการแปลงเวฟเลตเต็มหน่วย (Discrete Wavelet Transform: DWT) ดังที่นำเสนอใน [7] โดยจะกล่าวถึงในหัวข้อถัดไป

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.2.3 ระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้การแปลงเวฟเล็ทเต็มหน่วยและระบบอนุมานตรรกะคลุมเครือร่วมกับวิธีการเสียงข้างมาก

ในหัวข้อนี้จะอธิบายถึงระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้การแปลงเวฟเล็ทเต็มหน่วยและระบบอนุมานตรรกะคลุมเครือร่วมกับวิธีการเสียงข้างมากที่ถูกรวบรวมใน [7] โดยผู้วิจัยได้พัฒนาต่อยอดจากงานที่นำเสนอใน [6] เพื่อเพิ่มค่าอัตราการตรวจจับอุบัติเหตุ (DR) เนื่องจากข้อมูลทางจราจรจะมีความผันผวนอยู่มาก (Fluctuation) ผู้วิจัยจึงนำเสนอระบบที่ใช้การแปลงเวฟเล็ทเต็มหน่วยมาช่วยในการลดสัญญาณรบกวน (De-noising) และช่วยลดจำนวนของข้อมูล (Reduce data) โดยจะสามารถแสดงแผนผังได้ดังรูปที่ 3.22



รูปที่ 3.22 ระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้การแปลงเวฟเล็ทเต็มหน่วยและระบบอนุมานตรรกะคลุมเครือร่วมกับวิธีการเสียงข้างมาก


จากรูปที่ 3.22 จะเห็นว่าระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้การแปลงเวฟเล็ทเต็มหน่วยและระบบอนุมานตรรกะคลุมเครือร่วมกับวิธีการเสียงข้างมากที่นำเสนอใน [7] ซึ่งเป็นระบบที่นำการแปลงเวฟเล็ทเต็มหน่วยมาใช้กับข้อมูลจราจรที่เป็นข้อมูลอินพุตและนำผลการแปลงที่ได้จากการพิจารณาข้อมูลในโดเมนเวฟเล็ท (Wavelet domain) โดยไม่ได้สังเคราะห์ข้อมูลกลับ (Synthesis) นำไปเป็นอินพุตให้กับกลไกหลักในการตัดสินใจก็คือระบบอนุมานตรรกะคลุมเครือ เพื่อลดความซับซ้อนของระบบ ซึ่งจะต่างจากงานวิจัยใน [4] ที่พิจารณาข้อมูลที่ถูกแปลงเวฟเล็ทเต็มหน่วยและทำการสังเคราะห์ข้อมูลกลับให้อยู่ในโดเมนเวลา

สำหรับการออกแบบการแปลงเวฟเล็ทเต็มหน่วย (Discrete Wavelet Transform: DWT)

ในการแปลงเวฟเล็ทเต็มหน่วยเพื่อมาช่วยในการสกัดคุณลักษณะเด่นของข้อมูล (Feature extraction) ออกจากข้อมูลต้นฉบับซึ่งมีความผันผวนของข้อมูลอยู่มาก (Fluctuation) และช่วยลดสัญญาณรบกวน (De-noising) ที่ปะปนเข้ามา กับสัญญาณต้นฉบับ โดยใช้การวิเคราะห์แบบชุดตัวกรองสัญญาณ (Filter bank analysis) จะทำการแยกสัญญาณต้นแบบจากชุดตัวกรองสัญญาณออกเป็น 2 ส่วน คือส่วนที่มีความถี่ต่ำกับส่วนที่มีความถี่สูง โดยจะใช้ตัวกรองความถี่ต่ำผ่าน (Low Pass Filter) สำหรับแยกองค์ประกอบส่วนที่มีความถี่ต่ำ (Approximation coefficient) และใช้ตัวกรองความถี่สูงผ่าน (High Pass Filter) สำหรับแยกองค์ประกอบความถี่สูง (Detail coefficient)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดยสัญญาณที่ได้มานั้นจะผ่านอัตราสุ่มลง (Down Sampling) ด้วย 2 ซึ่งจะทำให้ผลลัพธ์จากการวิเคราะห์ลดลงครึ่งหนึ่ง ซึ่งโครงสร้างของชุดตัวกรองสัญญาณแสดงได้ดังรูปที่ 3.23



รูปที่ 3.23 โครงสร้างของชุดตัวกรองสัญญาณ (Filter bank analysis)

สำหรับเวฟเล็ตแม่ (Mother wavelet) ที่เลือกใช้จะเป็นแบบ “Daubechies-2” หรือ “db2” แสดงได้ดังรูปที่ 3.24




รูปที่ 3.24 เวฟเล็ตแม่ชนิด Daubechies-2

จากรูปที่ 3.24 เวฟเล็ตแม่ชนิด Daubechies-2 ซึ่งเป็นชนิดของเวฟเล็ตแม่ที่นำมาใช้ในการแปลงเวฟเล็ตเต็มหน่วย เนื่องจากในพิจารณาผลการแปลงของข้อมูลอินพุตทั้ง 2 คือ Approximation coefficient ของค่าความเร็วเฉลี่ย (Mean speed) และ Approximation coefficient ค่าเบี่ยงเบนมาตรฐานของเวลาในขณะที่ยอดกำลังเข้ามาในพื้นที่ถนนที่กำหนด (Std. inter-arrival time) เวฟเล็ตแม่ชนิด Daubechies-2 หรือ db2 ให้ค่าแอมพลิจูดของสัญญาณ (Amplitude) ที่สูง แสดงให้เห็นได้ว่าการนำเวฟเล็ตแม่ชนิด db2 มาใช้กับระบบจะช่วยให้การดึงคุณลักษณะเด่นของข้อมูล (Feature extraction) และสามารถเวฟเล็ตเป็นตัวแทนของสัญญาณ (Represent) สำหรับข้อมูลอินพุตได้

และระดับของการแปลงได้เลือกใช้การแปลงเป็นแบบ 1 ระดับ (1-level analysis) เนื่องจากงานวิจัยนี้ได้พิจารณาข้อมูลในเวฟเล็ตโดเมนโดยตรง (เมื่อแปลงเวฟเล็ตแบบ 1 ระดับ กระบวนการสุ่ม (Sampling rate) ของข้อมูลอินพุต จะใช้เวลาเพิ่มขึ้นจาก 30 วินาที เป็น 60 วินาที ต่อ sample)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ซึ่งการใช้ระดับของการแปลงที่สูงขึ้นจะส่งผลต่อเวลาในการตรวจจับอุบัติเหตุ จะสามารถแสดงโครงสร้างของชุดตัวกรองสัญญาณแบบ 1 ระดับ ได้ดังรูปที่ 3.25



รูปที่ 3.25 โครงสร้างของชุดตัวกรองสัญญาณแบบ 1 ระดับ

จากรูปที่ 3.25 จะเห็นได้ว่าโครงสร้างของชุดตัวกรองสัญญาณที่ใช้เป็นแบบ 1 ระดับ (1-level analysis) ซึ่งผลการแปลงเวฟเล็ตเต็มหน่วยที่ได้จากตัวกรองความถี่ต่ำ (Low-pass filter) โดยตัวกรองความถี่ต่ำผ่าน (Low Pass Filter) ที่ใช้งานซึ่งสอดคล้องกับเวฟเล็ตแม่ (Mother wavelet) ที่เป็น db2 มีฟังก์ชันถ่ายโอน (Transfer function) คือ

$$H_{Lo_D}(z) = -0.1294 + 0.2241z^{-1} + 0.8365z^{-2} + 0.4830z^{-3} \quad (3.1)$$

และจะถูกกระบวนการสุ่ม (Down-sampling) ด้วย 2 ผลการแปลงที่ได้จะถูกเรียกว่า "Approximation coefficient" ซึ่งในส่วนนี้จะถูกนำไปเป็นข้อมูลอินพุตให้กับระบบอนุमानตรระกลุ่มเครื่องบนฐานโครงข่ายปรับตัวได้ และผลการแปลงเวฟเล็ตที่ได้จากตัวกรองความถี่สูง (High-pass filter) โดยตัวกรองความถี่สูงผ่าน (High Pass Filter) ที่ใช้งานซึ่งสอดคล้องกับเวฟเล็ตแม่ (Mother wavelet) ที่เป็น db2 มีฟังก์ชันถ่ายโอน (Transfer function) คือ

$$H_{Hi_D}(z) = -0.4380 + 0.8365z^{-1} - 0.2241z^{-2} - 0.1294z^{-3} \quad (3.2)$$

และเมื่อถูก (Down-sampling) ด้วย 2 ผลการแปลงที่ได้จะถูกเรียกว่า "Detail coefficient" แต่ในส่วนของค่า Detail Coefficient จะถูกมองว่าเป็นสัญญาณรบกวนของข้อมูล ซึ่งจะไม่ถูกนำไปพิจารณา


แต่เนื่องจากระบบอนุमानตรระกลุ่มเครื่องไม่สามารถเรียนรู้จากข้อมูลได้ซึ่งเมื่อข้อมูลอินพุตมีการเปลี่ยนแปลงคือมีการแปลงข้อมูลให้มาอยู่ในโดเมนเวฟเล็ต (Wavelet domain) จึงจำเป็นต้องใช้ผู้เชี่ยวชาญในการกำหนดค่าพารามิเตอร์ต่างๆ ใหม่ ซึ่งจะต้องทำการออกแบบฟังก์ชันความเป็นสมาชิก (Membership function) และกฎของฟัซซี (Fuzzy rule) ให้มีความเหมาะสมกับลักษณะข้อมูลอินพุต

สำหรับการออกแบบฟังก์ชันความเป็นสมาชิก (Membership function)

ในการออกแบบฟังก์ชันความเป็นสมาชิก ซึ่งในงานวิจัยนี้ได้พิจารณาอินพุต 2 อินพุตก็คือ Approximation coefficient ของค่าความเร็วเฉลี่ย (Mean speed) และ Approximation coefficient ค่าเบี่ยงเบนมาตรฐานของเวลาในขณะที่ยานต์กำลังเข้ามาในพื้นที่ถนนที่กำหนด (Std. Dev. of time when the vehicle enters the road area) ซึ่งค่าเหล่านี้เป็นค่าที่ได้จากการคำนวณจากข้อมูลจริงที่เก็บมา ซึ่งค่าเหล่านี้จะขึ้นอยู่กับเงื่อนไขการจราจรในแต่ละช่วงเวลา ไม่ว่าจะเป็นรถติดหรือรถวิ่ง อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

inter-arrival time) ซึ่งจะพิจารณาในโดเมนเวฟเล็ต (Wavelet domain) โดยตรง โดยไม่ได้สังเคราะห์ข้อมูลกลับ (Synthesis)

จากการพิจารณาข้อมูลพบว่า Approximation coefficient ของค่าความเร็วเฉลี่ย (Mean speed) ควรแบ่งช่วงของฟังก์ชันความเป็นสมาชิกของอินพุท (Input membership function) ออกเป็น 3 ฟังก์ชันเซต คือ {Small Medium Large} และ Approximation coefficient ของค่าเบี่ยงเบนมาตรฐานของเวลาในขณะที่ยกกำลังเข้ามาในพื้นที่ถนนที่กำหนด (Std. inter-arrival time) ควรแบ่งช่วงของฟังก์ชันความเป็นสมาชิกของอินพุท (Input membership function) ออกเป็น 4 ฟังก์ชันเซต คือ {Small Medium Large Very-large} และแต่ละฟังก์ชันเซตจะเลือกใช้ฟังก์ชันความเป็นสมาชิกเป็นรูปสี่เหลี่ยมคางหมู (Trapezoid function) ซึ่งการออกแบบจะเหมือนกับหัวข้อ 3.2.1 ที่ได้กล่าวมาก่อนหน้านี้ โดยจะได้ฟังก์ชันความเป็นสมาชิก (Membership function) ของ Approximation coefficient ของความเร็วเฉลี่ย (Mean speed) ดังนี้




รูปที่ 3.26 ฟังก์ชันความเป็นสมาชิกของ Approximation coefficient ของค่าความเร็วเฉลี่ย

จากรูปที่ 3.26 ฟังก์ชันความเป็นสมาชิกของ Approximation coefficient ของค่าความเร็วเฉลี่ย ซึ่งแบ่งเป็น 3 ฟังก์ชันเซต คือ

- 1) Small มีค่าอยู่ในช่วง [0 0 70 110]
- 2) Medium มีค่าอยู่ในช่วง [80 95 120 135]
- 3) Large มีค่าอยู่ในช่วง [120 140 160 160]

และจะได้ฟังก์ชันความเป็นสมาชิก (Membership function) ของ Approximation coefficient ของค่าเบี่ยงเบนมาตรฐานของเวลาในขณะที่ยกกำลังเข้ามาในพื้นที่ถนนที่กำหนด (Std. inter-arrival time) ดังนี้



รูปที่ 3.27 ฟังก์ชันความเป็นสมาชิกของ Approximation coefficient ของค่าเบี่ยงเบนมาตรฐาน


ของเวลาในขณะที่ยกกำลังเข้ามาในพื้นที่ถนนที่กำหนด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 3.27 ฟังก์ชันความเป็นสมาชิกของ Approximation coefficient ของค่าเบี่ยงเบนมาตรฐานของเวลาในเวลาที่รถยนต์กำลังเข้ามาในพื้นที่ถนนที่กำหนด ซึ่งแบ่งเป็น 4 ฟัชซีเซต คือ

- 1) Small มีค่าอยู่ในช่วง [0 0 3 5.5]
- 2) Medium มีค่าอยู่ในช่วง [3.5 5.5 8 10.5]
- 3) Large มีค่าอยู่ในช่วง [8 10 12 14]
- 4) Very large มีค่าอยู่ในช่วง [12 15 40 40]

ในส่วนของเอาต์พุตที่ได้จากระบบอนุมานตรรกะคลุมเครือจะเป็นแบบ Mamdani คือ ผลลัพธ์ที่ได้จะถูกคำนวณเพื่อหาจุดศูนย์กลาง (Center of Gravity: COG) ดังนั้นฟังก์ชันความเป็นสมาชิกของเอาต์พุต (Output membership function) จะสามารถแบ่งออกเป็น 2 ฟัชซีเซต คือ {Normal Abnormal} ดังนี้



รูปที่ 3.28 ฟังก์ชันความเป็นสมาชิกของเอาต์พุต (Output membership function) สำหรับการแปลงเวฟเล็ตเต็มหน่วย

จากรูปที่ 3.28 ฟังก์ชันความเป็นสมาชิกของเอาต์พุต ซึ่งแบ่งเป็น 2 ฟัชซีเซต คือ

- 1) Normal มีค่าอยู่ในช่วง [0 0 60 80]
- 2) Abnormal มีค่าอยู่ในช่วง [75 80 100 100]

สำหรับการออกแบบกฎของฟัชซี (Fuzzy rules)

ในการออกแบบกฎของฟัชซีสามารถแสดงได้ดังตารางที่ 3.3

ตารางที่ 3.3 กฎของฟัชซี (Fuzzy rules) ของระบบที่นำเสนอใน [7]


Mean Speed	Small	Medium	large
Std. inter arrival time			
Small	Abnormal	Abnormal	Normal
Medium	Abnormal	Abnormal	Abnormal
Large	Abnormal	Abnormal	Abnormal
Very-large	Abnormal	Normal	Abnormal

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สำหรับงานวิจัยที่นำเสนอใน [7] นี้สามารถกำหนดกฎของฟัซซีได้ทั้งหมด 12 กฎ ดังตารางที่ 3.3

สำหรับการออกแบบวิธีการเสียงข้างมาก (Majority voting)

จากงานวิจัยที่นำเสนอก่อนหน้านี้ใน [7] ได้ออกแบบวิธีการเสียงข้างมาก ซึ่งจะพิจารณาข้อมูลโดยวิธีการเลื่อนของหน้าต่างเป็นแบบบล็อกหรือที่เรียกว่า Blocking window เช่นเดียวกับงานวิจัยที่นำเสนอใน [6] แต่เนื่องจากข้อมูลที่ถูกการแปลงเวฟเล็ตเต็มหน่วยจะมีจำนวนข้อมูลลดลง ทำให้ในการพิจารณาเลือกใช้ขนาดหน้าต่างของวิธีการเสียงข้างมากสำหรับระบบนี้คือ จะเลือกใช้ขนาดหน้าต่างที่มีขนาด 3 samples และ 5 samples ซึ่งวิธีการนี้จะให้ผลลัพธ์ก็ต่อเมื่อมีเสียงข้างมากของคำตอบภายในขนาดหน้าต่างๆ นั้นเช่นเดียวกับงานวิจัยที่นำเสนอใน [6] ซึ่งแสดงได้ดังรูปที่ 3.29



รูปที่ 3.29 Blocking window ขนาด 3 samples และ 5 samples


จากรูปที่ 3.29 แสดงวิธีการเสียงข้างมากแบบ Blocking window ขนาด 3 samples และ 5 samples จะเห็นได้ว่าผลลัพธ์ที่ได้จะไม่ได้แสดงทุกจุดของข้อมูล โดยผลลัพธ์ที่ได้จากหน้าต่างขนาด 3 samples จำเป็นต้องมีคำตอบเป็น 2 ใน 3 และผลลัพธ์ที่ได้จากหน้าต่างขนาด 5 samples จำเป็นต้องมีคำตอบเป็น 3 ใน 5 ของขนาดหน้าต่างนั้นๆ

สำหรับระบบอนุมานตรรกะคลุมเครือไม่สามารถเรียนรู้และปรับตัวจากข้อมูลได้ ทำให้เวลานำไปใช้งานจริงจะต้องใช้ผู้เชี่ยวชาญในการกำหนดค่าพารามิเตอร์ต่างๆ เพราะฉะนั้นผู้วิจัยจึงได้พัฒนาต่อยอดระบบโดยเลือกใช้ระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้หรือที่เรียกว่า ANFIS มาใช้เป็นกลไกหลักของระบบแทนระบบอนุมานตรรกะคลุมเครือ ซึ่งจะสามารถเรียนรู้และปรับตัวจากข้อมูลได้ (Learning from data) หลักการในการออกแบบจะได้กล่าวถึงในหัวข้อถัดไป

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.2.4 ระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้การแปลงเวฟเล็ตเติมหน่วยและระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ร่วมกับวิธีการเสียงข้างมาก

ในหัวข้อนี้จะอธิบายถึงระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้การแปลงเวฟเล็ตเติมหน่วยและระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ร่วมกับวิธีการเสียงข้างมาก โดยสามารถแสดงแผนผังการทำงานของระบบได้ดังรูปที่ 3.32 ซึ่งระบบที่นำเสนอนี้ได้ถูกพัฒนาต่อยอดมาจากงานวิจัยใน [7] โดยระบบที่นำเสนอนี้จึงได้เลือกใช้ระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้หรือที่เรียกว่า ANFIS มาใช้เป็นกลไกหลักของระบบแทนระบบอนุมานตรรกะคลุมเครือ ซึ่งจะสามารถเรียนรู้และปรับตัวจากข้อมูลได้ (Learning from data) โดยในการทำงานของระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้จะเป็นรูปแบบการทำงานร่วมกันของระบบอนุมานตรรกะคลุมเครือ (Fuzzy Inference System: FIS) และโครงข่ายประสาทเทียม (Artificial Neural Network) สำหรับการทำงานเพียงอย่างเดียวของตรรกะคลุมเครือหรือโครงข่ายประสาทเทียมนั้นจะไม่สามารถแก้ไขปัญหาเฉพาะบางอย่างได้ อย่างเช่นโครงข่ายประสาทเทียมจะมีคุณสมบัติในการเรียนรู้ (Learning) ที่ไม่สามารถอธิบายถึงการได้มาของสิ่งที่ตัดสินใจได้ ในขณะที่ตรรกะคลุมเครือสามารถให้เหตุผลที่เลียนแบบการตัดสินใจของมนุษย์ แต่ระบบของตรรกะคลุมเครือเองก็ไม่สามารถปรับตัวได้เมื่อลักษณะของข้อมูลมีการเปลี่ยนแปลง จะเห็นได้ว่ามีข้อจำกัดเกิดขึ้นในระบบอนุมานตรรกะคลุมเครือและโครงข่ายประสาทเทียม ซึ่งเป็นการเรียนรู้แบบผสม (Hybrid)



รูปที่ 3.30 ระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้การแปลงเวฟเล็ตเติมหน่วยและระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ร่วมกับวิธีการเสียงข้างมาก

จากรูปที่ 3.30 จะเห็นว่าการทำงานของระบบจะเริ่มต้นจากข้อมูลอินพุตของระบบที่เป็นค่าสัมประสิทธิ์ของข้อมูลค่าความเร็วเฉลี่ย (Mean speed) และค่าสัมประสิทธิ์ของข้อมูลค่าเบี่ยงเบนมาตรฐานของเวลาระหว่างการเข้าถึง (Std. of inter-arrival time) ในโดเมนของเวฟเล็ต (Wavelet domain) ซึ่งค่าสัมประสิทธิ์ที่ได้ก็คือผลการแปลงของเวฟเล็ตเติมหน่วยจะถูกนำมาพิจารณาเป็นข้อมูลอินพุตให้กับระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (Adaptive Neuro Fuzzy Inference System: ANFIS) จะสามารถออกแบบได้ดังนี้


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สำหรับการออกแบบระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (Adaptive Neuro Fuzzy Inference System: ANFIS)

ในกระบวนการทำงานของระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้จะแบ่งการพิจารณาได้เป็น 2 โหมดการทำงานคือ

1. โหมดของการฝึกหัด (Training mode)


ในโหมดการฝึกหัดกระบวนการทำงานจะเป็นแบบออฟไลน์ (Offline) โดยการสร้างแบบจำลองของระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้จะต้องมีการเรียนรู้จากข้อมูล (Learning from data) ที่เป็นชุดข้อมูลสำหรับให้แบบจำลองได้เรียนรู้และปรับค่าพารามิเตอร์ต่างๆ ให้มีความเหมาะสมกับลักษณะข้อมูลนั้นๆ ก่อนนำไปใช้งานจริง ซึ่งการทำงานในโหมดการฝึกหัดแสดงได้ดังรูปที่ 3.31



รูปที่ 3.31 การทำงานในโหมดการฝึกหัด (Training mode)

จากรูปที่ 3.31 จะเห็นว่าการทำงานในโหมดฝึกหัดจะใช้ข้อมูลอินพุต 2 ตัว ที่ผ่านการแปลงเวฟเล็ตเต็มหน่วยแล้ว โดยในกระบวนการฝึกหัดเพื่อให้ระบบสามารถตอบสนองกับลักษณะข้อมูลของอุบัติเหตุได้ทั้ง 3 รูปแบบ คือ 1 Lane blocking, 2 Lane blocking และ 3 Lane blocking เพราะฉะนั้นจะต้องใช้ข้อมูลทั้งหมดของอุบัติเหตุทั้ง 3 รูปแบบ เพื่อให้ระบบเรียนรู้และปรับตัวให้เป็นแบบจำลองที่เหมาะสมกับลักษณะข้อมูลที่สุด

จะเห็นได้ว่าโดยการปรับตัวของระบบก็คือการปรับโครงสร้างของฟังก์ชันสมาชิก (Membership function) และกฎ (Rule) ซึ่งฟังก์ชันความเป็นสมาชิกที่เลือกใช้ในงานวิจัยนี้จะเป็นรูปลักษณะฟังก์ชันสี่เหลี่ยมคางหมู (Trapezoid membership function) เนื่องจากการกำหนดระดับความเป็นสมาชิก (Degree of membership function) ของฟังก์ชันสี่เหลี่ยมคางหมูจะมีค่าอยู่ระหว่าง 0 และ 1 โดยจะมีความเป็นสมาชิกของคำตอบที่แน่นอนได้อยู่หลายค่าแสดงได้ดังรูปที่ 3.34



รูปที่ 3.32 ฟังก์ชันสี่เหลี่ยมคางหมู (Trapezoid membership function)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


โดยเขียนเป็นสมการได้ดังสมการที่ 3.3

$$\mu_A(x) = \begin{cases} 0, & (x < a) \text{ or } (x > d) \\ \frac{x-a}{b-a} & a \leq x \leq b \\ 1, & b \leq x \leq c \\ \frac{d-x}{d-c}, & c \leq x \leq d \end{cases} \quad (3.3)$$

โดย $\mu_A(x)$ เป็นรูปลักษณะฟังก์ชันสี่เหลี่ยมคางหมู

ในการปรับตัวคือการเลื่อนตำแหน่งของพารามิเตอร์ $\{a, b, c, d\}$ ของแต่ละฟuzzyเซต โดยที่ในการนำไปใช้งานกระบวนการฝึกหัดจะเรียนรู้จากข้อมูลที่เป็นอินพุทให้กับระบบ ซึ่งกระบวนการปรับตัวก็จะปรับค่าพารามิเตอร์ต่างๆ จนกว่าผลลัพธ์ที่ได้จากระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ตรงกับคำตอบที่แท้จริงของข้อมูล เมื่อให้ระบบได้เรียนรู้จากข้อมูลจะได้ฟังก์ชันสมาชิกดังนี้

สำหรับฟังก์ชันความเป็นสมาชิก (Membership function) ของ Approximation coefficient ของความเร็วเฉลี่ย (Mean speed) แสดงได้ตามรูปที่ 3.33




รูปที่ 3.33 ฟังก์ชันความเป็นสมาชิกของ Approximation coefficient ของค่าความเร็วเฉลี่ย สำหรับระบบที่ใช้ ANFIS เป็นกลไกหลัก

จากรูปที่ 3.33 ฟังก์ชันความเป็นสมาชิกของ Approximation coefficient ของค่าความเร็วเฉลี่ย สำหรับระบบที่ใช้ ANFIS เป็นกลไกหลักซึ่งแบ่งเป็น 3 ฟuzzyเซต คือ

- 1) Small มีค่าอยู่ในช่วง [0 0 19.94 61.23]
- 2) Medium มีค่าอยู่ในช่วง [14.78 50.91 96.51 130.90]
- 3) Large มีค่าอยู่ในช่วง [97.37 126.60 150.70 150.70]

และจะได้ฟังก์ชันความเป็นสมาชิก (Membership function) ของ Approximation coefficient ของค่าเบี่ยงเบนมาตรฐานของเวลาในขณะที่ยอดกำลังเข้ามาในพื้นที่ถนนที่กำหนด (Std. inter-arrival time) สำหรับระบบที่ใช้ ANFIS เป็นกลไกหลัก ดังนี้



รูปที่ 3.34 ฟังก์ชันความเป็นสมาชิกของ Approximation coefficient ของค่าเบี่ยงเบนมาตรฐานของเวลาในขณะที่ยอดรถกำลังเข้ามาในพื้นที่ถนนที่กำหนด สำหรับระบบที่ใช้ ANFIS เป็นกลไกหลัก


จากรูปที่ 3.34 ฟังก์ชันความเป็นสมาชิกของ Approximation coefficient ของค่าเบี่ยงเบนมาตรฐานของเวลาในขณะที่ยอดรถกำลังเข้ามาในพื้นที่ถนนที่กำหนด สำหรับระบบที่ใช้ ANFIS เป็นกลไกหลักซึ่งแบ่งเป็น 4 ฟังก์ชันเซต คือ

- 1) Small มีค่าอยู่ในช่วง [0 0 6.86 46.45]
- 2) Medium มีค่าอยู่ในช่วง [4.22 41.17 86.03 120.30]
- 3) Large มีค่าอยู่ในช่วง [74.15 116.40 165.20 196.90]
- 4) Very large มีค่าอยู่ในช่วง [165.20 196.90 220.60 220.60]

เมื่อระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้สามารถปรับตัวให้เป็นแบบจำลองที่เหมาะสมที่สุดแล้ว แบบจำลองที่ได้จะถูกนำไปใช้งานในโหมดการทำงาน (Working mode) ต่อไป

2. โหมดของการทำงาน (Working mode)

สำหรับในโหมดการทำงานจะใช้แบบจำลองที่ได้จากโหมดของการฝึกหัดมาใช้งาน โดยกระบวนการทำงานจะเป็นแบบออนไลน์ (Online) ซึ่งแบบจำลองดังกล่าวจะทำหน้าที่เสมือนเป็นระบบอนุมานตรรกะคลุมเครือสามารถแสดงได้ดังรูปที่ 3.35



รูปที่ 3.35 การทำงานในโหมดการทำงาน (Working mode)


จากรูปที่ 3.35 การทำงานในโหมดการทำงาน โดยระบบที่นำเสนอจะมีข้อมูลอินพุตเข้ามา 2 อินพุต ก็คือของ Approximation coefficient ของค่าความเร็วเฉลี่ยและ Approximation coefficient ของค่าเบี่ยงเบนมาตรฐานของเวลาในขณะที่ยอดรถกำลังเข้ามาในพื้นที่ถนนที่กำหนดให้กับแบบจำลองที่ได้จากโหมดของการฝึกหัดซึ่งทำหน้าที่เสมือนเป็นระบบอนุมานตรรกะคลุมเครือและทำหน้าที่ในการตัดสินใจเพื่อหาคำตอบของข้อมูลอินพุตที่เข้ามา โดยคำตอบที่ได้จากกระบวนการทำงานคือจะบ่งบอกสภาพจราจรที่ปกติ (Normal) หรือผิดปกติ (Abnormal) จากนั้นผลลัพธ์ที่ได้เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากระบบอนุমানตรระกะคลุมเครือบนฐานโครงข่ายปรับตัวได้นำไปใช้กับวิธีการเสียงข้างมาก (Majority voting) เพื่อช่วยเพิ่มความถูกต้องของระบบในการตรวจจับอุบัติเหตุการณ์ และจะถูกนำไปพิจารณาในการจำแนกลักษณะทางอุบัติเหตุการณ์

หลังจากที่พัฒนาระบบให้มีความสามารถในการบ่งบอกสภาพจราจรที่ปกติ (Normal) และผิดปกติ (Abnormal) ได้อย่างมีประสิทธิภาพแล้ว ระบบยังได้นำเสนอกระบวนการในการจำแนก ลักษณะของอุบัติเหตุการณ์ ซึ่งจะอธิบายหลักการทำงานได้ในหัวข้อถัดไป

3.2.1 ระบบตรวจจับและจำแนกอุบัติเหตุการณ์ทางจราจรแบบอัตโนมัติ โดยใช้การแปลงเวฟ เล็ตเติมหน่วยและระบบอนุমানตรระกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ร่วมกับ วิธีการเสียงข้างมาก

ในหัวข้อนี้จะอธิบายถึงระบบตรวจจับและจำแนกอุบัติเหตุการณ์ทางจราจรแบบอัตโนมัติ โดยใช้การแปลงเวฟเล็ตเติมหน่วยและระบบอนุমানตรระกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ร่วมกับ วิธีการเสียงข้างมาก แสดงได้ดังรูปที่ 3.36




รูปที่ 3.36 หลักการทำงานโดยรวมของระบบระบบตรวจจับและจำแนกอุบัติเหตุการณ์ทางจราจร

ระบบที่นำเสนอสำหรับการตรวจจับและจำแนกอุบัติเหตุการณ์ทางจราจรแบบอัตโนมัติแสดงได้ดังรูปที่ 3.36 โดยในการตรวจจับและจำแนกอุบัติเหตุการณ์ทางจราจร (Traffic incident) ของระบบจะเริ่มจากการประมวลผลสัญญาณโดยใช้การแปลงเวฟเล็ตเติมหน่วยและใช้ระบบอนุমানตรระกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ร่วมกับการใช้วิธีการเสียงข้างมากในการตัดสินใจเพื่อบ่งบอกสภาพจราจรที่ปกติหรือผิดปกติและระบบจะจำแนกลักษณะของอุบัติเหตุการณ์ทางจราจรที่เกิดขึ้น เมื่อระบบตรวจจับสภาพจราจรที่ผิดปกติ (Abnormal) โดยลักษณะของอุบัติเหตุการณ์จำแนกได้ออกเป็น 3 แบบ คือ 1 Lane blocking, 2 Lane blocking และ 3 Lane blocking ในการนำไปใช้งานจริงเมื่อระบบแจ้งสถานะและลักษณะของสภาพจราจรบนท้องถนนได้ทันท่วงที่จะช่วยทำให้เจ้าหน้าที่และหน่วยงานที่เกี่ยวข้องสามารถบริหารจัดการและดำเนินการขจัดปัญหาที่เกิดขึ้นได้อย่างเร็วที่สุด

สำหรับการออกแบบวิธีการจำแนกลักษณะของอุบัติเหตุการณ์ (Classification)

ในการจำแนกลักษณะของอุบัติเหตุการณ์ ซึ่งได้นิยามลักษณะของอุบัติเหตุการณ์ไว้ 3 แบบ คือ แบบ 1 Lane blocking, 2 Lane blocking และ 3 Lane blocking ซึ่งอุบัติเหตุการณ์ที่เกิดขึ้นแต่ละเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นิยามให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

แบบจะส่งผลถึงลักษณะของข้อมูลจราจรที่นำมาใช้เป็นอินพุทของระบบ ทำให้ระบบที่นำเสนอสามารถจำแนกอุบัติเหตุที่เกิดขึ้นได้แสดงได้ดังรูปที่ 3.37



รูปที่ 3.37 การจำแนกลักษณะของอุบัติเหตุ

โดยกระบวนการในการจำแนกลักษณะของอุบัติเหตุจะสามารถแบ่งการทำงานได้ออกเป็น 2 ขั้นตอน คือ

1. ขั้นตอนของการหาค่าระดับอ้างอิง (Offline phase)

สำหรับขั้นตอนของการหาค่าระดับอ้างอิงจะมีกระบวนการทำงานจะเป็นแบบออฟไลน์ (Offline) โดยในการจำแนกลักษณะของอุบัติเหตุจะใช้ข้อมูลอินพุทที่เป็นผลของการแปลงเวฟเล็ทเติมหน่วยซึ่งก็คือค่าแมกนิจูด (Magnitude) ของอินพุททั้ง 2 และใช้ผลลัพธ์ที่ได้จากระบบอนุกรมตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้เป็นข้อมูลในการอ้างอิงเพื่อให้ได้มาซึ่งช่วงของค่าที่เหมาะสมที่ใช้ในการตัดสินใจสำหรับการจำแนกลักษณะของอุบัติเหตุ

2. ขั้นตอนของการนำไปใช้งาน (Online phase)

สำหรับขั้นตอนของการนำไปใช้งาน ซึ่งก็คือการนำช่วงของค่าระดับอ้างอิงจากขั้นตอนของการหาค่าระดับอ้างอิงที่จะนำมาใช้ในการตัดสินใจ เพื่อกำหนดเป็นเงื่อนไขในการจำแนกลักษณะของอุบัติเหตุทั้ง 3 แบบคือ 1 Lane blocking, 2 Lane blocking และ 3 Lane blocking

3.3 วิธีการประเมินประสิทธิภาพของระบบ

สำหรับวิธีการประเมินประสิทธิภาพของระบบเพื่อใช้ตรวจสอบความแม่นยำในการตรวจจับอุบัติเหตุของระบบจะใช้พารามิเตอร์ 2 ตัว ด้วยกันคือ ค่า DR (Detection Rate) และค่า MTTD (Mean Time to Detect) ซึ่งจะสามารถคำนวณได้ดังนี้

3.3.1 คำนวณหาค่า DR (Detection Rate)

ค่า DR คือ ค่าอัตราการตรวจจับอุบัติเหตุของระบบ โดยคิดเป็นเปอร์เซ็นต์ในการตรวจจับสภาพจราจรแบบปกติ (Normal) สภาพจราจรแบบผิดปกติ (Abnormal) และสภาพจราจรทั้งหมดสามารถคำนวณได้ดังสมการที่ 3.4, 3.5 และ 3.6

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$\%DR \text{ (Normal)} = \frac{\text{จำนวนของสภาพจราจรที่ปกติที่สามารถตรวจจับได้}}{\text{จำนวนรวมของสภาพจราจรที่ปกติทั้งหมด}} \quad (3.4)$$

$$\%DR \text{ (Abnormal)} = \frac{\text{จำนวนของสภาพจราจรที่ผิดปกติที่สามารถตรวจจับได้}}{\text{จำนวนรวมของสภาพจราจรที่ผิดปกติทั้งหมด}} \quad (3.5)$$

DR (Total) =

$$\frac{\text{จำนวนของสภาพจราจรที่ปกติที่สามารถตรวจจับได้} + (\text{จำนวนของสภาพจราจรที่ผิดปกติที่สามารถตรวจจับได้})}{(\text{จำนวนรวมของสภาพจราจรที่ปกติทั้งหมด}) + (\text{จำนวนรวมของสภาพจราจรที่ผิดปกติทั้งหมด})} \times 100 \quad (3.6)$$

3.3.2 คำนวณค่า MTD (Mean Time to Detection)


ค่า MTTD คือ ค่าเฉลี่ยของผลรวมเวลาที่ระบบสามารถตรวจจับสภาพจราจรแบบปกติ (Normal) สภาพจราจรแบบผิดปกติ (Abnormal) และสภาพจราจรทั้งหมด สามารถคำนวณได้ดังสมการที่ 3.7, 3.8 และ 3.9

$$MTTD \text{ (Normal)} = \frac{\text{เวลาที่สามารถตรวจจับสภาพจราจรที่ปกติได้}}{\text{จำนวนรวมของสภาพจราจรที่ปกติทั้งหมด}} \quad (3.7)$$


$$MTTD \text{ (Abnormal)} = \frac{\text{เวลาที่สามารถตรวจจับสภาพจราจรที่ผิดปกติได้}}{\text{จำนวนรวมของสภาพจราจรที่ผิดปกติทั้งหมด}} \quad (3.8)$$

$$\text{(Total)} = \frac{(\text{เวลาที่สามารถตรวจจับสภาพจราจรที่ปกติได้}) + (\text{เวลาที่สามารถตรวจจับสภาพจราจรที่ผิดปกติได้})}{(\text{จำนวนรวมของสภาพจราจรที่ปกติทั้งหมด}) + (\text{จำนวนรวมของสภาพจราจรที่ผิดปกติทั้งหมด})} \quad (3.9)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




ก) ความเร็วเฉลี่ย




ข) ค่าเบี่ยงเบนมาตรฐานของเวลาระหว่างการเข้าถึง

รูปที่ 4.2 ลักษณะข้อมูลที่นำมาใช้กับระบบที่นำเสนอสำหรับอุบัติเหตุแบบ 2 Lane blocking



ก) ความเร็วเฉลี่ย



ข) ค่าเบี่ยงเบนมาตรฐานของเวลาระหว่างการเข้าถึง

รูปที่ 4.3 ลักษณะข้อมูลที่นำมาใช้กับระบบที่นำเสนอสำหรับอุบัติเหตุแบบ 3 Lane blocking


ส่วนในการจำลองสภาพจราจรจากโปรแกรมจำลองทางด้านวิศวกรรมจราจร Aimsun ของงานวิจัยที่นำเสนอสำหรับระบบที่ใช้ระบบอนุमानตรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้จะทำการจำลองสภาพจราจรเช่นเดียวกับงานวิจัยที่นำเสนอใน [5-7] และอุบัติเหตุแต่ละแบบจะถูกทำซ้ำ 8 ครั้ง โดยจะทำการหาค่าเฉลี่ยเพื่อใช้เป็นข้อมูลชุดเรียนรู้ (Training) ให้กับระบบอนุमानตรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ และจำลองสภาพจราจรขึ้นใหม่อีก 8 ครั้งซึ่งข้อมูลที่ได้จากการจำลองสภาพจราจรทั้ง 8 ครั้ง จะใช้เป็นข้อมูลชุดทดสอบ (Testing) ดังนั้นจะมีจำนวนข้อมูลที่จะนำไปเป็นอินพุตให้กับระบบที่นำเสนอทั้งหมด 12,480 samples

4.2 ผลของการแปลงเวฟเล็ตเต็มหน่วย

สำหรับผลการแปลงเวฟเล็ตเต็มหน่วยของระบบที่นำเสนอนี้ได้เลือกใช้เวฟเล็ตแม่ (Mother wavelet) เป็น “Daubechies-2” และการแปลงเวฟเล็ตเต็มหน่วยจะถูกวิเคราะห์ที่ 1 ระดับ (1 level analysis)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

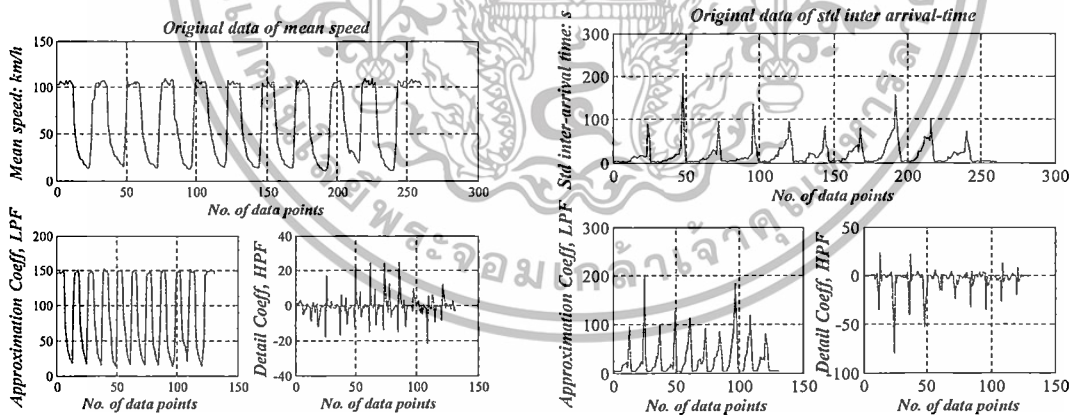
เมื่อข้อมูลอินพุททั้ง 2 ซึ่งก็คือค่าความเร็วเฉลี่ย (Mean speed) และค่าเบี่ยงเบนมาตรฐานของเวลาระหว่างการเข้าถึง (Standard deviation of inter-arrival time) ถูกแปลงเวฟเล็ตเต็มหน่วยจะได้สัญญาณของอินพุททั้ง 2 ในโดเมนเวฟเล็ต (Wavelet domain) โดยสามารถแสดงผลการแปลงเวฟเล็ตเต็มหน่วยของข้อมูลจราจรแบบ 1 Lane blocking, 2 Lane blocking และ 3 Lane blocking ได้ดังรูปที่ 4.4, 4.5 และ 4.6



ก) ความเร็วเฉลี่ย

ข) ค่าเบี่ยงเบนมาตรฐานของเวลาระหว่างการเข้าถึง

รูปที่ 4.4 ลักษณะข้อมูลที่ได้จากการแปลงเวฟเล็ตเต็มหน่วยสำหรับอุบัติเหตุแบบ 1 Lane blocking

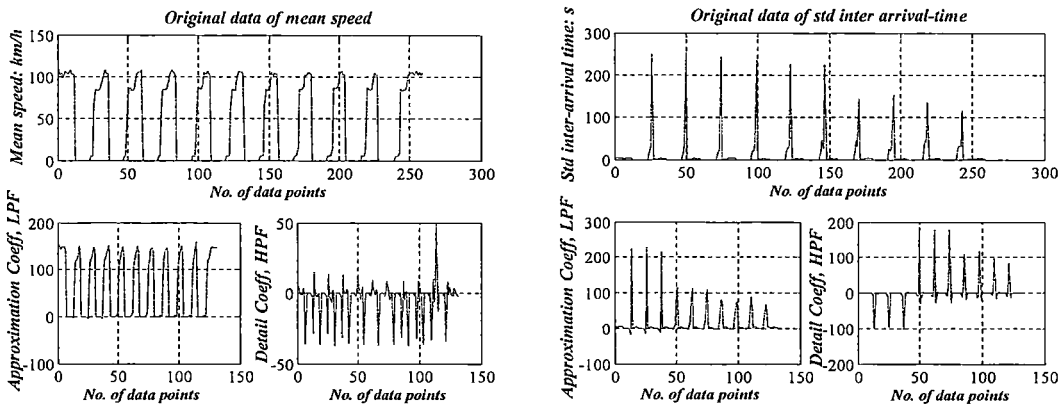


ก) ความเร็วเฉลี่ย

ข) ค่าเบี่ยงเบนมาตรฐานของเวลาระหว่างการเข้าถึง

รูปที่ 4.5 ลักษณะข้อมูลที่ได้จากการแปลงเวฟเล็ตเต็มหน่วยสำหรับอุบัติเหตุแบบ 2 Lane blocking

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ก) ความเร็วเฉลี่ย

ข) ค่าเบี่ยงเบนมาตรฐานของเวลาระหว่างการเข้าถึง

รูปที่ 4.6 ลักษณะข้อมูลที่ได้จากการแปลงเวฟเล็ดเต็มหน่วยสำหรับอุบัติเหตุแบบ 3 Lane blocking

เมื่อพิจารณาลักษณะข้อมูลของผลการแปลงของอินพุตทั้ง 2 จะเห็นได้ว่าลักษณะข้อมูลมีความผันผวนลดลงและจำนวนของข้อมูลลดลงครึ่งหนึ่ง เนื่องจากการแปลงเวฟเล็ดเต็มหน่วยจะช่วยการดึงคุณลักษณะเด่นของข้อมูลออกมา (Feature extraction) และลดสัญญาณรบกวนลง (De-noising) เพื่อส่งผลให้กระบวนการตัดสินใจ

4.3 ผลการเปรียบเทียบวิธีการทางปัญญาประดิษฐ์ (Artificial Intelligence)

4.3.1 ระบบอนุมานตรรกะคลุมเครือ (Fuzzy Inference System: FIS)

4.3.1.1 ระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้ระบบอนุมานตรรกะคลุมเครือและวิธีการเสียงข้างมาก

การเปรียบเทียบของระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้ระบบอนุมานตรรกะคลุมเครือและวิธีการเสียงข้างมากในแต่ละการตรวจจับอุบัติเหตุทั้ง 3 แบบ ได้ดังนี้

ตารางที่ 4.1 DR และ MTTD ของ 1 Lane blocking โดยใช้ขนาดหน้าต่าง 5 samples ของระบบอนุมานตรรกะคลุมเครือ

Window size: 5 samples	No. of detection	can detect	DR (%)	Total Time to Detection (s)	MTTD (s)
Normal	231	217	93.93	14400	62.33
Abnormal	185	147	79.54	11760	63.57
Overall	416	364	87.50	26160	62.88

จากตารางที่ 4.1 ในส่วนของผลลัพธ์ทั้งหมด (Overall) ของ 1 Lane blocking สำหรับระบบที่นำเสนอใน [6] สามารถตรวจจับอุบัติเหตุโดยให้ค่าอัตราการตรวจจับ (DR) = 87.50% และค่าเฉลี่ยของผลรวมเวลาที่ระบบสามารถตรวจจับอุบัติเหตุ (MTTD) ประมาณ 1 นาที เมื่อพิจารณาเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การตรวจจับสภาพจราจรที่ปกติ (Normal) จะพบว่าค่าอัตราการตรวจจับ (DR) สูงคือ 93.33% ในขณะที่การตรวจจับสภาพจราจรที่ผิดปกติ (Abnormal) สำหรับอุบัติเหตุการแบบ 1 Lane blocking จะให้ค่าอัตราการตรวจจับ (DR) = 79.54% ซึ่งในความเป็นจริงของอุบัติเหตุการแบบ 1 Lane blocking จะมีการปิดถนน 1 ช่องทางจราจร ทำให้นยานพาหนะที่เคลื่อนที่เข้ามาจะมีช่องทางในการหลบหลีกได้ 2 ช่องทางจราจร ทำให้การตรวจจับสภาพจราจรที่ผิดปกติทำได้ยากกว่าการตรวจจับสภาพจราจรที่ปกติ

ตารางที่ 4.2 DR และ MTTD ของ 1 Lane blocking โดยใช้ขนาดหน้าต่าง 7 samples ของระบบอนุมานตรรกะคลุมเครือ

Window size: 7 samples	No. of detection	can detect	DR (%)	Total Time to Detection (s)	MTTD (s)
Normal	178	170	95.50	18300	102.80
Abnormal	118	95	80.50	11790	99.91
Overall	296	265	89.52	30090	101.65

จากตารางที่ 4.2 แสดงให้เห็นว่าเมื่อขนาดหน้าต่างเพิ่มขึ้นจาก 5 samples เป็น 7 samples พบว่าค่าอัตราการตรวจจับ (DR) จะให้ค่าที่เพิ่มขึ้น อย่างไรก็ตามในการเพิ่มขึ้นของขนาดหน้าต่างทำให้ค่าเฉลี่ยของผลรวมเวลาที่ระบบสามารถตรวจจับอุบัติเหตุ (MTTD) เพิ่มขึ้นประมาณ 40 วินาที ดังนั้นในการนำไปใช้งานจริงต้องพิจารณาในการเลือกใช้ขนาดหน้าต่างให้เหมาะสม

ผลลัพธ์ต่อมาของระบบที่นำเสนอใน [6] ในการตรวจจับอุบัติเหตุการแบบ 2 Lane blocking จะแสดงได้ดังตารางที่ 4.3 และตารางที่ 4.4 สำหรับขนาดหน้าต่าง 5 samples และ 7 samples ตามลำดับ

ตารางที่ 4.3 DR และ MTTD ของ 2 Lane blocking โดยใช้ขนาดหน้าต่าง 5 samples ของระบบอนุมานตรรกะคลุมเครือ

Window size: 5 samples	No. of detection	can detect	DR (%)	Total Time to Detection (s)	MTTD (s)
Normal	224	184	82.14	11910	63.16
Abnormal	192	188	97.91	13080	68.12
Overall	416	372	89.42	24990	60.07

ตารางที่ 4.4 DR และ MTTD ของ 2 Lane blocking โดยใช้ขนาดหน้าต่าง 7 samples ของระบบอนุมานตรรกะคลุมเครือ

Window size: 7 samples	No. of detection	can detect	DR (%)	Total Time to Detection (s)	MTTD (s)
Normal	168	141	83.92	14880	88.57
Abnormal	128	125	97.65	13230	103.35
Overall	296	266	89.86	28110	94.96

จากตารางที่ 4.3 และตารางที่ 4.4 จะเห็นว่าระบบที่นำเสนอใน [6] จะให้ค่าอัตราการตรวจจับ (DR) ที่สูง (ประมาณ 98%) สำหรับตรวจจับสภาพจราจรที่ผิดปกติ (Abnormal) ของอุบัติเหตุแบบ 2 Lane blocking ซึ่งในการนำไปใช้งานจริงจะเห็นได้ว่าอุบัติเหตุแบบ 2 Lane blocking จะมีการปิดถนน 2 ช่องจราจร ทำใหยานพาหนะมีช่องทางการหลบหลีกน้อย ดังนั้นในการตรวจจับสภาพจราจรที่ผิดปกติ (Abnormal) จะสามารถตรวจจับได้ง่ายและผลลัพธ์ที่ได้ก็จะให้ค่าอัตราการตรวจจับ (DR) ที่สูงด้วยเช่นกัน

และผลลัพธ์ของระบบที่นำเสนอใน [6] ในการตรวจจับอุบัติเหตุแบบ 3 Lane blocking จะแสดงได้ดังตารางที่ 4.5 และตารางที่ 4.6 สำหรับขนาดหน้าต่าง 5 samples และ 7 samples ตามลำดับ

ตารางที่ 4.5 DR และ MTTD ของ 3 Lane blocking โดยใช้ขนาดหน้าต่าง 5 samples ของระบบอนุমানตรระกะคลุมเครือ

Window size:	No. of	can detect	DR (%)	Total Time to	MTTD
5 samples	detection			Detection (s)	(s)
Normal	224	176	78.57	11880	53.03
Abnormal	192	176	91.67	12000	62.50
Overall	416	352	84.61	23880	57.40

ตารางที่ 4.6 DR และ MTTD ของ 3 Lane blocking โดยใช้ขนาดหน้าต่าง 7 samples ของระบบอนุমানตรระกะคลุมเครือ

Window size:	No. of	can detect	DR (%)	Total Time to	MTTD
7 samples	detection			Detection (s)	(s)
Normal	168	127	76.00	13350	79.46
Abnormal	128	120	93.75	12690	99.14
Overall	296	247	83.45	26040	87.97

จากตารางที่ 4.5 และตารางที่ 4.6 ก็ยังให้ค่าอัตราการตรวจจับ (DR) ที่สูง สำหรับการตรวจจับสภาพจราจรที่ผิดปกติ (Abnormal) เนื่องในการใช้งานจริงอุบัติเหตุแบบ 3 Lane blocking จะปิดถนน 3 ช่องทางจราจรทำใหยานพาหนะไม่มีช่องทางการจราจรในการหลบหลีกและเมื่อสภาพจราจรกำลังเข้าสู่สภาวะปกติก็จะใช้ระยะเวลาหนึ่งเพื่อใหยานพาหนะเคลื่อนตัวจากหยุดนิ่ง จึงทำให้การตรวจจับสภาพจราจรแบบผิดปกติ (Abnormal) มีการตรวจจับผิดพลาดเล็กน้อย

จะเห็นได้ว่าข้อมูลจราจรมีความไม่แน่นอนและมีความคลุมเครือของข้อมูลอยู่มากทำให้การนำระบบอนุমানตรระกะคลุมเครือมาพิจารณาเพื่อตัดสินใจให้ได้มาซึ่งคำตอบของระบบจะทำได้ยาก ดังนั้นระบบที่นำเสนอใน [7] ที่จะได้กล่าวถึงในหัวข้อถัดไปได้้นำเทคนิคทางด้านการประมวลสัญญาณ (Signal processing) ก็คือการแปลงเวฟเล็ตเติมหน่วย (Discrete Wavelet Transform: DWT) มาช่วยในการสกัดคุณลักษณะเด่นของข้อมูล (Feature extraction) ออกจากข้อมูลต้นฉบับซึ่งมีความเอกสารนี้เป็นเอกสารที่สว่นไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ผันผวนของข้อมูลอยู่มาก (Fluctuation) และช่วยลดสัญญาณรบกวน (De-noising) ที่ปะปนเข้ามา กับสัญญาณต้นฉบับก่อนนำมาเป็นข้อมูลอินพุตให้กับระบบอนุมานตรรกะคลุมเครือ

4.3.1.2 ระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้การแปลงเวฟเล็ตเต็มหน่วยและระบบอนุมานตรรกะคลุมเครือร่วมกับวิธีการเสียงข้างมาก

ในหัวข้อนี้จะแสดงผลการเปรียบเทียบของระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้การแปลงเวฟเล็ตเต็มหน่วยและระบบอนุมานตรรกะคลุมเครือร่วมกับวิธีการเสียงข้างมากในแต่ละการตรวจจับอุบัติเหตุทั้ง 3 แบบ ได้ดังนี้

ผลลัพธ์ของระบบที่นำเสนอใน [7] ในการตรวจจับอุบัติเหตุแบบ 1 Lane blocking จะแสดงได้ดังตารางที่ 4.7 และตารางที่ 4.8 สำหรับขนาดหน้าต่าง 3 samples และ 5 samples ตามลำดับ

ตารางที่ 4.7 DR และ MTTD ของ 1 Lane blocking โดยใช้ขนาดหน้าต่าง 3 samples ของระบบอนุมานตรรกะคลุมเครือที่ใช้การแปลงเวฟเล็ตเต็มหน่วย

Window size: 3 samples	No. of detection	can detect	DR (%)	Total Time to Detection (s)	MTTD (s)
Normal	184	147	79.89	11280	61.30
Abnormal	160	146	91.25	13320	83.25
Overall	344	293	85.17	24600	71.51

ตารางที่ 4.8 DR และ MTTD ของ 1 Lane blocking โดยใช้ขนาดหน้าต่าง 5 samples ของระบบอนุมานตรรกะคลุมเครือที่ใช้การแปลงเวฟเล็ตเต็มหน่วย

Window size: 5 samples	No. of detection	can detect	DR (%)	Total Time to Detection (s)	MTTD (s)
Normal	114	108	94.73	16320	143.16
Abnormal	94	91	96.80	14760	157.02
Overall	208	199	95.67	31080	149.42

จากตารางที่ 4.7 ในส่วนของผลลัพธ์ทั้งหมด (Overall) ของ 1 Lane blocking สำหรับระบบที่นำเสนอใน [7] สามารถตรวจจับอุบัติเหตุโดยให้ค่าอัตราการตรวจจับ (DR) = 85.17% และค่าเฉลี่ยของผลรวมเวลาที่ระบบสามารถตรวจจับอุบัติเหตุ (MTTD) = 71.51 วินาที และจากตารางที่ 4.8 จะพบว่าเมื่อขนาดหน้าต่างมีขนาดเพิ่มขึ้นจาก 3 samples เป็น 5 samples ทั้งค่าอัตราการตรวจจับ (DR) ของผลลัพธ์ทั้งหมด (Overall) จะเพิ่มขึ้นเป็น 95.67% ด้วยค่าเฉลี่ยของผลรวมเวลาที่ระบบสามารถตรวจจับอุบัติเหตุ (MTTD) = 149.42 วินาที

ต่อมาผลลัพธ์ของระบบที่นำเสนอใน [7] ในการตรวจจับอุบัติเหตุแบบ 2 Lane blocking จะแสดงได้ดังตารางที่ 4.9 และตารางที่ 4.10 สำหรับขนาดหน้าต่าง 3 samples และ 5 samples ตามลำดับ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.9 DR และ MTTD ของ 2 Lane blocking โดยใช้ขนาดหน้าต่างต่าง 3 samples ของระบบ อนุমানตรรกะคลุมเครือที่ใช้การแปลงเวฟเล็ดเต็มหน่วย

Window size: 3 samples	No. of detection	can detect	DR (%)	Total Time to Detection (s)	MTTD (s)
Normal	184	162	88.04	10200	55.43
Abnormal	160	131	81.88	12600	78.75
Overall	344	293	85.17	22800	66.27

ตารางที่ 4.10 DR และ MTTD ของ 2 Lane blocking โดยใช้ขนาดหน้าต่างต่าง 5 samples ของระบบอนุমানตรรกะคลุมเครือที่ใช้การแปลงเวฟเล็ดเต็มหน่วย

Window size: 5 samples	No. of detection	can detect	DR (%)	Total Time to Detection (s)	MTTD (s)
Normal	123	120	97.56	19200	156.09
Abnormal	85	64	75.29	10200	120.00
Overall	208	199	88.46	29400	141.35

จากตารางที่ 4.9 และตารางที่ 4.10 จะเห็นได้ว่าเฉพาะค่าอัตราการตรวจจับ (DR) ของสภาพ จราจรปกติ (Normal) เพิ่มขึ้น ส่วนค่าอัตราการตรวจจับ (DR) ของสภาพจราจรที่ผิดปกติ (Abnormal) มีค่าลดลง แต่ผลลัพธ์โดยรวม (Overall) ของระบบก็ยังคงให้ค่าอัตราการตรวจจับ (DR) ที่สูงขึ้นเมื่อขนาดหน้าต่างเพิ่มขึ้น โดยเพิ่มขึ้นจาก 85.17% เป็น 88.46% และค่าเฉลี่ยของผลรวมเวลา ที่ระบบสามารถตรวจจับอุบัติเหตุได้ (MTTD) สำหรับขนาดหน้าต่างต่าง 3 samples และ 5 samples เท่ากับ 66.27 วินาที และ 141.35 วินาที ตามลำดับ

สำหรับผลลัพธ์ของระบบที่นำเสนอใน [7] ในการตรวจจับอุบัติเหตุแบบ 3 Lane blocking จะแสดงได้ดังตารางที่ 4.11 และตารางที่ 4.12 สำหรับขนาดหน้าต่างต่าง 3 samples และ 5 samples ตามลำดับ

ตารางที่ 4.11 DR และ MTTD ของ 3 Lane blocking โดยใช้ขนาดหน้าต่างต่าง 3 samples ของระบบอนุমানตรรกะคลุมเครือที่ใช้การแปลงเวฟเล็ดเต็มหน่วย

Window size: 3 samples	No. of detection	can detect	DR (%)	Total Time to Detection (s)	MTTD (s)
Normal	184	148	80.43	13260	72.07
Abnormal	160	160	100.00	14400	90.00
Overall	344	308	89.53	27660	80.41

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.12 DR และ MTTD ของ 3 Lane blocking โดยใช้ขนาดหน้าต่างต่าง 5 samples ของระบบอนุมานตรรกะคลุมเครือที่ใช้การแปลงเวฟเล็ตเต็มหน่วย

Window size: 5 samples	No. of detection	can detect	DR (%)	Total Time to Detection (s)	MTTD (s)
Normal	110	100	90.91	17340	157.63
Abnormal	98	98	100.00	16320	166.53
Overall	208	198	95.19	33660	161.83

จากตารางที่ 4.11 และตารางที่ 4.12 ขนาดหน้าต่างที่เพิ่มขึ้นจาก 3 samples เป็น 5 samples ค่าอัตราการตรวจจับ (DR) ของการตรวจจับสภาพจราจรที่ปกติ (Normal) จะเพิ่มขึ้นเป็น 90.91% และค่าอัตราการตรวจจับ (DR) ของการตรวจจับสภาพจราจรที่ผิดปกติ (Abnormal) จะสามารถตรวจจับได้ 100% ซึ่งผลลัพธ์โดยรวม (Overall) จะให้ค่าอัตราการตรวจจับ (DR) เพิ่มขึ้นจาก 89.53% เป็น 95.19% ด้วยค่าเฉลี่ยของผลรวมเวลาที่ระบบสามารถตรวจจับอุบัติเหตุได้ (MTTD) = 161.83 วินาที

ทั้งนี้ในการตรวจจับสภาพจราจรของระบบ ซึ่งก็คือพิจารณาค่าอัตราการตรวจจับ (DR) จะขึ้นอยู่กับกรอกแบบฟังก์ชันสมาชิก (Membership function) และกฎของฟัซซี (Fuzzy rule) ดังนั้นการปรับค่าฟังก์ชันสมาชิก โดยเฉพาะอย่างยิ่งการปรับที่สามารถเรียนรู้จากข้อมูลได้ (Learning from data) จะสามารถเพิ่มอัตราการตรวจจับ (DR) โดยจะได้กล่าวถึงในการนำระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (ANFIS) มาพิจารณาเป็นกลไกหลักให้กับระบบในหัวข้อถัดไป

4.3.2 ระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (ANFIS)

สำหรับระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้การแปลงเวฟเล็ตเต็มหน่วยและระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ร่วมกับวิธีการเสียงข้างมาก ซึ่งอัตราการตรวจจับ (DR) และค่าเฉลี่ยของผลรวมเวลาที่ระบบสามารถตรวจจับอุบัติเหตุได้ (MTTD) ที่เป็นค่าพารามิเตอร์เพื่อบ่งบอกประสิทธิภาพของระบบสำหรับการตรวจจับอุบัติเหตุทั้ง 3 แบบ ได้ดังนี้

ผลลัพธ์ของระบบที่นำเสนอสำหรับการตรวจจับอุบัติเหตุแบบ 1 Lane blocking ขนาดหน้าต่าง 3 samples และขนาดหน้าต่าง 5 samples ตามลำดับถูกนำเสนอตั้งตารางที่ 4.13 และตารางที่ 4.14

ตารางที่ 4.13 DR และ MTTD ของ 1 Lane blocking โดยใช้ขนาดหน้าต่างต่าง 3 samples ของระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (ANFIS)

Window size: 3 samples	No. of detection	can detect	DR (%)	Total Time to Detection (s)	MTTD (s)
Normal	184	184	100.00	15840	86.09
Abnormal	160	152	95.00	14400	90.00
Overall	344	336	97.67	30240	87.91

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.14 DR และ MTTD ของ 1 Lane blocking โดยใช้ ขนาดหน้าต่าง 5 samples ของระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (ANFIS)

Window size: 5 samples	No. of detection	can detect	DR (%)	Total Time to Detection (s)	MTTD (s)
Normal	112	112	100.00	16320	145.72
Abnormal	96	96	100.00	15360	160.00
Overall	208	208	100.00	31680	152.30

จากตารางที่ 4.13 แสดงค่าอัตราการตรวจจับ (DR) และค่าเฉลี่ยของผลรวมเวลาที่ระบบสามารถตรวจจับอุบัติเหตุ (MTTD) ของอุบัติเหตุแบบ 1 Lane blocking ที่ใช้ขนาดหน้าต่าง 3 samples จะให้ค่าอัตราการตรวจจับ (DR) ทั้งหมดเท่ากับ 97.67% และให้ค่าเฉลี่ยของผลรวมเวลาที่ระบบสามารถตรวจจับอุบัติเหตุ (MTTD) เท่ากับ 87.91 วินาที และในตารางที่ 4.14 แสดงค่าอัตราการตรวจจับ (DR) และค่าเฉลี่ยของผลรวมเวลาที่ระบบสามารถตรวจจับอุบัติเหตุ (MTTD) ของอุบัติเหตุแบบ 1 Lane blocking ที่ขนาดหน้าต่าง 5 samples โดยค่าอัตราการตรวจจับ (DR) เพิ่มขึ้นเป็น 100% เมื่อขนาดของหน้าต่างมีขนาดใหญ่ขึ้น ส่วนค่าเฉลี่ยของผลรวมเวลาที่ระบบสามารถตรวจจับอุบัติเหตุ (MTTD) เท่ากับ 152.30 วินาที

ส่วนผลลัพธ์ของระบบที่นำเสนอสำหรับการตรวจจับอุบัติเหตุแบบ 2 Lane blocking ขนาดหน้าต่าง 3 samples และขนาดหน้าต่าง 5 samples ตามลำดับถูกนำเสนอในตารางที่ 4.15 และตารางที่ 4.16

ตารางที่ 4.15 DR และ MTTD ของ 2 Lane blocking โดยใช้ ขนาดหน้าต่าง 3 samples ของระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (ANFIS)

Window size: 3 samples	No. of detection	can detect	DR (%)	Total Time to Detection (s)	MTTD (s)
Normal	184	184	100.00	15840	86.09
Abnormal	160	160	100.00	10560	66.00
Overall	344	344	100.00	26400	76.74

ตารางที่ 4.16 DR และ MTTD ของ 2 Lane blocking โดยใช้ ขนาดหน้าต่าง 5 samples ของระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (ANFIS)

Window size: 5 samples	No. of detection	can detect	DR (%)	Total Time to Detection (s)	MTTD (s)
Normal	96	96	100.00	14400	150.00
Abnormal	112	112	100.00	17280	154.29
Overall	208	208	100.00	31680	152.31

จากตารางที่ 4.15 และ 4.16 แสดงค่าอัตราการตรวจจับ (DR) และค่าเฉลี่ยของผลรวมเวลาที่ระบบสามารถตรวจจับอุบัติเหตุ (MTTD) ของอุบัติเหตุแบบ 2 Lane blocking จะให้ค่าอัตรา
ไม่ว่าการณ์ใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การตรวจจับ (DR) เป็น 100% ทั้งในขนาดหน้าต่าง 3 samples และ ขนาดหน้าต่าง 5 samples ส่วนค่าเฉลี่ยของผลรวมเวลาที่ระบบสามารถตรวจจับอุบัติเหตุ (MTTD) จะให้ค่าเท่ากับ 76.74 วินาที และ 152.31 วินาที ตามลำดับ

และผลลัพธ์ของระบบที่นำเสนอสำหรับการตรวจจับอุบัติเหตุแบบ 3 Lane blocking ขนาดหน้าต่าง 3 samples และขนาดหน้าต่าง 5 samples ตามลำดับถูกนำเสนอตั้งตารางที่ 4.17 และตารางที่ 4.18

ตารางที่ 4.17 DR และ MTTD ของ 3 Lane blocking โดยใช้ขนาดหน้าต่าง 3 samples ของระบบอนุমানตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (ANFIS)

Window size: 3 samples	No. of detection	can detect	DR (%)	Total Time to Detection (s)	MTTD (s)
Normal	184	184	100.00	15840	86.09
Abnormal	160	160	100.00	14400	90.00
Overall	344	344	100.00	30240	87.91

ตารางที่ 4.18 DR และ MTTD ของ 3 Lane blocking โดยใช้ขนาดหน้าต่าง 5 samples ของระบบอนุমানตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (ANFIS)

Window size: 5 samples	No. of detection	can detect	DR (%)	Total Time to Detection (s)	MTTD (s)
Normal	112	112	100.00	16320	145.71
Abnormal	96	96	100.00	14400	150.00
Overall	208	208	100.00	30720	147.69

จากตารางที่ 4.17 และ 4.18 แสดงค่าอัตราการตรวจจับ (DR) และค่าเฉลี่ยของผลรวมเวลาที่ระบบสามารถตรวจจับอุบัติเหตุ (MTTD) ของอุบัติเหตุแบบ 3 Lane blocking จะให้ค่าอัตราการตรวจจับ (DR) เป็น 100% ทั้งใน ขนาดหน้าต่าง 3 samples และ ขนาดหน้าต่าง 5 samples ส่วนค่าเฉลี่ยของผลรวมเวลาที่ระบบสามารถตรวจจับอุบัติเหตุ (MTTD) จะมีค่าเท่ากับ 87.91 วินาที และ 147.69 วินาที ตามลำดับ

เมื่อพิจารณาระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้การแปลงเวฟเล็ตเติมหน่วยและระบบอนุমানตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ร่วมกับวิธีการเสี่ยงข้างมากจะเห็นได้ว่าระบบสามารถตรวจจับอุบัติเหตุได้อย่างแม่นยำและมีความถูกต้อง

4.4 ผลการเปรียบเทียบของระบบที่นำเสนอ

ในส่วนหัวข้อนี้จะอธิบายถึงผลการเปรียบเทียบของระบบที่นำเสนอกับระบบที่นำเสนอใน [5] โดยระบบที่นำเสนอในงานวิจัย [6] ก็คือระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้ระบบอนุমানตรรกะคลุมเครือและระบบที่นำเสนอในงานวิจัย [7] ก็คือระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้การแปลงเวฟเล็ตเติมหน่วยและระบบอนุমানตรรกะคลุมเครือ รวมถึงระบบตรวจจับสภาพจราจรที่เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ผิดปกติโดยใช้การแปลงเวฟเล็ตเติมหน่วยและระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ ซึ่งผลการเปรียบเทียบจะพิจารณาถึงค่าอัตราการตรวจจับ (DR) และค่าเฉลี่ยของผลรวมเวลาที่ระบบสามารถตรวจจับอุบัติเหตุ (MTTD) โดยจะสามารถแสดงได้ดังตารางที่ 4.19

ตารางที่ 4.19 การเปรียบเทียบผลลัพธ์ของระบบที่นำเสนอ

ระบบสำหรับตรวจจับอุบัติเหตุ	DR (%)	MTTD (s)
1 Lane blocking		
- ระบบที่นำเสนอในงานวิจัยนี้ (ANFIS with DWT), ขนาดหน้าต่าง 5 samples	100.00	152.30
- ระบบที่นำเสนอในงานวิจัย [7] (FIS with DWT), ขนาดหน้าต่าง 5 samples	95.67	149.42
- ระบบที่นำเสนอในงานวิจัย [6] (FIS without DWT), ขนาดหน้าต่าง 7 samples	89.52	101.65
2 Lane blocking		
- ระบบที่นำเสนอในงานวิจัยนี้ (ANFIS with DWT), ขนาดหน้าต่าง 3 samples	100.00	86.09
- ระบบที่นำเสนอในงานวิจัย [7] (FIS with DWT), ขนาดหน้าต่าง 5 samples	88.46	141.35
- ระบบที่นำเสนอในงานวิจัย [6] (FIS without DWT), ขนาดหน้าต่าง 7 samples	89.86	94.96
3 Lane blocking		
- ระบบที่นำเสนอในงานวิจัยนี้ (ANFIS with DWT), ขนาดหน้าต่าง 3 samples	100.00	87.91
- ระบบที่นำเสนอในงานวิจัย [7] (FIS with DWT), ขนาดหน้าต่าง 5 samples	95.19	161.83
- ระบบที่นำเสนอในงานวิจัย [6] (FIS without DWT), ขนาดหน้าต่าง 5 samples	84.61	57.40
ระบบที่นำเสนอใน [5]	91.00	132.00

จากตารางที่ 4.19 แสดงการเปรียบเทียบผลลัพธ์ของระบบที่นำเสนอในงานวิจัยนี้และระบบที่นำเสนอก่อนหน้านี้ใน [5-7] โดยผลลัพธ์ที่นำมาเปรียบเทียบเป็นผลลัพธ์ที่ดีที่สุดในแต่ละอุบัติเหตุ เมื่อพิจารณาในงานวิจัยที่นำเสนอโดยใช้ระบบอนุมานตรรกะคลุมเครือเพียงอย่างเดียวจะเห็นได้ว่าเมื่อนำเปรียบเทียบกับงานวิจัยที่นำเสนอใน [5] จะให้ค่าอัตราการตรวจจับ (DR) ที่ใกล้เคียงกัน แต่ค่าเฉลี่ยของผลรวมเวลาที่ระบบสามารถตรวจจับอุบัติเหตุ (MTTD) จะใช้เวลาน้อยกว่า

ต่อมาระบบที่นำเสนอได้พัฒนาโดยเพิ่มการแปลงเวฟเล็ตเติมหน่วยมาช่วยเพิ่มความถูกต้องในการตรวจจับอุบัติเหตุ เมื่อพิจารณาลักษณะของอุบัติเหตุแบบ 1 Lane blocking และ 3 Lane blocking จะเห็นได้ว่าระบบที่นำเสนอในงานวิจัย [7] จะให้อัตราการตรวจจับ (DR) ที่ดีกว่าระบบที่นำเสนอในงานวิจัย [6] มีเฉพาะลักษณะอุบัติเหตุแบบ 2 Lane blocking ที่ให้ค่าใกล้เคียงกันกับระบบที่นำเสนอในงานวิจัย [6] ส่วนค่าเฉลี่ยของผลรวมเวลาที่ระบบสามารถตรวจจับอุบัติเหตุ (MTTD) จะใช้เวลาในการตรวจจับอุบัติเหตุเพิ่มขึ้นเนื่องจากการแปลงเวฟเล็ตเติมหน่วยมาใช้ในการคำนวณค่า

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ระบบและกลไกหลักที่ใช้ในการตรวจจับอุบัติเหตุการณ์ก็คือระบบอนุมานตรรกะคลุมเครือ ซึ่งจำเป็นต้องใช้ผู้เชี่ยวชาญในการกำหนดค่าฟังก์ชันสมาชิก (Membership function) และกฎของฟัซซี (Fuzzy rule) ขึ้นใหม่เพื่อให้มีความเหมาะสมกับลักษณะของข้อมูลที่มีการเปลี่ยนแปลงไป

จากนั้นระบบที่นำเสนอในงานวิจัยนี้ได้นำระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้มาใช้เป็นกลไกหลักแทนระบบอนุมานตรรกะคลุมเครือ ทำให้ผลลัพธ์ที่ได้คือให้ค่าอัตราการตรวจจับ (DR) ที่ดีที่สุดในทุกๆ กรณีทั้งในกรณีของ 1 Lane blocking, 2 Lane blocking และ 3 lane blocking นอกจากนี้กลไกหลักที่ใช้ในระบบซึ่งก็คือระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ที่สามารถเรียนรู้จากข้อมูลได้ (Learning from data) เพื่อปรับค่าฟังก์ชันสมาชิก (Membership function) และกฎของฟัซซี (Fuzzy rule) สำหรับสร้างแบบจำลองที่เหมาะสมที่สุดสามารถนำไปใช้งานจริงได้

4.5 ผลของการจำแนกอุบัติเหตุการณ์ทางจราจร

ในการจำแนกลักษณะของอุบัติเหตุการณ์ ซึ่งได้นิยามลักษณะของอุบัติเหตุการณ์ไว้ 3 แบบ คือ แบบ 1 Lane blocking, 2 Lane blocking และ 3 Lane blocking ซึ่งผลลัพธ์ของระบบที่นำเสนอสำหรับการการจำแนกลักษณะของอุบัติเหตุการณ์นำเสนอได้ดังตารางที่ 4.20

ตารางที่ 4.20 การจำแนกลักษณะของอุบัติเหตุการณ์แบบ 1 Lane blocking ของระบบอนุมานตรรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (ANFIS)

การทดสอบครั้งที่	จำนวนของอุบัติเหตุการณ์ที่เกิดขึ้นทั้งหมด	จำนวนของอุบัติเหตุการณ์ที่สามารถจำแนกได้ถูกต้อง	เปอร์เซ็นต์ของอุบัติเหตุการณ์ที่สามารถจำแนกได้
1	41.00	41.00	100.00
2	42.00	42.00	100.00
3	42.00	42.00	100.00
4	38.00	38.00	100.00
5	44.00	44.00	100.00
6	38.00	38.00	100.00
7	44.00	44.00	100.00
8	42.00	42.00	100.00
รวม	331.00	331.00	100.00

จากตารางที่ 4.20 การจำแนกลักษณะของอุบัติเหตุการณ์แบบ 1 Lane blocking จะเห็นได้ว่าจากผลการทดสอบทั้ง 8 ครั้งระบบสามารถจำแนกลักษณะอุบัติเหตุการณ์แบบ 1 Lane blocking ได้ถูกต้องโดยเปอร์เซ็นต์ของอุบัติเหตุการณ์ที่สามารถจำแนกได้เฉลี่ยเท่ากับ 100% และผลลัพธ์ของระบบที่นำเสนอสำหรับจำแนกลักษณะของอุบัติเหตุการณ์แบบ 2 Lane blocking นำเสนอได้ดังตารางที่ 4.21

ตารางที่ 4.21 การจำแนกลักษณะของอุบัติเหตุการแบบ 2 Lane blocking ของระบบอนุมาตรฐานรถจักรยานยนต์ (ANFIS)

การทดสอบครั้งที่	จำนวนของอุบัติเหตุที่เกิดขึ้นทั้งหมด	จำนวนของอุบัติเหตุที่สามารถจำแนกได้ถูกต้อง	เปอร์เซ็นต์ของอุบัติเหตุที่สามารถจำแนกได้
1	45.00	45.00	100.00
2	46.00	46.00	100.00
3	48.00	47.00	97.92
4	48.00	46.00	95.83
5	49.00	49.00	100.00
6	49.00	48.00	97.96
7	46.00	46.00	100.00
8	48.00	47.00	97.92

จากตารางที่ 4.21 การจำแนกลักษณะของอุบัติเหตุการแบบ 2 Lane blocking จะเห็นได้ว่าจากผลการทดสอบทั้ง 8 ครั้งระบบสามารถจำแนกลักษณะอุบัติเหตุการแบบ 2 Lane blocking ได้ถูกต้องโดยเปอร์เซ็นต์ของอุบัติเหตุที่สามารถจำแนกได้เฉลี่ยเท่ากับ 97.92% และผลลัพธ์ของระบบที่นำเสนอสำหรับจำแนกลักษณะของอุบัติเหตุการแบบ 3 Lane blocking นำเสนอได้ดังตารางที่ 4.22

ตารางที่ 4.22 การจำแนกลักษณะของอุบัติเหตุการแบบ 3 Lane blocking ของระบบอนุมาตรฐานรถจักรยานยนต์ (ANFIS)

การทดสอบครั้งที่	จำนวนของอุบัติเหตุที่เกิดขึ้นทั้งหมด	จำนวนของอุบัติเหตุที่สามารถจำแนกได้ถูกต้อง	เปอร์เซ็นต์ของอุบัติเหตุที่สามารถจำแนกได้
1	50.00	50.00	100.00
2	51.00	51.00	100.00
3	50.00	50.00	100.00
4	50.00	50.00	100.00
5	50.00	50.00	100.00
6	50.00	50.00	100.00
7	50.00	50.00	100.00
8	50.00	50.00	100.00
รวม	401.00	401.00	100.00

จากตารางที่ 4.22 การจำแนกลักษณะของอุบัติเหตุการแบบ 3 Lane blocking จะเห็นได้ว่าจากผลการทดสอบทั้ง 8 ครั้งระบบสามารถจำแนกลักษณะอุบัติเหตุการแบบ 3 Lane blocking ได้ถูกต้องโดยเปอร์เซ็นต์ของอุบัติเหตุที่สามารถจำแนกได้เฉลี่ยเท่ากับ 100% เช่นเดียวกับการจำแนกลักษณะของอุบัติเหตุการแบบ 1 Lane blocking

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

และเมื่อพิจารณาผลการจำแนกลักษณะของอุบัติเหตุทั้ง 3 แบบ คือ 1 Lane blocking, 2 Lane blocking และ 3 Lane blocking สำหรับระบบอนุमानตรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (ANFIS) จะสามารถแสดงได้ดังตารางที่ 4.23

ตารางที่ 4.23 ผลลัพธ์ของการจำแนกลักษณะของอุบัติเหตุสำหรับระบบอนุमानตรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (ANFIS)

ชนิดของอุบัติเหตุ	เปอร์เซ็นต์ของอุบัติเหตุที่สามารถจำแนกได้
1 Lane blocking	100.00
2 Lane blocking	97.92
3 Lane blocking	100.00

จากตารางที่ 4.23 ผลลัพธ์ของการจำแนกลักษณะของอุบัติเหตุสำหรับระบบอนุमानตรกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ (ANFIS) จะเห็นได้ว่าลักษณะอุบัติเหตุแบบ 2 Lane blocking จะให้เปอร์เซ็นต์ของอุบัติเหตุที่สามารถจำแนกได้เท่ากับ 97.92% และสำหรับลักษณะอุบัติเหตุแบบ 1 Lane blocking และ 3 Lane blocking จะให้เปอร์เซ็นต์ของอุบัติเหตุที่สามารถจำแนกได้คือ 100% โดยระบบสามารถจำแนกและบ่งบอกลักษณะของอุบัติเหตุได้ถูกต้องทั้งหมด



บทที่ 5

สรุปผล

5.1 สรุปผลการทดลอง

จากการนำเสนอระบบเพื่อตรวจจับและจำแนกอุบัติเหตุทางจราจรบนท้องถนนอย่างอัตโนมัติเพื่อการบริหารจัดการสำหรับหน่วยงานที่เกี่ยวข้องอันจะนำไปสู่การแก้ไขเพื่อบรรเทาปัญหาการจราจรที่เกิดขึ้น เพื่อตรวจจับการเกิดอุบัติเหตุบนท้องถนนได้อย่างทันท่วงที่จะช่วยทำให้เจ้าหน้าที่และหน่วยงานที่เกี่ยวข้องสามารถบริหารจัดการและดำเนินการขจัดปัญหาที่เกิดขึ้นได้อย่างเร็วที่สุดก่อนที่การอุบัติเหตุดังกล่าวจะนำไปสู่ปัญหาการจราจรติดขัดนั้น

ผลลัพธ์ที่ได้จากระบบที่นำเสนอสำหรับระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้ระบบอนุমানตรระกะคลุมเครือและวิธีการเสียงข้างมากที่นำเสนอในงานวิจัยนี้ [6] จะพบว่าระบบสามารถตรวจจับสภาพจราจรที่ปกติ (Normal) และสภาพจราจรที่ผิดปกติ (Abnormal) ได้และวิธีการเสียงข้างมากที่นำมาใช้เพื่อช่วยเพิ่มความถูกต้องในการตรวจจับ (เพิ่มค่าอัตราการตรวจจับ: DR) พบว่าเมื่อขนาดหน้าต่างใหญ่ขึ้นโดยเพิ่มขึ้นจากขนาดหน้าต่าง 5 samples เป็น 7 samples ค่าอัตราการตรวจจับ (DR) เพิ่มขึ้น อย่างไรก็ตามในการเพิ่มขึ้นของขนาดหน้าต่าง ทำให้ค่าเฉลี่ยของผลรวมเวลาที่ระบบสามารถตรวจจับอุบัติเหตุ (MTTD) เพิ่มขึ้นด้วย แต่ทั้งนี้ในการนำไปใช้งานจริงการเลือกใช้ขนาดหน้าต่างของวิธีการเสียงข้างมากจำเป็นจะต้องพิจารณาถึงผลลัพธ์ของการนำไปใช้ด้วย

ต่อมาผลลัพธ์ที่ได้จากระบบตรวจจับสภาพจราจรที่ผิดปกติโดยใช้การแปลงเวฟเล็ทเต็มหน่วยและระบบอนุমানตรระกะคลุมเครือร่วมกับวิธีการเสียงข้างมากที่นำเสนอในงานวิจัยนี้ [7] จะพบว่าระบบสามารถตรวจจับสภาพจราจรที่ปกติ (Normal) และสภาพจราจรที่ผิดปกติ (Abnormal) ได้และให้ค่าอัตราการตรวจจับ (DR) ที่ดีกว่างานที่นำเสนอในงานวิจัยนี้ [6] แต่ผลลัพธ์ของการตรวจจับอุบัติเหตุทั้ง 3 แบบ คือ 1 Lane blocking, 2 Lane blocking และ 3 Lane blocking ไม่ได้ให้ผลลัพธ์ที่ดีที่สุดในทุกๆ กรณี

แต่เมื่อพิจารณาผลลัพธ์ที่ได้จากระบบที่นำเสนอโดยใช้เทคนิคทางด้านปัญญาประดิษฐ์ของระบบอนุমানตรระกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ร่วมกับเทคนิคทางด้านการประมวลผลสัญญาณ คือการแปลงเวฟเล็ทเต็มหน่วยในการบ่งบอกสภาพจราจรที่ปกติและสภาพจราจรที่ผิดปกติผลลัพธ์ที่ได้คือให้ค่าอัตราการตรวจจับ (DR) ที่ดีที่สุดในทุกๆ กรณีทั้งในกรณีของ 1 Lane blocking, 2 Lane blocking และ 3 lane blocking นอกจากนี้กลไกหลักที่ใช้ในระบบซึ่งก็คือระบบอนุমানตรระกะคลุมเครือบนฐานโครงข่ายปรับตัวได้ที่สามารถเรียนรู้จากข้อมูลได้ เพื่อปรับค่าฟังก์ชันสมาชิกและกฎของฟัซซี่สำหรับสร้างแบบจำลองที่เหมาะสมที่สุดได้ในการนำไปใช้งานจริง

อีกทั้งระบบที่นำเสนอยังสามารถจำแนกลักษณะอุบัติเหตุทางจราจรแบบอัตโนมัติได้อย่างแม่นยำ ซึ่งเป็นการพิจารณาจากลักษณะของข้อมูลโดยเป็นการหาค่าระดับอ้างอิงเพื่อนำมาพิจารณาและตัดสินใจ ทำให้ระบบที่นำเสนอนี้เมื่อมีการตรวจจับสภาพจราจรที่ผิดปกติ (Abnormal) เกิดขึ้นระบบก็จะสามารถแจ้งเตือนได้ด้วยดีกว่าลักษณะของอุบัติเหตุที่เกิดขึ้นเป็นแบบใดได้อีกด้วย

5.2 ข้อเสนอแนะ

1) ระบบที่นำเสนออยู่บนพื้นฐานของการใช้ข้อมูลจากโปรแกรมจำลองวิศวกรรมจราจร ซึ่งระบบจะให้ความแม่นยำและความถูกต้องสูง แต่สำหรับการนำไปใช้งานในระบบเวลาจริง (Real time) จำเป็นต้องมีการพิจารณาลักษณะของข้อมูลเพิ่มเติม

2) ระบบที่นำเสนอยังสามารถนำไปใช้งานทางด้านระบบจราจรอัจฉริยะ (ITS) สำหรับหน่วยงานที่เกี่ยวข้องกับการบริหารจัดการจราจร อย่างเช่น กรมทางหลวงและการทางพิเศษแห่งประเทศไทย เพื่อใช้ในการวางแผนจัดการและแก้ปัญหาจราจรติดขัดได้อย่างทันท่วงที



เอกสารอ้างอิง

- [1] J. A. Barria and S. Thajchayapong, "Detection and classification of traffic anomalies using microscopic traffic variables," IEEE Trans. Intelligent Transportation Systems, vol. 12, no. 3, pp.695-704, Sept. 2011.
- [2] Hojjat Adeli and Asim Karim, "Fuzzy-wavelet RBFNN Model for Freeway Incident Detection," Journal of Transportation Engineering, November/December, 2000.
- [3] Q. Wang, "Traffic incident detection based on artificial neural network," Proc. IEEE 3rd International Conference on Communication Software and Networks, pp. 657-659, May 2011.
- [4] S. Thajchayapong, E. S. G.-Trevino, and J. A. Barria, "Distributed classification of traffic anomalies using microscopic traffic variables," IEEE Trans. Intelligent Transportation Systems, vol. 14, no. 1, pp. 448-458, March 2013.
- [5] X. Binglei, H. Zheng, and M. Hongwei, "Fuzzy-logic-based traffic incident detection algorithm for freeway," Proc. The 7th International Conference on Machine Learning and Cybernetics, pp. 1254-1259, July 2008.
- [6] J. La-inchua, S. Chivapreecha, and S. Thajchayapong, "A new system for traffic incident detection using fuzzy logic and majority voting," Proc. The 10th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON 2013), May 2013.
- [7] J. La-inchua, S. Chivapreecha, and S. Thajchayapong, "Fuzzy Logic-Based Traffic Incident Detection System with Discrete Wavelet Transform," Proc. The 11st International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON 2014), May 2014.
- [8] A. Samant and H. Adeli, "Feature Extraction for Traffic Incident Detection Using Wavelet Transform and Linear Discriminant Analysis," Computer-Aided Civil and Infrastructure Engineering, vol. 15, pp. 241-250, 2000.
- [9] H. Adeli and A. Karim, Wavelets in intelligent transportation systems, John Wiley & Sons, 2005.
- [10] M. Negnevitsky, Artificial intelligence: A guide to intelligent systems, Addison Wesley, 2002.
- [11] www.aimsun.com/wp/, TSS-Transport simulation systems.
- [12] Lighthill, M. J. and G. B. Whitham, (1955). On Kinematic Waves: II. A Theory of Traffic Flow on Long Crowded Roads. Proceedings of the Royal Society: A229, pp. 317-347, London.
- [13] Jang. J.-S.R. and Chuen-Tsai Sun, "Neuro-fuzzy modeling and control", IEEE Proceedings, Vol. 83, No. 3, pp. 378-406.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- [14] Jang. J.-S.R., “ANFIS: Adaptive Network-Based Fuzzy Inference System”, *IEEETrans. Syst., Man, Cybern.*, Vol. 23, No. 3, pp. 665-685.
- [15] K. Hi-ri-o-tappa, C. Likitkhajorn, A. Poolsawat, S. Thajchayapong, “Traffic Incident Detection System using Series of Point Detectors,” *Proc. 15th International IEEE Conference on Intelligent Transportation Systems*, September 16-19, 2012



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภาคผนวก

1. งานวิจัยที่ได้รับการตีพิมพ์เพื่อใช้สำเร็จการศึกษา

ผลงานวิจัยที่ได้นำเสนอในการประชุมวิชาการระดับนานาชาติ

J. La-inchua, S. Chivapreecha, and S. Thajchayapong, "Fuzzy Logic-Based Traffic Incident Detection System with Discrete Wavelet Transform," *Proc. The 11st International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON 2014)*, May 2014.



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Fuzzy Logic-Based Traffic Incident Detection System with Discrete Wavelet Transform

Jaraspat La-inchua*, Sorawat Chivapreecha*, Suttipong Thajchayapong#

*Department of Telecommunication Engineering, Faculty of Engineering,
King Mongkut's Institute of Technology Ladkrabang, Bangkok 10520, Thailand
sorawat@telecom.kmitl.ac.th

#National Electronic and Computer Technology Center (NECTEC),
National Science and Technology Development Agency, Pathumthani 12120, Thailand
suttipong.thajchayapong@nectec.or.th

Abstract—This paper presents a fuzzy logic-based traffic incident detection system to detect a lane-blocking traffic incident usually causes of traffic congestion. The proposed system uses fuzzy logic to identify traffic status as normal and abnormal. Macroscopic and microscopic traffic variables, namely, mean speed and standard deviation of inter-arrival time are used as inputs to the fuzzy inference system (FIS). As traffic variables have many fluctuations which are considered as noisy signals, discrete wavelet transform (DWT) is used for de-noising and also for extracting features from noisy signals. It is found that the proposed system that uses DWT can give higher detection rate compared with the system without DWT. Furthermore, the majority voting is also applied to the outputs of FIS in order to increase detection rate. Finally, based on simulation results, the performance of the proposed detection system for lane-blocking traffic incidents will be shown.

Keywords—Anomaly detection; traffic incident detection; fuzzy logic; discrete wavelet transform (DWT); intelligent transportation systems (ITS).

I. INTRODUCTION

Traffic incidents are the main cause of traffic congestion, which subsequently increases travel delay and fuel consumption in major cities. Usually, traffic incident cannot be predicted which poses great challenge to traffic management centers. Therefore, this paper focuses on developing the system that detects traffic incident automatically. The aim is to help the officer manage and take action to clear the roadway as early as possible and return to traffic back to normal condition.

The system that proposed in [1] can detect and classify traffic anomalies using only microscopic traffic variables based on statistical calculations. This system uses Bayesian detection which relies on prior assumption regarding the distribution of normal and anomalous traffic patterns. However, for real-time implementation point of view, this system has more complexity as it uses 3 traffic variables as inputs but the proposed system in this paper uses only 2 traffic variables.

Artificial intelligence can be applied to traffic incident detection as in [2-5]. Artificial neural network (ANN) has

been used for anomaly detection [2-3], where large amount of traffic data need to be used in the training process. In [4-5], traffic incident detection systems are proposed based on fuzzy logic where [4] uses four traffic variables and [5] uses only two traffic variables as input data. In addition, discrete wavelet transform (DWT) can be applied for incident detection which is proposed in [6]. In this paper, DWT will be used in order to extract features from the temporal variations and fluctuations of traffic data.

This paper proposes a traffic incident detection system based on fuzzy logic and using discrete wavelet transform for feature extraction. The proposed system uses only two traffic variables as inputs of system, namely, mean speed and standard deviation of inter-arrival time which has less computational complexity than the system in [4]. Moreover, discrete wavelet transform (DWT) based on a 1-level analysis filter bank will be used as the pre-processing stage in order to de-noising and extract the features from input data which have many fluctuations. The proposed system with DWT can give the detection rate (DR) better than the system without DWT [5]. Furthermore, majority voting with adjustable window size is also applied after the results are obtained from fuzzy logic to increase the detection rate (DR) and also compromise with the mean time to detection (MTTD).

The rest of paper is organized as follows: background of DWT and fuzzy inference system (FIS) is introduced in Section II. The proposed system is presented in Section III. Validation and effectiveness of proposed system by simulations are shown in Section IV. Finally, Section V concludes this paper.

II. BACKGROUND OF DWT AND FIS

The background that used for our proposed system consists of discrete wavelet transform (DWT) and fuzzy inference system (FIS). Therefore, in this section both topics will be explained.

A. Discrete Wavelet Transform

Discrete wavelet transform (DWT) is developed for signal

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

sis and time-frequency location analysis. Most commonly of DWT are in the form of filter bank. Filter bank consists of a lowpass filter and digital highpass filter which both filters cascaded with down-sampling by 2 as shown in Fig. 1.




Fig. 1. 1-level Analysis filter bank.

This structure of filter bank is called 1-level analysis filter bank. The output from lowpass filter which is down-sampled by 2 is called “approximation coefficient” and output from highpass filter which is down-sampled by 2 is called that “detail coefficient”. The transfer function of lowpass filter and highpass filter depend on the chosen mother wavelet. In our work, we use 1-level analysis filter bank with Daubechies-2 mother wavelet the transfer function of lowpass and highpass filter for such mother wavelet are defined as follows,

$$L_D(z) = -0.1294 + 0.2241z^{-1} + 0.8365z^{-2} + 0.4830z^{-3}, \quad (1)$$

$$H_D(z) = -0.4380 + 0.8365z^{-1} + 0.2241z^{-2} + 0.1294z^{-3}. \quad (2)$$

The reverse process that uses approximation coefficient and detail coefficient from analysis filter bank in order to reconstruct the original signal can use the so-called synthesis filter bank. So synthesis filter bank is not used in this work, so not discuss about synthesis filter bank.

Advantages of DWT which are considered to apply in this work are:

DWT can reduce noise in noisy signals. Both mean speed and standard deviation of inter-arrival time (std. inter-arrival time) which are input of the system, have many fluctuations are considered as noise.

Feature extraction of both input signals can be extracted by DWT and then detection rate (DR) of proposed system can be used when compared with the system without DWT as in [5].

Both mean speed and std. inter-arrival time will be processed by DWT (analysis filter bank) and the approximation coefficients of mean speed and std. inter-arrival time will be used as crisp inputs of the FIS.

B. Fuzzy Inference System

Fuzzy inference system (FIS) which is shown by block diagram in Fig. 2 can be defined as a process of mapping from a given input to an output using the theory of fuzzy sets, which is performed in the following steps [5, 7]:

- *Fuzzification* is to take the crisp inputs and determine the degree to which these inputs belong to each of the appropriate fuzzy sets.
- *Rule evaluation* is to take the fuzzified inputs and apply them to the antecedents of the fuzzy rules. The fuzzy operators will be used in this step in order to obtain a single number that represents the result of the antecedent evaluation and then applied to the consequent membership function.
- *Aggregation of the rule outputs* is the process of unification of the outputs of all rules.
- *Defuzzification* is to take the aggregated output fuzzy set to the crisp output. The most popular defuzzification method is center of gravity (COG).

Fuzzy logic is used as the main mechanism in proposed system, the membership function of each input which is approximation coefficients of mean speed and std. inter-arrival time and membership function of output including the fuzzy rules can be defined by analyzing the data which is obtained from traffic simulator software.

III. THE PROPOSED SYSTEM

The proposed system for traffic incident detection consists of DWT (analysis filter bank), FIS, and the majority voting. The inputs for our proposed system use only 2 inputs as mean speed and std. inter-arrival time, which are macroscopic and microscopic traffic variables respectively. Each input is transformed by DWT in order to reduce noise (reduce the fluctuations of input data) and also extract the feature from input data. Both mean speed and std. inter-arrival time are processed through each lowpass filter and down-sampled by 2 to obtain approximation coefficients which are then used as input to FIS (Notice that sampling rate is reduced by 2 times). Approximation coefficient of mean speed and std. inter-arrival time will be crisp inputs of FIS and then the crisp output can be evaluated by using the defined membership functions and fuzzy rules. The obtained crisp output from FIS is changed into a final decision by majority voting using odd samples window size.




Fig. 2. Fuzzy inference system.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Fig. 3 shows the proposed system for traffic incident detection which can be explained as follows: Every sample of mean speed and std. inter-arrival time (inputs data streaming) are transformed by DWT (only approximation coefficients are used) and then analyzed sample by sample using FIS. The status "normal" or "abnormal" is indicated at the output of FIS. The majority voting is then applied to the output of FIS applied to the proposed system. Furthermore, window size for majority

voting can be adjusted in order to trade-off between increasing DR (more accuracy) and reducing MTTD (faster detection) as proposed in [5]. The majority voting can help improve the accuracy in detecting "normal" or "abnormal" status. Since our system can analyze data sample by sample, it is suitable for the real-time application.




Fig. 3. The proposed system with DWT for traffic incident detection.




Fig. 4. Simulation scenarios (Red block indicates a lane-blocking incident).

Three scenarios of incident are considered in our system as one-lane blocking, two-lane blocking, and lane closure as shown in Fig. 4. The example of mean speed input which is macroscopic traffic variable and std. inter-arrival

time which is microscopic traffic variable obtained from traffic simulator software AIMSUN [8] and their approximation coefficients from DWT for 1-Lane blocking scenario are shown in Fig. 5 (a) and (b), respectively.




Fig. 5. Input data and its DWT coefficients for 1-Lane blocking.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

From Fig. 5, it can be seen that the fluctuations of input are reduced (consider from approximation coefficient) as the high frequency component is removed. Therefore, only approximation coefficient of both mean speed and std. inter-arrival time are used as crisp inputs to the FIS. However, since 1-stage analysis filter banks are used in the proposed system then sampling rate of crisp input to FIS will be reduced by 2 when compared with the original data before DWT (sampling rate is changed from 30 s to 60 s after DWT). In order to establish input membership functions, the approximation coefficient of mean speed and std. inter-arrival for 3 scenarios are analyzed where both membership functions are shown in Fig. 6 and Fig. 7, respectively. The membership function of output which is defined as percentage of incident (% of incident) is shown in Fig. 8. Criteria used to judge the occurrence of incidents is the crisp output after

defuzzification with 80% or greater. The rules used in our proposed FIS are shown in Table I.

TABLE I. FUZZY RULES

Approx. Coeff. of Mean speed \ Approx. Coeff. of Std. inter-arrival time	Small	Medium	Large
Small	abnormal	abnormal	normal
Medium	abnormal	abnormal	abnormal
Large	abnormal	abnormal	abnormal
Very large	abnormal	abnormal	abnormal




Fig. 6. The membership of input: Approximation coefficient of mean speed.




Fig. 7. The membership function of input: Approximation coefficient of std. inter-arrival time.




Fig. 8. Output membership function.

IV. PERFORMANCE EVALUATION USING SIMULATIONS

To validate the proposed system as shown in Fig. 3 for traffic incident detection, the system is evaluated with traffic data from the traffic simulator AIMSUN. The window size of 30 samples for majority voting are considered to show the trade-off between DR and MTTD. The simulation environment is set to be same as in [4, 5] in order to generate traffic flow

data. One-way 500 m road section of freeway with 3 lanes, free flow speed 105 km/h and traffic flow 3000 veh/h are considered as simulation parameters. Totally, 8 simulations are tested which each simulation uses 7800 seconds with 10 times traffic incidents.

Definition of DR and MTTD that used in performance evaluation are defined as follows,

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$DR = \frac{\text{Can Detect}}{\text{No. of Detection}} \times 100\% \quad (3)$$

$$MTTD = \frac{\text{Total Time to Detection}}{\text{No. of Detection}} \quad (4)$$

The purpose of this section is to assess the proposed system aspect to 1) its ability to detect incidents consist of discrete let transform, fuzzy inference system and majority voting, 2) the impact of adjustable window size 3) the performance in comparisons with the benchmark fuzzy-based systems [4,5].

Firstly, the DR and MTTD when the proposed system is used to detect a one-lane blocking incident with window sizes of 3 samples and 5 samples are shown in Tables II and III respectively.

TABLE II. DR AND MTTD OF 1-LANE BLOCKING DATA USING WINDOW SIZE = 3 SAMPLES

	No. of Detection	Can Detect	DR	Total Time to Detection	MTTD
Normal	184	147	79.89%	11280 s	61.30 s
Abnormal	160	146	91.25%	13320 s	83.25 s
Overall	344	293	85.17%	24600 s	71.51 s

TABLE III. DR AND MTTD OF 1-LANE BLOCKING DATA USING WINDOW SIZE = 5 SAMPLES

	No. of Detection	Can Detect	DR	Total Time to Detection	MTTD
Normal	114	108	94.73%	8160 s	71.57 s
Abnormal	94	91	96.80%	7380 s	78.51 s
Overall	208	199	95.67%	15540 s	74.71 s

As shown in Table II, in overall assessment with one-lane blocking incidents, the proposed system can achieve DR of 85.17% with MTTD of 71.51 s. Table III shows that when the window size is increased from 3 samples to 5 samples, both the number of normal detection and abnormal detection can be improved; DR is increased to 95.67% with MTTD of 74.71 s. Furthermore, increasing window size of the proposed system does not significantly increase MTTD when compared to the increase in MTTD of the system without DWT in [5].

Next, we assess the proposed system in detecting two-lane blocking. The performance evaluation results are shown in Tables IV and V when the window sizes of 3 samples and 5 samples are used respectively.

TABLE IV. DR AND MTTD OF 2-LANE BLOCKING DATA USING WINDOW SIZE = 3 SAMPLES

	No. of Detection	Can Detect	DR	Total Time to Detection	MTTD
Normal	184	162	88.04%	10200 s	55.43 s
Abnormal	160	131	81.88%	12600 s	78.75 s
Overall	344	293	85.17%	22800 s	66.27 s

TABLE V. DR AND MTTD OF 2-LANE BLOCKING DATA USING WINDOW SIZE = 5 SAMPLES

	No. of Detection	Can Detect	DR	Total Time to Detection	MTTD
Normal	123	120	97.56%	9600 s	78.04 s
Abnormal	85	64	75.29%	5100 s	60.00 s
Overall	208	199	88.46%	14700 s	70.63 s

From Table IV and V, it can be seen that only DR of normal detection is increased but DR of abnormal detection is decreased. However, the overall DR is increased when window size is increased. Optimum FIS for one scenario may not work well with a difference scenario. The optimum membership functions and also fuzzy rules are necessary in order to give the optimal DR for all interested scenarios.

The performance evaluation results of lane closure scenario are shown in Tables VI and VII when the window sizes of 3 samples and 5 samples are used respectively.

TABLE VI. DR AND MTTD OF LANE CLOSURE DATA USING WINDOW SIZE = 3 SAMPLES

	No. of Detection	Can Detect	DR	Total Time to Detection	MTTD
Normal	184	148	80.43%	13260 s	72.07 s
Abnormal	160	160	100%	14400 s	90.00 s
Overall	344	308	89.53%	27660 s	80.41 s

TABLE VII. DR AND MTTD OF LANE CLOSURE DATA USING WINDOW SIZE = 5 SAMPLES

	No. of Detection	Can Detect	DR	Total Time to Detection	MTTD
Normal	110	100	90.91%	8670 s	78.81 s
Abnormal	98	98	100%	8160 s	83.27 s
Overall	208	198	95.19%	16830 s	80.91 s

As shown in Table VI and VII, when the window size is increased from 3 samples to 5 samples, DR of normal detection can be improved to 90.91% and abnormal detection is 100% which result in overall DR is increased to 95.19% with MTTD of 80.91 s. Therefore, from the obtained DR for each scenario, we can consider that DR depends on the membership functions as shown in Figs. 6-8 including fuzzy rules.

To show the performance of the proposed system which uses DWT when compared with the system without DWT in [5] and with the benchmark fuzzy-based algorithm in [4], the performance evaluation results when all systems are applied to detect the incidents and can be shown DR and MTTD as in Table VIII.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

TABLE VIII. COMPARISON RESULTS

System for Traffic Incident Detection	DR	MTTD
One-lane blocking		
Our proposed system (with DWT), window size = 5 samples	95.67%	74.71 s
The system proposed in [5] (without DWT), window size = 7 samples	89.52%	101.65 s
Two-lane blocking		
Our proposed system (with DWT), window size = 5 samples	88.46%	70.63 s
The system proposed in [5] (without DWT), window size = 7 samples	89.86%	94.96 s
Lane closure		
Our proposed system (with DWT), window size = 5 samples	95.19%	80.91 s
The system proposed in [5] (without DWT), window size = 7 samples	83.45%	87.97 s
System proposed in [4]	91%	132 s

Notice that, the time interval for each sample of FIS input is 30 s; for the system without DWT and time interval for each sample of FIS input of the system with DWT is 60 s because the original data is down-sampled by 2 from analysis filter bank. Therefore, time base for MTTD calculation of the proposed system and the system proposed in [4, 5] will be 60 s and 30 s, respectively.

From comparison results in Table VIII which are the best of each scenarios, for a one-lane blocking and lane closure scenarios with window size of 5 samples, the obtained DR of the proposed system is higher than DR that obtained by the system in [4, 5], the MTTD of our proposed system is also lower. However, in case of two-lane blocking the proposed system can give DR comparable to the obtained from system [5] with window size of 7 samples because the effect of membership functions and fuzzy rules that used in the proposed system is not optimum for this scenario as the reasons are explained in Table IV and V. The optimal DR for all interested scenarios will be obtained by the optimum membership functions and fuzzy rules, if membership functions can be adjusted to the optimum point, so it is possible to increase DR in all scenarios. Fuzzy evolutionary system can be used to optimize the membership functions and also fuzzy rules. However, in this work we use only 1-level analysis filter bank Daubechies-2 mother wavelet, maybe number of level and of mother wavelet can affect to both DR and MTTD. Both fuzzy evolutionary system and the study in detail of DWT are future work.

V. CONCLUSIONS

A fuzzy logic-based system for lane-blocking traffic incident detection is proposed in this paper consisting of discrete wavelet transform (DWT) by analysis filter bank, fuzzy inference system and majority voting with adjustable window size that enables the balancing between detection rate and mean time to detection. The proposed system uses only traffic variables and also uses the advantage of DWT for feature extraction and feature extraction from input data which is not in our previous work [5]. From performance evaluation results based on simulation show that the proposed system has

lower mean time to detection than the system in [4, 5], while giving higher detection rate in case of 1-lane blocking and lane closure scenarios. In our future work, more details of discrete wavelet transform such as effect of changing the level of analysis filter bank and mother wavelet will be studied including the concept of optimum membership functions that used in the system to increase detection rate for all traffic incident scenarios will be considered.

ACKNOWLEDGMENT

This research was supported scholarship by Thailand Graduate Institute of Science and Technology (TGIST) from National Science and Technology Development Agency (NSTDA). The contract is no. TGIST 01-56-027.

REFERENCES

- [1] J. A. Barria and S. Thajchayapong, "Detection and classification of traffic anomalies using microscopic traffic variables," *IEEE Trans. Intelligent Transportation Systems*, vol. 12, no. 3, pp.695-704, Sept. 2011.
- [2] Q. Wang, "Traffic incident detection based on artificial neural network," *Proc. IEEE 3rd International Conference on Communication Software and Networks*, pp. 657-659, May 2011.
- [3] S. Thajchayapong, E. S. G.-Trevino, and J. A. Barria, "Distributed classification of traffic anomalies using microscopic traffic variables," *IEEE Trans. Intelligent Transportation Systems*, vol. 14, no. 1, pp. 448-458, March 2013.
- [4] X. Binglei, H. Zheng, and M. Hongwei, "Fuzzy-logic-based traffic incident detection algorithm for freeway," *Proc. The 7th International Conference on Machine Learning and Cybernetics*, pp. 1254-1259, July 2008.
- [5] J. La-inchua, S. Chivapreecha, and S. Thajchayapong, "A new system for traffic incident detection using fuzzy logic and majority voting," *Proc. The 10th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON 2013)*, May 2013.
- [6] H. Adeli and A. Karim, *Wavelets in intelligent transportation systems*, John Wiley & Sons, 2005.
- [7] M. Negnevitsky, *Artificial intelligence: A guide to intelligent systems*, Addison Wesley, 2002.
- [8] www.aimsun.com/wp/, TSS-Transport simulation systems.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ประวัติผู้เขียน

ชื่อ - นามสกุล	นางสาวจรัสพัฒน์ หล้าอินเชื้อ นักเรียนทุนโครงการทุนสถาบันบัณฑิตวิทยาศาสตร์และเทคโนโลยีไทย (TGIST) โดยสำนักงานพัฒนาวิทยาศาสตร์และเทคโนโลยีแห่งชาติ (สวทช.)
วัน เดือน ปีเกิด	13 สิงหาคม 2533
ที่อยู่	100/183 หมู่ 5 ตำบลพลายชุมพล อำเภอเมือง จังหวัดพิษณุโลก 65000
ประวัติการศึกษา	พ.ศ. 2555 สำเร็จการศึกษา หลักสูตรวิศวกรรมศาสตรบัณฑิต สาขาวิชาวิศวกรรมโทรคมนาคม คณะวิศวกรรมศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

บทความวิจัยที่ได้รับการตีพิมพ์ระหว่างการศึกษ

- [1] Jaraspat La-inchua, Sorawat Chivapreecha, and Suttipong Thajchayapong, "Adaptive Neuro-Fuzzy Inference System for Automatic Traffic Incident Detection," accepted for presentation in The 2015 International Workshop on Smart Info-Media System in Asia (SISA 2015), Chiba Institute of Technology, Narashino, Japan, August 26-28, 2015.
- [2] Jaraspat La-inchua, Sorawat Chivapreecha, and Suttipong Thajchayapong, "Fuzzy Logic-Based Traffic Incident Detection System with Discrete Wavelet Transform," Proc. *The 11st International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON 2014)*, Nakhon Ratchasima, Thailand, May 14-17, 2014.
- [3] Jaraspat La-inchua, Sorawat Chivapreecha, and Suttipong Thajchayapong, "A New System for Traffic Incident Detection Using Fuzzy Logic and Majority Voting," Proc. *The 10th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON 2013)*, Krabi, Thailand, May 15-17, 2013.
- [4] Jaraspat La-inchua, Sorawat Chivapreecha, and Suttipong Thajchayapong, "An Improved Traffic Incident Detection System Using Fuzzy Logic," Proc. *The 2013 IEEE Thailand Student Conference on Senior Capstone Project (IEEE Thailand SCAP 2013)*, Bangkok, Thailand, March 29, 2013.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้