

การสร้างแบบจำลองปริมาณอิเล็กตรอนในชั้นบรรยากาศ
ไอโอโนสเฟียร์ของกรุงเทพมหานครโดยเทคนิคโครงข่ายประสาท

IONOSPHERIC TOTAL ELECTRON CONTENT (TEC) MODELLING
OVER BANGKOK BY NEURAL NETWORK TECHNIQUE



กฤตยา นาคประสิทธิ์
KRITTAYA NAKPRASIT

๖๗
๑๗ ๑
๐๕๔๔

เลขหมู่.....
เลขทะเบียน..... 48945 /
วัน, เดือน, ปี 13 ส.ค. 2547

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

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชาวิศวกรรมไฟฟ้า
บัณฑิตวิทยาลัย

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
พ.ศ. 2546

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลง ISBN 974-324-790-4 เจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

**IONOSPHERIC TOTAL ELECTRON CONTENT (TEC) MODELLING OVER
BANGKOK BY NEURAL NETWORK TECHNIQUE**



**A THESIS SUBMITTED IN PARTIAL FULFILLMENT
OF THE REQUIREMENT FOR THE DEGREE OF
MASTER OF ENGINEERING IN ELECTRICAL ENGINEERING
SCHOOL OF GRADUATE STUDIES
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG**

2003

ISBN 974-324-790-4

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



COPYRIGHT 2003

SCHOOL OF GRADUATE STUDIES

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อวิทยานิพนธ์	การสร้างแบบจำลองปริมาณอิเล็กทรอนิกส์บนชั้นบรรยากาศไอโอโนสเฟียร์ของกรุงเทพมหานครโดยเทคนิคโครงข่ายประสาท
นักศึกษา	นางสาวกฤตยา นาคประสิทธิ์
รหัสประจำตัว	42061031
ปริญญา	วิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชา	วิศวกรรมไฟฟ้า
พ.ศ.	2546
อาจารย์ผู้ควบคุมวิทยานิพนธ์	รศ. นิภา ลีสารุจิ
อาจารย์ผู้ควบคุมวิทยานิพนธ์ร่วม	รศ. ณรงค์ เหมกรณ์

บทคัดย่อ

วิทยานิพนธ์ฉบับนี้จะสนใจถึงการสร้างแบบจำลองปริมาณอิเล็กทรอนิกส์บนชั้นบรรยากาศไอโอโนสเฟียร์ตลอดเส้นทางที่คลื่นดาวเทียมเดินทาง โดยอาศัยข้อมูลที่เก็บบันทึกจริงของปริมาณอิเล็กทรอนิกส์บนชั้นบรรยากาศไอโอโนสเฟียร์จากดาวเทียม GPS ซึ่งติดตั้งอยู่ที่ศูนย์วิจัยการสื่อสารและเทคโนโลยีสารสนเทศ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง กรุงเทพมหานคร พร้อมทั้งวิเคราะห์ถึงข้อมูลจำนวนจุดดับของดวงอาทิตย์ และข้อมูลดัชนีสนามแม่เหล็กโลก ซึ่งถือว่าเป็นข้อมูลที่สำคัญที่มีอิทธิพลต่อการเปลี่ยนแปลงปริมาณอิเล็กทรอนิกส์บนชั้นบรรยากาศไอโอโนสเฟียร์ โดยอาศัยเทคนิคโครงข่ายประสาทเพื่อให้ได้แบบจำลองที่สามารถมีการปรับปรุงให้ดีขึ้นสอดคล้องกับข้อมูลที่บันทึกได้จริงด้วยการเรียนรู้ (ข้อมูลตั้งแต่ 1 มกราคม 2541 – 31 ธันวาคม 2543) การปรับปรุงแบบจำลองจะเลือกใช้วิธีการ Backpropagation และหลังจากได้แบบจำลองที่สร้างขึ้นมาแล้ว จะมีการตรวจสอบความผิดพลาดของแบบจำลองจากเทคนิคโครงข่ายประสาทเปรียบเทียบกับค่าที่วัดได้จริง

จากผลการทดลองพบว่าค่าความผิดพลาดของแบบจำลอง IRI มีค่าคลาดเคลื่อนไปมากกว่าที่ได้จากการทำนายจากแบบจำลองที่สร้างขึ้นมาจากเทคนิคโครงข่ายประสาทโดยมีค่า 14.46 % ในช่วงการพยากรณ์อย่างต่อเนื่องเป็นเวลาถึง 192 ชั่วโมง หรือ 8 วัน ในระหว่างวันที่ 21–28 มกราคม 2544 เมื่อเปรียบเทียบกับค่าความผิดพลาดของแบบจำลองที่สร้างขึ้นมาพบว่ามีค่าความผิดพลาด 2.25% ดังนั้นจะเห็นได้ว่าแบบจำลองโครงข่ายประสาทสามารถทำนายค่าได้แม่นยำกว่า IRI 12.21%

Thesis Title	Ionospheric Total Electron Content (TEC) Modelling over Bangkok by Neural network technique
Student	Miss Krittaya Nakprasit
Student ID.	42061031
Degree	Master of Engineering
Programme	Electrical Engineering
Year	2003
Thesis Advisor	Assoc.Prof. Nipha Leelaruji
Thesis Co-advisor	Assoc.Prof. Narong Hemmakorn

ABSTRACT

This thesis focuses on the modelling of the ionospheric Total Electron Content (TEC) along the path of the propagation of satellite waves . This model is based on the TEC's collected data measured from GPS receiver which is located at the Research center for Communications and Information Technology, King Mongkut's Institute of Technology Ladkrabang, Bangkok, and also based on the analysis of the sunspot number data and the geomagnetic index data which are substantial factors of the TEC variation. This model was designed by using neural network technique to obtain an adaptable model, which corresponded to long term record data (from 1 January 1998 – 31 December 2000) , by learning procedure. To improve the model, the backpropagation method was selected. The last step of this thesis, after finishing the modelling ,is the examination of the error of neural network TEC model compare with IRI model.

From the experimental result, I found that the error from the IRI model has error more than the predicable value which received from the Neural Network model equal to 14.46%. The prediction has continued to 192 hours or 8 days, from 21-28 of January 2544 comparing with the error value of the prototype model which has the error value equal to 2.25%. So we can say that the accuracy result from using Neural Network model is better than the IRI model equal to 12.21%.

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงลงได้ ด้วยคำแนะนำและคำปรึกษาเกี่ยวกับระบบการเก็บข้อมูลปริมาณอิเล็กทรอนิกส์บนชั้นบรรยากาศไอโอโนสเฟียร์ แนวทางการทำงานและข้อคิดที่เป็นประโยชน์จาก รศ. ณรงค์ เหมกรณ์ ซึ่งเป็นอาจารย์ผู้ควบคุมวิทยานิพนธ์ และ รศ. นิภา ลีลาจุฑา ข้าพเจ้ารู้สึกซาบซึ้งในความอนุเคราะห์จากอาจารย์ทั้งสองท่านที่ได้เสียสละเวลาให้ความรู้และคำแนะนำ ตลอดจนประสบการณ์ในชีวิตนักศึกษาที่ติดลอดมา ข้าพเจ้าขอกราบขอบพระคุณท่านอาจารย์ทั้งสองเป็นอย่างสูง

ขอขอบพระคุณ ผศ. สะอาดศรี คงนิล ที่ได้เสียสละเวลาให้ความรู้ในเรื่องคณิตศาสตร์และให้คำแนะนำในการทำวิทยานิพนธ์

ขอขอบพระคุณนายทิมมิตร บุญชุก เพื่อน ๆ พี่ ๆ นักศึกษาทุกคนที่ช่วยเหลือให้คำแนะนำต่าง ๆ และนายบุญช่วย ชวานนท์พิทักษ์ ที่คอยช่วยแก้ปัญหาที่เกี่ยวข้องกับคอมพิวเตอร์รวมถึงการใช้งานโปรแกรม และยังให้กำลังใจต่อผู้วิจัยอย่างใกล้ชิดตลอดมา

ขอขอบพระคุณคุณพ่อและคุณแม่ที่ส่งเสริมสนับสนุนให้โอกาสข้าพเจ้าได้เรียนจนสามารถทำวิทยานิพนธ์สำเร็จ

สุดท้ายขอขอบคุณบัณฑิตวิทยาลัย ที่ได้ให้ทุนสนับสนุนการทำวิทยานิพนธ์ครั้งนี้

กฤตยา นาคประสิทธิ์

สารบัญ

	หน้า
บทคัดย่อภาษาไทย	I
บทคัดย่อภาษาอังกฤษ.....	II
กิตติกรรมประกาศ	III
สารบัญ	IV
สารบัญตาราง	VI
สารบัญรูป	VII
บทที่ 1 บทนำ	1
1.1 ความเป็นมาและความสำคัญของปัญหา	1
1.2 วัตถุประสงค์ของการศึกษา	2
1.3 สมมติฐานของการศึกษา	2
1.4 แนวความคิดที่ใช้ในการทำวิจัย	3
1.5 ขอบเขตการวิจัย	3
1.6 ขั้นตอนของการศึกษา	4
บทที่ 2 ทฤษฎีโครงข่ายประสาท	6
2.1 โครงข่ายประสาท	6
2.2 หลักการทำงานของโครงข่ายประสาท	7
2.3 ประโยชน์ของโครงข่ายประสาท	8
2.4 องค์ประกอบของโครงข่ายประสาท	9
2.5 การเรียนรู้แบบแพร่กระจายย้อนกลับ	17
บทที่ 3 ความสัมพันธ์ระหว่างจุดดับดวงอาทิตย์และดัชนีสนามแม่เหล็กโลกที่มีกับ ปริมาณอิเล็กตรอนในชั้นบรรยากาศไอโอโนสเฟียร์	25
3.1 การเปลี่ยนแปลงปริมาณอิเล็กตรอนในชั้นบรรยากาศไอโอโนสเฟียร์	40
3.2 การเปลี่ยนแปลงจุดดับดวงอาทิตย์	37
3.3 ความสัมพันธ์ของจุดดับดวงอาทิตย์ที่มีต่อปริมาณอิเล็กตรอนในชั้น บรรยากาศไอโอโนสเฟียร์	44
3.4 การเปลี่ยนแปลงดัชนีสนามแม่เหล็กโลก	52

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่ออนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ(ต่อ)

หน้า

3.5 ความสัมพันธ์ของดัชนีสนามแม่เหล็กโลกกับปริมาณอิเล็กตรอนใน ชั้นบรรยากาศไอโอโนสเฟียร์	56
3.6 ความสัมพันธ์ของตำแหน่งเส้นละติจูดบนโลกกับปริมาณอิเล็กตรอนใน ชั้นบรรยากาศไอโอโนสเฟียร์	57
บทที่ 4 การสร้างแบบจำลองปริมาณอิเล็กตรอนในชั้นบรรยากาศไอโอโนสเฟียร์ โดยเทคนิคโครงข่ายประสาท	61
4.1 การออกแบบสถาปัตยกรรมโครงข่ายประสาท	61
4.2 ขั้นตอนการสร้างแบบจำลอง	62
บทที่ 5 ผลการทดลองเปรียบเทียบค่าความผิดพลาดของแบบจำลองปริมาณ อิเล็กตรอนในชั้นบรรยากาศไอโอโนสเฟียร์โดยเทคนิคโครงข่ายประสาท กับแบบจำลอง IRI	71
5.1 แบบจำลอง IRI	71
5.2 การคำนวณปริมาณอิเล็กตรอน TEC จากแบบจำลอง IRI	73
5.3 ผลการทดลองหาค่าความผิดพลาดของแบบจำลอง IRI กับแบบจำลอง ปริมาณอิเล็กตรอนในชั้นบรรยากาศไอโอโนสเฟียร์โดยเทคนิคโครงข่าย ประสาท	78
บทที่ 6 สรุปผลการวิจัยและข้อเสนอแนะ	80
หนังสืออ้างอิง	82
ภาคผนวก	84
ภาคผนวก ก. ทรานสเฟอร์ฟังก์ชันชนิดต่าง ๆ	85
ภาคผนวก ข. การแปลงค่าปริมาณอิเล็กตรอนเป็นค่าความหนาแน่นอิเล็กตรอน	86
ภาคผนวก ค. โปรแกรม combine_data.py	87
ภาคผนวก ง. NSSDC Model Web International Reference Ionosphere – IRI	94

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ไว้เพื่อการศึกษาเท่านั้น เมื่ออนุญาตให้เผยแพร่โดยไม่เสียค่าใช้จ่าย

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภาคผนวก จ. Neural Network Toolbox 4	101
ภาคผนวก ฉ. บทความที่ได้รับการตีพิมพ์	106
ประวัติผู้เขียน	111



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญตาราง

ตารางที่	หน้า
3.1 ผลการวิเคราะห์ค่าสถิติของลักษณะการเปลี่ยนแปลง TEC ในแต่ละวัน	36
3.2 ผลการทดลองหาค่าสัมประสิทธิ์สหสัมพันธ์ของ TEC ที่เกิดขึ้นในแต่ละวัน กับค่า TEC ที่เกิดขึ้นในเมื่อวันก่อนและเมื่อ 2 วันก่อน	38
3.3 ผลการทดลองหาค่าสัมประสิทธิ์สหสัมพันธ์ของ TEC ที่เกิดขึ้นในแต่ละเวลา กับค่า TEC ที่เกิดขึ้นในอดีตเมื่อ 15 นาที, 1 ชั่วโมง, 6 ชั่วโมง และ 12 ชั่วโมง ที่ผ่านมา	39
3.4 ผลการทดลองหาค่าสัมประสิทธิ์สหสัมพันธ์ของ TEC สูงสุด , ต่ำสุด และเฉลี่ย ที่เกิดขึ้นในแต่ละวัน กับค่าจุดดับดวงอาทิตย์ในแต่ละวัน	52
3.5 การแบ่งประเภทของพายุสนามแม่เหล็กโลก	54
3.6 ผลการทดลองหาค่าสัมประสิทธิ์สหสัมพันธ์ของ TEC สูงสุด , ต่ำสุด และเฉลี่ย ที่เกิดขึ้นในแต่ละวัน กับดัชนีสนามแม่เหล็กโลก Ap	56
5.1 ค่าความหนาแน่นอิเล็กตรอนและองค์ประกอบของไอออนที่ความสูงต่าง ๆ	76

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญรูป

รูปที่	หน้า
2.1 ภาพวาดของนิเวศของสิ่งมีชีวิต	6
2.2 บล็อกไดอะแกรมการฝึกของโครงข่ายประสาท	8
2.3 ไดอะแกรมนิเวศพื้นฐานที่ไม่มีไบโอสและนิเวศที่มีไบโอส	10
2.4 ทรานสเฟอร์ฟังก์ชันชนิดฮาร์ดลิมิตและสัญลักษณ์	11
2.5 ทรานสเฟอร์ฟังก์ชันชนิดเชิงเส้นและสัญลักษณ์	11
2.6 ทรานสเฟอร์ฟังก์ชันชนิดล็อก-ซิกมอยด์และสัญลักษณ์	12
2.7 รายละเอียดของนิเวศแบบค่าอินพุตเป็นปริมาณเวกเตอร์	13
2.8 ไดอะแกรมนิเวศแบบค่าอินพุตเป็นปริมาณเวกเตอร์	13
2.9 รายละเอียดนิเวศ 1 เลเยอร์	14
2.10 ไดอะแกรมนิเวศ 1 เลเยอร์	15
2.11 ไดอะแกรมนิเวศที่มีเมทริกซ์ตัวดวงน้ำหนักที่เชื่อมกับอินพุต (IW)	16
2.12 โครงข่ายหลายเลเยอร์ (Multiple Layers) แบบ 3 เลเยอร์	17
2.13 ไดอะแกรมของโครงข่ายหลายเลเยอร์ (Multiple Layers) แบบ 3 เลเยอร์	17
3.1 การแบ่งชั้นบรรยากาศของโลกตามระดับความสูง	25
3.2 การเกิดปรากฏการณ์ไอออโนสเฟียร์	27
3.3 บล็อกไดอะแกรมอุปกรณ์ที่ใช้ในการศึกษาการเปลี่ยนแปลง TEC ในแต่ละวัน	32
3.4 บล็อกไดอะแกรมการทำงานของ TEC meter	33
3.5 Real time TEC meter รุ่น 7633	33
3.6 เครื่องรับสัญญาณเวลา GPS	34
3.7 สายอากาศรับสัญญาณ GPS	34
3.8 สายอากาศรับสัญญาณเวลาจาก GPS	35
3.9 ลักษณะการเปลี่ยนแปลงค่าปริมาณอิเล็กตรอนในแต่ละวัน	36
3.10 วัฏจักรสุริยะมีระยะเวลา 11 ปี	41
3.11 ความสัมพันธ์ของแอดติวิตีที่สนามแม่เหล็กโลกกับจำนวนจุดดับอาทิตย์	42
3.12 ช่วงเวลาที่ทำนายว่าเกิดวัฏจักรสุริยะสูงสุด	42
3.13 การเปลี่ยนแปลงของแอดติวิตีของดวงอาทิตย์, แอดติวิตีของสนามแม่เหล็กโลก และพลังงานอิเล็กตรอนที่เปลี่ยนแปลงในวัฏจักรสุริยะ	43

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญรูป(ต่อ)

รูปที่	หน้า
3.14 ปริมาณอิเล็กทรอนิกส์เปรียบเทียบกับจำนวนจุดบดวงอาทิตย์เฉลี่ย ในแต่ละเดือน ในช่วง มกราคม – ธันวาคม 2543	44
3.15 ปริมาณอิเล็กทรอนิกส์ในช่วงเดือนมกราคมในปี พ.ศ. 2541 –2543	45
3.16 ปริมาณอิเล็กทรอนิกส์ในช่วงเดือนกุมภาพันธ์ในปี พ.ศ. 2541 –2543	46
3.17 ปริมาณอิเล็กทรอนิกส์ในช่วงเดือนมีนาคมในปี พ.ศ. 2541 –2543	46
3.18 ปริมาณอิเล็กทรอนิกส์ในช่วงเดือนเมษายนในปี พ.ศ. 2541 –2543	47
3.19 ปริมาณอิเล็กทรอนิกส์ในช่วงเดือนพฤษภาคมในปี พ.ศ. 2541 –2543	47
3.20 ปริมาณอิเล็กทรอนิกส์ในช่วงเดือนมิถุนายนในปี พ.ศ. 2541 –2543	48
3.21 ปริมาณอิเล็กทรอนิกส์ในช่วงเดือนกรกฎาคมในปี พ.ศ. 2541 –2543	48
3.22 ปริมาณอิเล็กทรอนิกส์ในช่วงเดือนสิงหาคมในปี พ.ศ. 2541 –2543	49
3.23 ปริมาณอิเล็กทรอนิกส์ในช่วงเดือนกันยายนในปี พ.ศ. 2541 –2543	49
3.24 ปริมาณอิเล็กทรอนิกส์ในช่วงเดือนตุลาคมในปี พ.ศ. 2541 –2543	50
3.25 ปริมาณอิเล็กทรอนิกส์ในช่วงเดือนพฤศจิกายนในปี พ.ศ. 2541 –2543	50
3.26 ปริมาณอิเล็กทรอนิกส์ในช่วงเดือนธันวาคมในปี พ.ศ. 2541 –2543	51
3.27 มุมซีกนิตของดวงอาทิตย์ที่มีค่าเป็นศูนย์ในตำแหน่งของโลกที่เส้นละติจูด หรือเส้นรุ้งต่าง ๆ	57
3.28 แผนที่ตั้งของสถานีวัดปริมาณอิเล็กทรอนิกส์ในประเทศไทย	58
3.29 ค่าปริมาณอิเล็กทรอนิกส์ TEC ของเชียงใหม่ ในวันที่ 14-17 กรกฎาคม 2543	58
3.30 ค่าปริมาณอิเล็กทรอนิกส์ TEC ของกรุงเทพ ในวันที่ 14-17 กรกฎาคม 2543	59
3.31 ค่าปริมาณอิเล็กทรอนิกส์ TEC ของภูเก็ต ในวันที่ 14-17 กรกฎาคม 2543	59
4.1 โครงสร้างของโครงข่ายหนึ่งเลเยอร์	63
4.2 โครงสร้างของโครงข่ายสองเลเยอร์	63
4.3 การใช้งาน NNT Toolbox	67
4.4 การใช้งาน Network/Data Manager	68
4.5 โครงข่ายประสาทที่สร้างขึ้น	69
4.6 การฝึกโครงข่ายประสาทที่สร้างขึ้นโดยวิธี Lavenberg- Marquardt.....	69
5.1 ค่าพารามิเตอร์อินพุตที่เราใช้ในแบบจำลอง IRI คำนวณค่าที่กรุงเทพ วันที่ 7 กรกฎาคม 2543	74

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญญรูป(ต่อ)

รูปที่	หน้า
5.2 ผลการคำนวณจากแบบจำลองที่เราเลือก	75
5.3 ภาพวาดอธิบายคำจำกัดความของ TEC	77
5.4 ผลการทดลองเปรียบเทียบค่าความผิดพลาดของแบบจำลอง IRI กับแบบจำลอง ปริมาณอิเล็กทรอนิกส์บนชั้นบรรยากาศไอโอโนสเฟียร์โดยเทคนิคโครงข่ายประสาท ในระหว่างวันที่ 21 –28 มกราคม 2544	78
5.5 ผลการทดลองเปรียบเทียบค่าความผิดพลาดของแบบจำลอง IRI กับแบบจำลอง ปริมาณอิเล็กทรอนิกส์บนชั้นบรรยากาศไอโอโนสเฟียร์โดยเทคนิคโครงข่ายประสาท ในระหว่างวันที่ 21 –28 มกราคม 2544	79



บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

การสื่อสารระบบดาวเทียม เป็นการสื่อสารที่ใช้ดาวเทียมซึ่งลอยอยู่ในอวกาศ ทำหน้าที่เป็นสถานีทวนสัญญาณ ซึ่งการที่ดาวเทียมโคจรอยู่นอกโลกนี้จะทำให้การสื่อสารครอบคลุมพื้นที่ได้ไกลขึ้น บนตัวดาวเทียมจะมีชุดอุปกรณ์ทรานสปอนเดอร์ทำหน้าที่แปลงความถี่สัญญาณขาขึ้น (Uplink) ให้เป็นความถี่สัญญาณขาลง (Downlink) ซึ่งจะสามารถเชื่อมโยงการสื่อสารจากสถานีภาคพื้นดินได้ [1]

ดาวเทียมได้มีพัฒนามาใช้ประโยชน์ในด้านต่าง ๆ แบ่งประเภทการใช้งานได้ 11 ประเภทดังนี้

- 1) ดาวเทียมเพื่อการสื่อสารแบบจุดต่อจุด เช่น ดาวเทียมपालาปา, ดาวเทียมไทยคม
- 2) ดาวเทียมเพื่อการสื่อสารระหว่างดาวเทียม เช่น ดาวเทียม TDRS
- 3) ดาวเทียมเพื่อการสื่อสารเคลื่อนที่ทางบกทางน้ำและทางอากาศ เช่นดาวเทียมอินมาร์แซท
- 4) ดาวเทียมเพื่อการสื่อสารวิทยุกระจายเสียง และวิทยุโทรทัศน์ เช่น ดาวเทียม Astra
- 5) ดาวเทียมเพื่อการสำรวจโลก สำรวจทรัพยากรธรรมชาติ เช่น ดาวเทียม Landsat
- 6) ดาวเทียมเพื่อการสำรวจอวกาศ เช่น ดาวเทียม Meteor, ดาวเทียม Explorer
- 7) ดาวเทียมเพื่อการพยากรณ์อากาศ เช่น ดาวเทียม GMS, ดาวเทียม Nova 6-9
- 8) ดาวเทียมเพื่อการปฏิบัติงานในอวกาศ เช่น ดาวเทียม Spas, ดาวเทียม Skylab
- 9) ดาวเทียมเพื่อกิจการวิทยุสมัครเล่น เช่น ดาวเทียม Jas-1 หรือดาวเทียม Fuji
- 10) ดาวเทียมเพื่อกำหนดตำแหน่ง เช่น ดาวเทียม Navstar
- 11) ดาวเทียมเพื่อการนำร่องเรือและอากาศยาน เช่น ดาวเทียม Cosmos

ภายในตัวดาวเทียมจะมีอุปกรณ์ชุดรับ - ส่งคลื่นสัญญาณดาวเทียม โดยคลื่นความถี่ที่ใช้จะแตกต่างกันไปตามวัตถุประสงค์การใช้งาน เช่น ความถี่ย่าน L band ถูกนำมาใช้ประโยชน์ในการนำร่องของดาวเทียม GPS เนื่องจากสัญญาณดาวเทียมเดินทางผ่านชั้นบรรยากาศต่าง ๆ จะได้รับผลกระทบจากปฏิกิริยาที่เกิดขึ้นระหว่างคลื่นดาวเทียมที่เดินทางผ่านกับอิเล็กตรอน ทำให้คลื่นสัญญาณดาวเทียมมีความผิดเพี้ยนไปจากสัญญาณเดิม เป็นต้นว่า เกิดการเปลี่ยนแปลงทางแอมพลิจูดอย่างกะทันหัน (Scintillation effect) หรือ เกิดการหมุนของเฟส ถ้าเกิดความผิดปกติมากเกินไปด้วยสาเหตุที่กล่าวมา สามารถทำให้เกิดข้อผิดพลาดในการบอกตำแหน่งของดาวเทียม GPS ได้ ซึ่งผลกระทบต่าง ๆ ที่เกิดขึ้นนี้มีความสัมพันธ์อย่างมากกับการเปลี่ยนแปลงปริมาณอิเล็กตรอนในชั้นบรรยากาศไอโอโนสเฟียร์ ที่เรียกว่า " Total Electron Content " (TEC)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เมื่อเปรียบเทียบผลกระทบต่าง ๆ ที่เกิดขึ้นกับคลื่นสัญญาณดาวเทียมพบว่าผลกระทบดังกล่าวเกิดขึ้นในประเทศไทยนั้นเป็นปัญหาที่รุนแรงกว่าหลายประเทศ ทั้งนี้เป็นเพราะว่าประเทศไทยตั้งอยู่ในเขตที่ใกล้กับเส้นศูนย์สูตรจึงมีปริมาณอิเล็กตรอนในชั้นบรรยากาศไอโอโนสเฟียร์ที่หนาแน่นมากกว่าประเทศที่ตั้งอยู่ในเขตละติจูดสูง ๆ

ด้วยเหตุผลดังกล่าวมาแล้ว จะเห็นได้ว่าปริมาณอิเล็กตรอนในชั้นบรรยากาศไอโอโนสเฟียร์เป็นพารามิเตอร์หนึ่งที่สำคัญในการคำนึงถึงความเชื่อถือได้ของสัญญาณดาวเทียม ดังนั้นถ้าเราสามารถคาดคะเนการเปลี่ยนแปลงของปริมาณอิเล็กตรอนในชั้นบรรยากาศไอโอโนสเฟียร์ที่ส่งผลกระทบต่อความผิดพลาดของสัญญาณดาวเทียมที่เกิดขึ้นได้ โดยอาศัยชุดข้อมูลที่เก็บรวบรวมมาเป็นระยะเวลาอันยาวนานก็จะทำให้เกิดประโยชน์ในการพัฒนาแก้ไขความผิดพลาดของสัญญาณดาวเทียมได้ต่อไป การสร้างแบบจำลองปริมาณอิเล็กตรอนจึงมีความสำคัญอย่างยิ่ง

1.2 วัตถุประสงค์ของการศึกษา

วิทยานิพนธ์ฉบับนี้มีวัตถุประสงค์เพื่อศึกษาการสร้างแบบจำลองปริมาณอิเล็กตรอนในชั้นบรรยากาศไอโอโนสเฟียร์ตลอดเส้นทางที่คลื่นดาวเทียมเดินทางโดยใช้เทคนิคโครงข่ายประสาทซึ่งเทคนิคที่ถูกเลือกสำหรับการสร้างแบบจำลองในครั้งนี้ มีความสามารถในการปรับปรุงให้ดีขึ้นสอดคล้องกับข้อมูลที่เก็บบันทึกจริงจากดาวเทียม GPS ที่เกิดขึ้นใน 3 จังหวัดด้วยกัน ได้แก่ กรุงเทพมหานคร, เชียงใหม่ และภูเก็ต เพื่อให้ได้แบบจำลองที่สามารถถูกนำมาใช้สำหรับการวิเคราะห์อ้างอิงภายในประเทศไทยได้ต่อไปโดยมีความผิดพลาดในการพยากรณ์น้อยกว่าแบบจำลองมาตรฐาน IRI-2001 (International Reference Ionosphere 2001) ซึ่งใช้ฐานข้อมูลในการสร้างแบบจำลองเป็นค่าสถิติจากประเทศต่าง ๆ ทั่วโลก

1.3 สมมติฐานของการศึกษา

คาดว่าเมื่อได้สิ้นสุดการศึกษาวิทยานิพนธ์นี้จะได้แบบจำลองปริมาณอิเล็กตรอนชั้นบรรยากาศไอโอโนสเฟียร์ของกรุงเทพมหานคร โดยเทคนิคโครงข่ายประสาทที่มีความสามารถในการพยากรณ์โดยไม่ต้องอาศัยสมการทางคณิตศาสตร์ที่ยุ่งยากซับซ้อน ที่ประกอบด้วยการคำนวณจากแบบจำลองจำนวนมากมาย และที่สำคัญคือมีความแม่นยำกว่าแบบจำลอง IRI สำหรับใช้ในการวิเคราะห์ปริมาณอิเล็กตรอนในประเทศไทย เนื่องมาจากแบบจำลองที่สร้างขึ้นนี้ใช้ฐานข้อมูลเฉพาะของประเทศไทย

1.4 แนวความคิดที่ใช้ในการทำวิจัย

แบบจำลองปริมาณอิเล็กทรอนิกส์บนชั้นบรรยากาศไอโอโนสเฟียร์ ที่ได้รับความนิยมมากที่สุดคือ IRI มีลักษณะเป็นสมการอิมพีริคัล ในการคำนวณต้องทราบพารามิเตอร์ต่างๆ เช่น เวลา, จำนวนจุดดับของดวงอาทิตย์, ตำแหน่งสถานที่ (ละติจูด, ลองจิจูด), ความสูง รวมทั้งยังต้องอาศัยการคำนวณจากหลายแบบจำลองมาช่วยในการคำนวณ ประกอบด้วย แผนที่ URSI (The International Union of Radio Consultative Committee maps) ใช้สำหรับหาความสูงที่สุดของชั้นบรรยากาศ F2 (hmF2) , ตาราง Bo (Table option Bo) ใช้สำหรับหาความหนาของส่วนที่เป็นด้านล่างของชั้นบรรยากาศ และ แบบจำลอง Danilov ใช้สำหรับหาค่าประกอบที่เป็นไอออนบนชั้นบรรยากาศ [2]

แบบจำลองที่สร้างขึ้นมาจากความรู้ทางโครงข่ายประสาท ไม่จำเป็นต้องอาศัยค่าตัวแปรจากแบบจำลองอื่น ๆ เข้ามาช่วยปรับปรุงให้แบบจำลองดีขึ้น ด้วยเหตุผลที่ว่าวิธีโครงข่ายประสาทจะมีการเรียนรู้เลียนแบบการทำงานของสมองมนุษย์ มีการปรับค่าพารามิเตอร์ภายในโครงข่ายเพื่อให้ได้ค่าที่เหมาะสมที่สุดสำหรับการสร้างความสัมพันธ์ระหว่างอินพุตและเอาต์พุต ทำให้แบบจำลองสามารถปรับปรุงให้ดีขึ้นได้ง่ายจากเหตุการณ์บนฐานข้อมูลจริง

แบบจำลองที่สร้างขึ้นนี้มีขั้นตอนการเรียนรู้และการฝึก (Learning and Training) โดยในส่วนของกรอกแบบแบบจำลองนั้นการปรับปรุงแบบจำลองจะเลือกใช้วิธีการแพร่กระจายย้อนกลับ (Backpropagation) การสร้างแบบจำลองด้วยเทคนิคโครงข่ายประสาทจะใช้โปรแกรม MATLAB ซึ่งมี Toolbox ชื่อว่า Neuron Network ซึ่งจะพบว่าการคำนวณตลอดจนการปรับปรุงแบบจำลอง IRI ให้ดีขึ้นนั้นมีความซับซ้อนและยุ่งยากมากกว่าการสร้างแบบจำลองที่อาศัยโครงข่ายประสาท

1.5 ขอบเขตของการวิจัย

ขอบเขตของการศึกษาในวิทยานิพนธ์ฉบับนี้ประกอบด้วย 3 ประเด็นหลัก คือ

1.5.1 การศึกษาความสัมพันธ์ของจุดดับดวงอาทิตย์และดัชนีสนามแม่เหล็กโลกกับลักษณะการเปลี่ยนแปลงปริมาณอิเล็กทรอนิกส์ของกรุงเทพมหานคร

สถานที่ติดตั้งของอุปกรณ์การทดลองติดตั้งอยู่ที่ศูนย์วิจัยการสื่อสารและเทคโนโลยีสารสนเทศ ชั้น 10 อาคารกรมหลวงสงขลาราชนครินทร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง ข้อมูลที่ได้ถือเป็นตัวแทนข้อมูลของกรุงเทพมหานคร โดยทำการเปรียบเทียบในช่วงระยะเวลา 3 ปี ตั้งแต่ มกราคม 2541 – ธันวาคม 2543 กับตัวแทนข้อมูลของจังหวัดเชียงใหม่ ซึ่งสถานที่ติดตั้งอุปกรณ์การทดลองอยู่ที่ภาควิชาวิศวกรรมไฟฟ้า มหาวิทยาลัยเชียงใหม่ และตัวแทนข้อมูลของจังหวัดภูเก็ต ซึ่งสถานที่ติดตั้งอุปกรณ์การทดลองอยู่ที่ภาควิชาอิเล็กทรอนิกส์ วิทยาลัยเทคนิคภูเก็ต

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งยังมีให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1.5.2 การศึกษาหลักการออกแบบและการสร้างแบบจำลองปริมาณอิเล็กทรอนิกส์อนใน ชั้นบรรยากาศไอโอโนสเฟียร์โดยเทคนิคโครงข่ายประสาท (Artificial Neuron Networks)

การศึกษาในชั้นตอนนี้มีจุดประสงค์เพื่อให้ได้แบบจำลองที่เหมาะสมสำหรับการใช้งานพยากรณ์ปริมาณอิเล็กทรอนิกส์อนที่จะเกิดขึ้นล่วงหน้าได้

1.5.3 การศึกษาผลการทดลองที่ได้เปรียบเทียบกับค่าความผิดพลาดกับแบบจำลอง IRI การศึกษาในชั้นตอนนี้มีจุดประสงค์เพื่อจะยืนยันว่าค่าความผิดพลาดที่ได้จากแบบจำลองโครงข่ายประสาทว่าดีกว่าค่าจากแบบจำลอง IRI - 2000 มากน้อยเท่าใด

1.6 ขั้นตอนของการศึกษา

การศึกษาในวิทยานิพนธ์ฉบับนี้ สามารถแบ่งขั้นตอนของการศึกษาออกได้ 5 ขั้นตอน คือ

1.6.1 ขั้นตอนการเก็บข้อมูลปริมาณอิเล็กทรอนิกส์อนในชั้นบรรยากาศไอโอโนสเฟียร์
ขั้นตอนการเก็บรวบรวมข้อมูลได้จากการวัดปริมาณอิเล็กทรอนิกส์อนในช่วงเวลาระหว่างปี พ.ศ. 2541-2543 ข้อมูลที่ได้จากเครื่องวัดคือค่าปริมาณอิเล็กทรอนิกส์อนทุก 1 นาที รายละเอียดของตำแหน่งสถานที่ตั้งอุปกรณ์การทดลอง มี 3 แห่ง ดังนี้

- 1) กรุงเทพมหานคร ละติจูด 13.7°N ลองจิจูด 100.8°E หรือตำแหน่งทางแม่เหล็กโลก ละติจูด 2.8°N ลองจิจูด 171.9°E
- 2) เชียงใหม่ ละติจูด 18.8°N ลองจิจูด 99°E หรือตำแหน่งทางแม่เหล็กโลกละติจูด 7.9°N ลองจิจูด 170.4°E
- 3) ภูเก็ต ละติจูด 7.9°N ลองจิจูด 98.4°E หรือตำแหน่งทางแม่เหล็กโลกละติจูด 2.9°S ลองจิจูด 169.4°E

1.6.2 ขั้นตอนการคำนวณพารามิเตอร์ต่าง ๆ จากฐานข้อมูลที่เก็บไว้

กระบวนการพารามิเตอร์ต่าง ๆ เพื่อเป็นตัวแทนสำหรับการวิเคราะห์ เนื่องจากว่าข้อมูลปริมาณอิเล็กทรอนิกส์อนที่เก็บบันทึกในตอนแรกนั้นมีปริมาณที่มากเกินไปจนความจำเป็น พารามิเตอร์ที่คำนวณได้แก่ ปริมาณอิเล็กทรอนิกส์อนเฉลี่ยแต่ละวันในแต่ละช่วงเวลา 15 นาที, ปริมาณอิเล็กทรอนิกส์อนเฉลี่ยขณะทุกเวลา 15 นาที, ความคลาดเคลื่อนจากค่าเฉลี่ยปริมาณอิเล็กทรอนิกส์อนทุก 15 นาที (ปริมาณอิเล็กทรอนิกส์อนเฉลี่ยแต่ละวันในแต่ละช่วงเวลา 15 นาที – ปริมาณอิเล็กทรอนิกส์อนเฉลี่ยขณะทุกเวลา 15 นาที), ปริมาณอิเล็กทรอนิกส์อนเฉลี่ยในแต่ละวัน, ความคลาดเคลื่อนจากค่าเฉลี่ยปริมาณอิเล็กทรอนิกส์อนในวันนี้กับวันก่อน (ปริมาณอิเล็กทรอนิกส์อนเฉลี่ยในวันนี้ – ปริมาณอิเล็กทรอนิกส์อนเฉลี่ยในวันก่อน), ความคลาดเคลื่อนจากค่าเฉลี่ยปริมาณอิเล็กทรอนิกส์อนในวันนี้กับวันก่อนหน้า 2 วัน (ปริมาณอิเล็กทรอนิกส์อนเฉลี่ยในวันนี้ – ปริมาณอิเล็กทรอนิกส์อนเฉลี่ยในวันก่อนหน้า 2 วัน) เป็นต้น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1.6.3 ขั้นตอนการออกแบบและการสร้างแบบจำลองโครงข่ายประสาท

กำหนดค่าอินพุตและเอาต์พุตของโครงข่ายประสาทจากพารามิเตอร์ที่คำนวณไว้แล้ว ทำการเปลี่ยนแปลงค่าพารามิเตอร์ต่างๆ ของโครงข่ายประสาท ได้แก่ จำนวนเลเยอร์โครงข่ายประสาท, จำนวนของนิวรอน เพื่อให้เกิดความผิดพลาดซึ่งวัดจากดัชนี MSE (Mean Square Error) ที่น้อยที่สุดอย่างมีประสิทธิภาพ

1.6.4 ขั้นตอนการเปรียบเทียบผลที่ได้กับการประมาณจากแบบจำลอง IRI

1.6.5 ขั้นตอนการสรุปและวิเคราะห์ผลที่ได้จากการทดลอง




เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 2

ทฤษฎีโครงข่ายประสาท

2.1 โครงข่ายประสาท

โครงข่ายประสาท (Neural Network) มาจากคำเต็มว่า โครงข่ายประสาทเทียม (Artificial Neural Network) ทั้งนี้ก็เนื่องจากโครงข่ายประสาทมีเฉพาะในสิ่งมีชีวิตเท่านั้น และก็มีความสลับซับซ้อนในการทำงานมากกว่าโครงข่ายประสาทเทียมซึ่งสร้างมาจากแบบจำลองทางคณิตศาสตร์ แต่การเรียกชื่อเต็มนี้ค่อนข้างยาวทำให้บางคนไม่นิยมเรียกชื่อเต็ม โครงข่ายประสาทเทียมมีลักษณะการประมวลผลข้อมูลคล้ายกับระบบประสาทในสมองของมนุษย์ โครงสร้างของโครงข่ายประสาทจะต้องมีการเชื่อมโยงเกี่ยวพันกันมากมายระหว่างนิวรอน เพื่อที่จะทำหน้าที่แก้ไขปัญหาเฉพาะหน้าได้ ANN มีการเรียนรู้ได้โดยอาศัยตัวอย่างซึ่งเหมือนกับการทำงานของระบบประสาทของมนุษย์ที่ต้องอาศัยประสบการณ์ ANN ถูกสร้างให้มีโครงสร้างที่แตกต่างกันไปตามความต้องการ เช่นใช้ในการจดจำลักษณะ (Pattern recognition) , ใช้ในการจัดกลุ่ม (Classification) เป็นต้น การที่โครงข่ายประสาทสามารถทำงานในลักษณะต่างๆ ได้ขึ้นกับการเรียนรู้ (Learning) การเรียนรู้ในระบบประสาทของสิ่งมีชีวิตเกี่ยวข้องกับการปรับค่าความแข็งแรงในการเชื่อมโยงของไซแนปส์ (Synapse) ที่อยู่ระหว่างนิวรอนกับนิวรอน



รูปที่ 2.1 แสดงภาพวาดของนิวรอนของสิ่งมีชีวิต

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


ความหมายของโครงข่ายประสาท

- 1) โครงข่ายประสาทเป็นระบบที่ประกอบด้วยหน่วยประมวลผลพื้นฐานที่ทำงานแบบคู่ขนาน ซึ่งการทำงานของโครงข่ายประสาทสามารถกำหนดจากโครงสร้างโครงข่าย, การเชื่อมโยง และการประมวลผลทางคณิตศาสตร์ของโหนด [3]
- 2) โครงข่ายประสาทคือตัวประมวลผลแบบกระจายขนานที่มีจำนวนมากประกอบกันอยู่ มีคุณสมบัติตามธรรมชาติคือสามารถเก็บความรู้ที่เป็นประสบการณ์และสามารถนำมาแก้ปัญหาได้ ซึ่งมีความคล้ายกับการทำงานของสมองอยู่ 2 ลักษณะ คือ (1) โครงข่ายประสาทต้องการความรู้ประสบการณ์ในขั้นตอนกระบวนการเรียนรู้ และ (2) ค่าความแข็งแรงในการเชื่อมโยงกันระหว่างนิวรอนก็คือค่าถ่วงน้ำหนักของไซแนปส์ซึ่งใช้ในการเก็บความรู้ประสบการณ์ [4]

2.2 หลักการทำงานของโครงข่ายประสาท

โครงข่ายประสาทประกอบด้วยองค์ประกอบพื้นฐานจำนวนมากที่มีลักษณะการทำงานแบบคู่ขนานพร้อมกัน องค์ประกอบพื้นฐานของโครงข่ายประสาทได้รับแนวความคิดมาจากระบบประสาทของสิ่งมีชีวิต การทำงานของโครงข่ายมีลักษณะการเชื่อมโยงระหว่างองค์ประกอบเหมือนกับการทำงานของสมองคน โครงข่ายประสาทสามารถทำงานเฉพาะอย่างได้ต้องอาศัยการปรับค่าพารามิเตอร์ในการเชื่อมโยงระหว่างองค์ประกอบที่เรียกว่าตัวถ่วงน้ำหนัก (Weight) และ ไบอัส (Bias) ในระหว่างการฝึก (Training)

โครงข่ายประสาทที่ได้ถูกฝึกมาแล้วนั้นจะมีความสามารถจัดการกับอินพุตที่เข้ามาเพื่อให้ได้ค่าเอาต์พุตที่ต้องการ (Target output) สามารถแสดงเหตุการณ์ที่กล่าวถึงนี้ดังรูปที่ 2.1 การปรับค่าของโครงข่ายประสาทอาศัยหลักการเปรียบเทียบระหว่างเอาต์พุตกับค่าเอาต์พุตที่ต้องการ ซึ่งจะทำการปรับค่าพารามิเตอร์การเชื่อมโยงจนกว่าค่าเอาต์พุตจากโครงข่ายจะตรงกับค่าเอาต์พุตที่ต้องการ ตัวอย่างการเรียนรู้ (Learning) ที่มีการใช้คู่ของอินพุต - เอาต์พุตสำหรับฝึกโครงข่าย คือ การเรียนรู้แบบควบคุม (Supervised learning)



รูปที่ 2.2 แสดงบล็อกไดอะแกรมการฝึกของโครงข่ายประสาท

2.3 ประโยชน์ของโครงข่ายประสาท

โครงข่ายประสาทที่ได้รับการฝึกสามารถนำมาประยุกต์ใช้ทำงานที่มีความซับซ้อนได้หลากหลายสาขา เช่น การจดจำรูปแบบ (Pattern recognition), การจัดกลุ่ม (Classification), การพูด (Speech), การมองเห็น (Vision) และระบบควบคุม (Control)

การประยุกต์ใช้งานโครงข่ายประสาทเริ่มต้นตั้งแต่ปี ค.ศ. 1984 โดยนำมาใช้กับอุปกรณ์ปรับปรุงคุณภาพของสัญญาณแบบปรับค่าได้ (Adaptive channel equalizer) อุปกรณ์นี้ประกอบด้วยโครงข่ายประสาทเพียงโครงข่ายเดียว อุปกรณ์ที่ถูกสร้างขึ้นนั้นนับว่าประสบความสำเร็จทางธุรกิจอย่างมากเนื่องจากการนำมาใช้ในระบบโทรศัพท์ทางไกลเพื่อรักษาระดับสัญญาณเสียงให้มีคุณภาพดี หลังจากนั้นเป็นต้นมาการประยุกต์ใช้งานโครงข่ายประสาทก็ได้รับความนิยมสูงซึ่งจนสามารถแบ่งสาขาที่นำไปใช้งานเป็นด้านต่างๆ ได้ดังนี้

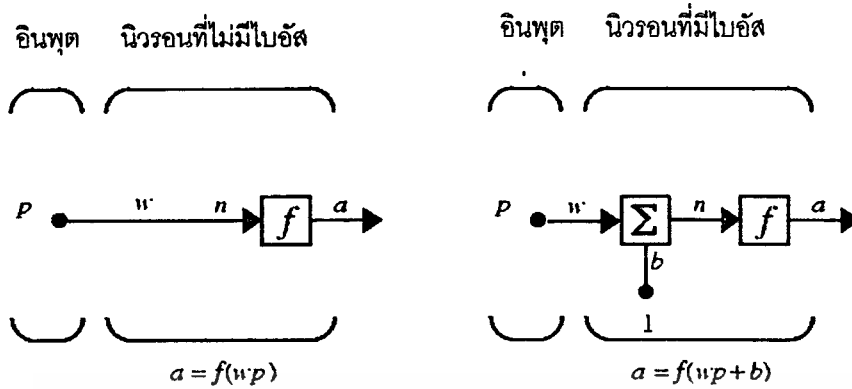
- ด้านการบิน ระบบการขับเครื่องบินแบบอัตโนมัติ, การจำลองสถานการณ์เส้นทางการบิน, ระบบควบคุมอากาศยาน, การจำลองอุปกรณ์ชิ้นส่วนอะไหล่ของอากาศยาน, การตรวจสอบความผิดปกติของอุปกรณ์ชิ้นส่วนอะไหล่ของอากาศยาน
- ด้านยานยนต์ ระบบนำทางอัตโนมัติ
- ด้านธนาคาร การประมาณเครดิต, การตรวจสอบและอ่านเอกสาร
- ด้านทหาร การปล่อยอาวุธ, การโจมตีเป้าหมาย, การจดจำภาพใบหน้า, ตัวตรวจจับแบบใหม่, เรดาร์, โซนาร์ และการประมวลผลด้านรูปภาพ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- ด้านอิเล็กทรอนิกส์ การทำนายนรหัสซีเคັນซ์, การสร้างไอซี, ควบคุมกระบวนการผลิต, การวิเคราะห์ความผิดพลาดในการสร้างไอซี, การมองเห็นของเครื่องจักร, การสังเคราะห์เสียง
- ด้านบันเทิง การสร้างภาพเคลื่อนไหว, การทำนายนตลาค, การสร้างเทคนิคพิเศษ
- ด้านการเงิน การประเมินอสังหาริมทรัพย์, ดูแลการกู้เงิน, วิเคราะห์สถานะการเงิน, ทำนายนราคาแลกเปลี่ยนเงินตราระหว่างประเทศ
- ด้านประกันภัย การประเมินนโยบาย, การจัดประกันภัยให้เหมาะสมกับลูกค้า
- ด้านอุตสาหกรรม ระบบควบคุมการผลิต, การวิเคราะห์และออกแบบผลิตภัณฑ์, ระบบตรวจสอบคุณภาพ, การทดสอบเบียร์, การวิเคราะห์การทอผ้า, การทำนายนคุณภาพกระดาษ, การวิเคราะห์คุณภาพของไอซีคอมพิวเตอร์
- ด้านการแพทย์ การวิเคราะห์เซลล์มะเร็งหน้าอก, การลดค่าใช้จ่ายของโรงพยาบาล, การปรับปรุงคุณภาพโรงพยาบาล, การวิเคราะห์หาระยะเวลาที่เหมาะสมในการปลูกถ่ายอวัยวะ, การตรวจสอบดูแลห้องฉุกเฉิน
- ด้านทรัพยากรน้ำมันและก๊าซธรรมชาติ ใช้ในการสำรวจ
- ด้านหุ่นยนต์ การควบคุมการเคลื่อนที่, การยกของของหุ่นยนต์, ระบบการมองเห็น
- ด้านเสียงพูด การจดจำเสียงพูด, การบีบอัดเสียง, การแบ่งแยกเสียงสระ
- ด้านรักษาความปลอดภัย การควบคุมดูแลคลังสินค้า
- ด้านสื่อสาร การบีบอัดภาพและเสียง, การบริการข้อมูลอัตโนมัติ, การแปลภาษาแบบเรียลไทม์, ระบบการชำระค่าบริการของลูกค้า
- ด้านขนส่ง การวิเคราะห์การหยุดของรถบรรทุก, การวิเคราะห์การจัดตารางจราจร, การวิเคราะห์ระบบเส้นทางเดินรถ

2.4 องค์ประกอบของโครงข่ายประสาท

เพื่อให้เข้าใจถึงหลักการทำงานเบื้องต้น ในที่นี้ให้พิจารณาโครงข่ายประสาทพื้นฐานที่เกดขึ้นจากองค์ประกอบ เรียกว่า นิวรอนพื้นฐาน โดย 1 นิวรอนพื้นฐาน ประกอบด้วยค่าอินพุตปริมาณสเกลาร์ 1 ค่า และไม่มีค่าไบอัส แต่โดยทั่วไปแล้วนิวรอนปกติจะประกอบด้วยค่าอินพุตปริมาณสเกลาร์ 1 ค่า และมีค่าไบอัส 1 ค่า ดังรูปที่ 2.3



รูปที่ 2.3 แสดงไดอะแกรมนิวรอนพื้นฐานที่ไม่มีไบอัส และนิวรอนที่มีไบอัส

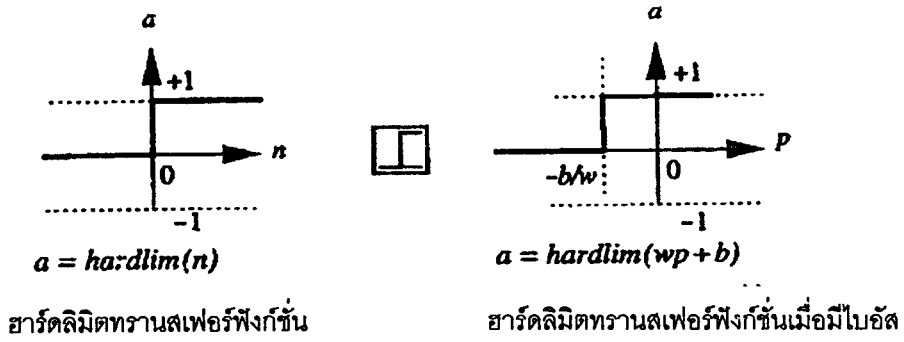
เมื่อมีอินพุตปริมาณสเกลาร์ P เข้าสู่นิวรอนจะถูกคูณด้วยค่าถ่วงน้ำหนัก (Weight) ได้ค่าเป็นสเกลาร์ $w p$ ผ่านเข้าไปในโครงข่ายทำหน้าที่เป็นอาร์กิวเมนต์ของทรานสเฟอร์ฟังก์ชัน ซึ่งเอาต์พุตปริมาณสเกลาร์แทนด้วย a การไบอัสด้วย b หมายถึงการบวกค่าเข้าไปกับ $w p$ ทำให้เกิดการเลื่อนฟังก์ชัน f ไปทางซ้ายด้วยปริมาณ b ค่า n เป็นปริมาณสเกลาร์ทำหน้าที่เป็นอาร์กิวเมนต์ของทรานสเฟอร์ฟังก์ชันมีค่า $w p + b$ f คือ ทรานสเฟอร์ฟังก์ชันต่าง ๆ เช่น ฟังก์ชันขั้นบันได (Step function) หรือ ซิกมอยด์ฟังก์ชัน ค่าพารามิเตอร์ทั้ง w และ b นี้คือค่า สเกลาร์ที่สามารถปรับค่าได้ของนิวรอน

2.4.1 ทรานสเฟอร์ฟังก์ชันของนิวรอน

ทรานสเฟอร์ฟังก์ชันที่นิยมใช้ส่วนใหญ่นั้นมี 3 ชนิด คือ

2.4.1.1 ทรานสเฟอร์ฟังก์ชันชนิดฮาร์ดลิมิต

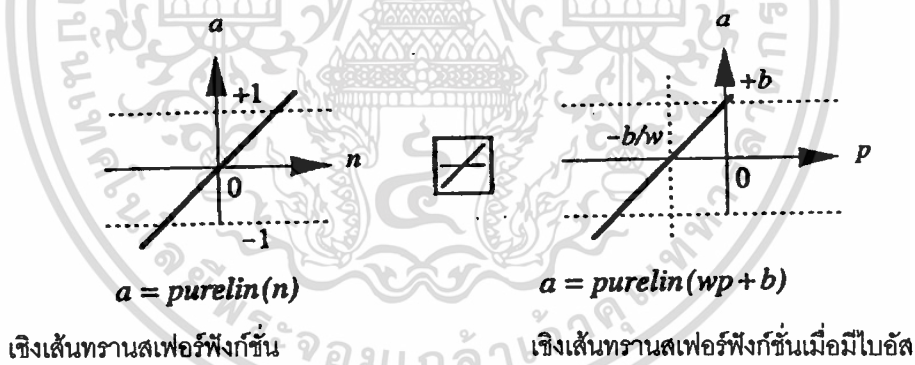
ทรานสเฟอร์ฟังก์ชันชนิดฮาร์ดลิมิต ให้ค่าเอาต์พุต 0 เมื่ออินพุตอาร์กิวเมนต์ n น้อยกว่า 0 และให้ค่าเอาต์พุต 1 เมื่ออินพุตอาร์กิวเมนต์ n มากกว่าหรือเท่ากับ 0 ฟังก์ชันชนิดนี้ถูกนำมาสร้างตัวรับรู้ (Perceptrons) เพื่อให้นิวรอนสามารถตัดสินใจการจำแนกประเภทได้



รูปที่ 2.4 แสดงทรานสเฟอร์ฟังก์ชันชนิดฮาร์ดลิมิตและสัญลักษณ์

2.4.1.2 ทรานสเฟอร์ฟังก์ชันชนิดเชิงเส้น

ทรานสเฟอร์ฟังก์ชันชนิดเชิงเส้นให้ความสัมพันธ์ของอินพุตอาร์กิวเมนต์กับเอาต์พุตเป็นแบบเชิงเส้น นิเวรอนที่ใช้ทรานสเฟอร์ฟังก์ชันชนิดนี้ถูกนำมาใช้งาน เช่นทำหน้าที่เป็นตัวประมาณค่าเชิงเส้นในวงจระแฉที่ฟิลเนียร์ฟิลเตอร์

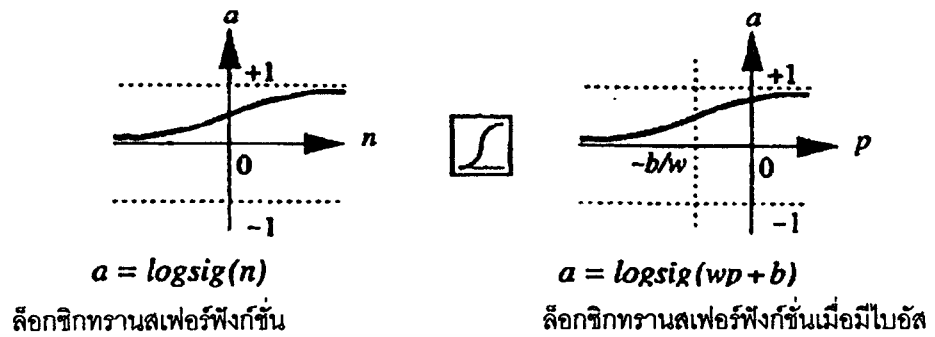


รูปที่ 2.5 แสดงทรานสเฟอร์ฟังก์ชันชนิดเชิงเส้นและสัญลักษณ์

2.4.1.3 ทรานสเฟอร์ฟังก์ชันชนิดซิกมอยด์

ทรานสเฟอร์ฟังก์ชันชนิดซิกมอยด์นี้ อินพุตอาร์กิวเมนต์มีค่าใด ๆ ตั้งแต่ $-\infty$ จนถึง $+\infty$ จะให้ค่าเอาต์พุตมีลักษณะเป็นตัวอักษร S ในช่วง 0 ถึง 1 ทรานสเฟอร์ฟังก์ชันชนิดนี้ถูกใช้ในโครงข่ายชนิดแพร่กระจายย้อนกลับ (Backpropagation Network) เนื่องจากสามารถแยกแยะความแตกต่างของอินพุตได้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 2.6 ทรานสเฟอร์ฟังก์ชันชนิดลือก-ซิกมอยด์และสัญลักษณ์

2.4.2 นิวรอนแบบค่าอินพุตเป็นปริมาณเวกเตอร์

พิจารณานิวรอนแบบค่าอินพุตเป็นปริมาณเวกเตอร์จำนวน R ค่า ค่าอินพุตเวกเตอร์แต่ละตัวแทนด้วย p_1, p_2, \dots, p_R คูณด้วยตัวถ่วงน้ำหนัก $W_{1,1}, W_{1,2}, \dots, W_{1,R}$ ค่าที่ได้จากการถ่วงน้ำหนักทั้งหมดจะถูกรวมกัน ซึ่งผลบวกรวมที่ได้นี้ใช้สัญลักษณ์แทนคือ W_p โดยเกิดจากกระบวนการคือทโปรดักท์ระหว่างเมทริกซ์ W กับเวกเตอร์ p ค่าอาทิวเม้นท์ของทรานสเฟอร์ฟังก์ชัน f ซึ่งแทนด้วย n สามารถเขียนสมการได้ว่า

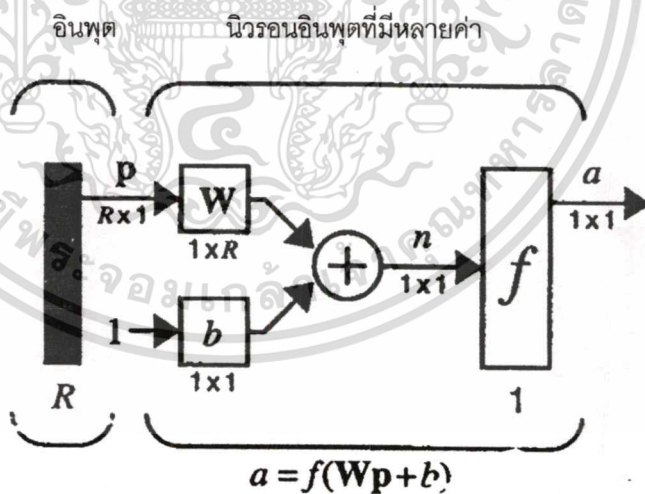
$$n = W_{1,1} p_1 + W_{1,2} p_2 + \dots + W_{1,R} p_R + b \quad (2.1)$$

สมการที่ 2.1 ถูกเขียนเป็นโค้ดในโปรแกรม MATLAB ได้ว่า $n = W * p + b$



รูปที่ 2.7 แสดงรายละเอียดของนิวรอนแบบค่าอินพุตเป็นปริมาณเวกเตอร์

พิจารณาในรูปที่ 2.7 จะพบว่านิวรอน 1 ตัวประกอบด้วยรายละเอียดต่างๆ ในการพิจารณาโครงข่ายที่มีนิวรอนจำนวนมากและบางครั้งก็มีจำนวนเลเยอร์ที่มาก สามารถเขียนเป็นไดอะแกรมที่ตัดรายละเอียดบางอย่างออกไปได้ ดังรูปที่ 2.8



รูปที่ 2.8 แสดงไดอะแกรมนิวรอนแบบค่าอินพุตเป็นปริมาณเวกเตอร์

ค่า R คือขนาดของเวกเตอร์อินพุต p ซึ่งมีขนาด $R \times 1$ เมทริกซ์ W มีขนาด 1 แถว และ R คอลัมน์ ค่า 1 ที่เข้าไปในนิวรอนนั้นจะถูกคูณด้วยสเกลาร์ไบอัส b ส่วนเลเยอร์ของโครงข่ายคือ


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บริเวณที่เป็นการรวมกันของค่าถ่วงน้ำหนัก (Wp) , ค่าไบอัส (b) และทรานสเฟอร์ฟังก์ชัน (f) โดยที่อินพุตที่เป็นปริมาณเวกเตอร์ p จะไม่ใช่ส่วนที่เป็นเลขอร์

2.4.3 สถาปัตยกรรมโครงข่ายประสาทเทียม

2.4.3.1 นิวรอน 1 เลเยอร์

พิจารณารูปที่ 2.9 แสดงรายละเอียดของโครงข่ายประสาทที่มีอินพุตจำนวน R และจำนวนนิวรอนเป็น S




รูปที่ 2.9 แสดงรายละเอียดนิวรอน 1 เลเยอร์

อินพุตเวกเตอร์ p เชื่อมต่อกับแต่ละนิวรอนโดยมีเมทริกซ์ถ่วงน้ำหนัก W ค่าเอาต์พุตจากนิวรอนลำดับที่ i เกิดจากผลคูณระหว่างอินพุตและถ่วงน้ำหนักรวมกับค่าไบอัส ซึ่งจะได้ค่าเป็นสเกลาร์ $n(i)$ มีองค์ประกอบจำนวน S ค่า จะเห็นได้ว่าเอาต์พุตของเลเยอร์เป็นเวกเตอร์คอลัมน์ a โดยจำนวนอินพุตเวกเตอร์ไม่จำเป็นต้องมีค่าเท่ากับจำนวนนิวรอน

องค์ประกอบของอินพุตเวกเตอร์ที่ถูกป้อนเข้าสู่โครงข่ายประสาทนั้นจะต้องถูกถ่วงน้ำหนักด้วยเมทริกซ์ถ่วงน้ำหนัก W

$$W = \begin{bmatrix} W_{1,1} & W_{1,2} & \cdots & W_{1,R} \\ W_{2,1} & W_{2,2} & \cdots & W_{2,R} \\ \vdots & \vdots & \vdots & \vdots \\ W_{S,1} & W_{S,2} & \cdots & W_{S,R} \end{bmatrix} \quad (2.2)$$

จำนวนแถวของเมทริกซ์ W บอกถึงจำนวนนิวรอน และจำนวนคอลัมน์บอกถึงจำนวนอินพุตที่เข้าสู่โครงข่ายก่อนจะทำการถ่วงน้ำหนัก ค่า $W_{1,2}$ คือระดับความแรงของสัญญาณจากอินพุตลำดับที่ 2 ไปยังนิวรอนตัวแรก เพื่อให้กะทัดรัดไดอะแกรมแบบย่อของโครงข่ายประสาทแบบ 1 เลเยอร์ ที่มีจำนวน S นิวรอนและ R อินพุต ถูกเขียนใหม่ได้ดังรูปที่ 2.10




รูปที่ 2.10 แสดงไดอะแกรมนิวรอน 1 เลเยอร์

P คืออินพุตเวกเตอร์ที่มีความยาว R , W คือเมทริกซ์ขนาด $S \times R$, a และ b เป็นเวกเตอร์ความยาว S

2.4.3.2 นิวรอนหลายเลเยอร์

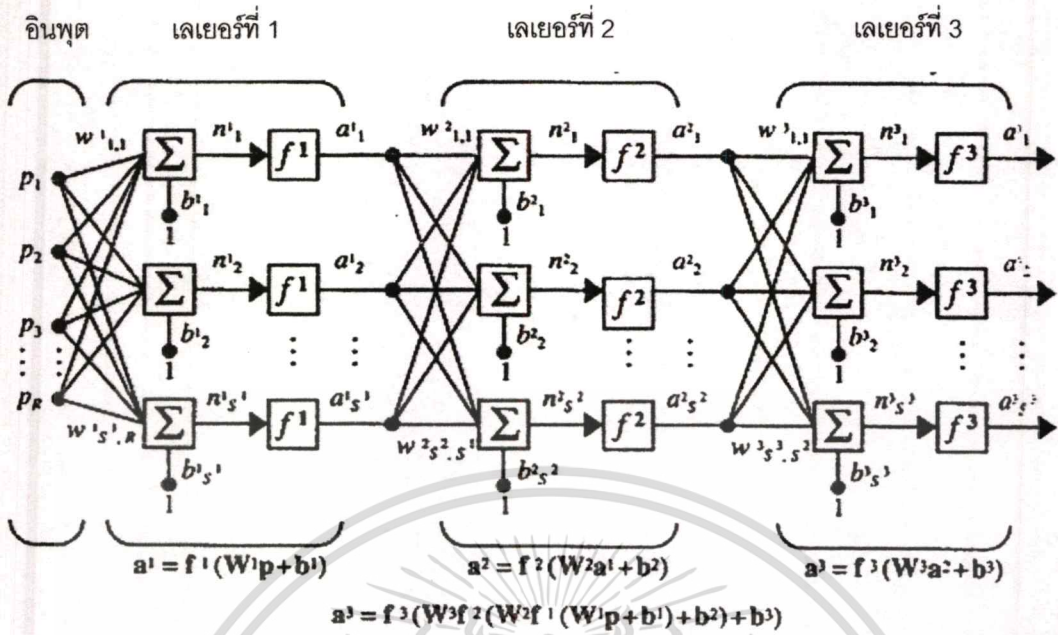
ในโครงข่ายแบบหลายเลเยอร์แบ่งเมทริกซ์ตัวถ่วงน้ำหนักออกเป็นเมทริกซ์ตัวถ่วงน้ำหนักที่เชื่อมกับอินพุต และเมทริกซ์ตัวถ่วงน้ำหนักที่เชื่อมระหว่างเลเยอร์ ซึ่งถูกเรียกว่าอินพุตเวกต์ (Input weight) และเลเยอร์เวกต์ (Layer weight) โดยมีอีกขั้วระบุต้นทาง (ตัวชี้ที่สอง) และระบุปลายทาง (ตัวชี้แรก) กำกับค่าตัวถ่วงน้ำหนักและองค์ประกอบอื่น ๆ ภายในโครงข่ายประสาท โดยแสดงไดอะแกรมได้ ดังรูปที่ 2.11



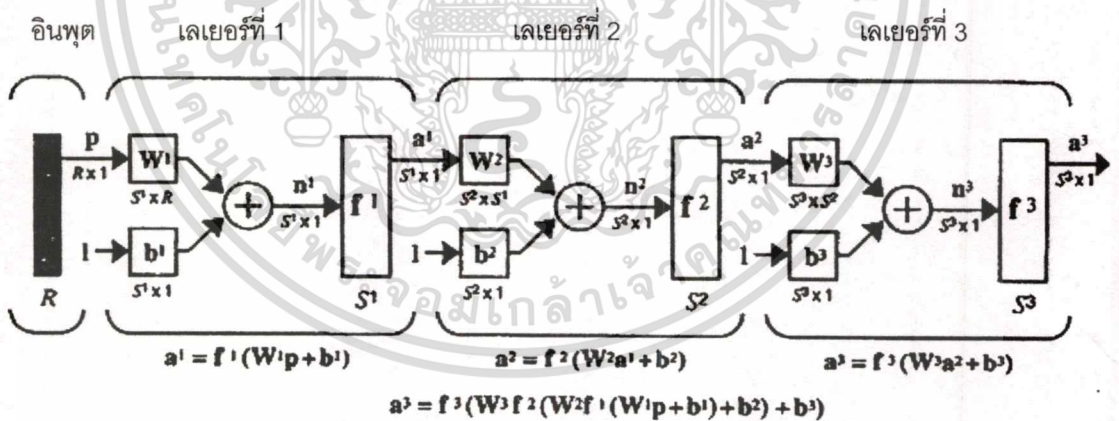
รูปที่ 2.11 แสดงไดอะแกรมนิวรอนที่มีเมทริกซ์ตัวถ่วงน้ำหนักที่เชื่อมกับอินพุต (IW)

$IW^{1,1}$ หมายถึงเมทริกซ์ตัวถ่วงน้ำหนักที่เชื่อมกับอินพุต โดยมีต้นทางเป็นเลเยอร์ที่ 1 และปลายทางเป็นเลเยอร์ที่ 1 ด้วย ดังนั้นองค์ประกอบในเลเยอร์แรก เช่น ค่าไบอัส, อินพุตของโครงข่าย และเอาต์พุตจะมีตัวยกเป็น 1 กำกับทั้งหมด ในเลเยอร์ถัดมาจะใช้สัญลักษณ์ LW แทนเมทริกซ์ตัวถ่วงน้ำหนักที่เชื่อมระหว่างเลเยอร์ โค้ดของ MATLAB สามารถเขียนแทนสมการคณิตศาสตร์ของ $IW^{1,1}$ ได้ว่าเป็น `net.IW{1,1}` ส่วนอินพุตโครงข่ายที่เข้าสู่ทรานสเฟอร์ฟังก์ชันนั้นเขียนเป็นโค้ดใน MATLAB ได้ว่าเป็น `n{1} = net.IW{1,1}*p + net.b{1}` ;

โครงข่ายที่มีเลเยอร์ 3 เลเยอร์จะเขียนค่าเมทริกซ์ตัวถ่วงน้ำหนักของเลเยอร์ที่ 1 แทนด้วย W^1 และค่าเมทริกซ์ตัวถ่วงน้ำหนักของเลเยอร์ที่ 2 แทนด้วย W^2 และค่าเมทริกซ์ตัวถ่วงน้ำหนักของเลเยอร์ที่ 3 แทนด้วย W^3 ตามลำดับ ดังนั้นโครงข่ายแบบ 3 เลเยอร์สามารถเขียนอักษรกำกับได้ดังรูปที่ 2.12 และเพื่อให้สะดวกขึ้นสามารถกำหนดสัญลักษณ์ย่อเป็นไดอะแกรมได้ดังรูปที่ 2.13



รูปที่ 2.12 แสดงโครงข่ายหลายเลเยอร์ (Multiple Layers) แบบ 3 เลเยอร์



รูปที่ 2.13 แสดงไดอะแกรมของโครงข่ายหลายเลเยอร์ (Multiple Layers) แบบ 3 เลเยอร์

2.5 การเรียนรู้แบบแพร่กระจายย้อนกลับ

การแพร่กระจายแบบย้อนกลับ (Backpropagation) เป็นโครงข่ายประสาทที่ใช้กฎการเรียนรู้วิดรอพ-ฮอฟท์ (Widrow-Hoff Learning rule) โดยลักษณะพิเศษของโครงข่ายชนิดนี้คือเป็นโครงข่ายหลายเลเยอร์ที่มีดิฟเฟอเรนทิเอเบิลทรานสเฟอร์ฟังก์ชันแบบไม่เชิงเส้น (Nonlinear

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

differentiable transfer function) เพื่อให้โครงข่ายสามารถทำงานประมาณค่าฟังก์ชันได้จำเป็นต้องมีการฝึก (Training) โดยอาศัยชุดข้อมูลฝึกซึ่งประกอบด้วยอินพุตเวกเตอร์ (Input Vector) และเป้าหมายเวกเตอร์ (Target Vector) โครงข่ายที่มีองค์ประกอบ โบอิส, ซิกมอยด์เลเยอร์ (Sigmoid Layer) และลิเนียร์เอาต์พุตเลเยอร์ จะเป็นโครงข่ายที่สามารถประมาณค่าฟังก์ชันในรูปแบบที่ไม่ต่อเนื่องแต่มีจำนวนจำกัดได้ (A Finite Number of Discontinuities) [5]

การแพร่กระจายแบบย้อนกลับที่เป็นมาตรฐานใช้อัลกอริทึมชนิดเกรเดียนท์เดสเซนทซึ่งใช้กฎการเรียนรู้วิตรอฟ-ฮอฟท์ โดยทำให้ค่าน้ำหนัก (Weight) เคลื่อนที่ไปตามทิศทางของเกรเดียนท์ที่มีค่าลบของฟังก์ชัน คำว่า "การแพร่กระจายย้อนกลับ" จึงมาจากลักษณะการคำนวณค่าเกรเดียนท์

การฝึกโครงข่ายอย่างเหมาะสมช่วยให้เราพบกับคำตอบที่เชื่อถือได้ เมื่อเราต้องเจออินพุตใหม่ที่เราไม่เคยพบมาก่อน ค่าเอาต์พุตจากอินพุตใหม่ที่ได้เกิดจากการฝึกให้รู้จักกับอินพุตเวกเตอร์ และเอาต์พุตที่ถูกต้องมาก่อนในอดีต เมื่อโครงข่ายมีประสบการณ์เพราะการฝึกมาก่อน ค่าอินพุตใหม่จึงคล้ายกับอินพุตเวกเตอร์เก่าและให้ค่าเอาต์พุตใหม่ โดยคำนึงถึงเอาต์พุตที่ถูกต้องในอดีต

2.5.1 อัลกอริทึมการแพร่กระจายย้อนกลับ

ขั้นตอนการพัฒนาอัลกอริทึมการแพร่กระจายย้อนกลับเพื่อให้เกิดความสะดวกในการพิจารณา เราสามารถกำหนดสัญลักษณ์ย่อกำกับไว้ดังรูปที่ 2.13 สัญลักษณ์อักษรต่าง ๆ ที่ปรากฏเป็นตัวอธิบายพารามิเตอร์ในโครงข่ายประสาทที่มี 3 เลเยอร์ ในโครงข่ายแบบหลายเลเยอร์นั้นค่าเอาต์พุตที่เกิดจากเลเยอร์หนึ่งจะเป็นค่าอินพุตของเลเยอร์ที่ตามมา โดยการทำงานสามารถเขียนอธิบายได้ดังนี้

$$a^{m+1} = f^{m+1}(W^{m+1}a^m + b^{m+1}) \quad \text{เมื่อ } m=0,2,\dots,M-1 \quad (2.3)$$

เมื่อค่า M คือจำนวนเลเยอร์ในโครงข่าย นิเวรอนในเลเยอร์แรกรับค่าอินพุตจากภายนอกสามารถเขียนเป็นสมการแสดงสภาวะเริ่มต้นได้ดังนี้

$$a^0 = p \quad (2.4)$$

เอาต์พุตของนิเวรอนในเลเยอร์สุดท้ายจะเป็นค่าเอาต์พุตของโครงข่าย เขียนเป็นสมการแสดงสภาวะสุดท้ายได้ดังนี้

$$a = a^M \quad (2.5)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.5.2 ดัชนีบอกประสิทธิภาพ

อัลกอริทึมการแพร่กระจายย้อนกลับในกรณีที่เป็นโครงข่ายแบบหลายเลเยอร์มีดัชนีบอกประสิทธิภาพเหมือนกับอัลกอริทึมแอลเอ็มเอส (LMS Algorithm: Least Mean Square Algorithm) ทั้งสองอัลกอริทึมใช้ "ค่าความผิดพลาดกำลังสองเฉลี่ย" (Mean Square Error: MSE) เป็นตัวดัชนีบอกประสิทธิภาพ (Performance Index) เซตของค่าตัวอย่างที่เป็นพฤติกรรมของโครงข่ายที่ทำงานได้อย่างเหมาะสมจะถูกจัดให้มีอัลกอริทึมในรูปแบบเป็นชุดข้อมูลในลักษณะดังต่อไปนี้คือ $\{p_1, t_1\}, \{p_2, t_2\}, \dots, \{p_o, t_o\}$ ค่า p คือ ค่าอินพุตในโครงข่าย และ t คือ ค่าเป้าหมายเอาต์พุต อินพุตแต่ละตัวที่เข้าไปในโครงข่ายจะทำให้ได้เอาต์พุตเกิดขึ้นมาแล้วนำค่าเอาต์พุตนั้นไปเปรียบเทียบกับค่าเป้าหมาย โดยอัลกอริทึมจะปรับค่าพารามิเตอร์ในโครงข่ายเพื่อให้เกิดค่าความผิดพลาดกำลังสองเฉลี่ยมีค่าน้อย สมการแสดงค่าความผิดพลาดของโครงข่ายแบบเลเยอร์เดียวมีสมการดังนี้

$$F(x) = E[e^2] = E[(t - a)^2] \quad (2.6)$$

ค่า x คือเวกเตอร์นำหนักและเวกเตอร์ไบอัสของโครงข่าย ในกรณีที่พิจารณาโครงข่ายแบบหลายเลเยอร์ต้องใช้สมการดังนี้

$$F(x) = E[e'e] = E[(t - a)'(t - a)] \quad (2.7)$$

เราจะประมาณค่าความผิดพลาดกำลังสองเฉลี่ยของโครงข่าย ในรูปแบบเดียวกันกับการใช้อัลกอริทึมแบบแอลเอ็มเอส โดยค่าความผิดพลาดกำลังสองที่คาดหวังจะกำหนดให้แสดงอยู่ในฟังก์ชันของ k มีสมการดังนี้

$$\bar{F}(X) = (t(k) - a(k))'(t(k) - a(k)) = e'(k)e(k) \quad (2.8)$$

ในอัลกอริทึมสตีเฟสเทสเซนท์ (The Steepest Descent Algorithm) จะประมาณค่าความผิดพลาดกำลังสองเฉลี่ยเป็นสมการดังนี้

$$w_{i,j}^m(k+1) = w_{i,j}^m(k) - \alpha \frac{\partial \bar{F}}{\partial w_{i,j}^m} \quad (2.9)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$b_i^m(k+1) = b_i^m(k) - \alpha \frac{\partial \bar{F}}{\partial b_i^m} \quad (2.10)$$

โดยที่ α คืออัตราการเรียนรู้ (Learning rate)

2.5.3 กฎลูกโซ่

เนื่องจากความผิดพลาดที่เกิดขึ้นโดยเชื่อมกับฟังก์ชันตัวถ่วงน้ำหนักในฮิดเดนเลเยอร์ เราจำเป็นต้องอาศัยกฎลูกโซ่ (Chain Rule) ของแคลคูลัสมาคำนวณค่าอนุพันธ์ หลักการของกฎลูกโซ่มีดังนี้ สมมติให้ฟังก์ชัน f เป็นฟังก์ชันที่มีตัวแปรที่ชัดเจนคือ n ถ้าเราต้องการหาอนุพันธ์ของ f เทียบกับตัวแปร w เราต้องใช้กฎลูกโซ่มีสมการดังนี้

$$\frac{df(n(w))}{dw} = \frac{df(n)}{dn} \times \frac{dn(w)}{dw} \quad (2.11)$$

ยกตัวอย่าง เช่น

$$f(n) = e^n \quad n = 2w \quad f(n(w)) = e^{2w} \quad (2.12)$$

เมื่อใช้กฎลูกโซ่จะหาค่าได้ดังนี้

$$\frac{df(n(w))}{dw} = \frac{df(n)}{dn} \times \frac{dn(w)}{dw} = (e^n)(2) \quad (2.13)$$

เราสามารถใช้หลักการกฎลูกโซ่เพื่อหาค่าอนุพันธ์ในสมการที่ 2.9 และ 2.10 โดยใช้สมการดังนี้

$$\frac{\partial \bar{F}}{\partial w_{i,j}^m} = \frac{\partial \bar{F}}{\partial n_i^m} \times \frac{\partial n_i^m}{\partial w_{i,j}^m} \quad (2.14)$$

$$\frac{\partial \bar{F}}{\partial b_i^m} = \frac{\partial \bar{F}}{\partial n_i^m} \times \frac{\partial n_i^m}{\partial b_i^m} \quad (2.15)$$

ในเทอมที่สองของสมการที่ 2.14 และ 2.15 สามารถคำนวณได้ง่ายเนื่องจาก n เป็นค่าอินพุตโครงข่ายของเลเยอร์ m ซึ่งเป็นฟังก์ชันที่มีตัวแปรชัดเจนในรูปของตัวถ่วงน้ำหนัก และไบอัส ค่า n สามารถมีสมการดังนี้

$$n_i^m = \sum_{j=1}^{s^{m-1}} w_{i,j}^m a_j^{m-1} + b_i^m \quad (2.16)$$

ดังนั้น

$$\frac{\partial n_i^m}{\partial w_{i,j}^m} = a_j^{m-1}, \quad \frac{\partial n_i^m}{\partial b_i^m} = 1 \quad (2.17)$$

กำหนดให้

$$s_i^m \equiv \frac{\partial \tilde{F}}{\partial n_i^m} \quad (2.18)$$

ค่าความไวของ \tilde{F} เปลี่ยนแปลงไปตามองค์ประกอบที่ i ของอินพุตโครงข่าย (n) ที่เลเยอร์ m ดังนั้นสมการที่ 2.14 และ 2.15 สามารถเขียนใหม่เป็นสมการดังนี้

$$\frac{\partial \tilde{F}}{\partial w_{i,j}^m} = s_i^m a_j^{m-1} \quad (2.19)$$

$$\frac{\partial \tilde{F}}{\partial b_i^m} = s_i^m \quad (2.20)$$

อัลกอริทึมสตีพเฟลด์เดสเซนท์สามารถเขียนในรูปการประมาณค่าใหม่ได้เป็นสมการดังนี้

$$w_{i,j}^m(k+1) = w_{i,j}^m(k) - \alpha s_i^m a_j^{m-1} \quad (2.21)$$

$$b_i^m(k+1) = b_i^m(k) - \alpha s_i^m \quad (2.22)$$

สามารถเขียนในรูปของเมทริกซ์

$$W^m(k+1) = W^m(k) - \alpha S^m (a^{m-1})^T \quad (2.23)$$

$$b^m(k+1) = b^m(k) - \alpha s^m \quad (2.24)$$

โดยที่

$$s^m = \frac{\partial \bar{F}}{\partial n^m} = \begin{bmatrix} \frac{\partial \bar{F}}{\partial n_1^m} \\ \frac{\partial \bar{F}}{\partial n_2^m} \\ \vdots \\ \frac{\partial \bar{F}}{\partial n_{s^m}^m} \end{bmatrix} \quad (2.25)$$

2.5.4 ความไวการแพร่กระจายย้อนกลับ

การคำนวณค่าความไวการแพร่กระจายย้อนกลับ S^m (The Sensitivities of Backpropagation) ต้องใช้การคำนวณที่แตกต่างออกไปจากกฎลูกโซ่ ในขั้นตอนการคำนวณค่าความไวนี้ต้องอาศัยเทอมที่แสดงความสัมพันธ์ของค่าความไวที่เลเยอร์ m จากการคำนวณค่าความไวที่เลเยอร์ $m+1$ ซึ่งทิศทางการคำนวณมีทิศทางย้อนกลับจากโครงข่ายด้านเอาต์พุตมาทางอินพุตมาจึงเป็นที่มาของคำว่า การแพร่กระจายย้อนกลับ เพื่อหาความสัมพันธ์ในทิศทางย้อนกลับ ค่าความไวสามารถใช้เมทริกซ์จาโคเบียนหาได้ดังสมการดังนี้

$$\frac{\partial n^{m+1}}{\partial n^m} \equiv \begin{bmatrix} \frac{\partial n_1^{m+1}}{\partial n_1^m} & \frac{\partial n_1^{m+1}}{\partial n_2^m} & \dots & \frac{\partial n_1^{m+1}}{\partial n_{s^m}^m} \\ \frac{\partial n_2^{m+1}}{\partial n_1^m} & \frac{\partial n_2^{m+1}}{\partial n_2^m} & \dots & \frac{\partial n_2^{m+1}}{\partial n_{s^m}^m} \\ \vdots & \vdots & \dots & \vdots \\ \frac{\partial n_{s^{m+1}}^{m+1}}{\partial n_1^m} & \frac{\partial n_{s^{m+1}}^{m+1}}{\partial n_2^m} & \dots & \frac{\partial n_{s^{m+1}}^{m+1}}{\partial n_{s^m}^m} \end{bmatrix} \quad (2.26)$$

พิจารณารองศ์ประกอบที่ i, j ในเมทริกซ์ สามารถเขียนแสดงความสัมพันธ์ได้ว่า

$$\frac{\partial n_i^{m+1}}{\partial n_j^m} = \frac{\partial \left(\sum_{l=1}^{s^m} w_{i,l}^{m+1} a_l^m + b_i^{m+1} \right)}{\partial n_j^m} = w_{i,j}^{m+1} \frac{\partial a_j^m}{\partial n_j^m} \quad (2.27)$$

$$\frac{\partial n_i^{m+1}}{\partial n_j^m} = w_{i,j}^{m+1} \frac{\partial f^m(n_j^m)}{\partial n_j^m} = w_{i,j}^{m+1} f^m(n_j^m) \quad (2.28)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับใช้งานเพื่อการศึกษานั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดยที่

$$f^m(n_j^m) = \frac{\partial f^m(n_j^m)}{\partial n_j^m} \quad (2.29)$$

ดังนั้นเมทริกซ์จาโคเบียนเขียนได้เป็น

$$\frac{\partial n^{m+1}}{\partial n^m} = W^{m+1} F^m(n^m) \quad (2.30)$$

โดยที่

$$F^m(n^m) = \begin{bmatrix} f^m(n_1^m) & 0 & \dots & 0 \\ 0 & f^m(n_2^m) & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & f^m(n_{s^m}^m) \end{bmatrix} \quad (2.31)$$

เมทริกซ์ที่แสดงความสัมพันธ์ของความไวในทิศทางย้อนกลับโดยใช้กฎลูกโซ่คือ

$$s^m = \frac{\partial \bar{F}}{\partial n^m} = \left(\frac{\partial n^{m+1}}{\partial n^m} \right)^T \frac{\partial \bar{F}}{\partial n^{m+1}} = F^m(n^m) (W^{m+1})^T \frac{\partial \bar{F}}{\partial n^{m+1}} = F^m(n^m) (W^{m+1})^T s^{m+1} \quad (2.32)$$

ขณะนี้เราได้เห็นอัลกอริทึมการแพร่กระจายย้อนกลับซึ่งเหมือนกับชื่อ ค่าความไวจะเคลื่อนที่จากกลับทิศทางจนกระทั่งถึงเลเยอร์สุดท้ายที่เป็นเลเยอร์แรก ตามทิศทางดังนี้

$$s^M \rightarrow s^{M-1} \rightarrow \dots \rightarrow s^2 \rightarrow s^1 \quad (2.33)$$

อัลกอริทึมการแพร่กระจายย้อนกลับใช้เทคนิคการประมาณค่าสตีเฟนส์เดสเซนท์แบบที่ใช้ในอัลกอริทึมแอลเอ็มเอส ความซับซ้อนในการคำนวณค่าเกรเดียนท์คือต้องหาค่าความไวของการแพร่กระจายย้อนกลับก่อน ขั้นตอนแรกของการคำนวณคือเริ่มที่การคำนวณ s^M โดยใช้สมการที่ 2.32 จะทำให้ได้ค่าความไวของเลเยอร์สุดท้ายดังนี้

$$s_i^M = \frac{\partial \bar{F}}{\partial n_i^M} = \frac{\partial (t-a)^T (t-a)}{\partial n_i^M} = \frac{\partial \sum_{j=1}^{s^M} (t_j - a_j)^2}{\partial n_i^M} = -2(t_i - a_i) \frac{\partial a_i}{\partial n_i^M} \quad (2.34)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เนื่องจากว่า

$$\frac{\partial a_i}{\partial n_i^m} = \frac{\partial a_i^m}{\partial n_i^m} = \frac{\partial r^m(n_i^m)}{\partial n_i^m} = f^m(n_i^m) \quad (2.35)$$

เราจึงเขียนได้เป็น

$$s_i^m = -2(t_i - a_i) f^m(n_i^m) \quad (2.36)$$

จัดในรูปเมทริกซ์ได้เป็น

$$s^m = -2F^m(n^m)(t - a) \quad (2.37)$$

2.5.5 สรุปอัลกอริทึมการแพร่กระจายย้อนกลับ

จากที่กล่าวมาในตอนต้นสามารถสรุปอัลกอริทึมการแพร่กระจายย้อนกลับได้ดังนี้คือ

- (1) ขั้นแรกต้องหาค่าอินพุตในทิศทางไปข้างหน้าของโครงข่ายทั้งหมดก่อน โดยอาศัย 3 สมการหลักดังนี้

$$a^0 = p \quad (2.38)$$

$$a = a^m a^{m+1} = f^{m+1}(W^{m+1} a^m + b^{m+1}) \quad \text{เมื่อ } m = 0, 2, \dots, M-1 \quad (2.39)$$

$$a = a^m \quad (2.40)$$

- (2) ขั้นตอนต่อไปคือการหาค่าความไวในทิศทางย้อนกลับตลอดทั้งโครงข่าย

$$s^m = -2F^m(n^m)(t - a) \quad (2.41)$$

$$s^m = F^m(n^m)(W^{m+1})^T s^{m+1} \quad \text{เมื่อ } m = M-1, \dots, 2, 1 \quad (2.42)$$

- (3) ขั้นตอนสุดท้ายคือค่าถ่วงน้ำหนักและค่าไบอัสถูกเปลี่ยนแปลงค่าใหม่โดยใช้การประมาณค่าแบบกฎสตีเฟลต์เดสเซนท์

$$W^m(k+1) = W^m(k) - \alpha s^m (a^{m-1})^T \quad (2.43)$$

$$b^m(k+1) = b^m(k) - \alpha s^m \quad (2.44)$$


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 3

ความสัมพันธ์ระหว่างจุดดับดวงอาทิตย์และดัชนีสนามแม่เหล็กโลกกับปริมาณอิเล็กตรอนในชั้นบรรยากาศ

3.1 การเปลี่ยนแปลงปริมาณอิเล็กตรอนในชั้นบรรยากาศไอโอโนสเฟียร์

ชั้นบรรยากาศไอโอโนสเฟียร์เป็นชั้นบรรยากาศที่อยู่สูงกว่าชั้นมีโซสเฟียร์ที่ชั้นบรรยากาศไอโอโนสเฟียร์นี้จะมีอิเล็กตรอนอิสระอยู่จำนวนมากโดยเป็นอิเล็กตรอนที่หลุดออกมาจากอะตอม, โมเลกุลและไอออนที่เป็นประจุบวก แสงอุลตราไวโอเล็ตจากดวงอาทิตย์คือตัวการที่ทำให้อิเล็กตรอนแตกตัวออกมาจากอะตอมของออกซิเจน โดยบริเวณขอบเขตของชั้นบรรยากาศไอโอโนสเฟียร์เริ่มต้นที่ความสูงประมาณ 60 กิโลเมตร บริเวณที่เกิดปรากฏการณ์ไอโอโนเซชันมากที่สุดคือที่ระดับความสูงจากผิวโลกประมาณ 300 กิโลเมตร [6]



รูปที่ 3.1 แสดงการแบ่งชั้นบรรยากาศของโลกตามระดับความสูง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ที่ระดับความสูงสูงสุดของชั้นบรรยากาศไอโอโนสเฟียร์ ความเข้มของแสงจากดวงอาทิตย์มีความแรงมากแต่เนื่องจากมีอะตอมของก๊าซไม่มากจึงทำให้เกิดการไอออไนเซชันที่น้อย ที่ระดับความสูงลดต่ำลงมาอะตอมของก๊าซจะมีจำนวนมากขึ้นการเกิดไอออไนเซชันจึงเกิดได้มาก แต่ในเวลาเดียวกันก็เกิดกระบวนการตรงกันข้ามนั่นคือการรวมตัว (Recombination) เพราะว่าที่ความสูงไม่มากความหนาแน่นของก๊าซมีมากทำให้โมเลกุลและไอออนต่าง ๆ อยู่ใกล้ชิดกันมากทำให้เกิดการชนกันได้ จุดสมดุลย์ของสองปรากฏการณ์นี้จะวัดกันที่ระดับของการเกิดไอออไนเซชันซึ่งเกิดขึ้นตลอดเวลา ที่ความสูงต่ำ ๆ แสงมีความเข้มในการแผ่รังสีไม่มากเนื่องจากถูกดูดซับพลังงานจากที่ระดับความสูงไปแล้ว ทำให้เกิดการไอออไนเซชันน้อยและเนื่องจากก๊าซอยู่หนาแน่นมากโอกาสที่เกิดการรวมตัวกันใหม่จึงสูง ความแรงสูงสุดของการไอออไนเซชันในแต่ละช่วงความสูงนั้นทำให้ชั้นบรรยากาศมีลักษณะเป็นเลเยอร์ ซึ่งเลเยอร์ของไอโอโนสเฟียร์ที่ถูกค้นพบครั้งแรกคือ " Heaviside Layer " [7]

เนื่องจากองค์ประกอบของชั้นบรรยากาศมีการเปลี่ยนแปลงไปตามความสูง อัตราการเกิดไอออนจึงเปลี่ยนแปลงไปทำให้เกิดช่วงความแรงของการไอออไนเซชันเป็นช่วง ๆ เรียกว่า เลเยอร์ " D ", " E ", " F1 " และ " F2 "

เลเยอร์ D อยู่ที่ความสูงประมาณ 60 - 90 กิโลเมตรจากผิวโลก เกิดไอออไนเซชันที่น้อยเมื่อเทียบกับเลเยอร์อื่น ที่ชั้นนี้จะทำให้การดูดซับพลังงานคลื่นวิทยุความถี่สูง

เลเยอร์ E อยู่ที่ความสูงประมาณ 90 - 150 กิโลเมตรจากผิวโลกในช่วงเวลากลางวัน ซึ่งเป็นความสูงที่คิดจากเลเยอร์ E ปกติ และที่ชั้นนี้ยังมีการเกิดเลเยอร์ที่ไม่ปกติขึ้น ชั้นที่มีความหนาแน่นมากเรียกว่า E2 ชั้นที่มีความบางกว่าเรียกว่า Sporadic E ไอออนในบริเวณนี้ส่วนใหญ่เป็น O_2^+

เลเยอร์ F อยู่ที่ความสูงตั้งแต่ 150 กิโลเมตรขึ้นไป เป็นเลเยอร์ที่มีผลกระทบต่อการศึกษาคลื่นวิทยุที่ใช้ในการสื่อสาร เลเยอร์ในชั้นนี้แบ่งออกได้เป็น F1 และ F2 ไอออนในบริเวณนี้ส่วนใหญ่เป็น NO^+ และ O^+

ส่วนสูงสุด (Topside) เป็นบริเวณตั้งแต่ความสูงที่ความหนาแน่นสูงสุดของ F2 ขึ้นไปจนถึงความสูงที่ O^+ มีปริมาณน้อยกว่า H^+ และ He^+ ความสูงที่ระดับนี้เรียกว่า " Transition Height " ซึ่งความสูงนี้จะอยู่ที่ 500 กิโลเมตรในเวลากลางคืน หรือ 800 กิโลเมตรในเวลากลางวัน บางครั้งความสูงนี้อาจจะสูงขึ้นไปจนถึง 1100 กิโลเมตร ที่ความสูงเหนือขึ้นไปกว่าระดับนี้จะมีการเกิดไอออไนเซชันเพียงเล็กน้อยจึงเกิดอิทธิพลต่อสัญญาณวิทยุเล็กน้อย

แสงจากดวงอาทิตย์มีความหนาแน่นพลังงาน 1,370 วัตต์ต่อตารางเมตร ซึ่งเป็นค่าคงที่ของดวงอาทิตย์ (Solar Constant) การแผ่รังสีนี้ครอบคลุมในช่วงสเปกตรัมที่กว้างรวมทั้งความถี่ย่านอินฟราเรด (IR) ย่านแสงที่ตามองเห็นจนถึงรังสีเอ็กซ์ แต่ในช่วงความถี่อัลตราไวโอเล็ต (UV) และย่านคลื่นความยาวคลื่นต่ำมาก ๆ จะทำให้เกิดการไอออไนเซชันขึ้นได้ เนื่องจากโปรตอนของรังสีเอกซาร์นี้เป็นเอกซาร์ที่สว่นไวสำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดลอกเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ในช่วงนี้สามารถทำให้อิเล็กตรอนหลุดออกมาจากอะตอมหรือโมเลกุลของก๊าซที่เป็นกลางทางไฟฟ้าโดยการวิงชน ซึ่งปรากฏการณ์ที่เกิดขึ้นนี้สามารถอธิบายเป็นภาพได้ดังรูปที่ 3.2



รูปที่ 3.2 แสดงการเกิดปรากฏการณ์ไอออไนเซชัน

อิเล็กตรอนอิสระเหล่านี้จะเกิดการเคลื่อนที่อย่างอิสระสามารถเปลี่ยนความเร็วของคลื่นแม่เหล็กไฟฟ้าที่เดินทางบริเวณนี้ได้ ผลกระทบที่เกิดขึ้นเมื่อคลื่นแม่เหล็กไฟฟ้าเดินทางผ่านอิเล็กตรอนอิสระ เช่น การเกิดปรากฏการณ์การเลี้ยวเบนของคลื่นวิทยุสั้น ทำให้การสื่อสารสามารถครอบคลุมพื้นที่ได้ไกลกว่าคลื่นเดินทางในแนวระดับสายตา

3.1.1 หลักการวัดค่าปริมาณอิเล็กตรอนในชั้นบรรยากาศไอโอโนสเฟียร์

ข้อมูลที่ใช้ในการบอกถึงสภาวะชั้นบรรยากาศไอโอโนสเฟียร์ว่ามีการเปลี่ยนแปลงเกิดขึ้นอย่างไรนั้น ส่วนใหญ่เราจะใช้ปริมาณอิเล็กตรอนในชั้นบรรยากาศไอโอโนสเฟียร์ (Total Electron Content: TEC) เป็นพารามิเตอร์หลัก TEC ได้จากการวัดปริมาณอิเล็กตรอนทั้งหมดตามเส้นทางหนึ่งที่เป็นเส้นตรง มีหน่วยเป็น Unit TEC ซึ่งมีค่า 10^{12} อิเล็กตรอนต่อตารางเซนติเมตร หรือ 10^{16} อิเล็กตรอนต่อตารางเมตร [8]

การหาค่า TEC มีหลายวิธี เช่น การใช้ Ionosonde หรือ Vertical Sounder ซึ่งเป็นวิธีที่นิยมมากที่สุด แต่ก็มีข้อจำกัดเนื่องจากใช้ได้ที่ระดับความสูงไม่เกินชั้น F2 ปัจจุบันวิธีการวัด TEC ที่ให้ความถูกต้องสูงคือการใช้ดาวเทียม GPS โดยอาศัยหลักการหักเหของคลื่นสัญญาณ 2 ความถี่ที่เดินทางผ่านชั้นบรรยากาศไอโอโนสเฟียร์จะเดินทางมาถึงเครื่องรับไม่พร้อมกัน ซึ่งทำให้เกิดเวลาหน่วงขึ้น ทั้งนี้เป็นผลมาจากสัญญาณทั้งสองได้รับผลกระทบจากค่าดัชนีหักเหไม่เท่ากัน โดยดัชนีการหักเหมีค่าแปรผกผันกับความถี่ ค่าเวลาหน่วงที่ได้นี้จะถูกนำมาคำนวณหา TEC ต่อไป โดยมีหลักการคำนวณทางคณิตศาสตร์ดังนี้

ความเร็วกลุ่มของคลื่น GPS สามารถเขียนแสดงได้ดังสมการที่ 3.1

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะวิธีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$V_{gr} = -\frac{df}{\lambda} \lambda^2 \quad (3.1)$$

ความเร็วเฟสคือ

$$V_{ph} = \lambda f \quad (3.2)$$

V_{gr} และ V_{ph} มีความสัมพันธ์กันตามสมการ Rayleigh ดังนี้

$$V_{gr} = V_{ph} - \lambda \frac{dV_{ph}}{d\lambda} \quad (3.3)$$

เนื่องจากชั้นบรรยากาศไอโอโนสเฟียร์เป็นตัวกลางแบบเปลี่ยนแปลงค่าตามความถี่ (dispersive medium) ดัชนีการหักเหของชั้นบรรยากาศเป็นฟังก์ชันกับความถี่ทำให้ความเร็วกลุ่มไม่เท่ากับความเร็วเฟส โดยความเร็วกลุ่มและความเร็วเฟสสามารถเขียนสมการความสัมพันธ์กับค่าดัชนีการหักเห n_{gr} และ n_{ph} ดังนี้

$$V_{gr} = \frac{C}{n_{gr}} \quad (3.4)$$

$$V_{ph} = \frac{C}{n_{ph}} \quad (3.5)$$

ดิฟเฟอเรนเชียลสมการที่ 3.5 ด้วยความสัมพันธ์กับ λ ได้

$$\frac{dV_{ph}}{d\lambda} = -\frac{C}{n_{ph}^2} \frac{dn_{ph}}{d\lambda} \quad (3.6)$$

นำสมการที่ 3.4 - 3.6 แทนลงในสมการที่ 3.3 จะได้ความสัมพันธ์ของ n_{ph} และ n_{gr} ดังนี้

$$n_{gr} = n_{ph} - \lambda \frac{dn_{ph}}{d\lambda} \quad (3.7)$$

สมการที่ 3.7 คืออีกรูปแบบของสมการ Rayleigh ซึ่งสามารถจัดรูปสมการนี้ใหม่โดยอาศัยความสัมพันธ์ของ λ และ f

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$\frac{d\lambda}{\lambda} = -\frac{df}{f} \quad (3.8)$$

สมการที่ 3.7 มีความสัมพันธ์กับความถี่คือ

$$n_{gr} = n_{ph} + f \frac{dn_{ph}}{df} \quad (3.9)$$

ชั้นบรรยากาศไอโอโนสเฟียร์ประกอบด้วยชั้นย่อยหลายชั้นโดยอยู่ที่ระดับความสูงตั้งแต่ประมาณ 60 – 1000 กิโลเมตรเหนือผิวโลก และดังที่กล่าวมาแล้วว่าชั้นบรรยากาศเป็นตัวกลางแบบเปลี่ยนแปลงค่าตามความถี่ที่มีความสัมพันธ์กับการแพร่กระจายของสัญญาณ GPS และสอดคล้องกับค่าดัชนีการหักเหของเฟสซึ่งสามารถประมาณได้ดังนี้

$$n_{ph} = 1 + \frac{c_2}{f^2} + \frac{c_3}{f^3} + \frac{c_4}{f^4} + \dots \quad (3.10)$$

ค่าสัมประสิทธิ์ c_2, c_3, c_4, \dots ไม่ได้ขึ้นกับค่าความถี่แต่สัมพันธ์กับความหนาแน่นอิเล็กตรอนตามเส้นทางการแพร่กระจายคลื่น ดังนั้นสามารถหาค่าประมาณของดัชนีการหักเหเฟสได้โดยการวัดส่วนขยายอนุกรมที่อยู่หลังเทอมควอดรaticออกไป ซึ่งจะได้

$$n_{ph} = 1 + \frac{c_2}{f^2} \quad (3.11)$$

ทำการดิฟเฟอเรนเชียลสมการที่ 3.11 จะได้เป็น

$$dn_{ph} = -\frac{2c_2}{f^3} df \quad (3.12)$$

แทนสมการที่ 3.11 และสมการที่ 3.12 ลงในสมการที่ 3.9 และใช้ความสัมพันธ์ของสมการที่ 3.8 จัดรูปใหม่ได้เป็นสมการที่ 3.13

$$n_{gr} = 1 - \frac{c_2}{f^2} \quad (3.13)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เมื่อแทนค่าประมาณ $c_2 = -40.3 N$ [9] จะได้ดัชนีการหักเหกลุ่มและเฟสดังนี้

$$n_{gr} = 1 + \frac{40.3N}{f^2} \quad (3.14)$$

$$n_{ph} = 1 - \frac{40.3N}{f^2} \quad (3.15)$$

เนื่องจากค่าความหนาแน่นอิเล็กตรอน N จะมีค่าเป็นบวกเสมอ ทำให้เกิด group delay และ phase advance ขึ้น นอกจากนี้ผลการวัดรหัสจาก GPS จะเกิดการหน่วงและเฟสของคลื่นพาหุจะเป็นแบบ phase advance ทำให้ code pseudorange ที่วัดได้ยาวเกินไปขณะที่เฟสของคลื่นพาหุก็สั้นเกินไปเมื่อเทียบกับระยะทางจริงระหว่างดาวเทียมกับเครื่องรับ

ค่าผลต่างของระยะทางที่วัดได้กับระยะทางตรง ถูกเรียกว่าระยะการหักเหเนื่องจากชั้นบรรยากาศไอโอโนสเฟียร์ เขียนแทนด้วย ΔL

$$\Delta L = \int n dl_0 - \int dl_0 \quad (3.16)$$

$$\Delta L = \int \left(1 - \frac{c_2}{f^2}\right) dl_0 - \int dl_0 \quad (3.17)$$

แทนค่า $c_2 = -40.3 N$ ได้

$$\Delta L_{gr} = \int \frac{40.3}{f^2} N dl_0 \quad (3.18)$$

TEC คือ total electron content มีนิยามคือ

$$TEC = \int N dl_0 \quad (3.19)$$

จากสมการที่ 3.18 และสมการที่ 3.19 ทำให้ได้ความสัมพันธ์คือ

$$\Delta L_{gr} = \int \frac{40.3}{f^2} TEC \quad (3.20)$$

เมื่อระยะทางคลาดเคลื่อนไป (ΔL) หารด้วยความเร็วที่เดินทาง (C ความเร็วแสง) จะได้เวลาหน่วงของคลื่นสัญญาณ (T_d) ดังสมการต่อไปนี้

$$T_d = \frac{1.345}{f^2} \times \text{TEC} \times 10^{-7} \quad (\text{วินาที}) \quad (3.21)$$

จากสมการจะเห็นได้ว่าเมื่อทราบค่าความหน่วงและความถี่เราก็จะสามารถคำนวณหา TEC ได้ และจากความแตกต่างของเวลาหน่วงสัญญาณ L_1 และ L_2 ของดาวเทียม GPS เราสามารถหา TEC ได้จากสมการต่อไปนี้

$$\Delta T_d = T_{d(f_{L2})} - T_{d(f_{L1})} \quad (3.22)$$

$$\Delta T_d = 134 \times \text{TEC} \times \left[\frac{1}{(f_{L2})^2} - \frac{1}{(f_{L1})^2} \right] \quad (\text{ns.}) \quad (3.23)$$

$$\text{TEC} = \frac{\Delta T_d}{134} \left[\frac{(f_{L1})^2 (f_{L2})^2}{(f_{L1})^2 - (f_{L2})^2} \right] \quad (\text{el/m}^2) \quad (3.24)$$

$$\therefore \text{TEC} = 2.863 \times 10^{16} \times \Delta T_d \quad (\text{el/m}^2) \quad (3.25)$$


เมื่อ $f_{L1} = 1,575.42 \text{ MHz}$. $f_{L2} = 1,227.6 \text{ MHz}$.

3.1.2 ลักษณะการเปลี่ยนแปลงปริมาณอิเล็กตรอนในชั้นบรรยากาศไอโอโนสเฟียร์

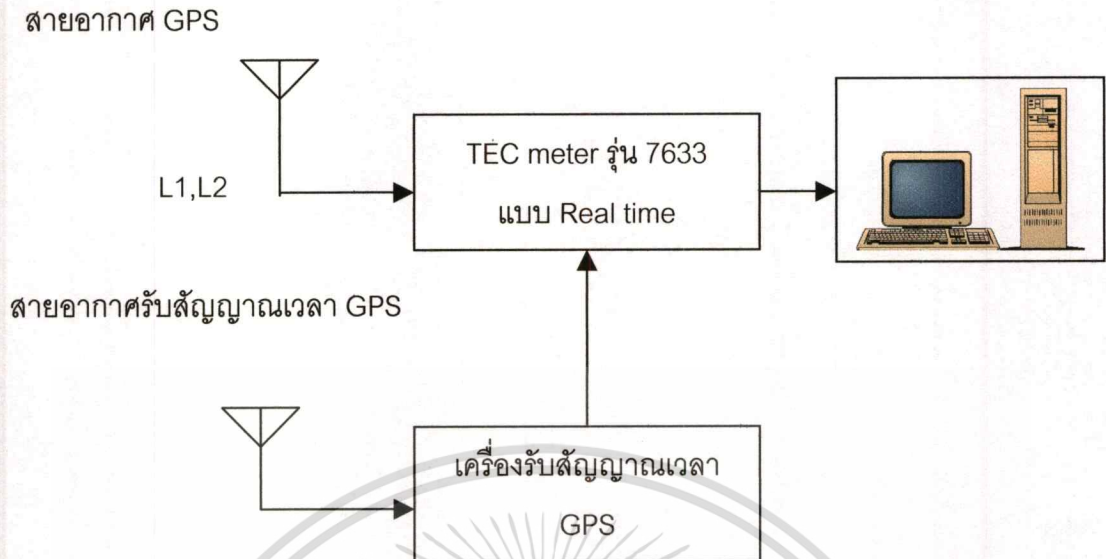
TEC มีการเปลี่ยนแปลงในแต่ละวันในลักษณะที่ค่า TEC จะมีค่ามากที่สุดในช่วงกลางวันเนื่องจากเป็นช่วงที่มีปริมาณแสงอุลตราไวโอเล็ตมาก และในเวลากลางคืนค่า TEC จะค่อย ๆ ลดลงอย่างช้า ๆ เนื่องมาจากปรากฏการณ์การรวมตัวของอิเล็กตรอนและไอออน ในตำแหน่งใดบนโลกค่าสูงสุดในแต่ละวันของ TEC จะเกิดขึ้นในช่วงประมาณบ่ายโมงและช่วงต่ำสุดของ TEC จะเกิดขึ้นในช่วงก่อนที่พระอาทิตย์จะขึ้น เมื่อพิจารณาถึงตำแหน่งต่าง ๆ บนแผนที่โลกการเปลี่ยนแปลงลักษณะประจำวันของ TEC ยังเกิดเพิ่มมากขึ้นในทิศทางจากทิศเหนือมาทิศใต้ด้วยซึ่งเป็นทิศทางที่แสงแดดเดินทางมาเป็นระยะทางที่ตรงมากขึ้น และค่า TEC ที่มากที่สุดจะเกิดขึ้นได้มาจากทิศตะวันออกไปจนถึงทิศตะวันตกตามลำดับซึ่งเป็นทิศทางที่โลกมีการหมุนเคลื่อนที่รอบตัวเอง ทำให้ได้ข้อสรุปที่ว่า การเปลี่ยนแปลงในแต่ละวันได้รับอิทธิพลจากแสงแดด [10]

3.1.2.1 อุปกรณ์และวิธีการทดลอง


ในการทดลองได้ใช้อุปกรณ์ในการทดลองแสดงเป็นบล็อกไดอะแกรมได้ดังรูปที่ 3.3 Real time TEC meter ที่ใช้เป็นรุ่น 7633 ผลิตจากบริษัท Nitsuki ประเทศญี่ปุ่น ทำหน้าที่เป็นอุปกรณ์คำนวณหาค่าปริมาณ TEC จากการรับสัญญาณดาวเทียมจาก GPS ค่าที่ได้จากการคำนวณจะถูกส่งให้กับคอมพิวเตอร์เพื่อทำการเก็บข้อมูล TEC ในรูปไฟล์จุดแตก (*.dat) ในการวิเคราะห์ผลที่ได้จำเป็นต้องมีการแปลงไฟล์จากจุดแตกให้เป็นไฟล์จุดเป็นเท็กซ์ไฟล์ (*.tec) โดยใช้โปรแกรม TMFC.exe ทำงานบนโหมดดอส โปรแกรมนี้เขียนมาจากผู้ผลิตเครื่อง TEC meter แต่เนื่องจากค่าที่ได้ในรูปเท็กซ์ไฟล์เป็นค่าที่มีความละเอียดของข้อมูล TEC ทุก ๆ 1 นาที เพื่อให้ข้อมูลที่ใช้ในการศึกษามีจำนวนที่ไม่มากเกินไปทำให้เปลืองเนื้อที่ในการเก็บข้อมูล จึงจำเป็นที่จะต้องทำการวิเคราะห์ข้อมูลเป็นทุก ๆ 15 นาทีโดยทำการเฉลี่ยค่าที่ได้ในช่วงเวลาทุก ๆ 15 นาที โดยใช้โปรแกรม tec.exe [11]



รูปที่ 3.3 แสดงบล็อกไดอะแกรมอุปกรณ์ที่ใช้ในการศึกษาการเปลี่ยนแปลง TEC ในแต่ละวัน



รูปที่ 3.4 แสดงบล็อกไดอะแกรมการทำงานของ TEC meter



รูปที่ 3.5 แสดง Real time TEC meter รุ่น 7633

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 3.6 แสดงเครื่องรับสัญญาณเวลา GPS



รูปที่ 3.7 แสดงสายอากาศรับสัญญาณ GPS

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.8 แสดงสายอากาศรับสัญญาณเวลาจาก GPS

อุปกรณ์การทดลองนี้ได้รับความสนับสนุนจากโครงการความร่วมมือในการทำการทดลองร่วมกับกระทรวงไปรษณีย์และโทรคมนาคม (Ministry of Posts and Telecommunication), Communication Research Laboratory (CRL) และ Association of Radio Industries and Business (ARIB) ประเทศญี่ปุ่น ภายใต้โครงการ POST PARTNERS PROJECT สถานที่ติดตั้งอุปกรณ์ในประเทศไทยมีทั้งหมด 3 ที่ คือที่ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง กรุงเทพมหานคร (ละติจูด 13.7°N , ลองจิจูด 100.8°E), มหาวิทยาลัยเชียงใหม่ (ละติจูด 18.8°N , ลองจิจูด 99.0°E) และวิทยาลัยเทคนิคภูเก็ต (ละติจูด 7.9°N , ลองจิจูด 98.4°E) เนื่องจากข้อมูลที่เก็บรวบรวมมีความสมบูรณ์มากที่สุดคือข้อมูล TEC ของสถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง จึงใช้ข้อมูลนี้เป็นหลักในการวิเคราะห์ โดยข้อมูลที่ใช้อยู่ในช่วง มกราคม 2541 – ธันวาคม 2543

3.1.2.2 การวิเคราะห์การเปลี่ยนแปลงปริมาณอิเล็กตรอนในชั้นบรรยากาศ

ไอโอโนสเฟียร์

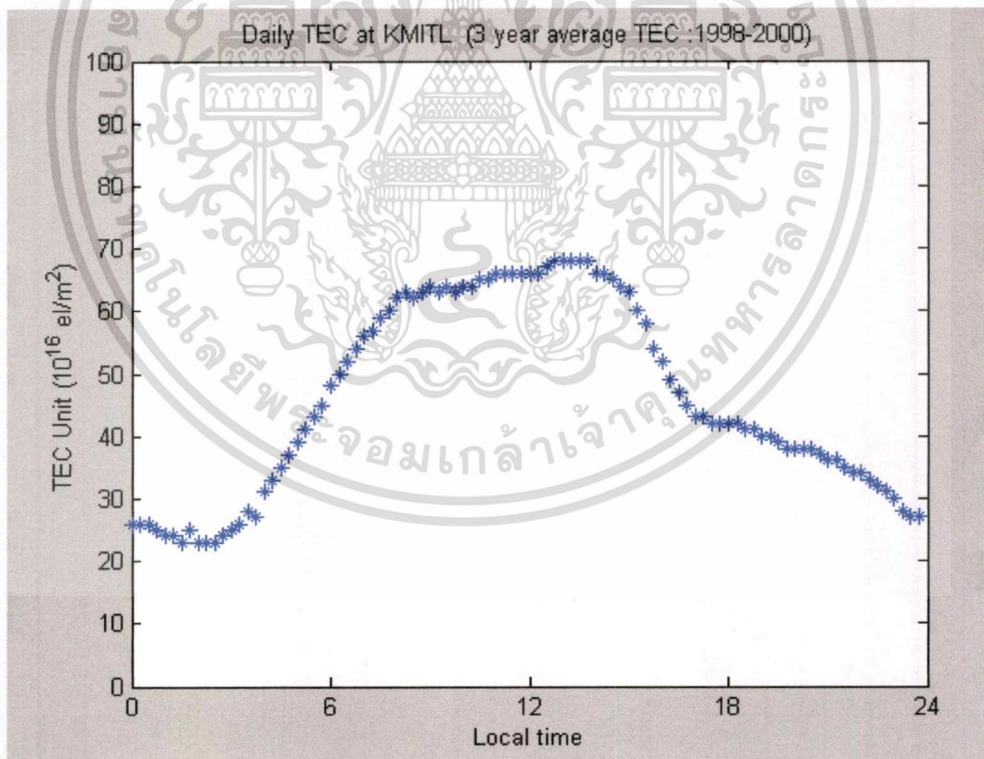
จากข้อมูล TEC ของสถานีกรุงเทพมหานคร ที่ทำการวัดค่าอย่างต่อเนื่องตลอด 3 ปี ตั้งแต่ มกราคม 2541 – ธันวาคม 2543 ค่าที่ได้รับจาก TEC meter จะเป็นข้อมูลทุก ๆ ช่วงเวลา 1 นาที ซึ่งเป็นข้อมูลที่ละเอียดมาก เพื่อประหยัดหน่วยความจำจึงได้ออกแบบโปรแกรมให้สามารถทำการ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เฉลี่ยค่า TEC ที่ได้ในทุก ๆ เวลา 15 นาที แล้วนำค่าที่ได้มาหาค่าเฉลี่ย TEC ในแต่ละเวลาเพื่อวิเคราะห์ลักษณะการเปลี่ยนแปลงในแต่ละวัน โดยใช้ข้อมูลเฉลี่ยในช่วง 3 ปี จากการทดลองหาค่าเฉลี่ยได้ผลการทดลองดังต่อไปนี้

ตารางที่ 3.1 แสดงผลการวิเคราะห์ค่าสถิติของลักษณะการเปลี่ยนแปลง TEC ในแต่ละวัน

ค่าทางสถิติ	ค่าที่ได้ (หน่วย :UTEc)
ค่าต่ำสุด (Minimum)	23
ค่าสูงสุด (Maximum)	68
ค่าเฉลี่ย (Average)	46.03
ค่ามัธยฐาน (Median)	42.5
ค่าเบี่ยงเบนมาตรฐาน (Std)	15.5



รูปที่ 3.9 แสดงลักษณะการเปลี่ยนแปลงค่าปริมาณอิเล็กตรอนในแต่ละวัน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากการวิเคราะห์เพื่อดูแนวโน้มการเปลี่ยนแปลงปริมาณอิเล็กทรอนิกส์ในแต่ละวันพบว่าปริมาณ TEC จะมีค่าต่ำสุดมีค่า 23 Unit TEC (1 UTEC = 10^{16} อิเล็กตรอน/ตารางเมตร) อยู่ในช่วงเวลาประมาณ 2.00-4.00 น. ซึ่งเป็นช่วงเวลาก่อนที่พระอาทิตย์จะขึ้น หลังจากนั้นการเพิ่มปริมาณอิเล็กทรอนิกส์จะมีค่าสูงขึ้นจน TEC มีค่ามากที่สุดมีค่า 68 Unit TEC ที่เวลาประมาณ 14.00 น. และหลังจากนั้นค่า TEC จะค่อยๆ ลดลง โดยค่าเฉลี่ย (Average) ของ TEC ที่วัดได้จะมีค่า 46.03 Unit TEC , มีค่ามัธยฐาน (Median) เท่ากับ 42.5 Unit TEC และค่าเบี่ยงเบนมาตรฐาน (STD) เท่ากับ 15.5

3.1.2.3 การวิเคราะห์การเปลี่ยนแปลงปริมาณอิเล็กทรอนิกส์ในชั้นบรรยากาศไอโอโนสเฟียร์โดยใช้ค่าสัมประสิทธิ์สหสัมพันธ์

การวิเคราะห์สัมประสิทธิ์สหสัมพันธ์ (Correlation coefficient) จะเป็นการวิเคราะห์หาความสัมพันธ์ของตัวแปร 2 ตัวว่ามีลักษณะลักษณะเป็นอย่างไร โดยใช้สมการดังนี้ คือ

$$\rho = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2}} \quad (3.26)$$

โดยที่ $-1 \leq \rho \leq 1$, $|\rho|$ คือ ขนาดของ ρ จะบอกว่าตัวแปร x และ y มีความสัมพันธ์กันมากหรือน้อย ในกรณีที่ $|\rho| = 1$ แสดงว่ามีสหสัมพันธ์กันในรูปแบบเชิงเส้น แต่ถ้า $\rho < 1$ แสดงว่ามีสหสัมพันธ์กันในทางตรงกันข้าม [12]

จากข้อมูลการเปลี่ยนแปลง TEC ที่ได้ ทำการเลือกข้อมูลในช่วงเวลา มกราคม - ธันวาคม 2543 ระยะเวลา 12 เดือนเป็นช่วงเวลาที่ศึกษา โดยนำข้อมูลนี้มาศึกษาหาสัมประสิทธิ์สหสัมพันธ์ (Correlation Coefficient) เพื่อแสดงความสัมพันธ์ระหว่างค่า TEC ที่ได้ในแต่ละวันกับค่า TEC ที่เกิดขึ้นเมื่อวันก่อนและเมื่อ 2 วันก่อน และหาค่าสัมประสิทธิ์สหสัมพันธ์ เพื่อแสดงความสัมพันธ์ระหว่างค่า TEC ที่เกิดขึ้นในแต่ละเวลากับค่า TEC ที่เกิดขึ้นในอดีตเมื่อ 15 นาที, 1 ชั่วโมง , 6 ชั่วโมง และ 12 ชั่วโมง ที่ผ่านมามาตามลำดับ ได้ผลการทดลองดังตารางที่ 3.2

ตารางที่ 3.2 แสดงผลการทดลองหาค่าสัมประสิทธิ์สหสัมพันธ์ ของ TEC ที่เกิดขึ้นในแต่ละวัน กับค่า TEC ที่เกิดขึ้นในเมื่อวันก่อนและเมื่อ 2 วันก่อน

เดือน ปี	ค่าสัมประสิทธิ์สหสัมพันธ์	
	เทียบกับวันก่อน	เทียบกับสองวันก่อน
ม.ค. 2543	0.95	0.93
ก.พ. 2543	0.95	0.95
มี.ค. 2543	0.97	0.96
เม.ย. 2543	0.93	0.92
พ.ค. 2543	0.95	0.92
มิ.ย. 2543	0.96	0.92
ก.ค. 2543	0.93	0.92
ส.ค. 2543	0.95	0.94
ก.ย. 2543	0.96	0.95
ต.ค. 2543	0.97	0.95
พ.ย. 2543	0.98	0.98
ธ.ค. 2543	0.98	0.96
ค่าเฉลี่ย	0.96	0.94
ค่าเบี่ยงเบนมาตรฐาน	0.02	0.02

จากผลการทดลองที่ได้พบว่าหาค่าสัมประสิทธิ์สหสัมพันธ์ ของ TEC ที่เกิดขึ้นในแต่ละวัน กับค่า TEC ที่เกิดขึ้นในเมื่อวันก่อนและเมื่อ 2 วันก่อน มีค่าเฉลี่ย 0.96 และ 0.94 ตามลำดับ โดยที่มีค่าเบี่ยงเบนมาตรฐานมีค่า 0.02 และ 0.02 ดังนั้นความสัมพันธ์ของ TEC ที่เกิดขึ้นในแต่ละวันกับค่า TEC ที่เกิดขึ้นในเมื่อวันก่อนจึงมากกว่าเมื่อ 2 วันก่อน ทำให้ได้ข้อสรุปว่านอกจากการเปลี่ยนแปลงของ TEC จะขึ้นกับเวลา (Local time) ในแต่ละวัน ดังแสดงได้ในรูปที่ 3.10 แล้วความสัมพันธ์ของ TEC ที่เวลาเดียวกันในวันนี้กับวันที่เพิ่งผ่านมา จะมีความสัมพันธ์มากกว่า TEC ที่ผ่านมานานวันกว่า ดังนั้นการทำนายปริมาณ TEC ในช่วงวันที่ผ่านมาไม่นานจะมีความแม่นยำกว่าการอาศัยข้อมูลจากวันที่ผ่านมานานวันกว่า

ตารางที่ 3.3 แสดงผลการทดลองหาค่าสัมประสิทธิ์สหสัมพันธ์ ของ TEC ที่เกิดขึ้นในแต่ละเวลา กับค่า TEC ที่เกิดขึ้นในอดีตเมื่อ 15 นาที, 1 ชั่วโมง , 6 ชั่วโมง และ 12 ชั่วโมง ที่ผ่านมา

เดือน ปี	ค่าสัมประสิทธิ์สหสัมพันธ์ เทียบกับเวลาในอดีต			
	15 นาที	1 ชั่วโมง	6 ชั่วโมง	12 ชั่วโมง
ม.ค. 2543	0.69	0.40	0.26	0.20
ก.พ. 2543	0.90	0.68	0.34	0.21
มี.ค. 2543	0.88	0.59	0.30	0.20
เม.ย. 2543	0.94	0.67	0.74	0.54
พ.ค. 2543	0.97	0.85	0.12	0.53
มิ.ย. 2543	0.96	0.86	0.70	0.62
ก.ค. 2543	0.91	0.70	0.28	0.10
ส.ค. 2543	0.94	0.82	0.58	0.56
ก.ย. 2543	0.98	0.90	0.78	0.69
ต.ค. 2543	0.90	0.58	0.20	0.18
พ.ย. 2543	0.84	0.52	0.40	0.31
ธ.ค. 2543	0.91	0.70	0.47	0.41
ค่าเฉลี่ย	0.90	0.69	0.43	0.43
ค่าเบี่ยงเบนมาตรฐาน	0.08	0.15	0.22	0.24

จากผลการทดลองที่ได้พบว่าหาค่าสัมประสิทธิ์สหสัมพันธ์ ของ TEC ที่เกิดขึ้นในแต่ละเวลา กับค่า TEC ที่เกิดขึ้นในอดีตเมื่อ 15 นาที, 1 ชั่วโมง , 6 ชั่วโมง และ 12 ชั่วโมง ที่ผ่านมา มีค่าเฉลี่ย 0.90, 0.69, 0.43 และ 0.43 ตามลำดับ โดยที่มีค่าเบี่ยงเบนมาตรฐานมีค่า 0.08, 0.15, 0.22 และ 0.24 ดังนั้นความสัมพันธ์ของ TEC ที่เกิดขึ้นในแต่ละเวลา กับค่า TEC ที่เกิดขึ้นในอดีตเมื่อ 15 นาทีที่มีค่ามากที่สุด ความสัมพันธ์ของ TEC ที่เกิดขึ้นในแต่ละเวลากับค่า TEC ที่เกิดขึ้นในอดีตเมื่อ 1 ชั่วโมงมีค่ามากรองลงมา , ความสัมพันธ์ของ TEC ที่เกิดขึ้นในแต่ละเวลากับค่า TEC ที่เกิดขึ้นในอดีตเมื่อ 6 ชั่วโมงมีค่ามากรองลงมาเป็นอันดับที่ 3 และความสัมพันธ์ของ TEC ที่เกิดขึ้นในแต่ละเวลากับค่า TEC ที่เกิดขึ้นในอดีตเมื่อ 12 ชั่วโมงที่ผ่านมามีค่าน้อย ที่สุด ทำให้ได้ข้อสรุปว่า

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

นอกจากการเปลี่ยนแปลงของ TEC จะขึ้นกับเวลา (Local time) ใน แต่ละวัน ดังแสดงได้ในรูปที่ 3.10 แล้ว ความสัมพันธ์ของ TEC ที่เวลาเดียวกันในวันนี้กับวันที่เพิ่งผ่านมาจะมีความสัมพันธ์มากกว่า TEC ที่ผ่านมานานวันกว่า ดังนั้นในการพยากรณ์เราสามารถที่ตัดข้อมูลอินพุตที่มีความสัมพันธ์น้อยออกได้ เพราะว่าไม่ได้ส่งผลต่อค่า TEC ที่จะเกิดขึ้นมากนัก การพิจารณาในเรื่องเวลานี้จะทำให้เราสามารถตัดสินใจเลือกพารามิเตอร์อินพุตที่สำคัญให้กับโครงข่ายประสาทได้

3.2 การเปลี่ยนแปลงจุดดับดวงอาทิตย์

จุดดับของดวงอาทิตย์มีการเปลี่ยนแปลงตลอดเวลา แต่เนื่องจากว่าตาของมนุษย์ไม่อาจจะเพ่งมองดวงอาทิตย์ได้โดยตรงเนื่องจากแสงอาจทำให้ตาบอดได้ จุดดับบนดวงอาทิตย์สามารถมองเห็นได้ด้วยวิธีการง่าย ๆ คือใช้หลักการของการฉายภาพ (Projection) นับเป็นระยะเวลายาวนานกว่า 300 ปีแล้วที่เราสามารถจับบันทึกการเกิดจำนวนจุดดับ จากข้อมูลค่าเฉลี่ยจุดดับทำให้ทราบว่าทุก 11 ปีจำนวนจุดดับบนดวงอาทิตย์จะเปลี่ยนแปลงจากค่าสูงสุดเป็นต่ำสุดเป็นวัฏจักรสุริยะ ดวงอาทิตย์ก็เหมือนกับโลกที่มีฤดูกาล ต่างกันตรงที่ว่าหนึ่งปีของดวงอาทิตย์มีค่าเท่ากับ 11 ปีของโลก การเปลี่ยนแปลงบนดวงอาทิตย์ที่เห็นได้ชัดอีกอย่างคือการเปลี่ยนแปลงหลุมโคโรนาที่จะมีจำนวนมากในปีที่เกิดจุดดับบนดวงอาทิตย์สูงสุด วัฏจักรสุริยะถูกนำมาใช้อ้างอิงเรียกปีของโลกโดยวัฏจักรสุริยะต่ำสุด (Solar Minimum) จะใช้เรียกปีที่สังเกตเห็นจุดดับได้จำนวนน้อยที่สุด และวัฏจักรสุริยะสูงสุด (Solar Maximum) จะใช้เรียกปีที่สังเกตเห็นจุดดับได้จำนวนที่มากที่สุดในรอบ 11 ปี

3.2.1 จุดดับดวงอาทิตย์ (Sunspot Number)

ดัชนีจุดดับดวงอาทิตย์ R คือการวัดพื้นที่ผิวของดวงอาทิตย์ที่ครอบคลุมไปด้วยจุดดับ เมื่อจำนวนจุดดับเพิ่มขึ้น สนามแม่เหล็กก็เพิ่มมากขึ้นทำให้กลายเป็นแหล่งกำเนิดการระเบิดปลดปล่อยพลังงานออกมาจากดวงอาทิตย์ที่เรียกว่าเปลวสุริยะ (Solar Flare) ดัชนีจุดดับดวงอาทิตย์รู้จักกันดีในชื่อของ "Wolf number" ซึ่งมาจากชื่อของนักบินอวกาศชาวสวิสเซอร์แลนด์ที่ชื่อ J.R. Holf ผู้คิดดัชนีนี้ ในปี ค.ศ. 1848 เป็นเวลานานหลายปีแล้วที่มีการบันทึกค่าการเปลี่ยนแปลงจุดดับดวงอาทิตย์ขึ้นที่ Zurich Observatory ทำให้เรียกชื่อจุดดับที่ได้นี้ว่า "Zurich Sunspot Number" ในปี ค.ศ. 1981 A. Koeckelenbergh ได้พัฒนาระบบการนับค่าจุดดับดวงอาทิตย์เพื่อใช้งานในการอ้างอิงศึกษาได้ทั่วโลกขึ้น เรียกว่า "Ri" (International Sunspot Number) โดยอาศัยข้อมูลที่ได้จาก World Data Center จากกว่า 70 สถานีต่าง ๆ ที่กระจายอยู่บนโลก การบันทึกข้อมูลจะเกิดการเปลี่ยนแปลงจุดดับดวงอาทิตย์ในแต่ละวัน แต่ละเดือน แต่ละปี (ข้อมูลจุดดับดวงอาทิตย์ในช่วง 12 เดือน เรียกว่า R12) โดยค่า R คำนวณได้ดังสมการต่อไปนี้


$$R = K(10G + S) \quad (3.27)$$

โดยที่ S คือจำนวนจุดดับดวงอาทิตย์ที่สังเกตเห็น , G คือจำนวนกลุ่มจุดดับดวงอาทิตย์ และ K คือค่าแฟคเตอร์ที่เกิดจากการเปรียบเทียบผลที่เกิดจากสถานีหลายแห่งได้จาก WDC [13]

3.2.2 ผลกระทบที่เกิดขึ้นในช่วงวัฏจักรสูงสุด

ในระหว่างช่วงเวลาวัฏจักรสุริยะสูงสุด แอตติวิตี้ (Activity) ที่เกิดขึ้นบนดวงอาทิตย์จะส่งผลกระทบต่อสิ่งแวดล้อมของโลกรุนแรง เช่นทำให้เกิดพายุสุริยะแม่เหล็กบนโลก นอกจากนั้นยังทำให้ปริมาณรังสีที่ส่งมายังโลกจากดวงอาทิตย์มีความเข้มข้นและสูงขึ้นในช่วงปีที่ใกล้กับวัฏจักรสุริยะสูงสุด

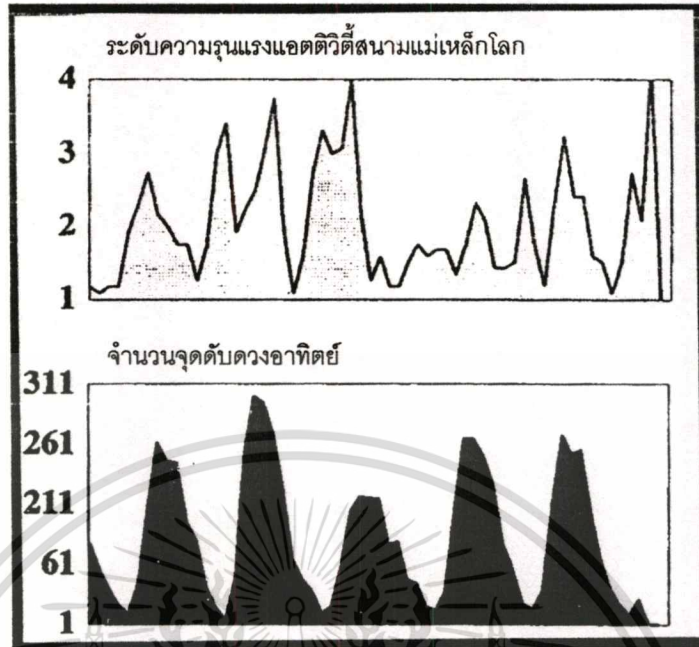
จำนวนจุดดับของดวงอาทิตย์



ปี ค.ศ.

รูปที่ 3.10 แสดงวัฏจักรสุริยะมีระยะเวลา 11 ปี

พายุแม่เหล็กที่เกิดขึ้นในบางครั้งแม้ว่าจะไม่เกิดความรุนแรงมากแต่ก็ส่งผลกระทบต่อเสียหายตามมาหลายอย่างคล้ายกับผลกระทบที่เกิดขึ้นในช่วงที่พายุแม่เหล็กรุนแรง จากรูปภาพที่ 3.11 ในช่วงการเกิดวัฏจักรสุริยะสูงสุด พบว่าเกิดความถี่ในการเกิดพายุแม่เหล็กมีจุดสูงสุดเกิดขึ้นสองครั้ง โดยจุดสูงสุดอันแรกเกิดขึ้นเมื่อจำนวนครั้งการเกิดพายุแม่เหล็กมีมากในช่วงก่อนปีวัฏจักรสุริยะต่ำสุด จุดสูงสุดอันที่สองเกิดขึ้นเมื่อจำนวนครั้งการเกิดพายุแม่เหล็กมีมากในช่วงหลังปีวัฏจักรสุริยะสูงสุด




รูปที่ 3.11 แสดงความสัมพันธ์ของแอดติวิตีสนามแม่เหล็กโลกกับจำนวนจุดดับดวงอาทิตย์



รูปที่ 3.12 แสดงช่วงเวลาที่ทำนายว่าเกิดวัฏจักรสุริยะสูงสุด

ในช่วงวัฏจักรสุริยะสูงสุดปริมาณโปรตอนในอวกาศรอบโลกจะสูงขึ้น และมีการเปลี่ยนแปลง เช่นเดียวกับการเกิดพายุแม่เหล็กโลก ในช่วงวัฏจักรสุริยะสูงสุด ปี ค.ศ. 1999-2002 สามารถสังเกตได้จากรูปที่ 3.12 พลังงานของโปรตอนที่เคลื่อนที่เข้ามาสู่โลกสามารถทำให้อุปกรณ์อิเล็กทรอนิกส์ของดาวเทียมมีความเสียหายได้ เช่นทำให้อุปกรณ์แวงโซลาร์เซลล์เสื่อม การขาดเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หายของสัญญาณบิตข้อมูล อุปกรณ์เชื่อมต่อบนดาวเทียมเสียหาย ปัจจุบันหน่วยงานอวกาศได้มีการติดตามศึกษาเรื่องพลังงานของโปรตอน que เข้าสู่โลกในช่วงวัฏจักรสุริยะสูงสุดเพื่อเตรียมการป้องกันความเสียหายที่จะเกิดขึ้น



รูปที่ 3.13 แสดงการเปลี่ยนแปลงของแอดติวิตี้ของดวงอาทิตย์, แอดติวิตี้ของสนามแม่เหล็กโลก และพลังงานอิเล็กทรอนิกส์ที่เปลี่ยนแปลงในวัฏจักรสุริยะ

จากรูปที่ 3.13 แอดติวิตี้ของดวงอาทิตย์มีความสัมพันธ์แอดติวิตี้ของสนามแม่เหล็กโลกในช่วงใกล้กับปีวัฏจักรสุริยะสูงสุด พลังงานของอิเล็กทรอนิกส์จะมีค่ามากในช่วงวัฏจักรสุริยะต่ำสุด เนื่องจากในช่วงปีวัฏจักรสุริยะสูงสุดมีอนุภาคโปรตอนมากทำให้เกิดการทำลายอิเล็กทรอนิกส์ขึ้น

3.2.3 การรบกวนชั้นบรรยากาศไอโอโนสเฟียร์

ปัจจุบันมีธุรกิจด้านการสื่อสารดาวเทียมได้เติบโตอย่างรวดเร็ว การแพร่สัญญาณภาพโทรทัศน์และวิทยุ โทรศัพททางไกล โทรศัพทเซลลูลาร์ ได้อาศัยดาวเทียมเป็นสถานีฐานในการส่งสัญญาณ ระบบการสื่อสารหลายระบบต้องอาศัยชั้นบรรยากาศไอโอโนสเฟียร์เพื่อที่สะท้อนคลื่นวิทยุให้เดินทางไปได้ไกล พายุไอโอโนสเฟียร์ทำให้การสื่อสารวิทยุบางย่านความถี่เสียหายได้ และทำให้เกิดการเปลี่ยนแปลงระดับสัญญาณอย่างกะทันหัน ทำให้เกิดเส้นทางการเดินทางของคลื่นที่


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เปลี่ยนแปลงไป สัญญาณดาวเทียม GPS ก็ได้รับผลกระทบจากพายุไอโอโนสเฟียร์ด้วยเช่นกัน เนื่องจากว่ามีการส่งสัญญาณดาวเทียมผ่านระหว่างดาวเทียมกับโลกซึ่งผ่านชั้นบรรยากาศไอโอโนสเฟียร์ทำให้เกิดปัญหาที่ตามมาคือ “ Scintillation ” ทำให้ยากต่อการเดินทางตามวงโคจรหรือการติดตามดาวเทียม (Tracking) ในกรณีสัญญาณจาก GPS มีการล่าช้าในการเดินทาง สัญญาณเกิดขึ้นก็เป็นผลมาจากปริมาณอิเล็กตรอนของ ไอโอโนสเฟียร์ที่มีปริมาณเปลี่ยนแปลงไปจากเดิมมาก ส่งผลให้เกิดความผิดพลาดในการบอกตำแหน่งพิกัด

3.3 ความสัมพันธ์ของจุดดับดวงอาทิตย์ที่มีต่อปริมาณอิเล็กตรอนในชั้นบรรยากาศไอโอโนสเฟียร์

ในหัวข้อนี้มีจุดประสงค์คือต้องการศึกษาถึงลักษณะการเปลี่ยนแปลงปริมาณอิเล็กตรอนในชั้นบรรยากาศไอโอโนสเฟียร์ว่าขึ้นกับการเปลี่ยนแปลงของจุดดับดวงอาทิตย์ในลักษณะใด ข้อมูลที่นำมาวิเคราะห์นี้ใช้ข้อมูลในช่วงเวลา มกราคม – ธันวาคม 2543 เป็นเวลา 12 เดือนซึ่งอยู่ในช่วงที่เป็นวัฏจักรสูงสุด ได้ผลการทดลองแสดงดังรูปที่ 3.14

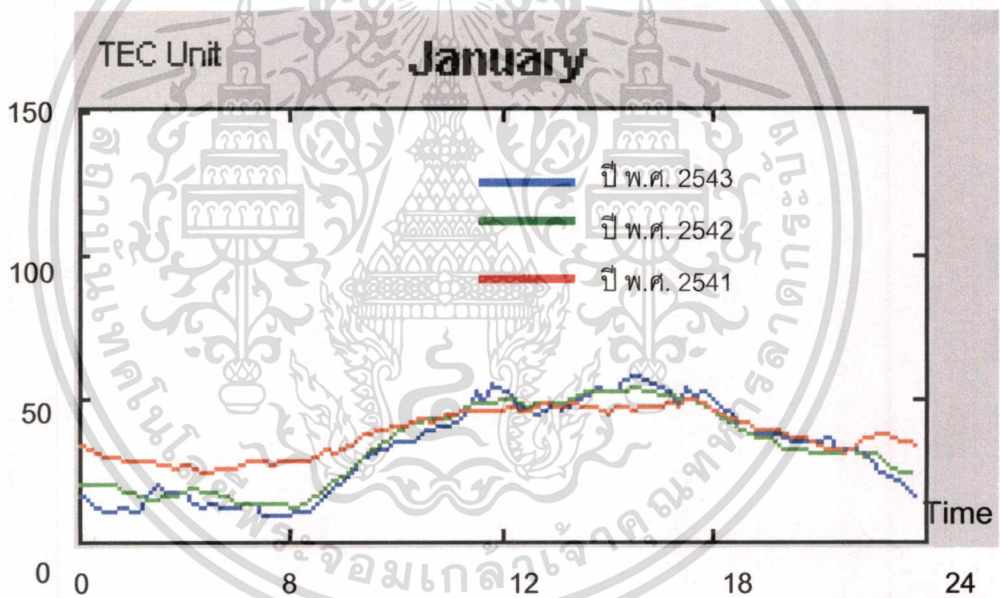


รูปที่ 3.14 แสดงปริมาณอิเล็กตรอนเฉลี่ยเปรียบเทียบกับจำนวนจุดดับดวงอาทิตย์เฉลี่ยในแต่ละเดือน ในช่วง มกราคม – ธันวาคม 2543


จากผลการทดลองรูปที่ 3.14 พบว่าการเปลี่ยนแปลงปริมาณอิเล็กตรอนไม่ได้มีการเปลี่ยนแปลงแบบแปรผันตรงกับการเปลี่ยนแปลงจุดดับของดวงอาทิตย์ จากผลที่ได้จากการทดลองแนวเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โน้มการเปลี่ยนแปลงยังไม่ชัดเจน การเปลี่ยนแปลงมีลักษณะที่ซับซ้อน ดังนั้นจึงควรพิจารณา ระยะเวลาให้นานขึ้นเพื่อที่จะเห็นแนวโน้มที่ชัดเจนได้ขึ้น จึงทำการศึกษาปริมาณการเปลี่ยนแปลง TEC เมื่อเทียบกับจุดดับดวงอาทิตย์โดยใช้ระยะเวลาที่นานขึ้นเป็นระยะเวลา 3 ปี ตั้งแต่ มกราคม 2541 – ธันวาคม 2543 โดยในปี พ.ศ. 2541-2543 มีปริมาณจุดดับดวงอาทิตย์ประจำปี (Annual mean) 64.3, 93.3 และ 119.6 ตามลำดับ [15]

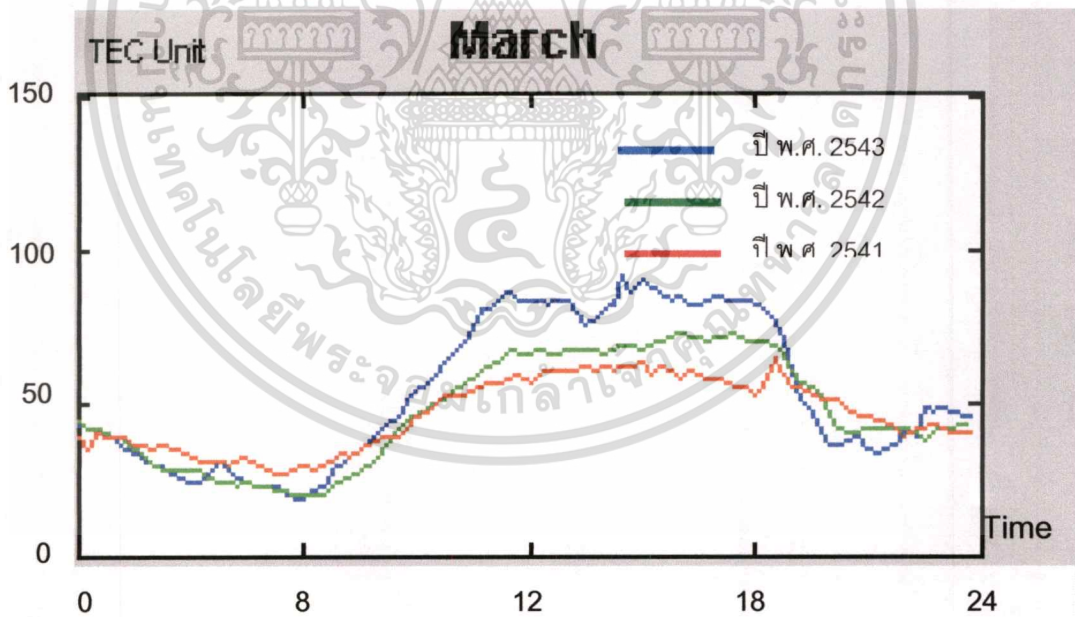
จากผลการทดลองรูปที่ 3.15 - 3.26 พบว่าการเปลี่ยนแปลงปริมาณอิเล็กทรอนิกส์ทรอนมีการเปลี่ยนแปลงกับการเปลี่ยนแปลงจุดดับของดวงอาทิตย์อย่างมีนัยสำคัญ พบว่าในแต่ละเดือนปริมาณ TEC ปี พ.ศ. 2543 มีค่าสูงสุด ,ปี พ.ศ. 2542 รองลงมา และปี พ.ศ. 2541 มีค่าต่ำสุด ตามการเปลี่ยนแปลงของจุดดับดวงอาทิตย์ประจำปี โดยเมื่อเรานำข้อมูลนี้มาศึกษาถึงไปถึงเรื่องความสัมพันธ์ของ TEC สูงสุด, ต่ำสุด และค่าเฉลี่ยที่เกิดขึ้นกับค่า SSN ที่เกิดขึ้นในแต่ละวัน จะได้ผลการทดลองดังตารางที่ 3.4



รูปที่ 3.15 แสดงปริมาณอิเล็กทรอนิกส์ทรอนเฉลี่ยในช่วงเดือนมกราคมในปี พ.ศ. 2541 –2543

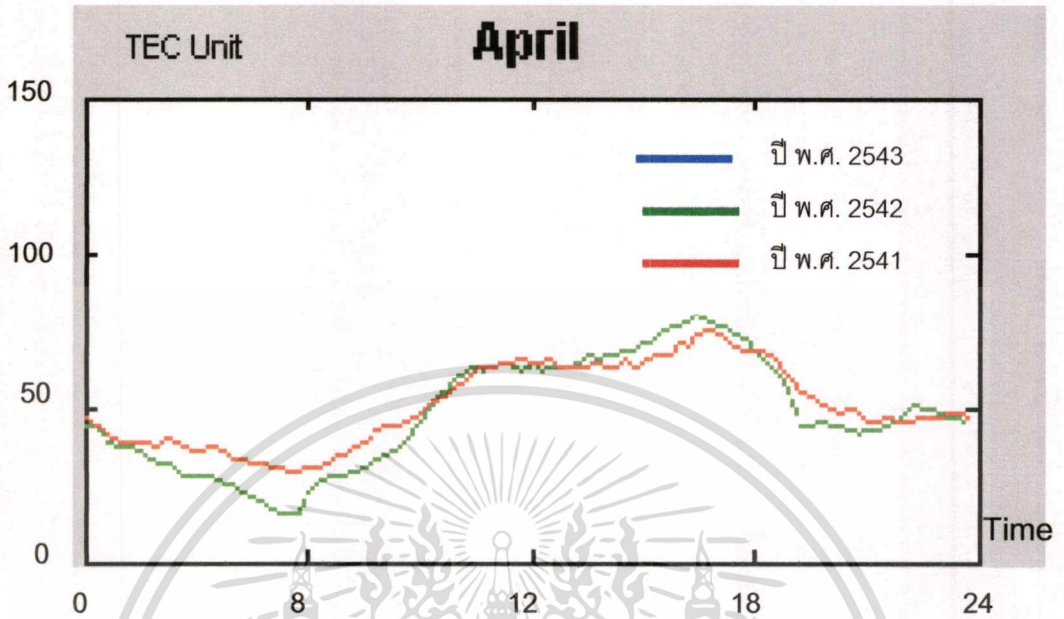


รูปที่ 3.16 แสดงปริมาณอิเล็กทรอนิกส์ในช่วงเดือนกุมภาพันธ์ในปี พ.ศ. 2541-2543

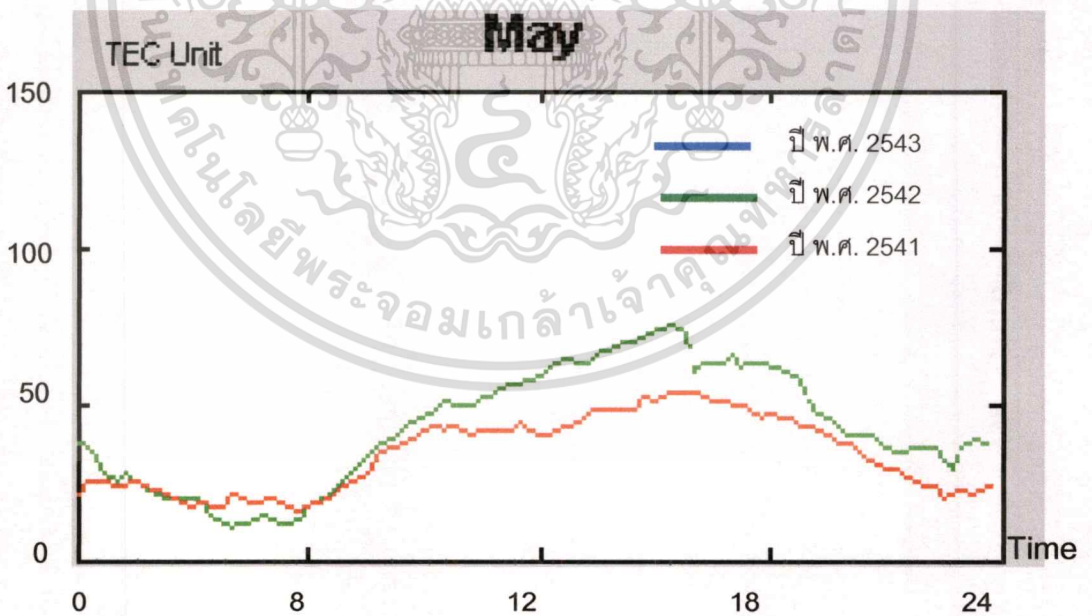


รูปที่ 3.17 แสดงปริมาณอิเล็กทรอนิกส์ในช่วงเดือนมีนาคมในปี พ.ศ. 2541-2543

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

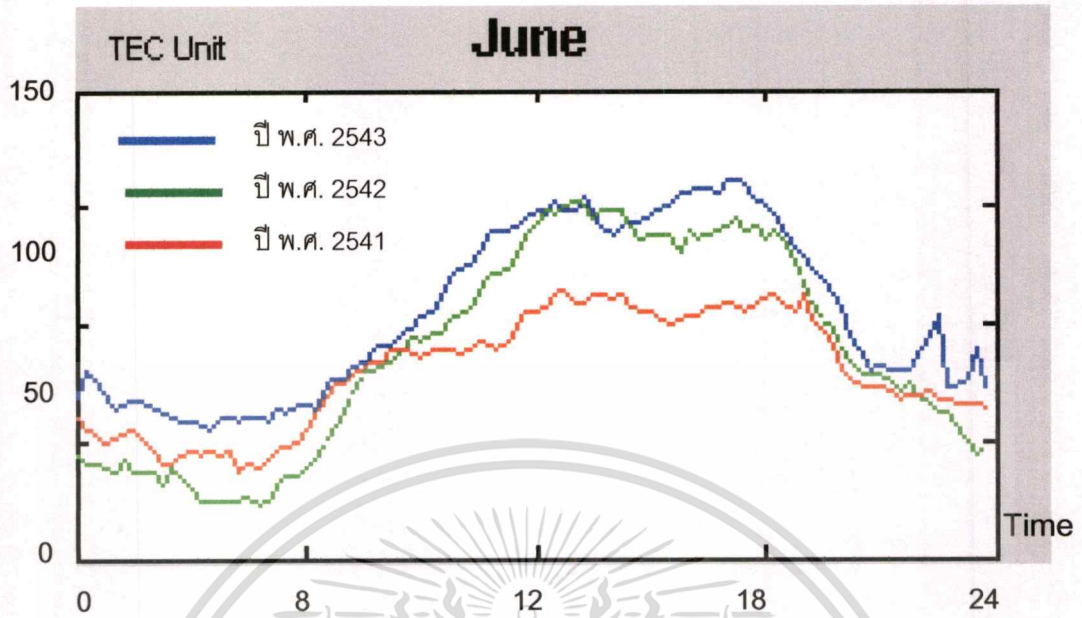


รูปที่ 3.18 แสดงปริมาณอิเล็กทรอนิกส์ในช่วงเดือนเมษายนในปี พ.ศ. 2541 –2543

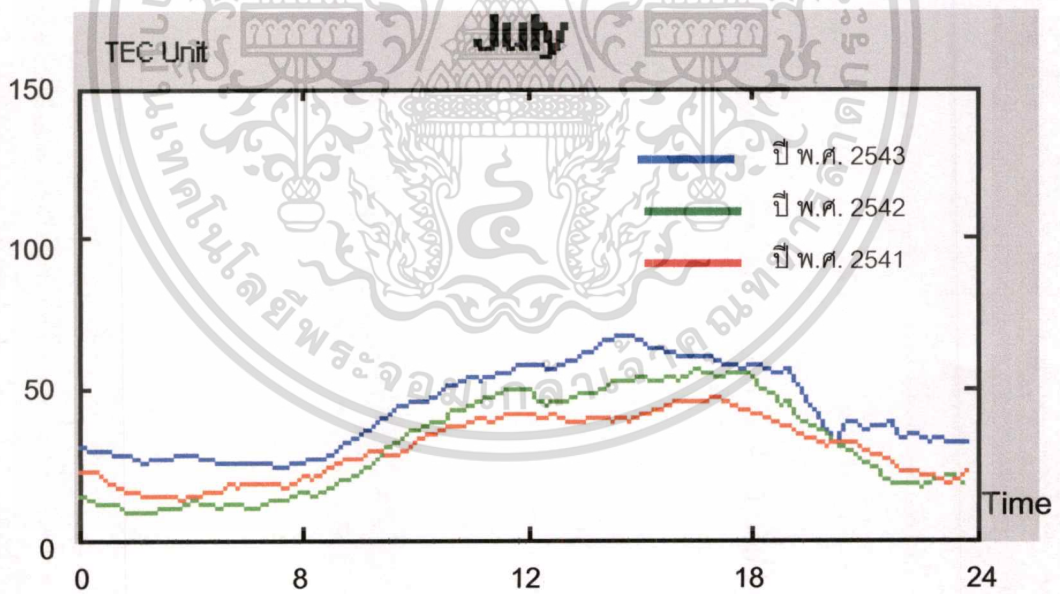


รูปที่ 3.19 แสดงปริมาณอิเล็กทรอนิกส์ในช่วงเดือนพฤษภาคมในปี พ.ศ. 2541 –2543

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

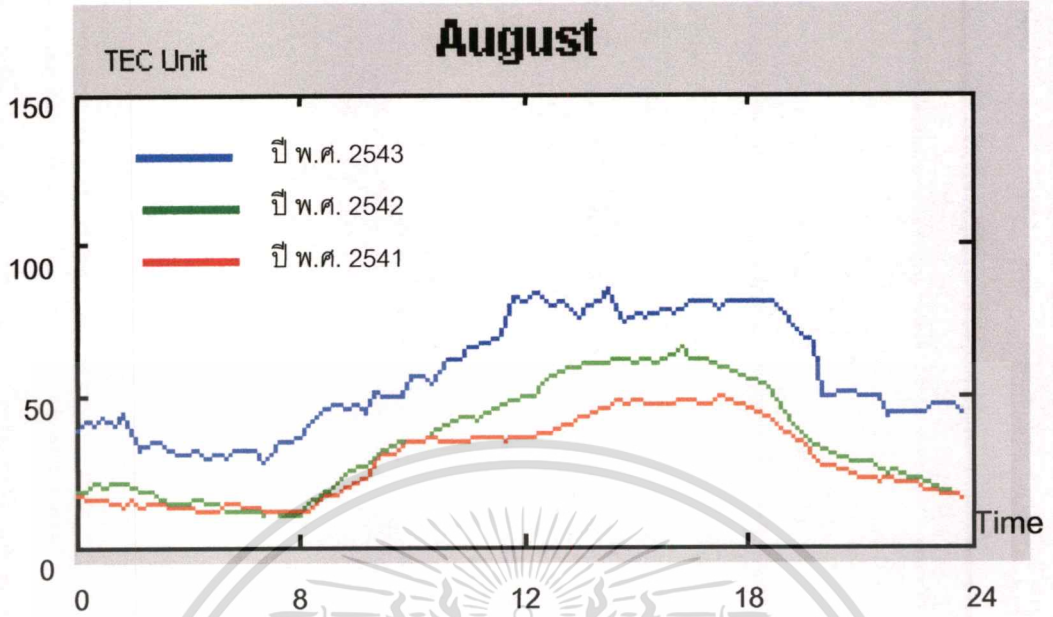


รูปที่ 3.20 แสดงปริมาณอิเล็กทรอนิกส์ในช่วงเดือนมิถุนายนในปี พ.ศ. 2541–2543

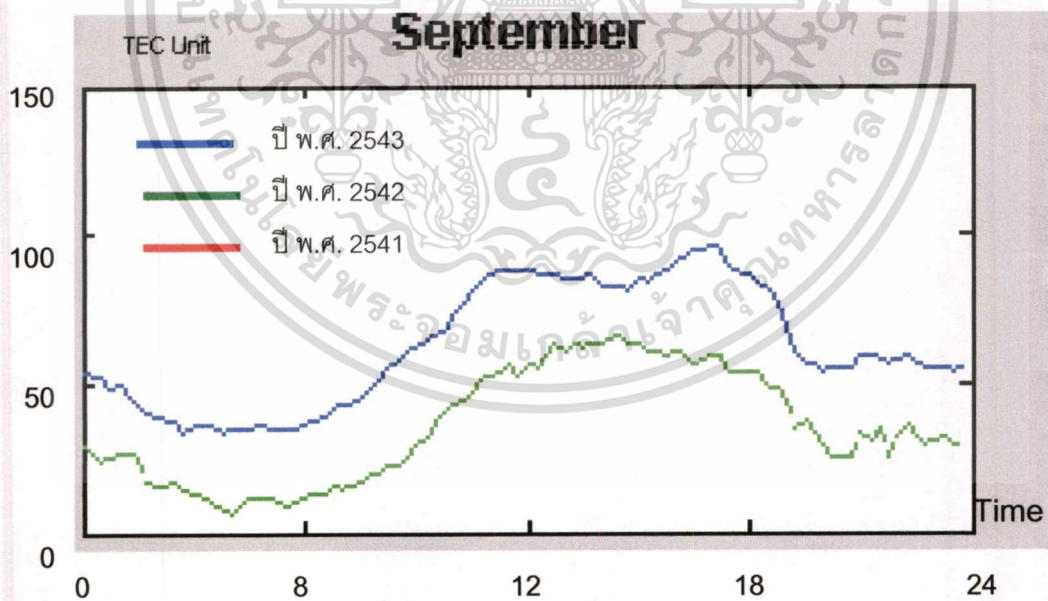


รูปที่ 3.21 แสดงปริมาณอิเล็กทรอนิกส์ในช่วงเดือนกรกฎาคมในปี พ.ศ. 2541–2543

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 3.22 แสดงปริมาณอิเล็กตรอนเฉลี่ยในช่วงเดือนสิงหาคมในปี พ.ศ. 2541–2543




รูปที่ 3.23 แสดงปริมาณอิเล็กตรอนเฉลี่ยในช่วงเดือนกันยายนในปี พ.ศ. 2541–2543

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

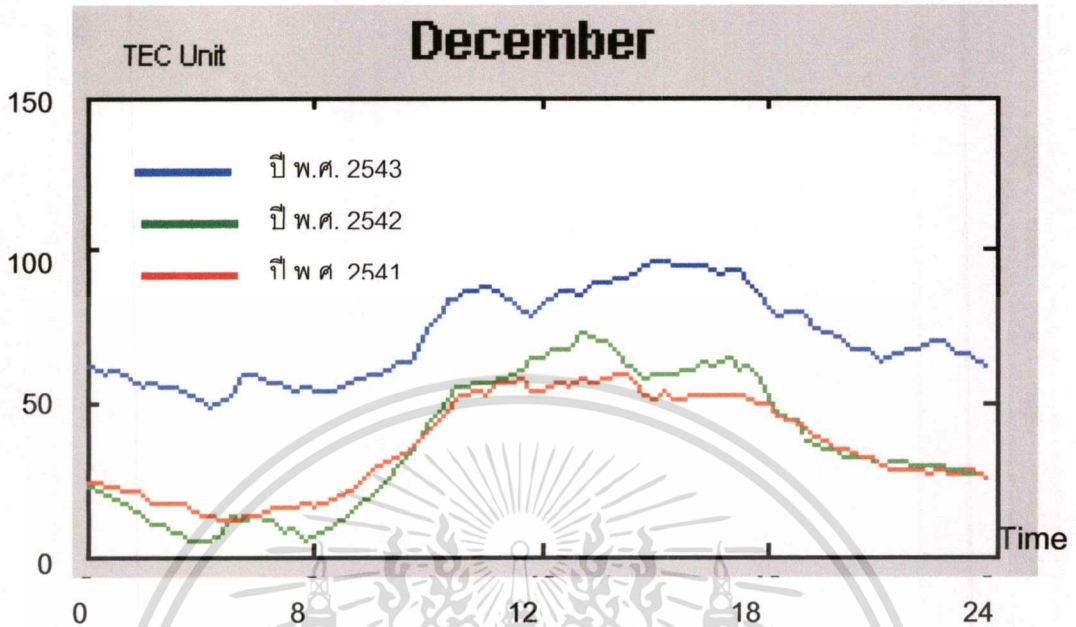


รูปที่ 3.24 แสดงปริมาณอิเล็กทรอนิกส์ในช่วงเดือนตุลาคมในปี พ.ศ. 2541–2543



รูปที่ 3.25 แสดงปริมาณอิเล็กทรอนิกส์ในช่วงเดือนพฤศจิกายนในปี พ.ศ. 2541–2543

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.26 แสดงปริมาณอิเล็กตรอนเฉลี่ยในช่วงเดือนธันวาคมในปี พ.ศ. 2541–2543

จากผลการทดลองที่ได้ดังตารางที่ 3.4 พบว่าค่าความสัมพันธ์ของ TEC สูงสุด, TEC ต่ำสุด และ TEC เฉลี่ย ในแต่ละวันกับ SSN ในแต่ละวันมีค่าเฉลี่ยสัมประสิทธิ์สหสัมพันธ์ คือ 0.18, 0.14 และ 0.25 ตามลำดับ มีความเบี่ยงเบนมาตรฐาน 0.12, 0.08 และ 0.07 ตามลำดับ ทำให้ได้ข้อสรุปว่าลักษณะการเปลี่ยนแปลงปริมาณ TEC เฉลี่ยในแต่ละวันจะมีความสัมพันธ์กับ SSN มากกว่า TEC สูงสุด และ TEC ต่ำสุด ซึ่งผลการทดลองที่ได้นี้สอดคล้องตรงกับผลการทดลองในรูปที่ 3.17 ดังนั้นจึงสรุปได้ว่า TEC สูงสุดในแต่ละวันขึ้นมีความสัมพันธ์ในทิศทางเดียวกับค่า SSN ถึงแม้จากค่าเฉลี่ยของสัมประสิทธิ์สหสัมพันธ์ที่ได้จากการทดลองจะมีขนาดที่น้อย แต่จากการศึกษาทฤษฎีที่เกี่ยวข้องในตอนต้น ทำให้เราไม่สามารถที่จะปฏิเสธได้ว่าไม่มีความสัมพันธ์กัน ทำให้ SSN จึงเป็นพารามิเตอร์หนึ่งที่จะใช้ในการกำหนดการเปลี่ยนแปลงของ TEC ด้วย แต่อิทธิพลของ SSN จะไม่ส่งผลกระทบต่อมากเท่ากับช่วงเวลาที TEC มีการเปลี่ยนแปลงในแต่ละวัน

ตารางที่ 3.4 แสดงผลการทดลองหาค่าสัมประสิทธิ์สหสัมพันธ์ ของ TEC สูงสุด , ต่ำสุด และเฉลี่ยที่เกิดขึ้นในแต่ละวัน กับค่าจุดดับดวงอาทิตย์ในแต่ละวัน

เดือน ปี	ค่าสัมประสิทธิ์สหสัมพันธ์		
	TEC สูงสุด & SSN	TEC ต่ำสุด & SSN	TEC เฉลี่ย & SSN
ม.ค. 2543	0.07	0.15	0.35
ก.พ. 2543	0.21	0.27	0.33
มี.ค. 2543	0.34	0.23	0.28
เม.ย. 2543	0.17	0.21	0.29
พ.ค. 2543	0.12	0.17	0.21
มิ.ย. 2543	0.22	0.02	0.16
ก.ค. 2543	0.30	0.12	0.33
ส.ค. 2543	0.01	0.18	0.20
ก.ย. 2543	0.01	0.07	0.11
ต.ค. 2543	0.15	0.04	0.23
พ.ย. 2543	0.39	0.11	0.27
ธ.ค. 2543	0.14	0.08	0.21
ค่าเฉลี่ย	0.18	0.14	0.25
ค่าเบี่ยงเบนมาตรฐาน	0.12	0.08	0.07

3.4 การเปลี่ยนแปลงดัชนีสนามแม่เหล็กโลก

3.4.1 สนามแม่เหล็กโลกและไอโอโนสเฟียร์

ในการศึกษาเรื่องชั้นบรรยากาศไอโอโนสเฟียร์สิ่งหนึ่งที่ควรศึกษาควบคู่กันไปด้วยคือสนามแม่เหล็กโลก เนื่องจากพบว่าในการทดลองสนามแม่เหล็กสามารถควบคุมการเคลื่อนที่ของไอโอโนสเฟียร์ได้ และสนามแม่เหล็กยังมีผลต่อการแพร่กระจายคลื่น

สนามแม่เหล็กโลกพุ่งออกจากโลกและล้อมรอบโลกไว้โดยสิ้นสุดที่ระยะทางซึ่งคิดเป็นความยาวเมื่อเทียบกับรัศมีโลกประมาณ 3 เท่า ทำให้มีการตั้งชื่อชั้นบรรยากาศนี้ว่า " แมกนีโตสเฟียร์ " (Magnetosphere) ซึ่งก่อนหน้านี้จะเรียกชั้นบรรยากาศว่า " โปรโตโนสเฟียร์ " (Protonosphere) และ " เอ็กโซสเฟียร์ " (Exosphere) เมื่อพิจารณาจากรูปที่ 3.1 เห็นได้ว่าแมกนีโตสเฟียร์อยู่ติดกับ

บริเวณไอโอโนสเฟียร์ที่ระดับความสูงสูง ๆ ดังนั้นปรากฏการณ์ที่เกี่ยวข้องกับสนามแม่เหล็กโลก และไอโอโนสเฟียร์จึงเกิดบริเวณนี้รวมถึงการเกิดพายุสนามแม่เหล็กโลก

ในการศึกษาเรื่องปรากฏการณ์สนามแม่เหล็กโลกมีการทดลองครั้งแรกในราวปี ค.ศ. 1600 โดย William Gilbert ซึ่งเป็นนักวิทยาศาสตร์ของ Queen Elizabeth รายละเอียดของการทดลองคือใช้แร่แม่เหล็กชื่อ " ไอโอดีสโตน " (lodestone) มาตัดเป็นทรงกลม แล้วนำมาศึกษาทิศทางการแพร่กระจายแรงแม่เหล็กรอบ ๆ ผิว โดยการทดลองครั้งนั้นเขาคิดว่าโลกน่าจะมีสนามแม่เหล็กโลกอยู่ โดยโลกเปรียบเสมือนแม่เหล็กทรงกลมขนาดใหญ่คล้ายกับแร่แม่เหล็กที่เขาใช้ในการทดลอง ในปัจจุบันเราสามารถพิสูจน์ผลการทดลองของ Gilbert เป็นสมการทางคณิตศาสตร์ของสนามไดโพล และยังพบว่าผลที่ได้จะเหมือนกับของ Gilbert เมื่อสังเกตจากบริเวณที่อยู่ใกล้พื้นผิวโลก

การค้นพบที่สำคัญต่อมาเกิดขึ้นในปี ค.ศ. 1722 โดย G. Graham ซึ่งเป็นช่างทำนาฬิกาในประเทศอังกฤษ เขาได้สังเกตเห็นความเปลี่ยนแปลงที่เกิดขึ้นกับเข็มทิศในแต่ละวัน และยังคงพบการรบกวนแม่เหล็ก (Magnetic disturbance) เกิดขึ้นเมื่อเกิดปรากฏการณ์พายุแม่เหล็กโลก ต่อมาการค้นคว้าของ A. Celsius และ J.C. Wilcke ค้นพบว่าเมื่อเกิดการรบกวนแม่เหล็กมีผลต่อการมองเห็นการเกิดแสงเหนือแสงใต้ (Aurora)

ในปี ค.ศ.1843 H. Schwabe ให้ข้อสังเกตเกี่ยวกับจำนวนจุดดับบนดวงอาทิตย์ว่ามีลักษณะเปลี่ยนแปลงสัมพันธ์กับคาบเวลา และต่อมานำไปสู่การค้นพบว่าลักษณะการเปลี่ยนแปลงเป็นคาบเวลานั้นมีความสัมพันธ์กับการเกิดการรบกวนทางคลื่นความถี่วิทยุและรบกวนทางแม่เหล็ก

ต่อมา Chapman และ Bartels ซึ่งนักวิทยาศาสตร์ที่มีชื่อเสียงมากในการศึกษาเรื่องปรากฏการณ์สนามแม่เหล็กได้ตีพิมพ์ผลงานใน ค.ศ. 1940 งานวิจัยของทั้งสองได้เกี่ยวข้องกับเรื่อง " แอสโมสเฟียร์ไดนาโม " (Atmospheric dynamo) ซึ่งเป็นหลักการของ Balfour Stewart ที่พูดถึงการศึกษไอโอโนสเฟียร์ ทฤษฎีต่าง ๆ ในตอนหลังได้ถูกปรับปรุงโดย A. Schuster

K. Birkeland และ C. Stormer เริ่มการศึกษาถึงการเคลื่อนที่ของอนุภาคไฟฟ้าในสนามแม่เหล็กโลกซึ่งเกี่ยวข้องกับรังสีคอสมิก ต่อมา Chapman และ Ferraro ได้ตีพิมพ์ผลงานการศึกษาที่เกี่ยวข้องปฏิกิริยาของอนุภาคสุริยะ (Solar particle) และสนามแม่เหล็กโลกเป็นครั้งแรก ในปี ค.ศ. 1931 ผลงานนี้นับว่าให้หลักการที่เป็นพื้นฐานในการศึกษาลักษณะทางกายภาพของดวงอาทิตย์และโลกรวมถึงทฤษฎีพายุแม่เหล็ก ซึ่งผลงานนี้ถือเป็นการเริ่มต้นการศึกษาในหัวข้อสนามแม่เหล็กโลกและไอโอโนสเฟียร์ในเวลาต่อมา

3.4.2 ดัชนีสนามแม่เหล็กโลก ap และ Ap

ในปี ค.ศ. 1949 J. Bartels ได้คิดระบบดัชนีสนามแม่เหล็กโลกขึ้น เพื่อบ่งบอกถึงระดับความแรงของสนามแม่เหล็กโลก ดัชนีสนามแม่เหล็กโลกเป็นการวัดค่าสนามแม่เหล็กทั้ง 3 องค์
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ประกอบที่เกิดขึ้นจากสถานีวัดภาคพื้นดินโดยมีการวัดทุก ๆ 3 ชั่วโมงเป็นค่า ap ค่าเฉลี่ยจาก 8 ค่าของ ap ในแต่ละวัน เรียกว่า " Ap " โดยค่าที่ได้มาจากสถานีวัด 13 แห่งกระจายทั่วโลกเรียกว่า " Planetary Index " [17] นอกจากนี้แล้วดัชนีสนามแม่เหล็กโลกยังมีหลายระบบดัชนี แต่ที่ได้รับความนิยม คือ Ap และ Kp แต่เนื่องจากว่าในการเปรียบเทียบค่านั้นการใช้ดัชนี Kp จะไม่สะดวก เนื่องจากไม่อยู่ในรูปแบบเชิงเส้น ทำให้การใช้ค่า Ap เหมาะสมสำหรับเป็นดัชนีที่ใช้ในการศึกษา ในวิทยานิพนธ์เล่มนี้ ซึ่งค่า Kp และ Ap มีความสัมพันธ์กันดังนี้

Kp 0_o 0+ 1- 1_o 1+ 2- 2+ 3- 3_o 3+ 4- 4_o

Ap 0 2 3 4 5 7 9 12 15 18 22 27

Kp 4+ 5- 5_o 5+ 6- 6_o 6+ 7- 7_o 7+ 8- 8_o 8+ 9- 9_o

Ap 32 39 48 56 67 80 94 111 132 154 179 207 236 300 400

ตารางที่ 3.5 แสดงการแบ่งประเภทของพายุสนามแม่เหล็ก

ประเภท	ผลกระทบ	ปริมาณที่วัดได้	ความถี่เฉลี่ยในการเกิด ในรอบ 11 ปี
รุนแรงมาก	<ul style="list-style-type: none"> - ระบบไฟฟ้าเสียหายมาก เกิดการพังของอุปกรณ์ - หม้อแปลงเสียหาย - คลื่นวิทยุ HF ใช้งานไม่ได้ 1-2 วัน - ดาวเทียมนำร่องใช้งานไม่ได้ 1 วัน - คลื่นวิทยุความถี่ต่ำใช้งานไม่ได้เป็นชั่วโมง - เกิดแสงเหนือแสงใต้ที่บริเวณละติจูดแม่เหล็ก 40° 	$Kp = 9$ $Ap = 400$	4 วันใน 11 ปี

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.5 (ต่อ)

ประเภท	ผลกระทบ	ปริมาณที่วัดได้	ความถี่เฉลี่ยในการเกิดในรอบ 11 ปี
รุนแรง	<ul style="list-style-type: none"> - ระบบควบคุมการจ่ายไฟฟ้าจะผิดพลาด - การปฏิบัติการกิจอวกาศจะเกิดปัญหาประจุไฟฟ้าและระบบติดตามผิดพลาด - คลื่นวิทยุ HF, การสื่อสารดาวเทียมใช้งานไม่ได้เป็นชั่วโมง - เกิดแสงเหนือแสงใต้ที่บริเวณละติจูดแม่เหล็ก 45° 	$K_p = 8$ และ $9 -$ $A_p = 207$ และ 300	60 วันใน 11 ปี
มาก	<ul style="list-style-type: none"> - ระบบไฟฟ้าเกิดไฟกระชากอุปกรณ์ป้องกันเกิดการทำงานผิดพลาด - ดาวเทียมวงโคจรต่ำจะเกิดปัญหาเรื่องตำแหน่ง - ดาวเทียมนำร่อง, คลื่นวิทยุคลื่นความถี่ต่ำและความถี่สูงจะมีปัญหาเกิดขึ้นไม่นาน - เกิดแสงเหนือแสงใต้ที่บริเวณละติจูดแม่เหล็ก 50° 	$K_p = 7$ $A_p = 132$	130 วันใน 11 ปี
ปานกลาง	<ul style="list-style-type: none"> - ถ้าช่วงการเกิดนานอาจทำให้หม้อแปลงเสียหาย - การปฏิบัติการกิจอวกาศจะเกิดการคลาดเคลื่อนการทำนายวงโคจร - คลื่นวิทยุ HF เกิดการจางหายที่บริเวณละติจูดสูง - เกิดแสงเหนือแสงใต้ที่บริเวณละติจูดแม่เหล็ก 55° 	$K_p = 6$ $A_p = 80$	360 วันใน 11 ปี
น้อย	<ul style="list-style-type: none"> - กระทบต่อการปฏิบัติการกิจอวกาศน้อย - การอพยพของสัตว์เกิดขึ้นมาก - เกิดแสงเหนือแสงใต้ที่บริเวณละติจูดแม่เหล็กสูง 	$K_p = 5$ $A_p = 48$	900 วันใน 11 ปี

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.5 ความสัมพันธ์ของดัชนีสนามแม่เหล็กโลกกับปริมาณอิเล็กตรอนในชั้นบรรยากาศไอโอโนสเฟียร์


ตารางที่ 3.6 แสดงผลการทดลองหาค่าสัมประสิทธิ์สหสัมพันธ์ ของ TEC สูงสุด ,ต่ำสุด และเฉลี่ยที่เกิดขึ้นในแต่ละวัน กับดัชนีสนามแม่เหล็กโลก Ap

เดือน ปี	ค่าสัมประสิทธิ์สหสัมพันธ์		
	TEC สูงสุด & Ap	TEC ต่ำสุด & Ap	TEC เฉลี่ย & Ap
ม.ค. 2543	0.33	0.08	0.19
ก.พ. 2543	0.29	0.09	0.09
มี.ค. 2543	0.37	0.09	0.15
เม.ย. 2543	0.50	0.02	0.27
พ.ค. 2543	0.46	0.11	0.06
มิ.ย. 2543	0.24	0.15	0.14
ก.ค. 2543	0.25	0.18	0.15
ส.ค. 2543	0.31	0.07	0.24
ก.ย. 2543	0.43	0.11	0.17
ต.ค. 2543	0.49	0.04	0.31
พ.ย. 2543	0.41	0.00	0.14
ธ.ค. 2543	0.38	0.01	0.07
ค่าเฉลี่ย	0.37	0.08	0.16
ค่าเบี่ยงเบนมาตรฐาน	0.09	0.06	0.08

ผลการทดลองหาค่าสัมประสิทธิ์สหสัมพันธ์ ของ TEC สูงสุด ,ต่ำสุด และเฉลี่ยที่เกิดขึ้นในแต่ละวัน กับดัชนีสนามแม่เหล็กโลก Ap พบว่าความสัมพันธ์ของ TEC สูงสุด, TEC ต่ำสุด และ TEC เฉลี่ย กับค่า Ap มีค่าสัมประสิทธิ์สหสัมพันธ์เฉลี่ย คือ 0.37 , 0.08 และ 0.16 ตามลำดับ และมีค่าเบี่ยงเบนมาตรฐาน 0.09, 0.06 และ 0.08 ตามลำดับ ดังนั้นจึงสรุปได้ว่า TEC สูงสุดในแต่ละวันมีความสัมพันธ์ในทิศทางเดียวกับค่า Ap มากที่สุด ความสัมพันธ์ที่เกิดขึ้นนี้เป็นไปตามแนวโน้มของรูปที่ 3.13


3.6 ความสัมพันธ์ของตำแหน่งเส้นละติจูดบนโลกกับปริมาณอิเล็กตรอนในชั้นบรรยากาศไอโอโนสเฟียร์

จากการศึกษาที่ผ่านมาในต่างประเทศ การเปลี่ยนแปลงปริมาณอิเล็กตรอน TEC มีค่าขึ้นอยู่กับมุมซีกของดวงอาทิตย์ที่เส้นศูนย์สูตร เนื่องจากที่มุมนี้จะทำให้ดวงอาทิตย์โคจรตรงศีรษะมากที่สุด พลังงานรังสีอัลตราไวโอเล็ตจึงมีพลังงานสูงกว่าตำแหน่งอื่นทำให้เกิดการไอออไนเซชันสูง และปริมาณอิเล็กตรอนที่มีค่าสูงสุดที่อยู่ย่านเส้นศูนย์สูตรจะส่งผลถึงปริมาณอิเล็กตรอนในทุกจุดของโลกด้วย [18]




รูปที่ 3.27 แสดงมุมซีกของดวงอาทิตย์ที่มีค่าเป็นศูนย์ในตำแหน่งของโลกที่เส้นละติจูดหรือเส้นรุ้งต่าง ๆ

- เชียงใหม่ ละติจูด 18.8°N ลองจิจูด 99°E
- กรุงเทพฯ ละติจูด 13.7°N ลองจิจูด 100.8°E
- ภูเก็ต ละติจูด 7.9°N ลองจิจูด 98.4°E




รูปที่ 3.28 แสดงแผนที่ตั้งของสถานีวัดปริมาณอิเล็กตรอนในประเทศไทย

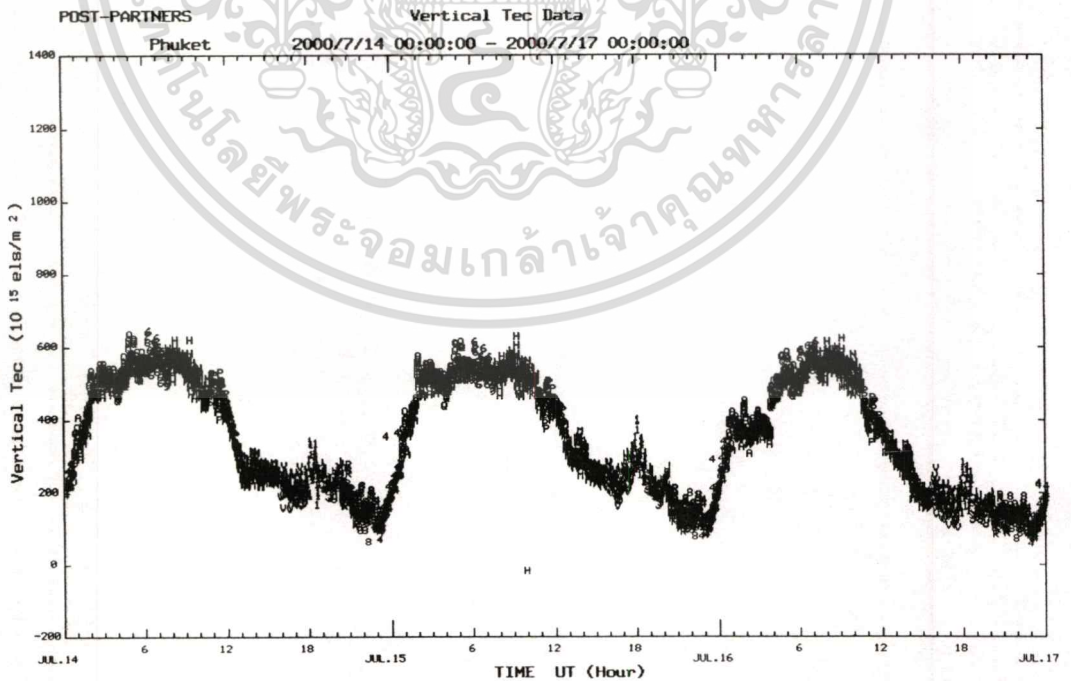


รูปที่ 3.29 แสดงค่าปริมาณอิเล็กตรอน TEC ของเชียงใหม่ ในวันที่ 14-17 กรกฎาคม 2543

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.30 แสดงค่าปริมาณอิเล็กตรอน TEC ของกรุงเทพ ในวันที่ 14-17 กรกฎาคม 2543



รูปที่ 3.31 แสดงค่าปริมาณอิเล็กตรอน TEC ของภูเก็ต ในวันที่ 14-17 กรกฎาคม 2543

เอกสารนี้เป็นเอกสารที่สวอนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากผลการทดลองในรูปที่ 3.29 – 3.31 เมื่อพิจารณาสถานที่ตั้งทั้ง 3 แห่ง พบว่ามีเส้น
 ลมจุดที่ใกล้เคียงกันมาก ดังนั้นตัวแปรอิสระที่สนใจในการทดลองนี้จึงเป็นเส้นละติจูด พบว่า
 ปริมาณ TEC ที่วัดได้มีค่ามากที่สุด คือสถานีวัดเชียงใหม่ที่ตั้งอยู่ในตำแหน่งละติจูดสูง แทนที่จะ
 เป็นจังหวัดภูเก็ตซึ่งสถานีวัดใกล้กับเส้นศูนย์สูตรของโลกมากที่สุด ทั้งนี้ก็เนื่องมาจากว่ามุม
 ซีนิธของดวงอาทิตย์ในช่วงเดือนกรกฎาคมนั้นมุมซีนิธศูนย์ที่ช่วงละติจูดประมาณ $20^{\circ}N$ (จากรูป
 ที่ 3.27) ซึ่งเป็นบริเวณที่ใกล้กับเชียงใหม่มากที่สุด รองลงมาคือกรุงเทพ และอันดับสุดท้ายคือ
 ภูเก็ต ส่งผลให้ปริมาณ TEC ที่มีการเปลี่ยนแปลงมากเรียงตามลำดับสถานีวัดได้ดังต่อไปนี้คือ
 เชียงใหม่ , กรุงเทพ และ ภูเก็ต ตามลำดับ



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 4

การสร้างแบบจำลองปริมาณอิเล็กทรอนิกส์ในชั้นบรรยากาศ ไอโอโนสเฟียร์โดยเทคนิคโครงข่ายประสาท

4.1 การออกแบบสถาปัตยกรรมโครงข่ายประสาท

สิ่งที่ต้องคำนึงถึงอย่างแรกในการออกแบบสถาปัตยกรรมของโครงข่ายประสาทคืออินพุตที่เข้าสู่โครงข่ายประสาทมีจำนวนเท่าใด ซึ่งจำนวนอินพุตที่เข้าสู่โครงข่ายนี้จะเป็นตัวกำหนดจำนวนเลเยอร์อินพุตของโครงข่ายประสาท โดยอินพุตนี้ต้องเป็นสิ่งที่สำคัญในการที่จะทำให้โครงข่ายสามารถนำข้อมูลนี้ไปใช้ในการทำนายค่าได้ ซึ่งจากการศึกษาพบว่าอินพุตมีพารามิเตอร์ที่เหมาะสมจำนวน 10 อินพุต คือ

- 1) ปริมาณอิเล็กทรอนิกส์ในชั้นบรรยากาศไอโอโนสเฟียร์ที่เวลาใด ๆ : TEC(t)
- 2) ค่าเฉลี่ยปริมาณอิเล็กทรอนิกส์ในชั้นบรรยากาศไอโอโนสเฟียร์ที่เวลาใด ๆ : ATEC(t)
- 3) ค่าเฉลี่ยปริมาณอิเล็กทรอนิกส์ในชั้นบรรยากาศไอโอโนสเฟียร์ที่เวลาผ่านมา 1 ชั่วโมง :

ATEC(t-1)

- 4) ค่าเฉลี่ยปริมาณอิเล็กทรอนิกส์ในชั้นบรรยากาศไอโอโนสเฟียร์ที่เวลาล่วงหน้าอีก 1 ชั่วโมง :

ATEC(t+1)

- 5) ปริมาณอิเล็กทรอนิกส์ในชั้นบรรยากาศไอโอโนสเฟียร์ที่เวลาล่วงหน้าอีก 1 ชั่วโมงของเมื่อวันก่อน : TEC(t-23)

- 6) ปริมาณอิเล็กทรอนิกส์ในชั้นบรรยากาศไอโอโนสเฟียร์ที่เวลาล่วงหน้าอีก 1 ชั่วโมงของเมื่อสองวันก่อน : TEC(t-47)

- 7) ผลต่างของปริมาณอิเล็กทรอนิกส์ที่เวลาใด ๆ กับค่าเฉลี่ยปริมาณอิเล็กทรอนิกส์ที่เวลาใด ๆ :

Delta TEC(t) = TEC(t) – ATEC(t)

- 8) ผลต่างของปริมาณอิเล็กทรอนิกส์ที่เวลาที่ผ่านไป 1 ชั่วโมงกับค่าเฉลี่ยปริมาณอิเล็กทรอนิกส์ที่เวลาผ่านไป 1 ชั่วโมง TEC(t) = TEC(t) – ATEC(t)

- 9) จุดดับดวงอาทิตย์ : SSN

- 10) ดัชนีสนามแม่เหล็กโลกชนิด ap : ap

ค่าเอาต์พุตที่ต้องการที่ส่งออกมาจากโครงข่ายที่ต้องการมี 1 เอาต์พุต คือ ค่าปริมาณอิเล็กทรอนิกส์ในชั้นบรรยากาศไอโอโนสเฟียร์ในอีก 1 ชั่วโมงข้างหน้า : TEC(t+1) จากข้อมูลในเบื้องต้นทำให้โครงสร้างของโครงข่ายประสาทต้องประกอบด้วยอินพุตเลเยอร์ที่มีจำนวนอินพุต 10 โหนด และมีเอาต์พุตเลเยอร์จำนวนเอาต์พุต 1 โหนด ส่วนเลเยอร์ที่ไม่ใช่อินพุตเลเยอร์และเอกซารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เอาต์พุตเลเยอร์เราจะเรียกว่าฮิดเดนเลเยอร์ (Hidden Layer) ซึ่งการกำหนดว่าฮิดเดนเลเยอร์จะมีจำนวนมากน้อยเท่าใดนั้นให้พิจารณาจากความเหมาะสมของค่าที่ได้จากการจำลองสถานการณ์ โดยให้มีค่าใกล้เคียงกับค่าเอาต์พุตที่ต้องการมากที่สุด

4.2 ขั้นตอนการสร้างแบบจำลอง

ฟังก์ชันที่อยู่ในกล่องเครื่องมือของ NNT (NNT Toolbox) ของโปรแกรม MATLAB สำหรับในการฝึกฟีดฟอร์เวิร์ดนิวรอลเน็ตเวิร์ค (Feedforward Neural Network) เพื่อให้โครงข่ายสามารถทำนายปริมาณอิเล็กทรอนิกส์ในเวลา 1 ชั่วโมงข้างหน้าได้ มีขั้นตอนการฝึก (Training) 4 ขั้นตอนดังต่อไปนี้


- 1) รวบรวมข้อมูลที่ใช้ในการฝึกโครงข่าย (Assemble the training data)
- 2) สร้างโครงข่าย (Create the network object)
- 3) ฝึกโครงข่าย (Train the network)
- 4) จำลองสถานการณ์เพื่อดูการทำงานของโครงข่ายเมื่อเจอกับอินพุตใหม่ (Simulate the network response to new inputs)

1.2.1 การสร้างฟีดฟอร์เวิร์ดเน็ตเวิร์ค

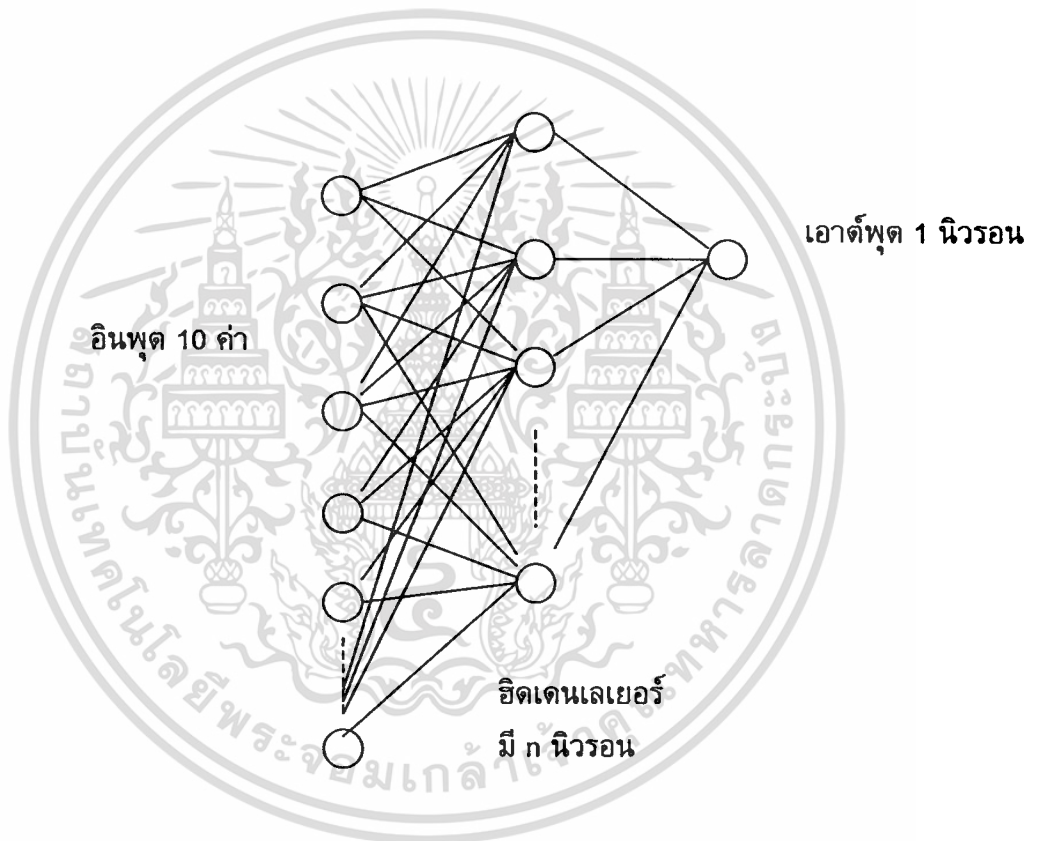
คำสั่งในโปรแกรม MATLAB ที่ใช้ในวิทยานิพนธ์นี้อยู่ในส่วน NNT network object ที่ชื่อว่า "nnt" เมื่อใช้คำสั่งนี้ผลลัพธ์ที่ได้คือจะได้โครงข่ายเปล่า ที่ไม่มีพารามิเตอร์คุณลักษณะอยู่ภายในโครงข่ายเลย จึงเป็นโครงข่ายที่ไม่สามารถทำงานได้ ดังนั้นเราจึงจำเป็นต้องกำหนดคุณลักษณะต่าง ๆ ของโครงข่ายในภายหลังเพื่อให้โครงข่ายสามารถทำงานได้

```
>> net = network ;
```

คุณลักษณะอันแรกที่ต้องพิจารณาในการสร้างโครงข่ายประสาท คือ "เลเยอร์" เลเยอร์ในความหมายของโครงข่ายประสาท หมายถึงเลเยอร์ที่มีนิวรอนอยู่เท่านั้น ดังนั้นเราจึงไม่นับรวมเลเยอร์ที่เป็นอินพุตมารวม โครงข่ายประสาทที่มีโครงสร้างที่แตกต่างกันนั้นจะมีจำนวนเลเยอร์ไม่เท่ากัน และคุณสมบัติภายในนิวรอนไม่เหมือนกัน โครงสร้างของโครงข่ายประสาทในรูปที่ 4.1 เรียกว่า "โครงข่ายหนึ่งเลเยอร์" (one-layer network) ส่วนโครงข่ายในรูปที่ 4.2 เรียกว่า "โครงข่ายสองเลเยอร์" (two-layer network)



รูปที่ 4.1 แสดงโครงสร้างของโครงข่ายหนึ่งเลเยอร์



รูปที่ 4.2 แสดงโครงสร้างของโครงข่ายสองเลเยอร์

เนื่องจากโครงข่ายประสาทที่มีประสิทธิภาพนั้นควรจะเป็นโครงข่ายที่มีฮิดเดนเลเยอร์ด้วย ดังนั้นในการสร้างโครงข่ายเพื่อใช้ในการสร้างแบบจำลองปริมาณอิเล็กทรอนิกส์จึงมีโครงสร้างเป็นแบบโครงข่ายสองเลเยอร์ ซึ่งจะมีฮิดเดนเลเยอร์เพียง 1 เลเยอร์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1.2.2 การสร้างเลเยอร์

ขั้นตอนแรกของการสร้างเลเยอร์คือการกำหนดคุณสมบัติของเลเยอร์อินพุต ใน NNT นั้นเราสามารถที่จะกำหนดเลเยอร์อินพุตให้มีจำนวนมากกว่า 1 เลเยอร์ได้ แต่ก็ไม่เคยปรากฏมาก่อนว่ามีใครใช้อินพุตเลเยอร์หลายเลเยอร์ ดังนั้นจึงกำหนดให้จำนวนเลเยอร์อินพุตเป็น 1

```
>> net.numInputs = 1;
```

ขั้นตอนต่อมาคือการกำหนดจำนวนนิวรอนในเลเยอร์อินพุต ซึ่งโดยปกติแล้วควรจะมีค่าเท่ากับขนาดของจำนวนข้อมูลที่ใช้ในการฝึกโครงข่าย คำสั่งที่ใช้คือ `net.inputs{i}.size` ค่า `i` คือตัวระบุลำดับของเลเยอร์อินพุต กรณีนี้เลเยอร์อินพุตมีเพียงหนึ่งเลเยอร์ ค่า `i` จึงเท่ากับ 1 เนื่องจากว่าในตอนต้นได้กล่าวไว้แล้วว่าข้อมูลอินพุตมีจำนวน 10 อินพุต การกำหนดนิวรอนในเลเยอร์อินพุตจึงทำได้โดยการพิมพ์ดังนี้

```
>> net.inputs{1}.size = 10 ;
```

เมื่อการกำหนดอินพุตเลเยอร์สิ้นสุด ขั้นตอนต่อมาคือการกำหนดจำนวนเลเยอร์ทั้งหมดของโครงข่ายประสาท โดยใช้คำสั่ง `net.numLayers` และขั้นตอนการกำหนดจำนวนนิวรอนในแต่ละเลเยอร์โดยใช้คำสั่ง `net.layers{i}.size`

จากรูปที่ 4.2 ตามโครงสร้างฮิดเดนเลเยอร์มี n นิวรอน และเอาต์พุตเลเยอร์มี 1 นิวรอน ดังนั้นการกำหนดจึงต้องใช้คำสั่งดังต่อไปนี้

```
>> net.numLayers = 2 ;
```

```
>> net.layers{1}.size = 3 ;
```

```
>> net.layers{2}.size = 1 ;
```

1.2.3 การเชื่อมโยงเลเยอร์

ในการกำหนดให้มีการเชื่อมโยงเลเยอร์อินพุตต้องกำหนดให้ `net.inputConnect(i)` มีค่าเป็น 1 ซึ่งโดยปกติจะกำหนดเลเยอร์อินพุตที่ 1 ก่อน ดังนั้นค่า `i = 1`

```
>> net.inputConnect(1) = 1 ;
```

การกำหนดการเชื่อมต่อเลเยอร์จะมีลักษณะการกำหนดเป็นแบบเมทริกซ์ โดยสามารถกำหนด `net.layerConnect` ให้มีค่าได้ทั้ง 0 หรือ 1 ถ้าค่า `(i,j)` ถูกกำหนดให้เป็น 1 หมายความว่าเอาต์พุตเลเยอร์ที่ `j` มีการเชื่อมโยงเข้ากับอินพุตเลเยอร์ `i`

```
>> net.layerConnect (2,1) = 1 ;
```

ขั้นตอนต่อมาคือเราจะต้องทำการกำหนดการเชื่อมโยงที่เอาต์พุตเลเยอร์ก่อนโดยการกำหนด `net.outputConnect(i)` ให้มีค่าเป็น 1

```
>> net.outputConnect (2) = 1 ;
```

ขั้นตอนสุดท้ายคือการเชื่อมโยงเลเยอร์เอาต์พุตเข้ากับค่าเป้าหมาย ซึ่งจำเป็นมากในการฝึกแบบซูปเวอไรส์ (Supervised Training) โดยการกำหนด `net.targetConnect(i) = 1`

```
>> net.targetConnect (2) = 1 ;
```

1.2.4 การกำหนดทรานสเฟอร์ฟังก์ชัน

ในแต่ละเลเยอร์ประกอบด้วยทรานสเฟอร์ฟังก์ชันที่แตกต่างกัน ซึ่งเป็นคุณลักษณะเฉพาะตัวของเลเยอร์ คำสั่งที่ใช้ในการกำหนดทรานสเฟอร์ฟังก์ชันคือ `net.layers{i}.transferFcn` กรณีที่เราต้องการกำหนดซิกมอยด์ทรานสเฟอร์ฟังก์ชันให้กับเลเยอร์ที่ 1 และกำหนดลิเนียร์ทรานสเฟอร์ฟังก์ชันให้กับเลเยอร์ที่ 2 ทำได้โดยการพิมพ์คำสั่งดังต่อไปนี้

```
>> net.layers{1}.transferFcn = 'logsig' ;
```

```
>> net.layers{2}.transferFcn = 'purelin' ;
```

การกำหนดทรานสเฟอร์ฟังก์ชันอาจแตกต่างไปจากนี้ได้ ขึ้นอยู่กับการนำไปใช้งาน ซึ่งสามารถทราบรายชื่อของทรานสเฟอร์ฟังก์ชันทั้งหมดได้ดังแสดงไว้ในภาคผนวก ก.

1.2.5 การกำหนดตัวถ่วงน้ำหนักและไบอัส

คำสั่งที่ใช้ในการกำหนดไบอัสให้กับเลเยอร์ คือ `net.biasConnect` ซึ่งสามารถกำหนดให้มีค่าเป็น 0 หรือ 1 ถ้ากำหนด `net.biasConnect(i) = 1` หมายความว่าเลเยอร์ i มีไบอัสเกิดขึ้นบนเลเยอร์ ในการกำหนดให้มีไบอัสเกิดขึ้นบนโครงข่ายเราสามารถพิมพ์คำสั่งต่อไปนี้ได้

```
>> net.biasConnect(i) = 1 ;
```

กระบวนการกำหนดสถานะเริ่มต้น (initialisation procedure) ของตัวถ่วงน้ำหนักและไบอัสสามารถกระทำได้โดยใช้คำสั่งต่อไปนี้

```
>> net = init(net) ;
```

เพื่อให้ได้ค่าน้ำหนักและไบอัสเป็นไปตามที่เราต้องการ เราต้องมีการกำหนดตั้งค่า `net.initFcn` ให้มีค่าเป็น 'initlay' โดยพิมพ์คำสั่งต่อไปนี้

```
>> net.initFcn = 'initlay' ;
```

ขั้นตอนต่อไปต้องมีการกำหนดค่าน้ำหนักและไบอัสให้กับแต่ละเลเยอร์ โดยใช้คำสั่ง `net.layers{i}.initFcn` การกำหนดค่าที่นิยมมี 2 แบบคือ 1. Nuyten-Widrow initialisation กำหนดค่า 'initnw' 2. กำหนดค่า 'initwb' การกำหนดค่าแบบหลังนั้นสามารถกำหนดสถานะเริ่มต้นให้กับค่าน้ำหนักและไบอัสแยกออกจากกันได้ ถ้าเลือกใช้ 'initnw' ต้องพิมพ์คำสั่งดังต่อไปนี้

```
>> net.layers{i}.initFcn = 'initnw' ;
```

ถ้าเลือกใช้ 'initwb' จะต้องระบุค่าให้กับตัวถ่วงน้ำหนักและไบอัสแยกจากกันโดยมีตัวเลือกที่นิยมใช้กันคือ 'rands' ซึ่งตัวเลือกนี้จะกำหนดค่าตัวถ่วงน้ำหนักหรือไบอัสเป็นค่าที่ได้จากการสุ่มเลือกระหว่าง -1 ถึง 1 โดยพิมพ์คำสั่งดังต่อไปนี้

```
>> net.layers{i}.initFcn = 'initwb' ;
```

การกำหนดค่าอินพุตตัวถ่วงน้ำหนักให้กับเลเยอร์ i ใช้คำสั่งดังนี้

```
>> net.inputWeights{1,1}.initFcn = 'rands' ;
```

การกำหนดค่าไบอัสใช้คำสั่ง

```
>> net.biases{i}.initFcn = 'rands' ;
```

การกำหนดค่าเมทริกซ์ตัวถ่วงน้ำหนักใช้คำสั่ง

```
>> net.layerWeight{l, j}.initFcn = 'rands' ;
```

โดย net.layerWeights{i, j} หมายถึงน้ำหนักระหว่างเลเยอร์ j กับเลเยอร์ i

4.2.6 การกำหนดฟังก์ชันในการฝึกและพารามิเตอร์

การฝึกโครงข่ายแบ่งออกเป็น 2 วิธี

1) Incremental training เป็นการเปลี่ยนแปลงตัวถ่วงน้ำหนักและไบอัสหลังจากที่มีตัวอย่างที่ใช้ในการฝึกเข้ามาเพียง 1 ค่า

2) Batch training เป็นการเปลี่ยนแปลงตัวถ่วงน้ำหนักและไบอัสหลังจากที่มีตัวอย่างที่ใช้ในการฝึกเข้ามาพร้อมกันทั้งหมด ซึ่งเป็นการฝึกที่เราใช้กันในการสร้างแบบจำลองด้วยโครงข่ายประสาทเพื่อทำนายค่าปริมาณอิเล็กทรอนิกส์ในชั้นบรรยากาศไอโอโนสเฟียร์

เมื่อใดก็ตามที่ใช้คำสั่ง " train " การฝึกจะถูกกำหนดให้มีรูปแบบเป็นแบบ Batch training เท่านั้น โดยไม่มีการคำนึงถึงรูปแบบของชุดข้อมูลที่ใช้ในการฝึก ฟังก์ชันที่ใช้ควบคู่กับคำสั่ง train มีหลายอย่างเช่น gradient descent , gradient descent with momentum , Levenberg-Marquardt เป็นต้น ซึ่งแต่ละวิธีต่างก็เป็นวิธีที่มีประสิทธิภาพ ทำให้เราไม่จำเป็นต้องใช้ incremental training

การกำหนดค่าการใช้งานตัวแสดงประสิทธิภาพการทำงาน (Performance function) สามารถทำได้โดยการพิมพ์คำสั่งดังต่อไปนี้

```
>> net.performFcn = 'mse' ;
```

ในการกำหนดพารามิเตอร์ต่าง ๆ เพื่อใช้ในการฝึกตามรูปแบบที่เราเลือก สามารถทำได้ดังต่อไปนี้คือ ในกรณีที่เราต้องการฝึกโครงข่ายโดยใช้อัลกอริทึมแบบ Gradient Descent with Momentum ต้องกำหนดค่าดังต่อไปนี้

```
>> net.trainFcn = 'traingdm' ;
```

หลังจากนั้นทำการกำหนดพารามิเตอร์ที่ใช้ในการฝึกตามรูปแบบของ Gradient Descent with Momentum

```
>> net.trainParam.lr = 0.1 ;
```

```
>> net.trainParam.mc = 0.9 ;
```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

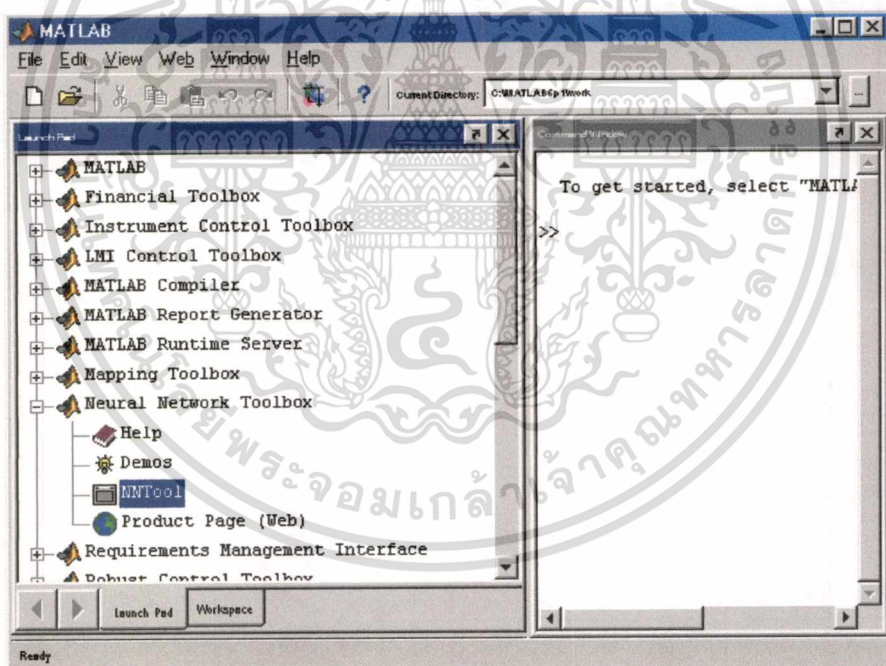
ในที่นี้กำหนดให้ค่า lr คืออัตราการเรียนรู้ (learning rate) และค่า mc คือค่าโมเมนตัม (Momentum term) รวมทั้งยังมีพารามิเตอร์ที่ใช้อย่างน้อย ๆ คือ net.trainParam.epochs โดยเป็นการกำหนดจำนวนครั้งมากที่สุดที่ใช้ในการฝึกโครงข่ายด้วยชุดข้อมูลและ net.trainParam.show ซึ่งใช้ในการกำหนดเวลาการรายงานสถานะในการฝึก การใช้งานสามารถกำหนดได้โดยการพิมพ์ดังข้างล่าง

```
>> net.trainParam.epochs = 1000 ;
```

```
>> net.trainParam.show = 100 ;
```

สำหรับ NNT Toolbox ในเวอร์ชันตั้งแต่ 4.0 ขึ้นไปพบว่าการใช้งาน NNT ค่อนข้างที่จะสะดวกเนื่องจากมี Network/Data Manager มาให้ ทำให้การกำหนดค่าต่าง ๆ ในโครงข่ายประสาทเป็นไปได้ง่ายขึ้น รายละเอียดต่าง ๆ ของ NNT Toolbox v. 4.0 นี้จะอยู่ในภาคผนวก ง.

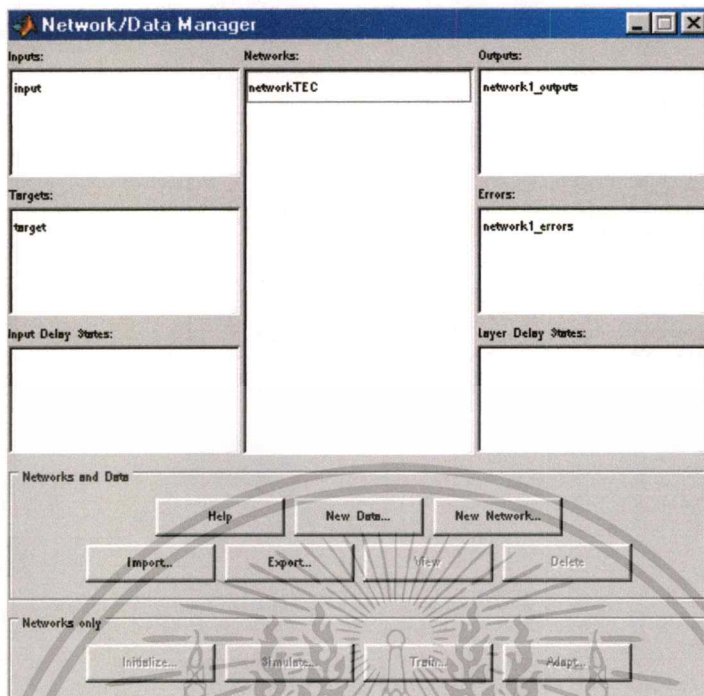
หน้าจอกอมพิวเตอร์เมื่อใช้งาน NNT Toolbox v. 4.0 ในการทำงานโหมดต่าง ๆ สามารถนำมาแสดงได้ในรูปที่ 4.3 – 4.6



รูปที่ 4.3 แสดงการใช้งาน NNT Toolbox

การเรียกโปรแกรม NNT Toolbox มาใช้งาน สามารถทำได้โดยการดับเบิลคลิกเข้าไปที่ NNTool ดังรูปที่ 4.3

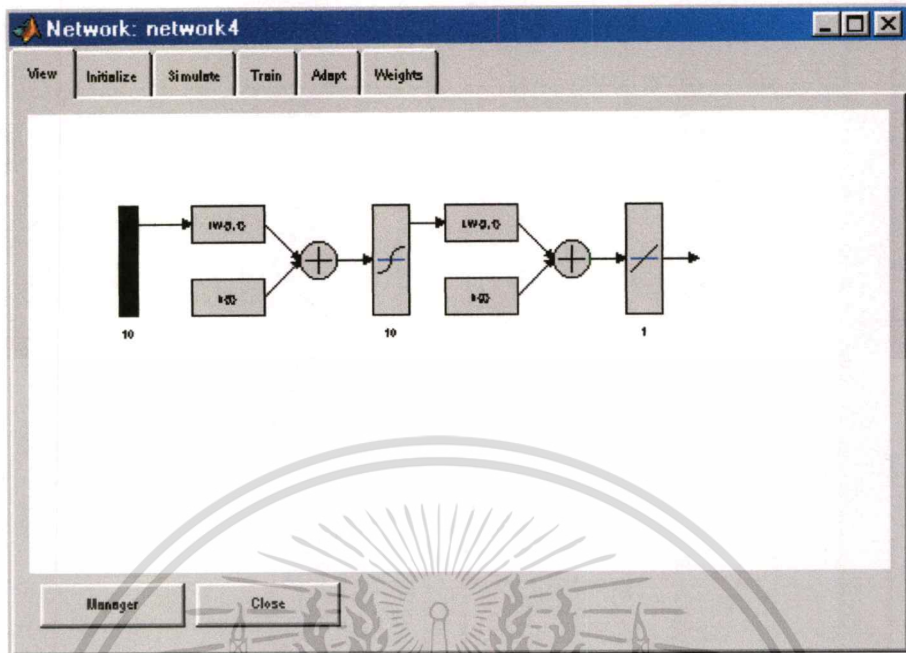
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.4 แสดงการใช้งาน Network/Data Manager

หน้าจอในรูปที่ 4.4 แสดงรายละเอียดของโครงข่าย ซึ่งในเราสามารถที่จะกำหนดค่าอินพุต และค่าเอาต์พุตที่ต้องการ (Target) โดยสามารถโหลดไฟล์เข้ามาประมวลผลได้ สามารถเลียนแบบการทำงาน (Simulate) เมื่อประมวลผลเรียบร้อยแล้วก็จะแสดงชื่อไฟล์ต่าง ๆ ที่เกี่ยวข้อง เป็นต้นว่า ไฟล์ข้อมูลที่เก็บค่าความผิดพลาด ไฟล์ข้อมูลที่แสดงค่าเอาต์พุต ซึ่งบันทึกค่าเก็บไว้

โครงข่ายที่สร้างขึ้นสามารถกำหนดค่าพารามิเตอร์ต่าง ๆ ได้ เช่น ให้ค่าอินพุตมี 10 โหนด ชนิดของนิวรอน และเอาต์พุตมี 1 โหนด จากรูปที่ 4.5 ได้มีการกำหนดชนิดของทรานสฟังก์ชันใน เลเยอร์ที่ 1 เป็นชนิดซิกมอยด์ และเลเยอร์ที่ 2 มีทรานสเฟอร์ฟังก์ชันชนิดลิเนียร์



รูปที่ 4.5 แสดงโครงข่ายประสาทที่สร้างขึ้น



รูปที่ 4.6 แสดงการฝึกโครงข่ายประสาทที่สร้างขึ้นโดยวิธี Lavenberg – Marquardt

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 4.6 เมื่อฝึกโครงข่ายประสาทโดยวิธี Lavenberg – Marquardt ที่ส่วนบนแถบชื่อ (Title Bar) จะแสดงคำว่า “Traning with trainlm” เส้นกราฟที่แสดงในหน้าจอคือการแสดงค่าประสิทธิภาพของการฝึกจะกำหนดให้เป็นค่า MSE (Mean Square Error) ซึ่งตั้งเป้าหมายให้มีค่าน้อยที่สุดคือ 0 แต่ผลที่ได้จากการฝึกโครงข่ายแสดงออกมาว่าค่าประสิทธิภาพ (Performance) มีค่าเพียง 31 เท่านั้น ซึ่งถือว่าเป็นค่าความผิดพลาดที่น้อยมากกับจำนวนข้อมูลที่ใช้ฝึกโครงข่ายนานถึง 3 ปี



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 5

ค่าความผิดพลาดของแบบจำลอง IRI กับแบบจำลอง ปริมาณอิเล็กตรอนในชั้นบรรยากาศไอโอโนสเฟียร์โดย เทคนิคโครงข่ายประสาท

5.1 แบบจำลอง IRI

ชั้นบรรยากาศไอโอโนสเฟียร์อยู่ที่ความสูงประมาณ 60 – 2,000 กิโลเมตร อิทธิพลของการแผ่รังสีจากดวงอาทิตย์ทำให้เกิดพลาสมาไอออน ไอออน H^+ และ He^+ อยู่ที่ระดับความสูงประมาณ 1,000 กิโลเมตร ,ไอออน O^+ อยู่ที่ระดับความสูงประมาณ 300-500 กิโลเมตร, และไอออนโมเลกุล NO^+ , O_2^+ และ N_2^+ อยู่ที่ระดับความสูงต่ำกว่า 200 กิโลเมตร ความหนาแน่นของปริมาณไอออนทั้งหมดก็คือค่าความหนาแน่นอิเล็กตรอน ซึ่งจะอยู่ในช่วง $10^8 - 10^{13}$ ไอออน (อิเล็กตรอน) ต่อลูกบาศก์เมตร ไอออนและอิเล็กตรอนเหล่านี้จะมีการเคลื่อนที่ไปตามลมธรรมชาติและตามสนามไฟฟ้าโดยทิศทางการเคลื่อนที่จะไปตามเส้นสนามแม่เหล็กโลก

ความรู้ที่ได้จากการศึกษาเรื่องความหนาแน่นอิเล็กตรอนในชั้นบรรยากาศไอโอโนสเฟียร์นี้สามารถนำไปประยุกต์ใช้งานได้กว้างขวาง เช่น ด้านวิทยุ, ด้านโทรคมนาคม ,การติดตามดาวเทียม (Satellite tracking) และการเก็บข้อมูลที่เกี่ยวข้องกับโลกจากอวกาศ ทำให้จำเป็นที่จะต้องสร้างแบบจำลองพารามิเตอร์ต่าง ๆ ของชั้นบรรยากาศไอโอโนสเฟียร์เพื่อใช้งานได้ตรงตามวัตถุประสงค์

International Reference Ionosphere (IRI) เป็นโครงการนานาชาติได้รับความสนับสนุนโดย Committee on Space Research (COSPAR) และ International Union of Radio Science (URSI) มีทีมงานประมาณ 70 กลุ่มซึ่งทำงานเพื่อสร้างแบบจำลองมาตรฐานอิมพีริคัลของชั้นบรรยากาศไอโอโนสเฟียร์โดยการเก็บข้อมูล แบบจำลอง IRI มีการปรับปรุงอยู่หลายครั้ง เช่น IRI-95, IRI-97 และล่าสุด IRI-2001 เราสามารถที่จะใช้แบบจำลอง IRI หาค่าความหนาแน่นอิเล็กตรอน, อุณหภูมิอิเล็กตรอน, อุณหภูมิไอออน และองค์ประกอบของไอออนในช่วงความสูง 60 – 2,000 กิโลเมตร ซึ่งจะบอกถึงปริมาณอิเล็กตรอนด้วย โดยเราสามารถเปลี่ยนแปลงสถานที่, เวลาและวันที่ ตามความต้องการในการวิเคราะห์ได้

แบบจำลองที่เกี่ยวข้องกับชั้นบรรยากาศไอโอโนสเฟียร์มีดังต่อไปนี้

1. แบบจำลองทั่วไป

- IRI

2. แบบจำลองความหนาแน่นอิเล็กตรอน

- Chiu Ionospheric Model
- Bent Ionospheric Model
- Penn State Mk III Model
- SLIM Model
- FAIM Model

3. แบบจำลอง F2-Peak

- CCIR foF2 and M(3000)F2 Model Maps
- URSI foF2 Model Maps
- ISS-b foF2 Maps
- MINIMUF/QSTMUF Model
- IONCAP Model
- WBMOD Ionospheric Scintillation Model

4. แบบจำลองอุณหภูมิอิเล็กตรอน

- Density Dependent Electron Temperature Model
- AEROS Electron Temperature Model
- AE/ISIS Electron Temperature Model

5. แบบจำลององค์ประกอบไอออนและความเร็วลอยเลื่อนของไอออน

- DY Ion Composition Model
- ISR Ion Drift Model
- St. Santin Ion Drift Model

แบบจำลองความหนาแน่นอิเล็กตรอนที่ใช้กันอย่างแพร่หลายในการติดตามดาวเทียม คือแบบจำลอง Chiu และ Bent แบบจำลอง SLIM เป็นแบบจำลองกึ่งสมการอิมพีริคัลโดยอาศัยทฤษฎีที่ได้จาก grid value ส่วนแบบจำลอง FAIM เป็นแบบจำลองล่าสุดที่ใช้รูปแบบของ Chiu และใช้ผลลัพธ์จากแบบจำลอง SLIM ร่วมกัน โปรไฟล์ความหนาแน่นอิเล็กตรอนที่ได้จะทำให้เกิด peak ได้ 2-3 peak ที่เรียกว่า ค่า F2-Peak ซึ่งเป็นค่าที่มีความสำคัญและเมื่อหาความสัมพันธ์กับความถี่วิกฤติ foF2 พบว่า F2-Peak มีความสัมพันธ์ในลักษณะเชิงเส้นกับความถี่วิกฤติ foF2 ยกกำลังสอง นอกจากนี้ IRI ยังพัฒนาแบบจำลองเฉพาะภารกิจขึ้น เช่น แบบจำลองอุณหภูมิอิเล็กตรอน, แบบจำลององค์ประกอบไอออน และแบบจำลองความเร็วลอยเลื่อนของไอออน (Ion Drift)

ข้อจำกัดของแบบจำลองอิมพีริคัลเหล่านี้ในตอนนี้เป็นอยู่ภายใต้สภาวะไม่เกิดปรากฏการณ์แสงเอกซอสเฟียร์เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เหนือแสงใต้ และสภาพทางแม่เหล็กไฟฟ้าไม่ถูกรบกวน จึงทำให้เกิดความพยายามจากนักวิจัย เพื่อหาการพยากรณ์ในเรื่องชั้นบรรยากาศไอโอโนสเฟียร์โดยอยู่เหนือข้อจำกัดดังกล่าว ซึ่งขณะนี้ National Space Science Data Center (NSSDC) กำลังทดลอง ปรับปรุงใช้เทคนิคการบันทึก และการสเกลแบบต่าง ๆ อยู่ โดยข้อมูลที่เกี่ยวข้องกับแบบจำลองของชั้นบรรยากาศไอโอโนสเฟียร์ ได้เผยแพร่ในรูปแบบ online ทำให้สะดวกในการใช้งาน

5.2 การคำนวณปริมาณอิเล็กตรอน TEC จากแบบจำลอง IRI

เมื่อเราเข้าไปใช้งานโปรแกรมแบบจำลอง IRI เราสามารถป้อนค่าอินพุตต่าง ๆ ที่ตามต้องการ ได้ เช่น วันที่, เวลา, จำนวนจุดดับของดวงอาทิตย์เฉลี่ย (R_{12}), ความสูงเหนือพื้นโลก พิกัดสถานที่ทางภูมิศาสตร์ซึ่งประกอบด้วยเส้นละติจูดและเส้นลองจิจูด หรือ พิกัดสถานที่ทางแม่เหล็กซึ่งประกอบด้วยเส้นละติจูดแม่เหล็กและเส้นลองจิจูดแม่เหล็ก โดยต้องกำหนดให้มีค่าพารามิเตอร์ตัวหนึ่งสามารถเปลี่ยนค่าได้ โดยในการทดลองจะใช้ค่าความสูงเหนือพื้นโลกเป็นค่าที่เปลี่ยนแปลงไป เพื่อใช้ในการอินทิเกรตหาค่าปริมาณอิเล็กตรอน TEC จากค่าความหนาแน่นอิเล็กตรอนได้ โดยจะใช้ช่วงความสูง 60 – 2,000 กิโลเมตร โดยต้องป้อนค่า 60 กิโลเมตรเป็นค่าเริ่มต้น และป้อนค่า 2,000 กิโลเมตรเป็นค่าสิ้นสุดที่ใช้ในการคำนวณ ค่าความห่างในการคำนวณจะใช้ความสูงทุก ๆ ช่วง 50 กิโลเมตรเพื่อความสะดวกในการอินทิเกรต และใช้ค่าตัวแปรแบบจำลองต่าง ๆ ตามการตั้งค่าเริ่มต้นของแบบจำลอง IRI เช่น แบบจำลอง URSI ใช้ในการหาค่าความหนาแน่น F2 Peak (N_mF_2), แบบจำลอง CCIR ใช้สำหรับหาค่าความสูง F2 Peak (h_mF_2), แบบจำลอง B0 ใช้ในการหาค่าความหนาแน่นของด้านล่างชั้นบรรยากาศ, แบบจำลอง Danilov ใช้ในการหาค่าองค์ประกอบของไอออน ในการวิเคราะห์หาค่าปริมาณอิเล็กตรอน TEC ของกรุงเทพ ในวันที่ 7 กรกฎาคม 2543 เวลา 14.00 น. จุดดับของดวงอาทิตย์ (R_z12) มีค่า 119.5 ผลการคำนวณจากแบบจำลอง IRI-2001 แสดงได้ดังต่อไปนี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

NSSDC

International Reference Ionosphere (IRI-2001) Model

You submitted the following name/value pairs:

DATE: year =2000. month=07 day=7

TIME: hour=14.LT

Geographical latitude = 13.7

Geographical longitude = 100.8

height = 60.

start_height = 60.

stop_height = 2000.

step = 50.

รูปที่ 5.1 แสดงค่าพารามิเตอร์ไอออโนสเฟียร์ที่เราใช้ในแบบจำลอง IRI คำนวณค่าที่กรุงเทพฯ วันที่ 7 กรกฎาคม 2543

Results of MODEL calculations:

URSI maps are used for the F2 peak density (NmF2)

CCIR maps are used for the F2 peak height (hmF2)

B0-Table option is used for the bottomside thickness parameter B0

Danilov- option is used for the ion composition

The foF2 STORM model is turned on

Scotto-97 no L option is used for the F1 occurrence probability

Peak Densities/cm-3: NmF2=1457831.0 NmF1= 0.0 NmE= 184988.4

Peak Heights/km: hmF2= 449.82 hmF1= 0.00 hmE= 110.00

Solar Zenith Angle/degree 28.6

Dip (Magnetic Inclination)/degree 9.50

Modip (Modified Dip)/degree 9.55

Solar Sunspot Number (12-months running mean) Rz12 119.5


Ionospheric-Effective Solar Index IG12 142.2

รูปที่ 5.2 แสดงผลการคำนวณจากแบบจำลอง IRI

ตารางที่ 5.1 แสดงค่าความหนาแน่นอิเล็กตรอนและองค์ประกอบของไอออนที่ความสูงต่าง ๆ

H	ELECTRON DENSITY	TEMPERATURES	ION PERCENTAGES/%										1E16m-2
km	Ne/cm3	Ne/NmF2	Tn/K	Ti/K	Te/K	O+	N+	H+	He+	O2+	NO+	Clust	
60.0	-1	-1.000	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	
110.0	184988	0.127	-1	-1	-1	0	0	0	0	38	62	0	
160.0	214454	0.147	876	876	954	15	0	0	0	28	57	0	
210.0	265233	0.182	1091	1091	1643	66	0	0	0	8	26	0	
260.0	425338	0.292	1160	1160	2279	98	0	0	0	1	1	0	
310.0	729311	0.500	1183	1183	1183	98	2	0	0	0	0	0	
360.0	1082472	0.743	1191	1191	1191	98	2	0	0	0	0	0	
410.0	1370033	0.940	1193	1193	1199	98	2	0	0	0	0	0	
460.0	1456860	0.999	1194	1194	1272	98	2	0	0	0	0	0	
510.0	1206245	0.827	1194	1194	1346	98	2	0	0	0	0	0	
560.0	836336	0.574	1195	1332	1421	97	2	1	0	0	0	0	
610.0	561718	0.385	1195	1477	1498	96	2	2	1	0	0	0	
660.0	396539	0.272	1195	1580	1580	94	1	3	2	0	0	0	
710.0	302410	0.207	1195	1664	1664	91	1	5	3	0	0	0	
760.0	248455	0.170	1195	1747	1747	86	1	9	5	0	0	0	
810.0	216796	0.149	1195	1830	1830	78	1	14	7	0	0	0	
860.0	197771	0.136	1195	1914	1914	68	0	21	10	0	0	0	
910.0	186124	0.128	1195	1997	1997	56	0	31	13	0	0	0	
960.0	178899	0.123	1195	2081	2081	44	0	41	15	0	0	0	
1010.0	174379	0.120	1195	2164	2164	32	0	52	16	0	0	0	
1060.0	171539	0.118	1195	2248	2248	23	0	62	15	0	0	0	
1110.0	169745	0.116	1195	2331	2331	16	0	71	14	0	0	0	
1160.0	168615	0.116	1195	2415	2415	11	0	78	12	0	0	0	
1210.0	167903	0.115	1195	2498	2498	7	0	83	10	0	0	0	
1260.0	167452	0.115	1195	2582	2582	6	0	84	10	0	0	0	
1310.0	167168	0.115	1195	2665	2665	4	0	85	10	0	0	0	
1360.0	166987	0.115	1195	2746	2746	3	0	86	11	0	0	0	
1410.0	166874	0.114	1195	2816	2816	3	0	87	11	0	0	0	
1460.0	166803	0.114	1195	2866	2866	2	0	87	11	0	0	0	
1510.0	166759	0.114	1195	2910	2910	1	0	88	11	0	0	0	
1560.0	166732	0.114	1195	2953	2953	1	0	88	11	0	0	0	
1610.0	166714	0.114	1195	2995	2995	1	0	88	11	0	0	0	
1660.0	166703	0.114	1195	3038	3038	1	0	89	11	0	0	0	
1710.0	166697	0.114	1195	3081	3081	0	0	89	11	0	0	0	
1760.0	166691	0.114	1195	3124	3124	0	0	89	11	0	0	0	
1810.0	166692	0.114	1195	3167	3167	0	0	89	11	0	0	0	
1860.0	166687	0.114	1195	3210	3210	0	0	89	11	0	0	0	
1910.0	166687	0.114	1195	3253	3253	0	0	89	11	0	0	0	
1960.0	166687	0.114	1195	3296	3296	0	0	89	11	0	0	0	

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 5.3 แสดงภาพวาดอธิบายคำจำกัดความของ TEC

จากตารางที่ 5.1 ความหนาแน่นอิเล็กตรอนอยู่ในหน่วย อิเล็กตรอนต่อลูกบาศก์เซนติเมตร (Ne/cm^3) ต้องการทำให้อยู่ในหน่วยอิเล็กตรอนต่อลูกบาศก์เมตรทำได้โดยการคูณ 10^6 จากนั้นทำการอินทิเกรตรวมค่าความหนาแน่นอิเล็กตรอนตั้งแต่ความสูง 60 – 2,000 กิโลเมตร โดยมีช่วงความสูง dS เป็น 50 กิโลเมตร เมื่อรวมค่าในรูปที่ 5.3 พบว่าความหนาแน่นอิเล็กตรอนรวมมีค่าเท่ากับ $13,414,490 \times 10^6 \text{ el}/\text{m}^3$ ถ้าต้องการหาค่าปริมาณอิเล็กตรอน TEC ทำได้โดยการคูณ $dS = 50$ กิโลเมตรเข้าไป เขียนเป็นสมการคำนวณได้ดังนี้

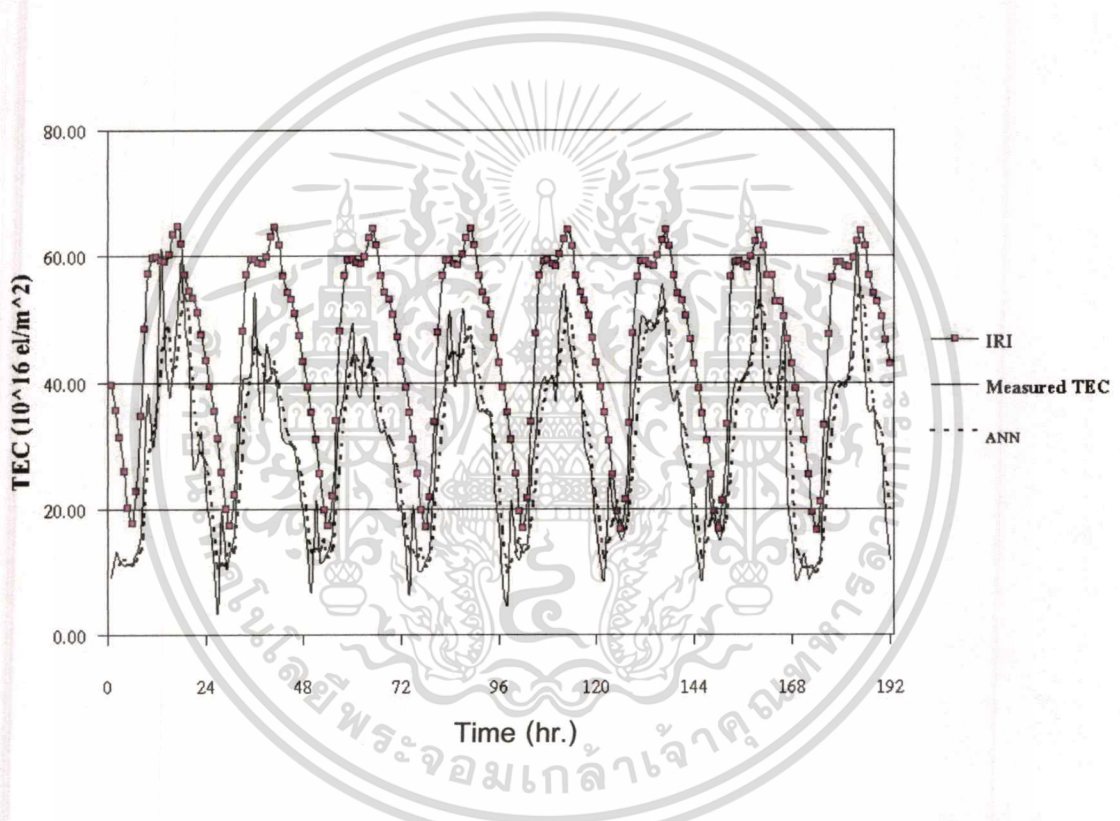
$$\text{TEC} = 13.414 \times 10^{12} \times 50 \times 10^3 = 670.7 \times 10^{15} \quad \text{el}/\text{m}^2 \quad (5.1)$$

ข้อจำกัดของค่าช่วงความสูงคือต้องไม่ทำให้เกิดช่วงการคำนวณเกิน 100 ค่า ถ้าใช้ dS ช่วงความสูงเท่ากับ 20 กิโลเมตร สำหรับความสูงที่ 60 – 2,000 กิโลเมตรแล้ว ค่าปริมาณอิเล็กตรอน TEC ที่คำนวณได้จะเท่ากับ $673.298 \times 10^{15} \text{ el}/\text{m}^2$ ซึ่งมีความคลาดเคลื่อนไปจากค่าที่เราใช้ช่วงความสูง dS เท่ากับ 50 กิโลเมตร เพียง 0.492 % เท่านั้น ดังนั้นเราสามารถใช้ช่วงความสูง 50 กิโลเมตรในการคำนวณแบบจำลอง IRI ได้ ซึ่งทำให้สะดวกและใช้เวลาคำนวณไม่นาน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

5.3 ผลการทดลองหาค่าความผิดพลาดของแบบจำลอง IRI กับแบบจำลอง ปริมาณอิเล็กตรอนในชั้นบรรยากาศไอโอโนสเฟียร์โดยเทคนิคโครงข่ายประสาท

เมื่อเราทำการเปรียบเทียบหาแตกต่างของค่าความผิดพลาดของแบบจำลอง IRI กับปริมาณอิเล็กตรอนโดยเทคนิคโครงข่ายประสาทที่เราสร้างขึ้นมาจากข้อมูลที่ใช้ฝึกจากค่าที่เก็บรวบรวมตลอดระยะเวลา 3 ปี ตั้งแต่ มกราคม 2541 – ธันวาคม 2543 พบว่าค่าความผิดพลาดที่ได้ในการทำนายค่าปริมาณอิเล็กตรอนในอีก 1 ชั่วโมงข้างหน้าของวันที่ 21–28 มกราคม 2544 ของกรุงเทพฯ แสดงได้ดังรูปภาพที่ 5.4

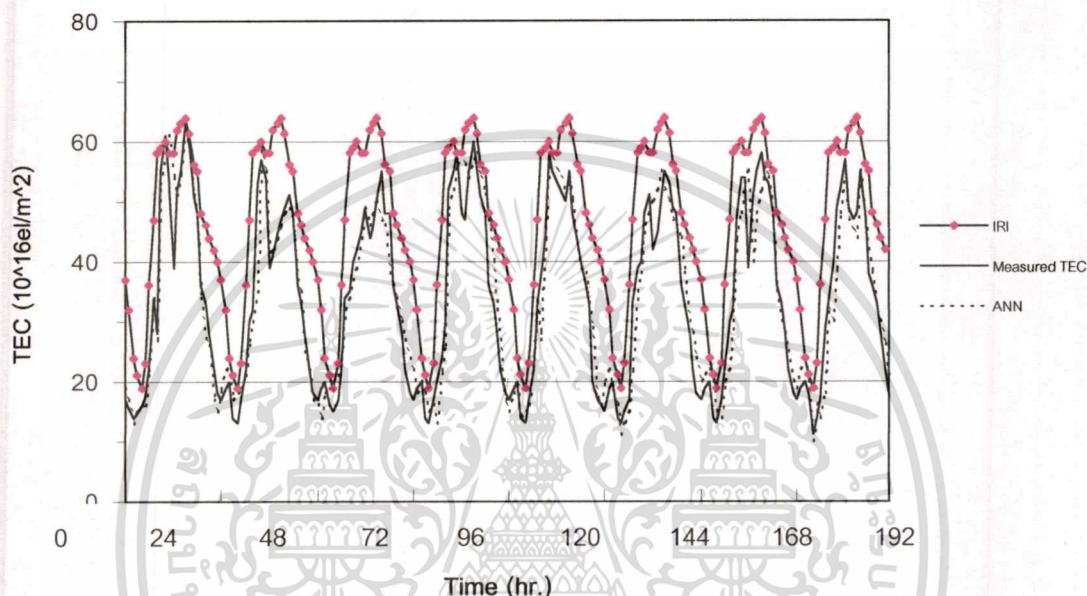


รูปที่ 5.4 แสดงผลการทดลองเปรียบเทียบค่าความผิดพลาดของแบบจำลอง IRI กับแบบจำลอง ปริมาณอิเล็กตรอนในชั้นบรรยากาศไอโอโนสเฟียร์โดยเทคนิคโครงข่ายประสาท ในระหว่างวันที่ 21–28 มกราคม 2544

จากผลการทดลองพบว่าค่าความผิดพลาดของแบบจำลอง IRI มีค่าคลาดเคลื่อนไปมากกว่าค่าที่ได้จากการทำนายจากแบบจำลองที่สร้างขึ้นมาจากเทคนิคโครงข่ายประสาทโดยมีค่า 14.46% ในช่วงการพยากรณ์อย่างต่อเนื่องเป็นเวลาถึง 192 ชั่วโมง หรือ 8 วัน ในระหว่างวันที่ 21–28 มกราคม 2544 เมื่อเปรียบเทียบกับค่าความผิดพลาดของแบบจำลองที่สร้างขึ้นมาพบว่ามี

ค่าความผิดพลาด 2.25% ดังนั้นจะเห็นได้ว่าแบบจำลองที่สร้างขึ้นสามารถทำนายค่าได้แม่นยำกว่าถึง 12.21%

ค่าความผิดพลาดที่ได้ในการทำนายค่าปริมาณอิเล็กตรอนในอีก 1 ชั่วโมงข้างหน้าของวันที่ 15 – 22 กุมภาพันธ์ 2544 ของกรุงเทพ แสดงได้ดังรูปภาพที่ 5.5



รูปที่ 5.5 แสดงผลการทดลองเปรียบเทียบค่าความผิดพลาดของแบบจำลอง IRI กับแบบจำลองปริมาณอิเล็กตรอนในชั้นบรรยากาศไอโอโนสเฟียร์โดยเทคนิคโครงข่ายประสาท ในระหว่างวันที่ 15 – 22 กุมภาพันธ์ 2544

จากผลการทดลองพบว่าค่าความผิดพลาดของแบบจำลอง IRI มีค่าคลาดเคลื่อนไปมากกว่าค่าที่ได้จากการทำนายจากแบบจำลองที่สร้างขึ้นมาจากเทคนิคโครงข่ายประสาทโดยมีค่า 15.47% ในช่วงการพยากรณ์อย่างต่อเนื่องเป็นเวลาถึง 192 ชั่วโมง หรือ 8 วัน ในระหว่างวันที่ 15–22 กุมภาพันธ์ 2544 เมื่อเปรียบเทียบกับค่าความผิดพลาดของแบบจำลองที่สร้างขึ้นมาพบว่ามีค่าความผิดพลาด 2.35% ดังนั้นจะเห็นได้ว่าแบบจำลองที่สร้างขึ้นสามารถทำนายค่าได้แม่นยำกว่าถึง 13.12%

บทที่ 6

สรุปผลการวิจัยและข้อเสนอแนะ

เมื่อทำการศึกษาปริมาณอิเล็กทรอนิกส์ในชั้นบรรยากาศไอโอโนสเฟียร์ (TEC) ในเรื่องความสัมพันธ์ระหว่างจุดดับของดวงอาทิตย์ (SSN) และดัชนีสนามแม่เหล็กโลก (ap) เราไม่สามารถจะทราบความสัมพันธ์แนวโน้มนการเปลี่ยนแปลงได้อย่างแน่ชัดได้ เนื่องจากการคำนวณหาค่าสัมประสิทธิ์สหสัมพันธ์ที่ได้ค่อนข้างที่จะต่ำ ดังนั้นจึงมีความสัมพันธ์กันในระดับต่ำ แต่มีทฤษฎีหลักฐานอย่างอื่นประกอบว่าการเปลี่ยนแปลงปริมาณอิเล็กทรอนิกส์ขึ้นกับปัจจัยทั้งสอง ทำให้เราไม่อาจที่จะตัดประเด็นความสำคัญทั้งสองนี้ออกไปได้จากการพิจารณา ซึ่งความสามารถของมนุษย์ไม่เพียงพอที่จะบอกแนวโน้มความสัมพันธ์ได้ ทำให้เราจำเป็นต้องพึ่งเทคนิคทางคณิตศาสตร์ที่สูงกว่านั้น ซึ่งในงานวิจัยนี้เลือกที่จะใช้เทคนิคโครงข่ายประสาท ทั้งนี้ก็เนื่องมาจากจุดเด่นในเรื่องความสามารถในการทำงานได้โดยประสบการณ์ที่ผ่านมา ซึ่งเราจะทำการฝึกโครงข่ายประสาทได้จากชุดข้อมูลค่าปริมาณอิเล็กทรอนิกส์ที่เก็บรวบรวมไว้อย่างต่อเนื่อง ในการสร้างโครงข่ายประสาทจะกำหนดให้มีอัลกอริทึมเป็นแบบ Backpropagation โดยให้โปรแกรม MATLAB ที่มี NNT Toolbox ทำให้ง่ายในการใช้งาน โดยอาจจะไม่ต้องเสียเวลาพิมพ์คำสั่งที่ยาวเหมือนกับแต่ก่อน ซึ่งจะเห็นว่าเป็นวิธีที่ง่ายไม่มีความซับซ้อนมาก โดยเราจะต้องเปลี่ยนค่าคุณลักษณะต่าง ๆ ของโครงข่ายแล้วทำการฝึกด้วยพารามิเตอร์การฝึกไปจนกว่าจะได้ Performance Index ที่น้อยที่สุด ซึ่งในที่นี้เราใช้ค่าเป็น "mse" ค่า mse ที่ได้จะแสดงให้เห็นถึงประสิทธิภาพของโครงข่ายที่สร้างขึ้นว่ามีประสิทธิภาพสูงหรือต่ำเมื่อนำไปใช้เป็นแบบจำลองปริมาณอิเล็กทรอนิกส์

เพื่อให้แน่ใจว่าแบบจำลองปริมาณอิเล็กทรอนิกส์โดยเทคนิคโครงข่ายประสาทที่สร้างขึ้นมีความผิดพลาดไปจากแบบจำลองมาตรฐาน IRI - 2001 มากน้อยเท่าใด เราสามารถที่จะทำการตรวจสอบค่าความผิดพลาดได้ โดยผลการทดลองที่ได้พบว่าค่าความผิดพลาดของแบบจำลอง IRI มีค่าคลาดเคลื่อนไปมากกว่าค่าที่ได้จากการทำนายจากแบบจำลองที่สร้างขึ้นมาจากเทคนิคโครงข่ายประสาทโดยมีค่า 14.46 % ในช่วงการพยากรณ์อย่างต่อเนื่องเป็นเวลาถึง 192 ชั่วโมง หรือ 8 วัน ในระหว่างวันที่ 21 - 28 มกราคม 2544 เมื่อเปรียบเทียบกับค่าความผิดพลาดของแบบจำลองที่สร้างขึ้นมาพบว่ามีค่าความผิดพลาด 2.25 % ดังนั้นจะเห็นได้ว่าแบบจำลองเทคนิคโครงข่ายประสาทสามารถทำนายค่าได้แม่นยำกว่าถึง 12.21 % และผลการทดลองพบว่าค่าความผิดพลาดของแบบจำลอง IRI มีค่าคลาดเคลื่อนไปมากกว่าค่าที่ได้จากการทำนายจากแบบจำลองที่สร้างขึ้นมาจากเทคนิคโครงข่ายประสาทโดยมีค่า 15.47 % ในช่วงการพยากรณ์อย่างต่อเนื่องเป็นเวลาถึง 192 ชั่วโมง หรือ 8 วัน ในระหว่างวันที่ 15 - 22 กุมภาพันธ์ 2544 เมื่อเปรียบเทียบกับค่า

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ความผิดพลาดของแบบจำลองที่สร้างขึ้นมาพบว่ามีค่าความผิดพลาด 2.35 % ดังนั้นจะเห็นได้ว่าแบบจำลองที่สร้างขึ้นสามารถทำนายค่าได้แม่นยำกว่าถึง 13.12 %

ในการศึกษาการสร้างแบบจำลองปริมาณอิเล็กทรอนิกส์ตรอนโดยโครงข่ายประสาทมีจุดด้อยของแบบจำลองอิเล็กทรอนิกส์ตรอนโดยโครงข่ายประสาทในเรื่องการควบคุมการทำงานค่อนข้างที่จะลำบาก และการใช้เวลาในการฝึกโครงข่ายประสาทในแต่ละครั้งก็ใช้เวลานานครั้งละหลายชั่วโมง แต่ถึงอย่างไรก็ตามจากผลการทดลองที่ได้สนับสนุนสมมติฐานการทดลองว่าแบบจำลองปริมาณอิเล็กทรอนิกส์ตรอนโดยโครงข่ายประสาทเป็นทางเลือกอีกทางหนึ่งที่สามารถนำมาใช้ในการทำนายค่าในอนาคตได้อย่างมีประสิทธิภาพ



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หนังสืออ้างอิง

- [1] J.E. Allnutt, **Satellite to ground radiowave propagation**, London : Peter Peregrinus. 1990.
- [2] IRI. "International Reference Ionosphere." [Online]. Available <http://nssdc.gsfc.nasa.gov/space/model/models/iri.html>. 2003.
- [3] J.J. Hopfield. 1982. "Neural networks and physical systems with emergent collective computational abilities," **Proceedings of the National Academy of Sciences**. (79) : 2554-2558.
- [4] Martin T. Hagan, H., et.al. **Neural Network Design**. Boston : PWS. 1995.
- [5] Mathworks. **Neural Network Toolbox in MATHLAB**. Boston : PWS. 1994.
- [6] M.P.M. Hall, L.W., et.al. **Propagation of Radiowave**. London : Short Run. 1996.
- [7] D. Kenneth. **Ionospheric Radio**. London : Peter Penetrinus. 1989.
- [8] Nihon Tsushinki. **Model 7633 Realtime TECMETER Operation Manual**.
- [9] B. Hofmann-Wellenhof, H., et. al. **Global Positioning System**. 3. New York : Springer- Verlag Wien. 1994.
- [10] Igarashi, K., et.al. "GPS Observations of Ionospheric Total Electron Content and Scintillation in the Equatorial Zone as part of PARTNERS Project." **International Beacon Satellite Symposium**, United Kingdom, July 1994.
- [11] อรอนงค์ เพชรนิ่ม. "การศึกษาการเปลี่ยนแปลงปริมาณอิเล็กตรอนในชั้นบรรยากาศไอโอโนสเฟียร์บริเวณใกล้เส้นศูนย์สูตรที่มีผลกระทบต่อสัญญาณดาวเทียม." **วิทยานิพนธ์ วิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมไฟฟ้า บัณฑิตวิทยาลัย, สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง**. 2542.
- [12] ทรงศิริ แต้สมบัติ. **การวิเคราะห์การถดถอย**. พิมพ์ครั้งที่ 2. กรุงเทพฯ : มหาวิทยาลัยเกษตรศาสตร์. 2542.
- [13] K. Bilitza. "Sunspot Number." [Online]. Available : <http://www.ngdc.noaa.gov/stp/SOLAR/SSN/ssn.html>. 1995.
- [14] NOAA. "EVA Mission." [Online]. Available : <http://www.sec.noaa.gov>. 1998.
- [15] Spaceweather. "Sunspot Number Archive." [Online]. <http://www.spaceweather.com/java/archive.html>. 2000.

- [16] Kyoto University. "Geomagnetic Index." [Online]. <http://swdcdb.kugi.kyoto-u.ac.jp/ap/index.html>. 1996.
- [17] N. Balan and P.B. Rao. "Latitudinal Variations of Nighttime Enhancements in Total Electron Content." *Journal of Geophysical research*, vol. 92, no. 1, April 1987. pp. 3436-3440.
- [18] A.K. Rigler, J.K, et.al. "Variables in back propagation learning," *Neural Networks*, vol. 3, no. 5, 1990, pp. 561-573.
- [19] Krittaya Nakprasit and Narong Hemmakorn. "The predictability of vertical TEC using Artificial neural networks on Bangkok." *International Symposium on Communications and Information Technology (ISCIT 2001)*, vol. 1, Nov. 2001. pp. 654-657.
- [20] J. Cander, S.S. , et.al. "Dynamic ionospheric prediction by neural networks." *Proc. Artificial Intelligence Applications in Solar-terrestrial Physics*, 1998. (accepted for publication)
- [21] Klobuchar and John A. "Ionospheric Time-Delay Algorithm for Single-frequency GPS Users." *IEEE Transactions on Aerospace and Electronics Systems*, vol. AES - 23, no. 3, May 1987, pp. 325-331.
- [22] กาญจน์ เหล่าพิพัฒน์. "การศึกษาปริมาณอิเล็กตรอนในชั้นบรรยากาศโดยใช้ดาวเทียม GPS." *วิทยานิพนธ์วิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมไฟฟ้า บัณฑิตวิทยาลัย, สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง*. 2542.
- [23] Killeen, T.L., et. al. "On the relationship between dynamics of the polar thermosphere and morphology of the aurora." *Journal Geophysics research*, vol 93, 1988, pp. 2675.
- [24] NOAA. "GPS derived TEC." [Online]. <http://noaa.gov/NOAA-NOS-NGS-GRD-TEC-page.html>. 2000.
- [25] K.M. Hornik, M. , et.al. "Multilayer feedforward networks are universal approximators." *Neural Networks*, vol. 2, no. 5, 1989, pp. 359-366.
- [26] D.E. Rumelhart, G.E., et.al. "Learning representations by back-propagating errors." *Nature*, Vol. 323, 1986, pp. 533-536.



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภาคผนวก ก.

ทรานสเฟอ์ฟังก์ชันชนิดต่าง ๆ

Transfer Functions

Name	Input/Output Relation	Icon	MATLAB Function
Hard Limit	$a = 0 \quad n < 0$ $a = 1 \quad n \geq 0$		hardlim
Symmetrical Hard Limit	$a = -1 \quad n < 0$ $a = +1 \quad n \geq 0$		hardlims
Linear	$a = n$		purelin
Saturating Linear	$a = 0 \quad n < 0$ $a = n \quad 0 \leq n \leq 1$ $a = 1 \quad n > 1$		satlin
Symmetric Saturating Linear	$a = -1 \quad n < -1$ $a = n \quad -1 \leq n \leq 1$ $a = 1 \quad n > 1$		satlins
Log-Sigmoid	$a = \frac{1}{1 + e^{-n}}$		logsig
Hyperbolic Tangent Sigmoid	$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$		tansig
Positive Linear	$a = 0 \quad n < 0$ $a = n \quad 0 \leq n$		poslin
Competitive	$a = 1$ neuron with max n $a = 0$ all other neurons		compet

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภาคผนวก ข.

การแปลงค่าปริมาณอิเล็กตรอนเป็นค่าความหนาแน่น อิเล็กตรอน

การแปลงค่าปริมาณอิเล็กตรอน (Total Electron Content :TEC) ในหน่วยอิเล็กตรอนต่อตารางเมตร (el/m^2) ไปเป็นค่าความหนาแน่นอิเล็กตรอนในหน่วยอิเล็กตรอนต่อลูกบาศก์เมตร (el/m^3) ทำได้ดังนี้

ในกรณีค่าปริมาณอิเล็กตรอน (TEC) ตลอดเส้นทางการเดินทางของคลื่นสัญญาณ ดาวเทียมถึงสถานีรับภาคพื้นดินมีค่าประมาณ 60×10^{16} (el/m^2) เมื่อต้องการทราบค่าความหนาแน่นอิเล็กตรอนที่ระดับความสูงของการวางตัวของชั้นบรรยากาศไอโอโนสเฟียร์ที่ความสูงประมาณ $60-2000 \times 10^3$ เมตร หรือมีค่าผลต่างของความสูง = $1,940 \times 10^3$ เมตร

ดังนั้นสามารถคำนวณค่าความหนาแน่นอิเล็กตรอนที่ค่าเฉลี่ย ณ ความสูงใด ๆ ในชั้นบรรยากาศไอโอโนสเฟียร์ได้เป็น

$$\frac{60 \times 10^{16} (el/m^2)}{1940 \times 10^3 (m)} = 3.09 \times 10^{11} (el/m^3)$$

ภาคผนวก ค.

โปรแกรม combine_data.py

โปรแกรมนี้ใช้สำหรับการแปลงข้อมูลในไฟล์เอกเซล (.xls) มาอยู่ในรูปข้อมูลชนิดสตริง แล้วจึงแปลงจากข้อมูลสตริงให้อยู่ในรูปของเมทริกซ์เพื่อที่จะสามารถเป็นข้อมูลที่ให้กับ Neural Network Toolbox ได้ เขียนขึ้นมาจากภาษา Python

โปรแกรมนี้ทำงานต่อจากโปรแกรมย่อย 4 โปรแกรม คือ

1. โปรแกรม addtime.py ทำหน้าที่แปลงข้อมูลในไฟล์เอกเซล (.xls) มาอยู่ในรูปข้อมูลสตริงไฟล์เท็กซ์ alltime.all

```
import string
import sys
lines = sys.__stdin__.readlines()
count = 0
for line in lines:
    print count%96,line.strip()
    count += 1
```

2. โปรแกรม kmitl.py ทำหน้าที่แปลงข้อมูลในไฟล์เอกเซล (.xls) มาอยู่ในรูปข้อมูลสตริงไฟล์เท็กซ์ kmitl.all

```
import string
import sys
lines = sys.__stdin__.readlines()
tmp = []
year = sys.argv[1]
for line in lines:
    tokens = line.strip().split()
    if lines.index(line) == 0:
        head = tokens[1:-2]
```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

elif len(tokens) > 0:
    tmp.append(tokens[1:-2])
if len(tmp[0]) != len(head):
    exit(1)
for i in range(len(tmp[0])):
    for t in tmp:
        if len(head[i]) == 3:
            print '%s%d%s %s' % (year,int(head[i][0]),head[i][1:],t[i])
        else:
            print '%s%d%s %s' % (year,int(head[i][0]),head[i][1:],t[i])

```

3. โปรแกรม avgtec.py ทำหน้าที่แปลงข้อมูลในไฟล์เอกเซล (.xls) มาอยู่ในรูปข้อมูลสตริง
ไฟล์เท็กซ์ avgtec.all

```

import string
import sys
lines = sys.__stdin__.readlines()
count = 0
for line in lines:
    print count,line.strip().split()[-1]
    count += 1

```

4. โปรแกรม ssn.py ทำหน้าที่แปลงข้อมูลในไฟล์เอกเซล (.xls) มาอยู่ในรูปข้อมูลสตริง
ไฟล์เท็กซ์ ssn.all

```

import string
import sys
lines = sys.__stdin__.readlines()
for line in lines:
    if lines.index(line) != 0:

```

```

        tokens = line.strip().split()

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

year = int(tokens[0])
day = int(tokens[1])
month = 1
for token in tokens[2:]:
    s_month = str(month)
    s_day = str(day)
    if month < 10:
        s_month = '0'+s_month
    if day < 10:
        s_day = '0'+s_day
    if int(token) != 0:
        print '%d%s%s %s' % (year,s_month,s_day,token)
    month += 1

```

โปรแกรม combine_data.py ทำหน้าที่รวบรวมข้อมูลเท็กซต์ให้อยู่ในรูปเมทริกซ์ โดยแต่ละชุดข้อมูลอินพุตที่เข้าสู่ Neural Network Toolbox ประกอบด้วย 10 ค่า

```

import string
import sys

lines = open('ssn.all.txt','r').readlines()
ssn = {}
for line in lines:
    tokens = line.strip().split()
    ssn[tokens[0]] = int(tokens[1])

lines = open('ap.all.txt','r').readlines()
ap = {}
for line in lines:
    tokens = line.strip().split()
    ap[tokens[0]] = int(tokens[1])

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

lines = open('avgtec.all.txt','r').readlines()
atec = {}
for line in lines:
    tokens = line.strip().split()
    atec[int(tokens[0])] = float(tokens[1])

```

```

lines = open('kmitl.all.txt','r').readlines()
tec = {}
count = 0
for line in lines:
    tokens = line.strip().split()
    tec[count] = tuple(tokens)
    count += 1

```

```

data0 = []
data1 = []
data2 = []
data3 = []
data4 = []
data5 = []
data6 = []
data7 = []
data8 = []
data9 = []

```

```

for i in range(count)[47:-1]:
    data = []
    output = float(tec[i+1][2])
    time, date, value = int(tec[i][0]),tec[i][1],float(tec[i][2])
    prev1_date, prev1_value = tec[i-1][1],float(tec[i-1][2])
    prev2_date, prev2_value = tec[i-23][1],float(tec[i-23][2])

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```
prev3_date, prev3_value = tec[i-47][1],float(tec[i-47][2])
```

```
check1 = value != 0 and ssn.has_key(date) and ssn[date] != 0 and ap.has_key
(date) and output != 0
```

```
check2 = prev1_value != 0 #and ssn.has_key(prev1_date) and ssn[prev1_date]
!= 0 and ap.has_key(prev1_date)
```

```
check3 = prev2_value != 0 #and ssn.has_key(prev2_date) and ssn[prev2_date]
!= 0 and ap.has_key(prev2_date)
```

```
check4 = prev3_value != 0 #and ssn.has_key(prev3_date) and ssn[prev3_date]
!= 0 and ap.has_key(prev3_date)
```

```
if check1 and check2 and check3 and check4:
```

```
data.append(value) # TEC(t)
```

```
data.append(atec[time]) # ATEC(t)
```

```
data.append(atec[(time-1)%96]) # ATEC(t-1)
```

```
data.append(atec[(time+1)%96]) # ATEC(t+1)
```

```
data.append(data[0]-data[1]) # DeltaTEC(t) = TEC(t) - ATEC(t)
```

```
data.append(prev1_value-data[2]) # DeltaTEC(t-1) = TEC(t-1) - ATEC(t-1)
```

```
data.append(prev2_value-data[3]) # DeltaTEC(t-23) = TEC(t-23) - ATEC(t+1)
```

```
data.append(prev3_value-data[3]) # DeltaTEC(t-47) = TEC(t-47) - ATEC(t+1)
```

```
data.append(ssn[date]) # SSN
```

```
data.append(ap[date]) # AP
```

```
data0.append(data[0])
```

```
data1.append(data[1])
```

```
data2.append(data[2])
```

```
data3.append(data[3])
```

```
data4.append(data[4])
```

```
data5.append(data[5])
```

```
data6.append(data[6])
```

```
data7.append(data[7])
```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```
data8.append(data[8])
```

```
data9.append(data[9])
```

```
for d in data0:
```

```
    print '%.2f' % (d),
```

```
print "
```

```
for d in data1:
```

```
    print '%.2f' % (d),
```

```
print "
```

```
for d in data2:
```

```
    print '%.2f' % (d),
```

```
print "
```

```
for d in data3:
```

```
    print '%.2f' % (d),
```

```
print "
```

```
for d in data4:
```

```
    print '%.2f' % (d),
```

```
print "
```

```
for d in data5:
```

```
    print '%.2f' % (d),
```

```
print "
```

```
for d in data6:
```

```
    print '%.2f' % (d),
```

```
print "
```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```
for d in data7:
```

```
    print '%.2f' % (d),
```

```
print "
```

```
for d in data8:
```

```
    print '%.2f' % (d),
```

```
print "
```

```
for d in data9:
```

```
    print '%.2f' % (d),
```

```
print "
```



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



International Reference Ionosphere - IRI

This page enables the computation of IRI parameters for user-selected profile. The available IRI parameters are electron, ion and neutral (CIRA-86) temperatures, electron and ion (O+, H+, He+, O2+, NO+) densities.

Height Profile

Year(1958 - 2006):

Note: If date is outside the Ap index range (1960-9/2002), then STROM model will be turned off.

Month: Day(1-31):

Time Hour of day (e.g. 1.5):

Coordinates

Latitude(deg., from -90. to 90.): Longitude(deg., from 0. to 360.):

Height(km, from 60. to 2000.): Start Stop Stepsize

Optional Input:

Sunspot number(Rz12) Ionospheric index(IG12)

Electron content: Upper boundary (km., from 50. - 2000.)

F peak model Bottomside Thickness Ion Composition

foF2 Storm model Topside Te D-Region Ne

F1 occurrence probability:

NmF2/cm-3 (1000.-100000000.) or foF2/MHz(2.-14.):

hmF2/km (100. - 1000.) or M(3000)F2(1.5 - 4.):

Profile Listing Profile Listing and Plotting

Submit Query

Reset

Latitude Profile

Year(1958-2006):

Note: If date is outside the Ap index range (1960-9/2002), then STROM model will be turned off.

Month: Day(1-31):

Time Hour of day (e.g. 1.5):

Coordinates Longitude(deg., from 0. to 360.):

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Height (km, from 60. to 2000.):

Note: Enter Height=0. to obtain peak heights and densities,
or Height= -1. to obtain bottomside/valley parameters and plasma frequencies.
or Height= -2. to obtain F-region equ. vert. ion drift and F1 occurrence parameters

Latitude (deg.,from -90.0 to 90.0): Start Stop Stepsize

Optional Input:

Sunspot number(Rz12) **Ionospheric index(IG12)**

Electron content: **Upper boundary** (km., from 50. - 2000.)

F peak model **Bottomside Thickness** **Ion Composition**

foF2 Storm model **Topside Te** **D-Region Ne**

F1 occurrence probability:

Profile Listing Profile Listing and Plotting

Submit Query

Reset

Longitude Profile

Year(1958-2006):

Note:If date is outside the Ap index range (1960-9/2002), then STROM model will be turned off.

Month: **Day(1-31):**

Time **Hour of day** (e.g. 1.5)

Coordinates **Latitude**(deg.,from -90. to 90.):

Height (km, from 60. to 2000.):

Note: Enter Height=0. to obtain peak heights and densities,
or Height= -1. to obtain bottomside/valley parameters and plasma frequencies.
or Height= -2. to obtain F-region equ. vert. ion drift and F1 occurrence parameters

Longitude(deg.,from 0.0 to 360.0): Start Stop Stepsize

Optional Input:

Sunspot number(Rz12) **Ionospheric index(IG12)**

Electron content: **Upper boundary** (km., from 50. - 2000.)

F peak model **Bottomside Thickness** **Ion Composition**

foF2 Storm model **Topside Te** **D-Region Ne**

F1 occurrence probability:

Profile Listing Profile Listing and Plotting

Submit Query

Reset

เอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Year Profile

Month: Day of month (1-31):

Time Hour of day (e.g. 1.5):

Coordinates

Latitude(deg.,from -90. to 90.): Longitude(deg.,from 0. to 360.):

Height(km, from 60. to 2000.):

Note: Enter Height=0. to obtain peak heights and densities,
or Height= -1. to obtain bottomside/valley parameters and plasma frequencies.
or Height= -2. to obtain F-region equ. vert. ion drift and F1 occurrence parameters

Year(1958-2006): Start Stop Stepsize

Note:If date is outside the Ap index range (1960-9/2002), then STROM model will be turned off.

Optional Input:

Sunspot number(Rz12) Ionospheric index(IG12)

Electron content: Upper boundary (km., from 50. - 2000.)

F peak model Bottomside Thickness Ion Composition

foF2 Storm model Topside Te D-Region Ne

F1 occurrence probability:

Profile Listing Profile Listing and Plotting

Submit Query

Reset

Monthly Profile

Year(1958-2006):

Note:If date is outside the Ap index range (1960-9/2002), then STROM model will be turned off.

Day(1-31): Time

Hour of day (e.g. 1.5): Coordinates

Latitude (deg.,from -90. to 90.): Longitude(deg.,from 0. to 360.):

Height (km,from 60. to 2000.):

Note: Enter Height=0. to obtain peak heights and densities,
or Height= -1. to obtain bottomside/valley parameters and plasma frequencies.
or Height= -2. to obtain F-region equ. vert. ion drift and F1 occurrence parameters

Month (1-12): Start Stop Stepsize

Optional Input:
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Sunspot number(Rz12) Ionospheric index(IG12)

Electron content: **Upper boundary** (km., from 50. - 2000.)

F peak model **Bottomside Thickness** **Ion Composition**

foF2 Storm model **Topside Te** **D-Region Ne**

F1 occurrence probability:

Profile Listing Profile Listing and Plotting

Submit Query

Reset

Day of Month Profile

Year(1958 - 2006):

Note: If date is outside the Ap index range (1960-9/2002), then STROM model will be turned off.

Month:

Time **Hour of day** (e.g. 1.5):

Coordinates

Latitude(deg., from -90. to 90.): **Longitude**(deg., from 0. to 360.):

Height(km, from 60. to 2000.):

Note: Enter Height=0. to obtain peak heights and densities,
or Height= -1. to obtain bottomside/valley parameters and plasma frequencies.
or Height= -2. to obtain F-region equ. vert. ion drift and F1 occurrence parameters

Day(1-31): Start Stop Stepsize:

Optional Input:

Sunspot number(Rz12) Ionospheric index(IG12)

Electron content: **Upper boundary** (km., from 50. - 2000.)

F peak model **Bottomside Thickness** **Ion Composition**

foF2 Storm model **Topside Te** **D-Region Ne**

F1 occurrence probability:

Profile Listing Profile Listing and Plotting

Submit Query

Reset

Day of year profile

Year(1958-2006):

Note: If date is outside the Ap index range (1960-9/2002), then STROM model will be

ไม่ทำงานใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งหากนำไปใช้

turned off.

Time Hour of day (e.g. 1.5):

Coordinates

Latitude(deg.,from -90. to 90.): Longitude(deg.,from 0. to 360.):

Height(km, from 60. to 2000.):

Note: Enter Height=0. to obtain peak heights and densities,
or Height= -1. to obtain bottomside/valley parameters and plasma frequencies.
or Height= -2. to obtain F-region equ. vert. ion drift and F1 occurrence parameters

Day(1-366): Start Stop Stepsize

Optional Input:

Sunspot number(Rz12) Ionospheric index(IG12)

Electron content: Upper boundary (km., from 50. - 2000.)

F peak model Bottomside Thickness Ion Composition

foF2 Storm model Topside Te D-Region Ne

F1 occurrence probability:

Profile Listing Profile Listing and Plotting

Submit Query

Reset

Hour Profile

Year(1958-2006):

Note:If date is outside the Ap index range (1960-9/2002), then STROM model will be turned off.

Month: Day(1-31):

Time Coordinates

Latitude(deg.,from -90. to 90.): Longitude(deg.,from 0. to 360.):

Height(km, from 60. to 2000.):

Note: Enter Height=0. to obtain peak heights and densities,
or Height= -1. to obtain bottomside/valley parameters and plasma frequencies.
or Height= -2. to obtain F-region equ. vert. ion drift and F1 occurrence parameters

Hour (e.g. 1.5): Start Stop Stepsize

Sunspot number(Rz12) Ionospheric index(IG12)

Electron content: Upper boundary (km., from 50. - 2000.)

F peak model Bottomside Thickness Ion Composition

foF2 Storm model Topside Te D-Region Ne

F1 occurrence probability:

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ของกรมการศึกษานานาชาติ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Profile Listing Profile Listing and Plotting

Submit Query

Reset

 [Go to NSSDC home page](#)

*If you have any questions/comments about this model available from NSSDC, contact:
Dr. Dieter Bilitza, E-mail: bilitza@mail630.gsfc.nasa.gov, National Space Science
Data Center, Mail Code 632, NASA/Goddard Space Flight Center, Greenbelt, MD 20771*



*If you have any questions/comments about WWW access to this model, contact:
Dr. Natalia Papitashvili, E-mail: natasha@mail630.gsfc.nasa.gov, National Space Science
Data Center, Mail Code 633, NASA/Goddard Space Flight Center, Greenbelt, MD 20771*

**NASA Official: J. H. King, king@nssdca.gsfc.nasa.gov
Last Updated: 6 February 2003, NEP**



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Neural Network Toolbox 4

for designing and simulating neural networks

The Neural Network Toolbox extends the MATLAB® computing environment to provide tools for the design, implementation, visualization, and simulation of neural networks. Neural networks are uniquely powerful tools in applications where formal analysis would be difficult or impossible, such as pattern recognition and nonlinear system identification and control. The Neural Network Toolbox provides comprehensive support for many proven network paradigms, as well as a graphical user interface that allows you to design and manage your networks. The toolbox's modular, open, and extensible design simplifies the creation of customized functions and networks.


Working with Neural Networks

Inspired by the biological nervous system, neural network technology is being used to solve a wide variety of complex scientific, engineering, and business problems. Commercial applications include investment portfolio trading, data mining, process control, noise suppression, data compression, and speech recognition. Neural networks are ideally suited for such problems because, like their biological counterparts, a neural network can learn, and therefore can be trained to find solutions, recognize patterns, classify data, and forecast events.

Unlike analytical approaches commonly used in fields such as statistics and control theory, neural networks require no explicit model and no limiting assumptions of normality or linearity. The behavior of a neural network is defined by the way its individual computing elements are connected and by the strength of those connections, or weights. The weights are automatically adjusted by training the network according to a specified learning rule until it properly performs the desired task.

KEY FEATURES

- Graphical user interface (GUI) for creating, training, and simulating your neural networks
- Support for the most commonly used supervised and unsupervised network architectures
- A comprehensive set of training and learning functions
- A suite of Simulink® blocks, as well as documentation and demonstrations of control-system applications
- Automatic generation of Simulink models from neural network objects
- Modular network representation, allowing an unlimited number of input sets, layers, and network interconnections
- Pre- and post-processing functions for improving network training and assessing network performance
- Routines for improving generalization
- Visualization functions for viewing network performance



This window displays portions of the neural network GUI. Dialogs and panes allow you to visualize your network (top), evaluate training results (bottom), and manage your networks (center).

Because neural networks require intensive matrix computations, MATLAB provides a natural framework for rapidly implementing neural networks and for studying their behavior and application.

Neural Network Toolbox GUI

This tool lets you import potentially large and complex data sets. The GUI also allows you to create, initialize, train, simulate, and manage your networks. Simple graphical representations allow you to visualize and understand network architecture.

Supported Network Architectures

Supervised Networks

Supervised neural networks are trained to produce desired outputs in response to example inputs, making them particularly well suited for modeling and controlling dynamic systems, classifying noisy data, and predicting future events. The Neural Network Toolbox supports the following supervised networks:

- **Feed-forward networks** have one-way connections from input to output layers. They are commonly used for prediction, pattern recognition, and nonlinear function fitting. Supported feed-forward networks include feed-forward backpropagation, cascade-forward backpropagation, feed-forward input-delay backpropagation, linear, and perceptron networks.
- **Radial basis networks** provide an alternative fast method for designing nonlinear feed-forward networks. Supported variations include generalized regression and probabilistic neural networks.
- **Recurrent networks** use feedback to recognize both spatial and temporal patterns. Supported recurrent networks include Elman and Hopfield.
- **Learning vector quantization (LVQ)** is a powerful method for classifying patterns that are not linearly separable. LVQ allows

Supported Training Functions

<code>trainb</code>	Batch training with weight and bias learning rules
<code>trainbfg</code>	BFGS quasi-Newton backpropagation
<code>trainbr</code>	Bayesian regularization
<code>trainc</code>	Cyclical order incremental update
<code>traincgb</code>	Powell-Beale conjugate gradient backpropagation
<code>traincgf</code>	Fletcher-Powell conjugate gradient backpropagation
<code>traincgp</code>	Polak-Ribiere conjugate gradient backpropagation
<code>traingd</code>	Gradient descent backpropagation
<code>traingda</code>	Gradient descent with adaptive learning rate (lr) backpropagation
<code>traingdm</code>	Gradient descent with momentum backpropagation
<code>traingdx</code>	Gradient descent with momentum & adaptive lr backpropagation
<code>trainlm</code>	Levenberg-Marquardt backpropagation
<code>trainoss</code>	One step secant backpropagation
<code>trainr</code>	Random order incremental update
<code>trainrnp</code>	Resilient backpropagation (Rprop)
<code>trains</code>	Sequential order incremental update
<code>trainscg</code>	Scaled conjugate gradient backpropagation

you to specify class boundaries and the granularity of classification.

Unsupervised Networks

Unsupervised neural networks are trained by letting the network continually adjust itself to new inputs. They find relationships within data as it is presented and can automatically define classification schemes. The Neural Network Toolbox supports two types of self-organizing unsupervised networks:

- **Competitive layers** recognize and group similar input vectors. By using these groups, the network automatically sorts the inputs into categories.

- **Self-organizing maps** learn to classify input vectors according to similarity. Unlike competitive layers, they also preserve the topology of the input vectors, assigning nearby inputs to nearby categories.

Supported Training and Learning Functions

Training and learning functions are mathematical procedures used to automatically adjust the network's weights and biases. The training function dictates a global algorithm that affects all the weights and biases of a given network. The learning function can be applied to individual weights and biases within a network.

Supported Learning Functions

learncon	Conscience bias learning function
learngd	Gradient descent weight/bias learning function
learnngdm	Gradient descent with momentum weight/bias learning function
learnh	Hebb weight learning function
learnhd	Hebb with decay weight learning rule
learnis	Instar weight learning function
learnk	Kohonen weight learning function
learnlv1	LVQ1 weight learning function
learnlv2	LVQ2 weight learning function
learnos	Outstar weight learning function
learnp	Perceptron weight and bias learning function
learnpn	Normalized perceptron weight and bias learning function
learnsom	Self-organizing map weight learning function
learnwh	Widrow-Hoff weight and bias learning rule


Control System Applications

Neural networks have been successfully applied to the identification and control of nonlinear systems. Included in the toolbox are descriptions, demonstrations, and Simulink blocks for three popular control applications: model predictive control, feedback linearization, and model reference adaptive control.

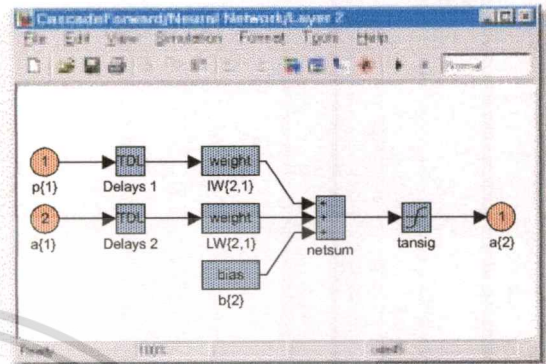
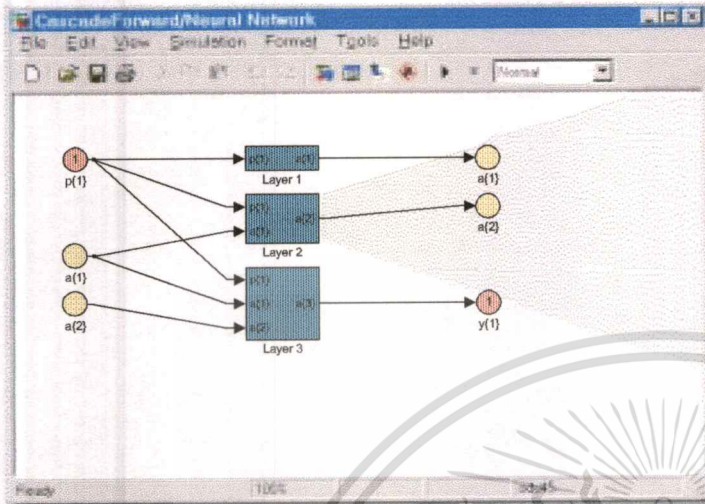
Model Predictive Control Example

The following example shows the model predictive control of a continuous stirred tank reactor (CSTR). This controller creates a neural network model of a nonlinear plant to predict future plant response to potential control signals. An optimization algorithm then computes the control signals that optimize future plant performance.

You can incorporate neural network control blocks included in the toolbox into your existing Simulink models. By changing the parameters of these blocks you can tailor the network's performance to your application.



This window displays a Simulink model that includes the neural network predictive control block and CSTR plant model (top left). Dialogs and panes allow you to visualize validation data (lower left) and manage the neural network control block (lower center) and your plant identification (right).



Neural network simulation blocks for use in Simulink can be automatically generated using the `gensim` command. Here, a three-layer neural network has been converted into Simulink blocks.

Simulink Support

Once a network has been created and trained, it can be easily incorporated into Simulink models. A simple command (`gensim`) automatically generates network simulation blocks for use with Simulink. This feature also makes it possible for you to view your networks graphically.

Pre- and Post-Processing Functions

Pre-processing the network inputs and targets improves the efficiency of neural network training. Post-processing enables detailed analysis of network performance. The Neural Network Toolbox provides the following pre- and post-processing functions:

- **Principal component analysis** reduces the dimensions of the input vectors.
- **Post-training analysis** performs a regression analysis between the network response and the corresponding targets.
- **Scale minimum and maximum** scales inputs and targets so that they fall in the range $[-1,1]$.
- **Scale mean and standard deviation** normalizes the mean and standard deviation of the training set.

Improving Generalization

Improving the network's ability to generalize helps prevent overfitting, a common problem in neural network design. Overfitting occurs when a network has memorized the training set but has not learned to generalize to new inputs. Overfitting produces a relatively small error on the training set but will produce a much larger error when new data is presented to the network.

The Neural Network Toolbox provides two solutions to improve generalization:

- **Regularization** modifies the network's performance function, the measure of error that the training process minimizes. By changing it to include the size of the weights and biases, training produces a network that not only performs well with the training data, but produces smoother behavior when presented with new data.
- **Early stopping** is a technique that uses two different data sets: the training set, which is used to update the weights and biases, and the validation set, which is used to stop training when the network begins to overfit the data.

Documentation and Examples

The *Neural Network Toolbox User's Guide* was written by Professor Emeritus Howard Demuth and Mark Beale, developers of the Neural Network Toolbox and authors, with Professor Martin Hagen, of *Neural Network Design*. The *User's Guide* is of textbook quality and provides a thorough treatment of neural network architectures, paradigms, and neural network applications. It also includes a tutorial and application examples. Additional demonstrations and application examples are included with the product.

For demos, application examples, tutorials, user stories, and pricing:

• Visit www.mathworks.com

• Contact The MathWorks directly

US & Canada 508-647-7000

Benelux +31 (0)182 53 76 44

France +33 (0)1 41 14 67 14

Germany +49 (0)89 995901 0

Spain +34 93 362 13 00

Switzerland +41 (0)31 954 20 20

UK +44 (0)1223 423 2000

Visit www.mathworks.com to obtain contact information for authorized MathWorks representatives in countries throughout Asia Pacific, Latin America, the Middle East, Africa, and the rest of Europe.



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

THE PREDICTABILITY OF VERTICAL TEC USING ARTIFICIAL NEURAL NETWORKS ON BANGKOK

Krittaya Nakprasit and Narong Hemmakorn

Faculty of Engineering and Research Center for
Communications and Information Technology
King Mongkut's Institute of Technology
Ladkrabang
3-2, Chalongkrung Road, Ladkrabang,
Bangkok, 10520, Thailand
Phone: +66-1-830-0084
Email: s2061031@kmitl.ac.th

Faculty of Engineering and Research Center for
Communications and Information Technology
King Mongkut's Institute of Technology
Ladkrabang
3-2, Chalongkrung Road, Ladkrabang, Bangkok,
10520, Thailand
Phone: +66-2-326-6100 Ext. 3345 or 3348,
Fax: +66-2-326-9086
Email: khnarong@kmitl.ac.th

ABSTRACT

Recently, there has been much interest in the use of artificial neural networks (ANNs) in ionospheric prediction models. This paper is divided into two parts. The first part presents the characteristics of long-term vertical TEC (ionospheric Total Electron Content) on equatorial station of Bangkok, Thailand. (KMITL: 13.7°N 100.8°E Geographical Lat&Long.; 2.8°N 171.9°E Magnetic Lat&Long.) during 1 January 1998 – 31 December 2000. It is further shown how much the nonionospheric geophysical parameters representing time, sunspot number, and magnetic index correlate to vertical TEC. In the second part, the TEC is forecast 1 hour in advance by using artificial neural networks. The input parameters used for the neural network are past observation of TEC, geomagnetic index (A_p), time, sunspot number (SSN), mean TEC, delta of TEC and delta of mean TEC. The performance of a neural network is measured by considering errors. For the errors to be more meaningful, training and test times and times for comparison with other results are selected from the same solar activity period. Among the various backpropagation structures of neural network, the best configuration is found to be the one layers with two hidden layer, giving relative errors of 4% while errors for the international reference ionosphere model (IRI-95) around 18%.

1. INTRODUCTION

A signal travelling between an earth station and a satellite must pass through the earth's atmosphere, including the ionosphere. The ionosphere is the upper region of the earth's atmosphere, which has been ionized mainly by solar radiation. The free electron in the ionosphere are not uniformly distributed but form in layers. Furthermore clouds of electrons (known as travelling ionospheric disturbances) may travel through the ionosphere and give rise to fluctuations in the signal that can only be determined on a

statistical basis. The effects include scintillation, absorption, variations in the direction of arrival, propagation delay, dispersion, frequency change, and polarization rotation. All of these effects decrease as frequency increases, most in inverse proportion to the frequency squared and only polarization rotation and the scintillation effects are of major concern for satellite communications [Ajayi *et al.*, 1996].




Fig. 1 Major ionospheric propagation effects on satellite – to – ground links

The modern measurement techniques for TEC are based on propagation effect observed on signals transmitted from the satellite to ground stations. In this experiment, the Differential Doppler Effect technique is used. The ionospheric total electron content (TEC) is a parameter of great importance for transionospheric radio waves propagation systems and for checking the validity of ionospheric model. The ionospheric corrections that have to be applied to determine the satellite position accurately are proportional to the TEC along the radar-satellite path. So for ionospheric corrections, TEC measurements are required, or TEC predictions from ionospheric models can be a useful tool [Ezquer *et al.*, 1994].

Dynamic ionospheric forecasting, for resource management of GPS navigation systems, requires accurate real-time mode and in hours-ahead

prediction. It was the non-linearity of this prediction problem which was the reason for application of an artificial neural network (ANN) method to find its solution.

2. METHOD

2.1 Ionospheric Total Electron Content

The model 7633A TECMETER is a receiver for continuously monitoring of all number of electrons in the path of the wave. It receives radio waves from GPS satellite, currently being operated by US Department of Defense. The GPS satellite emits two radio waves, L1 (1575.42 MHz) and L2 (1227.6 MHz). These two waves are "coherent" and are 154 times and 120 times standard frequencies of the GPS satellite. TECMETER measures propagation delay time difference among two P code, L1 and L2, by correlation between two signals.

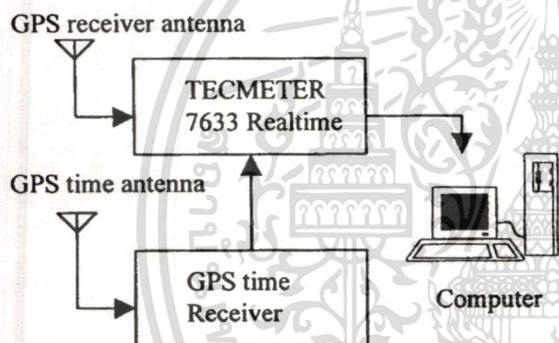


Fig. 2 Block diagram of TEC observation system

The GPS measurement method provide correctly TEC by principle of delay time of 2 different frequency signal.

$$\Delta T_d = 134 \times TEC \times \left[\frac{1}{(f_{L2})^2} - \frac{1}{(f_{L1})^2} \right] \text{ (ns.)} \quad (1)$$

$$TEC = \frac{\Delta T_d}{134} \left[\frac{(f_{L1})^2 (f_{L2})^2}{(f_{L1})^2 - (f_{L2})^2} \right] \text{ (el/m}^2\text{)} \quad (2)$$

$$\therefore TEC = 2.863 \times 10^{16} \times \Delta T_d \text{ (el/m}^2\text{)} \quad (3)$$

where $f_{L1} = 1,575.42$ MHz, $f_{L2} = 1,227.6$ MHz.

2.2 Neural network architecture

An artificial neural network is a structure of computing elements which allows easy integration of a priori knowledge, as well as having the ability to represent a complex dynamic system through training with data [Haykin, 1994].

We designed to apply multilayer network because it is more powerful than single-layer networks. Two-layer network having sigmoid first layer and linear second layer can be trained to approximate most functions arbitrarily well. Single-layer networks cannot do this.

The backpropagation algorithm for multilayer networks use the performance index: mean square error. The algorithm is provided with set of network behavior:

$$\{P_1, T_1\}, \{P_2, T_2\}, \dots, \{P_N, T_N\} \quad (4)$$

where P_N is an input to the network, and t_N is the corresponding target output. As each input is applied to the network, the network output is compared to the target. The algorithm should adjust the network parameters in order to minimize the mean square error [Cander et al., 1998].

Performance Index:

$$F(x) = E [e^T e] = E [(t-a)^T (t-a)] \quad (5)$$

Approximate Performance Index:

$$F'(x) = e^T(k) e(k) = (t(k) - a(k))^T (t(k) - a(k)) \quad (6)$$

Sensitivity:

$$s^m = \frac{\partial F'}{\partial n^m} \quad (7)$$

Forward propagation: for $m = 0, 2, \dots, M-1$

$$a^{m+1} = f^{m+1}(W^{m+1} a^m + b^{m+1}) \quad (8)$$

$$a = a^M \quad (9)$$

Backward propagation: for $m = M-1, \dots, 2, 1$

$$s^M = -2F'(n^M)(t-a) \quad (11)$$

$$s^m = F'(n^m) (W^{m+1})^T s^{m+1} \quad (12)$$

Weight Update (Approximate Steepest Descent):

$$W^m(k+1) = W^m(k) - \alpha s^m (a^{m-1})^T \quad (13)$$

$$b^m(k+1) = b^m(k) - \alpha s^m \quad (14)$$




Fig. 3 Schematic diagram of ANN




Fig. 4 Architecture of three-layer network in detail (First layer and Second layer are hidden layer ; Third layer is Output layer)

2.3 Input to Artificial Neural Networks

Since the difficulty of making accurate forecasts increases with increasing lead time, this neural network has been designed to have a short-term forecasting ability, in the order of an hour ahead. The functionality of the ANN varies considerably depending on its architecture and energy function. Fig. 3 shows a schematic diagram of the hybrid time-delay multi-layer perceptron neural network used with inputs as follows. $f(t)$: TEC at time t ; $Mf(t)$: mean TEC at time t ; $Mf(t-1)$: mean TEC at time $t-1$; $Mf(t-23)$: mean TEC at $t-23$; $Mf(t-47)$: mean TEC at $t-47$; $Mf(t+1)$: mean TEC at $t+1$; $\Delta f(t) = f(t) - M(t)$; $\Delta f(t-1) = f(t-1) - M(t-1)$; $\Delta f(t-23) = f(t-23) - M(t-23)$; $\Delta f(t-47) = f(t-47) - M(t)$; SSN: daily sunspot number and A_p : geomagnetic index. SSN and 3 hourly- A_p are internationally published indices while Mf values have been calculated using only the learning set of data to produce the background daily variations of TEC. There is one neural network output value, $f(t+1)$: predicted TEC values at $t+1$.

2.4 International Reference Ionosphere Model (IRI-95)

One of the most widely used empirical models is the IRI. The TEC value can be determined by integrate the topside electron density and the bottom side electron density in the ionosphere. The TEC variations used the CIRA (COSPAR International Reference Atmosphere) and URSI (International Union of Radio Science) coefficients, which included the solar activity indicated by smooth sunspot number (SSN). By input the location, time of day, the TEC value can be determined (for which the data are easily accessible from the internet) [Bilitza et al., 1995].

3. RESULTS

3.1 The correlation coefficient of variations v.s. TEC

Fig. 5 shows three-year TEC variations in each month that impacted by solar cycle. In analysis, we found the average correlation coefficient following:

- (1.) Yesterday TEC $f(t-24)$ v.s. today TEC $f(t)$ is 0.96
- (2.) 2 day before TEC $f(t-24)$ v.s. today TEC $f(t)$ is 0.95
- (3.) 3 hourly- A_p v.s. daily maximum TEC is 0.18
- (4.) 3 hourly- A_p v.s. daily minimum TEC is 0.13
- (5.) SSN v.s. daily maximum TEC is 0.37
- (6.) SSN v.s. daily minimum TEC is 0.07

3.2 The comparison between IRI and ANN

Fig. 6 illustrates an example of the comparison between IRI-95 and ANN during 21-28 January 2000. The ANN prediction (dash line) presents more powerful for forecasting TEC in any period while IRI-95 (line with rectangle) can forecast closely to measured TEC only in some period especially in the night for each days.

4. CONCLUSIONS

We have investigated the application of artificial neural networks to the estimation and forecasting of TEC. The ANN provides a useful memory of historical ionospheric behavior that can be easily and conveniently interrogated to discover trends based on different input criteria. It can provide answers to questions such as, By what amount, and in what direction, on average, will TEC change if magnetic activity changes from quite to disturbed, at 1000 local time. Such information is useful for the study of the theory of global circulation.

ประวัติผู้เขียน

นางสาวกฤตยา นาคประสิทธิ์ เกิดเมื่อวันที่ 13 พฤศจิกายน 2518 ที่จังหวัดชัยนาท สำเร็จการศึกษาระดับปริญญาตรี สาขาวิศวกรรมศาสตรบัณฑิต (วิศวกรรมโทรคมนาคม) จากสถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง ปีการศึกษา 2540

เข้ารับราชการในตำแหน่งอาจารย์ 1 ระดับ 3 สถาบันราชภัฏนครราชสีมา ตั้งแต่ปี พ.ศ. 2544

- ผลงานทางวิชาการที่ได้รับการตีพิมพ์

Krittaya Nakprasit and Narong Hemmakorn. "The predictability of vertical TEC using Artificial neural networks on Bangkok." International Symposium on Communications and Information Technology (ISCIT 2001), vol. 1, Nov. 2001. pp. 654-657.

