


การทำนายการเคลื่อนไหวของแขนโดยใช้สัญญาณ ECoG ในลิง

PREDICTION OF ARM MOTION USING ELECTROCORTICOGRAPHIC  
SIGNALS IN MONKEYS



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาคามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมชีวการแพทย์

คณะวิศวกรรมศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ.2562

KMITL-2019-EN-M-045-092

การทำนายการเคลื่อนไหวของแขนโดยใช้สัญญาณ ECoG ในลิง

PREDICTION OF ARM MOTION USING ELECTROCORTICOGRAPHIC  
SIGNALS IN MONKEYS



ภคกุล วิลไพระสิทธิ์พร  
PAKAKUL WILAIPRASITPORN

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมชีวการแพทย์

คณะวิศวกรรมศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ.2562

KMITL-2019-EN-M-045-092

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

PREDICTION OF ARM MOTION USING ELECTROCORTICOGRAPHIC  
SIGNALS IN MONKEYS



A THESIS SUBMITTED IN PARTIAL FULFILLMENT  
OF THE REQUIREMENT FOR THE DEGREE OF  
MASTER OF ENGINEERING IN BIOMEDICAL ENGINEERING  
FACULTY OF ENGINEERING  
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG 2019

KMITL-2019-EN-M-045-092

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



COPYRIGHT 2019

FACULTY OF ENGINEERING

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อวิทยานิพนธ์	การทำนายการเคลื่อนไหวของแขนโดยใช้สัญญาณ ECoG ในลิง
นักศึกษา	นางสาวภคกุล วิไลประสิทธิ์พร
รหัสประจำตัว	60601150
ปริญญา	วิศวกรรมศาสตรมหาบัณฑิต
ภาควิชา	วิศวกรรมชีวการแพทย์
ปีการศึกษา	2562
อาจารย์ที่ปรึกษาวิทยานิพนธ์	ผศ.ดร. ยุทธนา คิดใจเดียว

### บทคัดย่อ

Brain-machine interfaces (BMIs) เป็นวิธีการสื่อสารโดยตรงระหว่างสมองกับอุปกรณ์ภายนอก BCIs มักถูกนำร่องในการค้นคว้า, การทำแผนที่, การช่วยเหลือ, การแก้ไขความรู้ความเข้าใจหรือการทำงานของประสาทสัมผัสมนุษย์ สัญญาณ Electrocorticographic (ECoG) ให้ข้อมูลที่เชื่อถือได้เกี่ยวกับทิศทางการเคลื่อนไหวของแขน การค้นพบนี้แสดงให้เห็นว่า ECoG เป็นพื้นฐานที่มีศักยภาพสำหรับ BMIs เพื่อผู้ป่วยที่เป็นอัมพาต การกำหนดจุดประสงค์ของบุคคล เช่น ตำแหน่งและเวลาที่จะเคลื่อนย้าย สัญญาณสมองจะมีส่วนสำคัญในด้านการแพทย์หรือด้านอื่น ๆ มากกว่าจากกล้ามเนื้อ การตรวจจับการเริ่มต้นและทิศทางของการเคลื่อนไหวเป็นขั้นตอนแรก บทความนี้ยังแสดงให้เห็นการจำลองว่าข้อมูล ECoG จากลิงที่เกี่ยวกับการเคลื่อนไหวเหล่านี้ อาจช่วยเพิ่มประสิทธิภาพในงานกำหนดเป้าหมายได้ สรุปผลการวิจัยในเอกสารฉบับนี้แสดงให้เห็นว่าการตรวจจับการเคลื่อนย้ายที่ตั้งใจไว้นั้นเป็นไปได้ และอาจเป็นประโยชน์ต่อการทำงาน

<b>Thesis Title</b>	Prediction of arm motion using electrocorticographic signals in monkeys
<b>Student</b>	Mrs. Pakakul Wilaiprasitporn
<b>Student ID</b>	60601150
<b>Degree</b>	Master of Engineering
<b>Department</b>	Biomedical Engineering
<b>Year</b>	2019
<b>Thesis Advisor</b>	Asst. Prof. Dr. Yutthana Kitjaidure

## ABSTRACT

Brain-machine interfaces (BMIs) is a direct communication pathway between brain and an external device. BCIs are often directed at researching, mapping, assisting, or repairing human cognitive or sensory-motor functions. Electrographic (ECoG) signals have been contain reliable information about the direction of arm movements. These findings indicate that the ECoG is a potential basis for a brain-machine interface (BMI) for application in paralyzed patients. Determining a person's intent, e.g., where and when to move, from brain signals rather than from muscles would have important applications in clinical or other domains. Detecting the onset and direction of actual movements are a first step in this direction. This paper also demonstrate in a simulation that the information encoded in ECoG from monkeys about these movements may improve performance in a targeting task. In summary, the results in this paper suggest that detection of intended movement is possible, and may serve useful functions.

# กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงได้ด้วยความกรุณาของอาจารย์ที่ปรึกษา ผศ.ดร.ยุทธนา คิติใจ  
เดี่ยว ที่คอยให้คำปรึกษาในทุกๆเรื่อง และช่วยแก้ไขปัญหาต่างๆ ทั้งทางด้านการศึกษาตลอดจน  
กระบวนการดำเนินงานจนวิทยานิพนธ์ฉบับนี้เสร็จสมบูรณ์ ขอขอบพระคุณคุณพ่อคุณแม่ที่คอย  
ช่วยเหลือในเรื่องค่าใช้จ่าย และให้กำลังใจในการศึกษาเล่าเรียน ขอขอบคุณพี่ๆที่คอยช่วยเหลือและ  
ให้คำปรึกษาและแนะนำในทุกปัญหา เพื่อนๆและน้องๆในห้องที่คอยอยู่ช่วยให้คำปรึกษา และทุกคน  
ที่มีส่วนร่วมกับวิทยานิพนธ์ฉบับนี้



ภาคกุล วิไลประสิทธิ์พร

# สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	I
บทคัดย่อภาษาอังกฤษ.....	II
กิตติกรรมประกาศ.....	III
สารบัญ.....	IV
สารบัญตาราง.....	VI
สารบัญรูปภาพ.....	VII
บทที่ 1 บทนำ.....	1
1.1 ความเป็นมาและความสำคัญของปัญหา.....	1
1.2 ความมุ่งหมายและวัตถุประสงค์.....	1
1.3 สมมติฐานของการศึกษา.....	1
1.4 ขอบเขตของการศึกษา.....	2
1.5 ขั้นตอนการดำเนินงาน.....	2
บทที่ 2 ทฤษฎีที่เกี่ยวข้อง.....	3
2.1 Electrocorticographic (ECoG).....	3
2.2 Wavelet Transform.....	6
2.2.1 การแปลงฟูเรียร์ (Fourier Transform; FT).....	6
2.2.2 การแปลงฟูเรียร์ในช่วงเวลาสั้น (Short Time Fourier Transform; STFT).....	6
2.2.3 การแปลงเวฟเล็ท (Wave Transform).....	6
2.2.4 การแปลงเวฟเล็ทต่อเนื่อง (Continuous Wavelet Transform; CWT).....	7
2.2.5 การแปลงเวฟเล็ทแบบเต็มหน่วย (Discrete Wavelet Transform; DWT).....	8
2.3 Principal Component Analysis.....	9
2.3.1 Standard Deviation.....	9
2.3.2 Covariance.....	10
2.3.3 Covariance Matrix.....	10
2.3.4 EigenValues.....	10
2.3.5 EigenVectors.....	10
2.4 Recurrent Neural Networks.....	12
2.4.1 Feed-Forward Neural Networks.....	12
2.4.2 Back Propagation.....	14
2.4.3 Recurrent Neural Networks.....	16

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญ(ต่อ)

หน้า

2.5 Correlation Coefficient.....	17
2.6 งานวิจัยที่เกี่ยวข้อง.....	19
บทที่ 3 วิธีดำเนินงานวิจัย.....	20
3.1 Data Set.....	21
3.2 Pre-Processing.....	23
3.3 Feature Extraction.....	24
3.3.1 Discrete Wavelet Scalogram (DWT) .....	24
3.3.2 Resampled and Normalized Feature matrices.....	24
3.4 Principal Component Analysis.....	25
3.5 Movement Position.....	26
3.6 Recurrent Neural Network.....	27
บทที่ 4 ผลการทดลอง.....	29
4.1 Electrocorticographic (ECoG) .....	29
4.2 Pre-Processing.....	29
4.2.1 Signal to noise ratio.....	29
4.2.2 Down Sample.....	30
4.3 Feature Extraction.....	30
4.3.1 Continuous Wavelet Scalogram (CWT).....	30
4.3.2 Resampled at 25 time lags.....	31
4.4 Data Reduction.....	34
4.5 Movement Position.....	34
4.6 Prediction.....	35
4.6.1 Training Recurrent Neural Networks.....	35
4.6.2 ผลการทดลอง.....	41
บทที่ 5 อภิปรายผลการทดลอง.....	43
เอกสารอ้างอิง.....	44
ภาคผนวก.....	46
ประวัติผู้เขียน.....	53

## สารบัญตาราง

ตารางที่	หน้า
2.1 ช่วงความถี่และสถานะของคลื่นชนิดต่างๆ.....	4
4.1 เปรียบเทียบค่า Correlation Coefficient ( $r$ ).....	42



## สารบัญรูปภาพ

รูปที่	หน้า
2.1 ตำแหน่งวางอิเล็กโทรดตามมาตรฐาน 10-20 EEG Placement.....	3
2.2 ลักษณะคลื่นชนิดต่างๆของ EEG.....	4
2.3 ลักษณะของคลื่นสมองตามตำแหน่งที่วัด.....	4
2.4 ตำแหน่งการวางแผ่นอิเล็กโทรดบนเยื่อหุ้มสมอง.....	5
2.5 การแปลงเวฟเล็ตแบบเต็มหน่วย.....	8
2.6 รูปแบบกราฟของข้อมูลที่มีค่า Covariance.....	10
2.7 Neural Networks .....	12
2.8 โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ.....	14
2.9 ไดอะแกรมของ Recurrent Neural Networks.....	16
2.10 รูปแบบกราฟของข้อมูลที่มีค่า $r$ แบบต่างๆ.....	18
3.1 Prediction processing diagram .....	20
3.2 ตำแหน่งอิเล็กโทรดบนสมองของลิงสองตัว (A และ K) .....	21
3.3 พิกัดที่อยู่ตรงกลางของร่างกายสำหรับการวัดตำแหน่งมือ 3D ด้วยมุมมองจากด้านบน.....	22
3.4 สัญญาณ ECoG มี 1000 ค่า ใน 1 unit หรือ 1 sec.....	22
3.5 Motion Data มี 120 ค่าใน 1 unit หรือ 1 sec.....	23
3.6 ค่า Movement Position ของแกน x,y และ z.....	26
3.7 Recurrent Neural Networks.....	27
4.1 ตัวอย่างข้อมูลสัญญาณ ECoG ที่บันทึกได้จาก 4 ช่องสัญญาณใน 1 unit(sec) .....	29
4.2 สัญญาณ ECoG ใน 1 unit(sec) ที่ผ่าน CAR และ Down sample ตามลำดับ.....	30
4.3 Wavelet Transform ของสัญญาณ 1 Channel.....	30
4.4 Wavelet Scalogram ของสัญญาณ 1 Channel.....	31
4.5 Wavelet Coefficient 1 unit(sec) ของสัญญาณ 1 Channel.....	31
4.6 Wavelet Coefficient 1unit(sec)ที่ผ่านการ Resampled แล้วของสัญญาณ 1Channel....	32
4.7 Wavelet Scalogram 1unit(sec)ที่ผ่านการ Resampled แล้วของสัญญาณ 1Channel.....	32
4.8 Wavelet Coefficient 1unit(sec)ที่ถูกรวมมอดโรซ์แล้วของสัญญาณ 1Channel.....	33
4.9 Wavelet Coefficient 1unit(sec)ที่ถูกรวมมอดโรซ์แล้วของสัญญาณ 1Channel.....	33
4.10 Eigenvalues ที่คำนวณได้ของสัญญาณ 1 Channel.....	34
4.11 Motion Data sampling rate = 120 Hz.....	34
4.12 Motion Data ที่ผ่านการ Resampled ตามเวลาของสัญญาณ ECoG.....	35
4.13 Recurrent Neural Networks ที่มี input จาก PCA และ state ก่อนหน้า 2timesteps... 36	

## สารบัญรูปภาพ(ต่อ)

รูปที่	หน้า
4.14 Performance การ predict ของ RNN ในแกน X.....	37
4.15 Performance การ predict ของ RNN ในแกน Y.....	37
4.16 Performance การ predict ของ RNN ในแกน Z.....	38
4.17 Error Histogram การ predict ค่าในแกน X.....	38
4.18 Error Histogram การ predict ค่าในแกน Y.....	39
4.19 Error Histogram การ predict ค่าในแกน Z.....	39
4.20 Regression plot ของแกน X จากข้อมูลฝึกอบรม ชุดตรวจสอบ และชุดทดสอบ.....	40
4.21 Regression plot ของแกน Y จากข้อมูลฝึกอบรม ชุดตรวจสอบ และชุดทดสอบ.....	40
4.22 Regression plot ของแกน Z จากข้อมูลฝึกอบรม ชุดตรวจสอบ และชุดทดสอบ.....	41
4.23 ผลของการทำนายตำแหน่งของการเคลื่อนไหวของมือในแนวแกน X.....	41
4.24 ผลของการทำนายตำแหน่งของการเคลื่อนไหวของมือในแนวแกน Y.....	42
4.25 ผลของการทำนายตำแหน่งของการเคลื่อนไหวของมือในแนวแกน Z.....	42

# บทที่ 1

## บทนำ

### 1.1 ความเป็นมาและความสำคัญของปัญหา

ในปัจจุบัน Machine Learning ได้เข้ามามีบทบาทสำคัญมากขึ้นทั้งในระดับมหภาคและจุลภาค เนื่องจากสามารถประยุกต์ใช้ได้กับงานได้แทบทุกด้าน เนื่องด้วยประโยชน์ที่มีมากมายหลายประการ ที่อำนวยความสะดวกให้กับมนุษย์มากขึ้น ทั้งช่วยเพิ่มประสิทธิภาพ ความรวดเร็ว ความแม่นยำให้เพิ่มขึ้น หรือแม้แต่ในงานบางประเภทที่มนุษย์ไม่สามารถทำได้ก็อาจใช้ Machine Learning เข้ามาแทนที่

สำหรับทางการแพทย์ Machine Learning ก็ได้เข้ามามีส่วนร่วมเช่นกัน เนื่องจากร่างกายมนุษย์เป็นสิ่งที่ละเอียดอ่อน ในการรักษาเพียงแค่สมองและสองมือของมนุษย์อาจไม่เพียงพอ จึงต้องชวนช่วยสร้างสิ่งต่างๆขึ้นมาเพิ่มขอบเขตความสามารถในการรักษา

### 1.2 ความมุ่งหมายและวัตถุประสงค์

- 1.2.1 เพื่อศึกษาการทำงาน และชนิดของคลื่นสมอง ECoG
- 1.2.2 เพื่อทดลองนำข้อมูลจากคลื่นสมอง ECoG มาใช้งาน
- 1.2.3 เพื่อศึกษาการวิเคราะห์สัญญาณของคลื่นสมอง ECoG (Signal Processing)
- 1.2.4 เพื่อศึกษาหา Algorithm ที่เหมาะสมสำหรับการใช้งาน คลื่นสมอง ECoG
- 1.2.5 เพื่อศึกษาการนำ Machine Learning มาใช้งานด้านการวิเคราะห์ข้อมูล
- 1.2.6 เพื่อเรียนรู้และเข้าใจถึงปัญหาที่พบจากการทดลอง ตลอดจนการหาวิธีการแก้ไขและการปรับเปลี่ยนวิธีปัญหานั้นๆ

### 1.3 สมมติฐานของการศึกษา

หลักการทำงานของ Machine Learning สามารถช่วยเพิ่มประสิทธิภาพในการวิเคราะห์ข้อมูลของ Electrocorticographic Signals และสามารถใช้งานเพื่อทำนายผลลัพธ์ที่จะเกิดในอนาคตได้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 1.4 ขอบเขตของการศึกษา

งานวิจัยนี้จะแบ่งออกได้เป็นส่วนหลักๆดังนี้

1.4.1 นำข้อมูล Raw Data ของสัญญาณ ECoG มาผ่านกระบวนการ Pre-Processing เพื่อให้ข้อมูลเหมาะสมและพร้อมใช้งาน

1.4.2 Discrete Wavelet Transform เพื่อให้ได้ Feature ที่จะนำไปใช้

1.4.3 Data Reduction เพื่อลดภาระในการคำนวณ

1.4.4 Prediction ทำนายผลลัพธ์จากกระบวนการทั้งหมด

## 1.5 ขั้นตอนการดำเนินงาน

1.5.1 ศึกษาข้อมูลของ Electrocorticographic Signals

1.5.2 ศึกษาทฤษฎีเกี่ยวกับ Signal Processing

1.5.3 ศึกษาเกี่ยวกับ Discrete Wavelet Transform

1.5.4 ศึกษาเกี่ยวกับ Principle Component Analysis

1.5.5 ศึกษาเกี่ยวกับ Recurrent Neural Networks

1.5.6 ศึกษาการใช้งานโปรแกรม MATLAB

1.5.7 นำหลักการทั้งหมดมาออกสร้าง Algorithm ที่จะใช้สำหรับการวิเคราะห์ และทำนายผลของข้อมูล

1.5.8 ทดสอบ Algorithm ที่สร้างเพื่อรวบรวมผลการทดลองและสรุป


## บทที่ 2

# ทฤษฎีที่เกี่ยวข้อง

### 2.1 Electrocorticographic (ECoG)


Electroencephalography (EEG) เป็นการวัดคลื่นสมองโดยที่อิเล็กโทรดจะถูกวางหรือฝังไว้บริเวณเยื่อหุ้มสมองโดยตรงอยู่ภายใต้กะโหลกศีรษะ หรือที่เรียกว่า intracranial electroencephalography (iEEG) [1] ซึ่งจะตรงกันข้ามกับ Electroencephalography (EEG) ที่จะวางอิเล็กโทรดที่ใช้วัดไว้บนอกกะโหลกศีรษะหรือก็คือเป็นการวัดจากภายนอกเหนือชั้นผิวหนัง

ความก้าวหน้าในเทคโนโลยี Electroencephalography (EEG) ช่วยให้สามารถเพิ่มขอบเขตการศึกษาในการสุมตัวอย่างเชิงพื้นที่และเชิงเวลา ซึ่งนำไปสู่การประเมินค่าของการแกว่งความถี่สูง [2] โดยที่การตรวจคลื่นไฟฟ้าสมอง ( Electroencephalography หรือ EEG ) เป็นการบันทึกสัญญาณไฟฟ้า ซึ่งเกิดจากผลรวมของกระแสไฟฟ้าของกลุ่มเซลล์ในสมอง ทั้งนี้โดยปกติสมองคนมีเซลล์ประสาทชนิดหนึ่งที่เรียกว่า นิวรอน (Neuron) จำนวนมากมายเป็นพันล้านเซลล์ เซลล์เหล่านี้สามารถติดต่อกันได้โดยการขนส่งอนุภาคไฟฟ้าผ่านเยื่อเซลล์ เมื่อเซลล์ประสาทส่วนหนึ่งได้รับการกระตุ้นโดยสารเคมีที่เรียกว่า สารสื่อประสาท (Neurotransmitter) จะปล่อยอนุภาคที่มีประจุไฟฟ้าให้เดินไปตามเนื้อเยื่อที่เรียกว่า ใยประสาท (Nerve fiber) ที่เชื่อมระหว่างเซลล์ประสาท โดยกระแสไฟฟ้าปริมาณน้อยๆที่เกิดขึ้นนี้จะไปกระตุ้นเซลล์ประสาทให้ปล่อยประจุไฟฟ้าต่อไปเป็นทอดๆ ซึ่งสัญญาณไฟฟ้าที่เกิดขึ้นนี้เรียกว่า คลื่นสมอง หรือ คลื่นไฟฟ้าสมอง (Brain wave) คลื่นสมองจะมีลักษณะเคลื่อนไหวขึ้นและลงเหมือนคลื่นทั่วไป โดยใช้หน่วยการวัดเป็นรอบต่อวินาที เมื่ออยู่ในภาวะปกติคลื่นไฟฟ้าสมองก็เป็นปกติ แต่เมื่อเกิดความผิดปกติของสมอง ความผิดปกตินั้นก็สามารตรวจได้จาก การตรวจคลื่นไฟฟ้าสมอง



รูปที่ 2.1 ตำแหน่งวางอิเล็กโทรดตามมาตรฐาน 10-20 EEG Placement

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะโดยใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 2.2 ลักษณะคลื่นชนิดต่างๆของ EEG [3]

ตารางที่ 2.1 ช่วงความถี่และสถานะของคลื่นชนิดต่างๆ

Brainwave Type	Frequency range	Mental states and conditions
Delta	0.1Hz to 3Hz	Deep, dreamless sleep, non-REM sleep, unconscious
Theta	4Hz to 7Hz	Intuitive, creative, recall, fantasy, imaginary, dream
Alpha	8Hz to 12Hz	Relaxed, but not drowsy, tranquil, conscious
Low Beta	12Hz to 15Hz	Formerly SMR, relaxed yet focused, integrated
Midrange Beta	16Hz to 20Hz	Thinking, aware of self & surroundings
High Beta	21Hz to 30Hz	Alertness, agitation

พร้อมกันนี้นักประสาทวิทยาและวิศวกรพบว่าความเที่ยงตรงและความทนทานของสัญญาณ Electrocorticographic (ECoG) เป็นรูปแบบที่มีแนวโน้มเหมาะสมสำหรับการบุกเบิกด้าน brain-computer interface (BCI) [4,5] จุดบรรจบที่เป็นเอกลักษณ์ของนวัตกรรมเหล่านี้มีความสำคัญต่อการใช้งานที่หลากหลาย เช่น การคาดการณ์อาการของโรคลมชัก, การวิจัยเกี่ยวกับระบบประสาท, ECoG-based functional mapping และ Neuroprosthetics ที่ขับเคลื่อนด้วย BCI สัญญาณ ECoG ที่บันทึกด้วยขั้วไฟฟ้าสามารถวิเคราะห์ได้ทั้งแบบออฟไลน์และแบบเรียลไทม์ เพื่อแยกความแตกต่างของกิจกรรมที่เกี่ยวข้องกับงานจากการพักผ่อนหรือกิจกรรมพื้นฐาน การตอบสนองของ ECoG เหล่านี้ถูกนำมาใช้เพื่อทดสอบความสัมพันธ์ของระบบประสาทในสมองของมนุษย์ที่หลากหลาย รวมถึงการเคลื่อนไหว การรับรู้ ความสนใจด้านภาษาและความจำ




รูปที่ 2.3 ลักษณะของคลื่นสมองตามตำแหน่งที่วัด [6]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การศึกษา ECoG ได้ให้ข้อมูลเชิงลึกเกี่ยวกับลักษณะการตอบสนองเชิงพื้นที่และเชิงเวลาที่ต่างกัน ณ ความถี่ที่ต่างกัน ซึ่งการตอบสนองของสัญญาณ ECoG จะมีค่าสูงโดยเฉพาะแอมพลิจูดในช่วงความถี่ที่กว้างกว่าความถี่แกมมาแบบดั้งเดิม (30–60 Hz) จึงเรียกว่า "High Gamma" (~ 60–200 Hz) ช่วงเวลาและการกระจายทางกายวิภาคของการตอบสนองแกมมาสูงมักจะไม่ต่อเนื่องมากกว่าการตอบสนองในความถี่ต่ำ รวมถึงระดับอัลฟา เบต้าและแม้แต่ความถี่แกมมาแบบดั้งเดิม

สัญญาณ ECoG จะแบ่งได้เป็น 2 ประเภทได้แก่ subdural ECoG (sECoG) ซึ่งบันทึกสัญญาณสมองไฟฟ้าจากใต้ dura (เยื่อหุ้มสมองและไขสันหลังชั้นนอก) และ epidural ECoG (eECoG) ซึ่งบันทึกสัญญาณจากเหนือ dura โดยที่ sECoG ให้ signal-to-noise ratio ที่ดีกว่า, ความละเอียดเชิงพื้นที่ที่สูงกว่า และแบนด์วิดท์ที่กว้างกว่า [7]



รูปที่ 2.4 ตำแหน่งการวางอิเล็กโทรดบนเยื่อหุ้มสมองและตำแหน่งที่เกี่ยวข้องกับการเคลื่อนไหวของร่างกาย โดยที่จุดที่แดงเกี่ยวข้องกับการเคลื่อนไหวของแขน, สีน้ำเงินเกี่ยวข้องกับการเคลื่อนไหวของนิ้วมือทั้งห้า, สีขาวเกี่ยวข้องกับการเคลื่อนไหวของนิ้วหัวแม่มือ และสีเขียวเกี่ยวข้องกับการพูด [8]

## 2.2 Wavelet Transform

### 2.2.1 การแปลงฟูรีเยร์ (Fourier Transform; FT)

การแปลงฟูรีเยร์เป็นคณิตศาสตร์ที่ใช้ในการวิเคราะห์สัญญาณ และเพื่อให้ง่ายต่อการวิเคราะห์จะทำการแปลงสัญญาณจากโดเมนเวลา (Time-Domain) ให้อยู่ในรูปของโดเมนความถี่ (Frequency-Domain) ซึ่งจะเรียกกันโดยทั่วไปว่าเป็นการหา “สเปกตรัม (Spectrum)” ของสัญญาณ สมการที่ใช้ในการวิเคราะห์ของการแปลงฟูรีเยร์แสดงตามสมการ

$$X(f) = \int_{-\infty}^{\infty} x(t)e^{-j2\pi ft} dt \quad (2.1)$$

วิธีการนี้จะเหมาะสมสำหรับสัญญาณที่รวมหลายๆความถี่เข้าด้วยกัน จึงเหมาะกับสัญญาณที่มีลักษณะเป็นคาบเวลาที่แน่นอน (Stationary signal) แต่สำหรับสัญญาณที่มีการเปลี่ยนแปลงไม่คงที่ (Non-Stationary signal) อาจทำให้เกิดการผิดพลาดในการวิเคราะห์สัญญาณรวมถึงการขาดหายของข้อมูลทางเวลา และเนื่องจากว่าการแปลงฟูรีเยร์นี้ จะทำให้ทราบถึงความถี่ของสัญญาณแต่ไม่ทราบเวลาที่เกิดความถี่นั้น จึงมีการปรับปรุงการวิเคราะห์สัญญาณกลายเป็นการแปลงฟูรีเยร์ในช่วงเวลาสั้น

### 2.2.2 การแปลงฟูรีเยร์ในช่วงเวลาสั้น (Short Time Fourier Transform; STFT)

การแปลงฟูรีเยร์ในช่วงเวลาสั้นจะสามารถวิเคราะห์ข้อมูลได้ทั้งด้านความถี่และเวลา โดยจะเลือกบริเวณของสัญญาณที่จะทำการวิเคราะห์แล้วทำการแปลงสัญญาณจากโดเมนเวลาให้เป็นโดเมนความถี่ เพื่อให้ได้ข้อมูลความถี่ที่เกิดในช่วงเวลานั้นๆมา ตามสมการ

$$STFT(f, \tau) = \int_{-\infty}^{\infty} x(t)x(t - \tau)e^{-2j\pi ft} dt \quad (2.2)$$

ซึ่งจะมีการใช้ฟังก์ชันหน้าต่าง (Window function) โดยเริ่มวางจากต้นสัญญาณแล้วจึงใช้การคำนวณแบบฟูรีเยร์จากนั้นค่อยเลื่อนฟังก์ชันหน้าต่างถัดไปเพื่อคำนวณต่อจนกว่าจะหมดสัญญาณ การเลื่อนฟังก์ชันหน้าต่างนี้ทำให้ได้ข้อมูลทางเวลาและทางความถี่ในการแปลงฟูรีเยร์ แต่เนื่องจากใช้ฟังก์ชันหน้าต่างเดียวกันสำหรับทุกความถี่ความละเอียดจึงเหมือนกันทุกตำแหน่งและทำให้เกิดความคลาดเคลื่อนในการวิเคราะห์ข้อมูลได้

### 2.2.3 การแปลงเวฟเลต (Wave Transform)

การวิเคราะห์สัญญาณด้วยการแปลงเวฟเลต (Wavelet Transform) มาจากการพัฒนารูปแบบการวิเคราะห์สัญญาณเพื่อแก้ไขปัญหาของการแปลงฟูรีเยร์และการแปลงฟูรีเยร์ในช่วงเวลาสั้น โดยที่สามารถปรับระดับช่วงเวลาและความถี่ตามความเหมาะสมได้ หากเป็นสัญญาณที่มีความถี่

สูงจะมีการเปลี่ยนแปลงที่รวดเร็วจึงควรปรับช่วงเวลาของฟังก์ชันหน้าต่างที่ใช้ให้แคบลง ในขณะที่ควรปรับช่วงเวลาของฟังก์ชันหน้าต่างให้กว้างขึ้นเมื่อเป็นสัญญาณที่มีความถี่ต่ำและมีการเปลี่ยนแปลงช้า [9]

การวิเคราะห์สัญญาณด้วยการแปลงเวฟเล็ตจะไม่แสดงข้อมูลเชิงเวลากับความถี่แต่จะแสดงข้อมูลเชิงเวลากับสเกล (scale) แทน หลักการของเวฟเล็ตคือการนำคลื่นเล็กๆมารวมกันเป็นกลุ่มเพื่อใช้อธิบายโครงสร้างของสัญญาณใดๆ ซึ่งคลื่นเล็กๆนี้เป็นสัญญาณเฉพาะที่เรียกกันทั่วไปว่า “เวฟเล็ต” โดยที่คลื่นเวฟเล็ตแต่ละตัวจะมีโครงสร้างมาจากฟังก์ชันเดียวกันซึ่งฟังก์ชันนี้จะเป็นเวฟเล็ตต้นกำเนิดที่เรียกว่า "เวฟเล็ตแม่" (Mother Wavelets)

$$h_{b,a}(t) = \frac{1}{\sqrt{a}} h \frac{t-b}{a} \quad (2.3)$$

เมื่อ  $h(t)$  คือ Mother Wavelet

$a$  คือ พารามิเตอร์สเกล (scale)

$b$  คือ พารามิเตอร์เวลา (time)

จากสมการที่ 2.3 จะอธิบายได้ว่าชุดของฟังก์ชันเวฟเล็ตมักจะได้มาจาก อินนิเซียลเวฟเล็ต (เวฟเล็ตแม่)  $h(t)$  จะเป็นฟังก์ชันเวฟเล็ตแม่ที่ถูกเลื่อนตำแหน่งและถูกสเกลโดยพารามิเตอร์ " $a$ " และ " $b$ " ตามลำดับ โดยที่ช่วงเวลาและความถี่ในการแปลงจะสัมพันธ์กันและเพื่อให้เวฟเล็ตที่ถูกสเกลไปแล้วมีพลังงานเท่ากับเวฟเล็ตแม่จึงต้องทำการนอร์มัลไลซ์ด้วย  $1/\sqrt{a}$  เสมอ [10]

#### 2.2.4 การแปลงเวฟเล็ตต่อเนื่อง (Continuous Wavelet Transform; CWT)

รูปแบบของการแปลงเวฟเล็ตแบบต่อเนื่องนั้นมีลักษณะการวิเคราะห์สัญญาณโดยอาศัยการปรับเปลี่ยนคุณสมบัติของเวฟเล็ตแม่ที่ใช้ในการวิเคราะห์คือ สำหรับการวิเคราะห์ห้องค์ประกอบความถี่สูงจะใช้ช่วงเวลาที่แคบ และการวิเคราะห์ห้องค์ประกอบความถี่ต่ำจะใช้ช่วงเวลาที่กว้าง โดยที่ความกว้างของหน้าต่างในการแปลงเวฟเล็ตจะถูกปรับไปเรื่อยๆตลอดการวิเคราะห์สัญญาณในทุกๆความถี่เพื่อให้เหมาะสมสำหรับการวิเคราะห์ดังแสดงในสมการที่ 2.4

$$CWT(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} f(t) \varphi \frac{t-b}{a} dt \quad (2.4)$$

เมื่อ  $f(t)$  = สัญญาณที่ทำการแปลง

$\varphi(t)$  = เวฟเล็ตแม่

$a$  = แพลคเตอร์สเกล (scale)

$b$  = แพลคเตอร์การเลื่อนตำแหน่ง (shifting)

จากสมการที่ 2.4 Mother wavelet;  $\varphi(t)$  จะเทียบได้กับฟังก์ชันหน้าต่างในการแปลงฟูเรียร์ช่วงเวลานั่นเอง แต่ Mother wavelet;  $\varphi(t)$  จะมีการปรับเปลี่ยนค่าพารามิเตอร์  $a$  และ  $b$

ซึ่งวิเคราะห์ได้ด้วยวิธีการนำสัญญาณมาคอนโวลูชัน(Convolution)กับฟังก์ชันเวฟเล็ต เริ่มจากจุดเริ่มต้นของสัญญาณไปที่ละส่วนจนครบทั้งสัญญาณ จากนั้นจึงเปลี่ยนระดับสเกลโดยไล่จากสเกลต่ำสุดจนไปถึงการเพิ่มระดับสเกลขึ้นเรื่อยๆจนครบทุกระดับสเกลที่ต้องการ ทำให้ได้ค่าความถี่ที่แตกต่างกันออกไปในแต่ละระดับสเกล โดยผลจากการวิเคราะห์ที่ได้จะอยู่ในรูปของสัมประสิทธิ์เวฟเล็ต (Wavelet Coefficient) แม้ว่าวิธีนี้จะมีคามแม่นยำทางด้านเวลาและความถี่สูง แต่ยังคงมีข้อจำกัดหากเป็นงานที่ต้องการความรวดเร็วเนื่องจากต้องใช้เวลาในการวิเคราะห์ที่ค่อนข้างมากและมีความซับซ้อนเกินความจำเป็น

### 2.2.5 การแปลงเวฟเล็ตแบบเต็มหน่วย (Discrete Wavelet Transform; DWT)

การแปลงเวฟเล็ตแบบเต็มหน่วยพัฒนาขึ้นมาเพื่อแก้ไขปัญหาของการแปลงเวฟเล็ตแบบต่อเนื่อง โดยมีรูปแบบการปรับสเกลและเลื่อนตำแหน่งในลักษณะเป็นช่วงๆที่ไม่ต่อเนื่องกัน ซึ่งจะคำนวณได้ตามสมการที่ 2.5

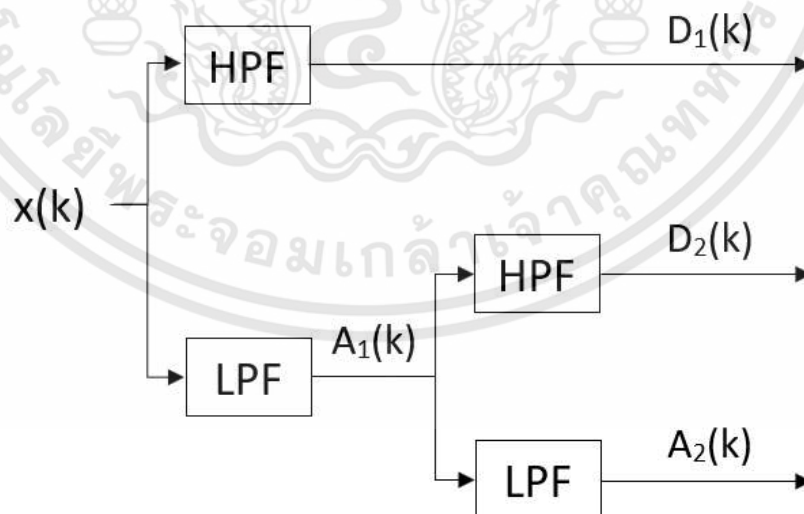
$$DWT(m, n) = \frac{1}{\sqrt{2^m}} \sum_k f(k) \phi \left( \frac{n - k2^m}{2^m} \right) \quad (2.5)$$

เมื่อ  $m, n, k$  เป็นเลขจำนวนเต็มโดยที่

$n$  คือ จำนวนข้อมูล

$m$  คือ เลขแสดงการเปลี่ยนแปลงของสเกล

$k$  คือ เลขแสดงการเลื่อนตำแหน่ง



รูปที่ 2.5 การแปลงเวฟเล็ตแบบเต็มหน่วย

การแปลงเวฟเล็ทแบบเต็มหน่วย เป็นการนำสัญญาณมาผ่านตัวกรองความถี่ต่ำ (Low pass filter) และความถี่สูง (High pass filter) เพื่อทำการแยกองค์ประกอบสัญญาณออกเป็นส่วนที่มีความถี่ต่ำ (Approximation) และส่วนที่มีความถี่สูง (Detail) โดยสัญญาณที่ได้มานั้นจะผ่านอัตราการสุ่มลง (Down sampling) ด้วย 2 ทำให้จำนวนตัวอย่าง (Sample) ของผลลัพธ์ที่ได้ลดลงครึ่งหนึ่งของสัญญาณเดิม

## 2.3 Principal Component Analysis

ในปัจจุบันมีอัลกอริทึมมากมายสำหรับการลดขนาดของข้อมูลที่ได้รับการพัฒนาเพื่อให้งานซึ่งจำเป็นต้องใช้การลดขนาดของข้อมูลประสบความสำเร็จ อย่างไรก็ตามเนื่องจากความจำเป็นในการวิเคราะห์ดังกล่าวเกิดขึ้นในหลาย ๆ ด้านของการศึกษา ดังนั้นการพัฒนาจึงเกิดจากการมีส่วนร่วมในหลายสาขาวิชา ในขณะที่วิธีการเหล่านี้ทั้งหมดมีเป้าหมายคล้ายคลึงกัน แต่วิธีการแก้ไขปัญหานั้นแตกต่างกัน [11]

Principal components analysis (PCA) เป็นเทคนิคยอดนิยมสำหรับการลดขนาดจุดประสงค์ของการทำ PCA คือ แก้ปัญหา high-dimensional data ข้อมูลที่มีจำนวนตัวแปรเยอะกว่าจำนวนตัวอย่าง ซึ่งจะประกอบไปด้วยเทคนิคทางคณิตศาสตร์หลายเรื่องรวมกัน [12,13]

### 2.3.1 Standard Deviation

Mean คือค่าเฉลี่ย ซึ่งคิดจากผลรวมของค่าทั้งหมดหารด้วยจำนวนข้อมูล มีสมการดังนี้

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n} \quad (2.6)$$

โดยที่  $x_i$  คือตัวแปรที่จะนำมาหาค่าเฉลี่ย

และ  $n$  เป็นจำนวนของข้อมูล

Variance คือค่าความแปรปรวน ใช้เพื่อวัดการกระจายของข้อมูลโดยจะคิดจากความแตกต่างจากค่าเฉลี่ยยกกำลัง 2 มีสมการดังนี้

$$s^2 = \frac{\sum (x - \bar{x})^2}{n} \quad (2.7)$$

โดยที่  $\bar{x}$  เป็นค่าเฉลี่ยของข้อมูล

และ  $n$  เป็นจำนวนของข้อมูล

Standard Deviation คือส่วนเบี่ยงเบนมาตรฐาน ใช้เพื่อดูการกระจายข้อมูลจากค่าเฉลี่ย หรือก็คือ รากที่ 2 ของค่าแปรปรวน มีสมการดังนี้

$$s = \frac{\sum (x - \bar{x})}{n} \quad (2.8)$$

โดยที่  $\bar{x}$  เป็นค่าเฉลี่ยของข้อมูล

และ  $n$  เป็นจำนวนของข้อมูล


### 2.3.2 Covariance

**Variance** และ Standard Deviation เป็นการวิเคราะห์ที่ใช้กับข้อมูล 1 มิติ แต่หากข้อมูลมีมากกว่า 1 ชุดขึ้นไปก็จำเป็นต้องหาความสัมพันธ์ของตัวแปรแต่ละมิติด้วย ซึ่งจะถูกเรียกว่าการหาค่า Covariance หรือค่าความแปรปรวนร่วม โดยจะมีสมการดังนี้

$$cov(x, y) = \frac{\sum(x-\bar{x})(y-\bar{y})}{n-1} \quad (2.9)$$

โดยที่  $\bar{x}$  เป็นค่าเฉลี่ยของตัวแปร  $x$

และ  $\bar{y}$  เป็นค่าเฉลี่ยของตัวแปร  $y$



รูปที่ 2.6 รูปแบบกราฟของข้อมูลที่มีค่า Covariance เท่ากับ 0, น้อยกว่า 0, มากกว่า 0 ตามลำดับ

### 2.3.3 Covariance Matrix

Covariance Matrix คือ เมทริกซ์ของ Covariance ทุกคู่ระหว่างชุดต่างๆ ยกตัวอย่างเช่น ข้อมูล 3 ชุด  $x, y$  และ  $z$  ดังนั้นแล้ว Covariance Matrix ก็จะสามารถเขียนได้ว่า

$$\begin{pmatrix} cov(x, x) & cov(x, y) & cov(x, z) \\ cov(y, x) & cov(y, y) & cov(y, z) \\ cov(z, x) & cov(z, y) & cov(z, z) \end{pmatrix} \quad (2.10)$$

### 2.3.4 EigenValues

EigenValues หรือค่าเฉพาะ ( $\lambda$ ) ซึ่งค่าเฉพาะของเมทริกซ์จัตุรัส  $A$  คือค่าคงตัวใดๆที่ทำให้  $Ax = \lambda x$  โดยที่  $x$  ไม่เป็นศูนย์ ซึ่งหาได้จาก

$$|A - \lambda I| = 0 \quad (2.11)$$

### 2.3.5 EigenVectors

EigenVectors หรือเวกเตอร์เฉพาะ ( $x$ ) เป็นการคูณกันระหว่าง matrix กับ vector แต่ที่ต่างไปจากการคูณเมทริกซ์ธรรมดาก็คือ ผลคูณระหว่าง matrix กับ vector นี้ ก็คือ vector ที่เอาไปคูณนั่นเอง เพียงแต่อาจมีขนาดสั้นยาวของเวกเตอร์ผลลัพธ์ที่ต่างไปจาก vector ตัวตั้งที่นำไปคูณ

$$Ax = \lambda x = \lambda Ix \quad (2.12)$$

$$[A - \lambda I]x = 0 \quad (2.13)$$

จากเทคนิคที่กล่าวมาข้างต้น จะสามารถนำมาจัดการกับข้อมูล เพื่อค้นหารูปแบบของข้อมูลนั้นๆ เป็นการมองข้อมูลในมุมใหม่ ในมุมที่แสดงถึงความสัมพันธ์กันภายในข้อมูลชุดนั้นๆ สมมติว่ามีข้อมูลหลายมิติ ซึ่งยากที่จะทำความเข้าใจ หรือยากที่จะแสดงออกมาในมุมที่มีความหมาย PCA จึงเข้ามาลดความซับซ้อนตรงนี้ลงไป

ข้อดีอีกอย่างหนึ่งก็คือหลังจากที่เจอค่าเจาะจงข้อมูลแล้ว จะสามารถลดขนาดของข้อมูลโดยการลดมิติที่ไม่ค่อยมีความสำคัญออกไป โดยที่ไม่ได้ทำการเปลี่ยนแปลงข้อมูลดิบ ซึ่งอัลกอริทึมของ PCA จะแบ่งเป็นขั้นตอนดังต่อไปนี้

ขั้นตอนที่ 1. รับค่า Resampled Matrices ที่คำนวณได้จากสัญญาณ  $I_1, I_2, \dots, I_M$  (ข้อมูลต้นแบบการเรียนรู้) และแสดงไว้ในรูปเวกเตอร์  $\Gamma_i$

ขั้นตอนที่ 2. คำนวณหาเวกเตอร์ของค่าเฉลี่ย  $\Psi$  ของแต่ละ Channel ตามสมการที่ 2.14

$$\Psi = \frac{1}{M} \sum_{i=1}^M \Gamma_i \quad (2.14)$$

ขั้นตอนที่ 3. นำเวกเตอร์  $\Gamma_i$  ของข้อมูลมาลบด้วยค่าเฉลี่ย  $\Psi$

$$\phi_i = \Gamma_i - \Psi \quad (2.15)$$

ขั้นตอนที่ 4. คำนวณหาเมทริกซ์โควาเรียนซ์  $C$

$$C = \frac{1}{M} \sum_{n=1}^M \phi_n \phi_n^T = AA^T \quad (2.16)$$

เมื่อ  $A = [\phi_1 \ \phi_2 \ \dots \ \phi_M]$  (2.17)

หรือก็คือ  $C = \begin{pmatrix} cov(x, x) & cov(x, y) & cov(x, z) \\ cov(y, x) & cov(y, y) & cov(y, z) \\ cov(z, x) & cov(z, y) & cov(z, z) \end{pmatrix}$  (2.18)

ขั้นตอนที่ 5. คำนวณหา Eigenvectors  $v_i$  ของเมทริกซ์  $AA^T$  (เมทริกซ์  $AA^T$  มีขนาดใหญ่! มากไม่ควรนำไปใช้งานจริง)

$$A^T A v_i = u_i v_i \quad (2.19)$$

ขั้นตอนที่ 6. เก็บเฉพาะค่าเวกเตอร์เจาะจง  $K$  (เป็น EigenValues ที่ชี้เฉพาะค่าเจาะจง) [14]

ขั้นตอนที่ 7. เมื่อได้เวกเตอร์เจาะจง จึงนำสัญญาณมาทำการ Project ตามสมการที่ 2.20

$$proj_v u = \left( \frac{u \cdot v}{\|v\|^2} \right) v \quad (2.20)$$

เมื่อ  $u$  คือสัญญาณที่จะนำมา Project

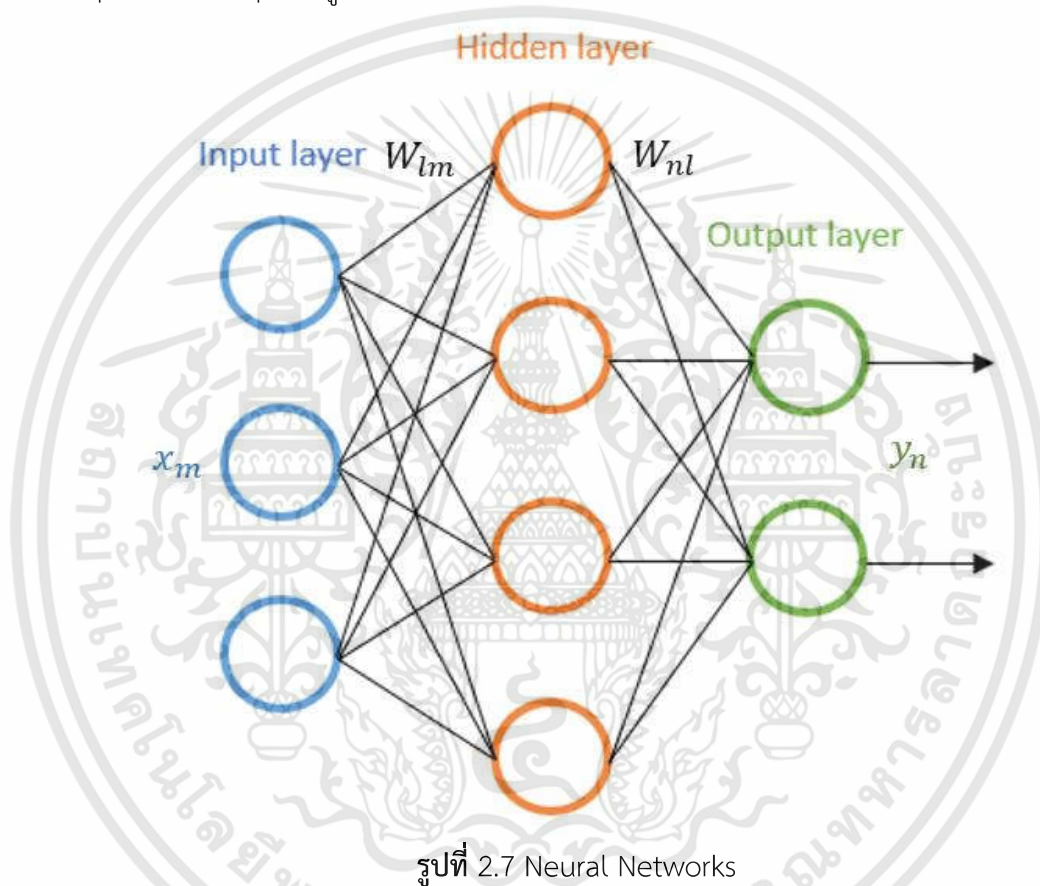
$v$  คือ ค่าเจาะจง

## 2.4 Recurrent Neural Networks

### 2.4.1 Feed-Forward Neural Networks

การจำแนกข้อมูลด้วยโครงข่ายประสาทเทียมหรือ Neural network เป็นวิธีการที่ได้มาจากการจำลองการทำงานของสมองมนุษย์ โดยระบบมีการประมวลผลที่คล้ายกับหน่วยความจำหรือเซลล์ประสาทจำนวนมากที่มีการเชื่อมต่อกันเป็นโครงข่าย

ซึ่ง Neural Networks ทำงานโดยที่นำเทคนิคการพยากรณ์ด้วยสมการเชิงเส้น มาใช้ต่อกันหลายๆตัวและหลายๆชั้นดังรูปที่ 2.7



โดยที่ส่วนประกอบของ Neural Network จะประกอบไปด้วยส่วนสำคัญหลักๆสามส่วน ได้แก่

1. **Input Layer** ชั้นนี้จะเป็นข้อมูล input ส่วนจำนวนของโหนดขึ้นอยู่กับจำนวนของ input ว่ามีข้อมูลอะไรบ้างที่จะนำเข้ามาคิดในโมเดล (ใน Machine Learning จะเรียกปัจจัยที่นำมาวิเคราะห์เหล่านี้ว่า feature)
2. **Hidden Layer** เป็นชั้นที่อยู่ระหว่างกลาง ซึ่งจะมีผลอย่างมากต่อประสิทธิภาพในการเรียนรู้ของโมเดล ซึ่ง hidden layer นั้นจะมีกี่ชั้นก็ได้ และแต่ละชั้นจะมีจำนวนของ Neuron เท่าไหร่ก็ได้เช่นกัน ซึ่งการเพิ่มชั้นและจำนวน neuron ก็จะมีผลต่อการทำงานของโมเดล ในส่วนของ hidden layer มีการทำงานเปรียบเสมือนส่วนที่เรียนรู้ข้อมูลเชิงลึกหรือก็คือ deep learning นั่นเอง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3. **Output Layer** คือชั้นที่นำข้อมูลซึ่งได้มาจากการคำนวณไปใช้งาน จำนวนของโหนดในชั้นนี้จะขึ้นอยู่กับรูปแบบของ output ที่ต้องการนำไปใช้ ยกตัวอย่างเช่น งานที่ทำเป็น Regression อาจกำหนดให้ output layer เป็นแบบ 1 โหนด เนื่องจากว่าต้องการคำตอบค่าเดียว แต่ถ้าหากเป็นหลายค่าก็เพิ่มไปตามจำนวนที่ต้องการ เช่น ต้องการ predict หาตำแหน่งของภาพในแกน x และ y พร้อมๆ กัน ในกรณีนี้จึงต้องใส่ output layer เป็น 2 โหนดแทน เป็นต้น

โครงสร้างของ Neural Networks ในรูปที่ 2.7 ใช้อธิบายความสัมพันธ์ระหว่างเซตของ

พารามิเตอร์ Input  $x_m$  ( $m= 1, \dots, M$ ) และเซตของพารามิเตอร์ Output  $y_n$  ( $n= 1, \dots, N$ ) ด้านซ้ายมือของรูปเป็นส่วนหนึ่งของ Input layer โดยที่ตัวแปรเหล่านี้จะถูกคูณด้วยเมทริกซ์ของพารามิเตอร์  $W_{lm}$  ( $l= 1, \dots, L$ ;  $m = 1, \dots, M$ ) และรวมกับ  $b_l$  ในขณะที่  $L$  คือ Layer number ซึ่งแต่ละองค์ประกอบของเวกเตอร์นี้จะถูกแปลงด้วย nonlinear function ดังนั้น Output ที่ได้จากยูนิทชั้นกลางจะคำนวณได้จากสมการที่ 2.21

$$z_l = f(\sum W_{lm}x_m + b_l) \quad (l = 1, \dots, L) \quad (2.21)$$

โดยที่  $b_l$  คือ offset (หรือ threshold)

โดยทั่วไปฟังก์ชัน  $f(*)$  จะถูกใช้เป็นฟังก์ชันซิกมอยด์ ที่กำหนดด้วย

$$f(x) = \frac{1}{(1+e^{-x})} \quad (2.22)$$

และ Output จากชั้นของ hidden layers นี้จะถูกคูณด้วยเมทริกซ์ลำดับสองซึ่งก็คือพารามิเตอร์  $W_{nl}$  ( $n= 1, \dots, N$ ;  $l= 1, \dots, L$ ) และค่า offset  $b_n$  จะถูกรวมเข้ากับเวกเตอร์ผลลัพธ์เพื่อสร้าง Network Output ตามสมการที่ 2.23

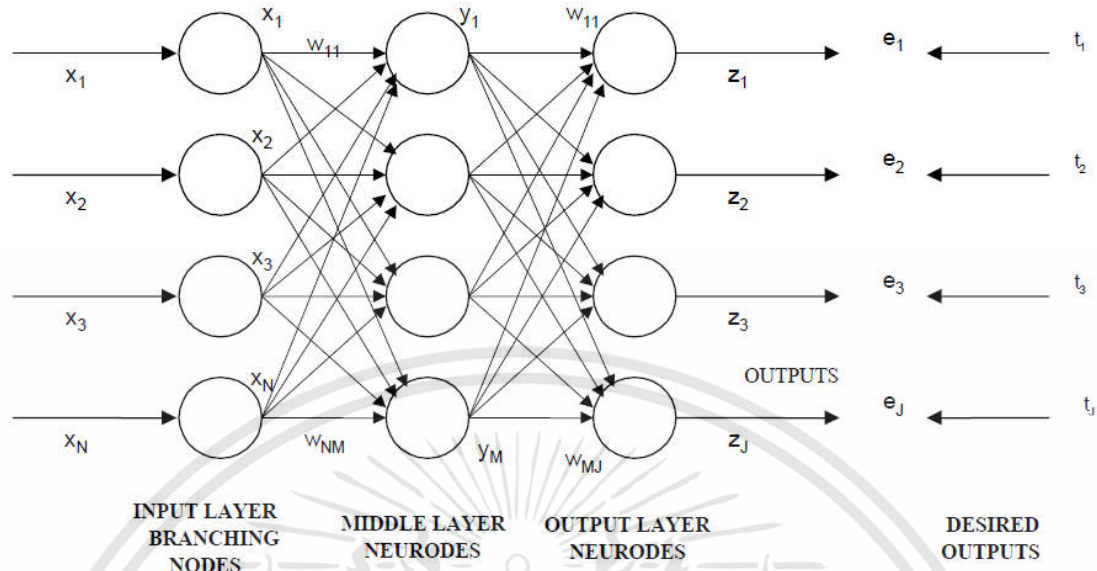
$$y_n = \sum W_{nl}z_l + b_n \quad (n = 1, \dots, N) \quad (2.23)$$

จากสมการที่ 2.23 จะเห็นได้ว่าเครือข่ายทั้งหมดสอดคล้องกับการ mapping จาก Input  $x_m$  ไปยัง Output  $y_n$  ซึ่งสามารถระบุความสัมพันธ์ของ Input และ Output ดังกล่าวได้ตามสมการที่ 2.24

$$y_n(x_1, \dots, x_m) = \sum W_{nl} f(\sum W_{lm}x_m + b_l) + b_n \quad (2.24)$$

โดยที่  $f(*)$  ถูกกำหนดโดยสมการที่ ซึ่งความสัมพันธ์นี้จะถูกกำหนดโดยพารามิเตอร์  $W_{lm}$ ,  $b_l$ ,  $W_{nl}$  และ  $b_n$  ซึ่งจะสามารถเพิ่มชั้นของ hidden layer ได้มากกว่า 1 layer

## 2.4.2 Back Propagation



รูปที่ 2.8 โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ [15]

$x_n$  คือ input โหนดที่  $n$  มีทั้งหมด  $N$  โหนด

$S_m$  คือ output พุทของ hidden layer ก่อนทำการปรับค่า (Activation) เป็น  $y_m$

$y_m$  คือ output ของ hidden layer หลังทำการปรับค่าของโหนดที่  $m$  มีทั้งหมด  $M$  โหนด

$v_j$  คือ output ของ output layer ก่อนทำการปรับค่า (Activation) เป็น  $z_j$

$z_j$  คือค่า output ที่ปรับค่าแล้วของ output layer โหนดที่  $j$  มีทั้งหมด  $J$  โหนด

$t_j$  คือค่า output ที่ต้องการที่ output layer โหนดที่  $j$  มีทั้งหมด  $J$  โหนด

$w_{nm}$  คือน้ำหนักของเส้นเชื่อมระหว่าง input layer กับ hidden layer

$w_{mj}$  คือน้ำหนักของเส้นเชื่อมระหว่าง hidden layer กับ output layer

$\eta$  คืออัตราการเรียนรู้มีค่าระหว่าง 0 ถึง 1

$r$  คือจำนวนรอบที่จะทำการเรียนรู้ มี  $R$  เป็นจำนวนรอบที่กำหนด

$q$  คือจำนวนชุดของข้อมูลตัวอย่าง มี  $Q$  เป็นตัวกำหนด

$e^{(q)}$  คือค่าผิดพลาดของข้อมูลตัวอย่าง

$E$  คือค่าผิดพลาดรวมเฉลี่ยของข้อมูลตัวอย่าง

ขั้นตอนการเรียนรู้ของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับอ้างอิงจากรูปที่ 2.8 แบ่งเป็นขั้นตอนดังนี้

2.4.2.1 กำหนดจำนวนโหนดใน input layer(N), output layer(J), hidden layer(M) และ กำหนดจำนวนข้อมูล input และ output จากนั้นกำหนดจำนวนรอบสูงสุดที่จะทำการเรียนรู้(R) รวมถึงค่าผิดพลาดที่ยอมรับได้

2.4.2.2 กำหนดพารามิเตอร์ของอัตราการเรียนรู้ ( $\eta$ ) ที่อยู่ในช่วง [0, 1]

2.4.2.3 สุ่มน้ำหนักเริ่มต้นให้ทุกเส้นเชื่อมโยงในโครงข่ายทั้ง 2 ชั้น โดยให้มีค่าอยู่ระหว่าง [-1,1]

2.4.2.4 รับค่า input เพื่อหาค่า output

2.4.2.5 คำนวณค่าผลรวมใน hidden layer( $S_m$ ) ก่อนทำการปรับค่ารวมด้วยฟังก์ชัน กระตุ้น (Activation Function) ฟังก์ชันซิกมอยด์ ซึ่งจะได้ค่าใน hidden layer ที่อยู่ในช่วง [0,1] โดยมีรายละเอียดดังสมการที่ 2.25 - 2.27

Output ของ hidden layer ก่อนทำการปรับค่ามีค่าดังสมการที่ 2.25

$$S_m = \sum_{n=1}^N x_n * w_{nm} \quad (2.25)$$

Output ของ hidden layer หลังทำการปรับค่ามีค่าดังสมการที่ 2.26

$$y_m = f(S_m) \quad (2.26)$$

ฟังก์ชันที่ใช้ปรับค่า

$$f(x) = \frac{1}{1+e^{-x}} \quad (2.27)$$

2.4.2.6 คำนวณค่า output ใน output layer ด้วยสมการที่ 2.28 จากนั้นปรับค่าผลรวม ด้วยฟังก์ชันซิกมอยด์ดังสมการที่ 2.27 ซึ่งจะได้ค่าใน output layer อยู่ในช่วง [0,1] สำหรับผลลัพธ์ ใน output layer หลังทำการปรับค่าจะแสดงดังสมการที่ 2.29

$$v_j = \sum_{m=1}^M y_m * w_{mj} \quad (2.28)$$

Output ของ output layer หลังทำการปรับค่ามีค่าดังสมการที่ 2.29

$$z_j = f(v_j) \quad (2.29)$$

2.4.2.7 หาค่าความผิดพลาดของ output layer และปรับน้ำหนัก โดยการนำ output ที่ คำนวณได้เปรียบเทียบกับ output ที่กำหนดไว้ เพื่อหาค่าความผิดพลาด ถ้าค่าความผิดพลาด มากกว่าที่ยอมรับได้จะทำการปรับน้ำหนักตามสมการที่ 2.31,2.32 แต่ถ้าค่าความผิดพลาดน้อยกว่าที่ ยอมรับได้โครงข่ายจะรับข้อมูลชุดต่อไปเข้ามา แล้วกลับไปทำข้อ 2.4.2.5 แต่ถ้าเป็นข้อมูลชุดสุดท้าย ของข้อมูลนั้นจะไปทำข้อ 2.4.2.8

สามารถหาค่าความผิดพลาดได้จากสมการที่ 2.30

$$e^{(q)} = \frac{1}{2} \sum_{j=1}^J t_j^{(q)} - z_j^{(q)} \quad (2.30)$$

การปรับน้ำหนักระหว่างโหนดใน hidden layer และ output layer ตามสมการที่ 2.31

$$w_{mj}^{(r+1)} = w_{mj}^{(r)} \eta \{ (t_j^{(q)} - z_j^{(q)}) * [z_j^{(q)}(1 - z_j^{(q)})] * y_m^{(q)} \} \quad (2.31)$$

การปรับน้ำหนักระหว่างโหนดใน input layer และ hidden layer ตามสมการที่ 2.32

$$w_{nm}^{(r+1)} = w_{nm}^{(r)} \eta \left\{ \sum_{j=1}^J (t_j^{(q)} - z_j^{(q)}) [z_j^{(q)}(1 - z_j^{(q)})] w_{mj}^{(r)} \right. \\ \left. [* y_m^{(q)}(1 - y_m^{(q)})] [x_n^{(q)}] \right\} \quad (2.32)$$

2.4.2.8 คำนวณค่าผิดพลาดรวมเฉลี่ย (Mean Squared Error : MSE) ในทุกๆ แลวข้อมูล

โดยนำความผิดพลาดของแต่ละแลวของชุดข้อมูลมารวมกัน แล้วทำการหาค่าเฉลี่ย เพื่อใช้ในการตรวจสอบว่าผลลัพธ์ของทุกๆ ข้อมูลในแต่ละรอบนั้นมีค่าน้อยกว่าค่าผิดพลาดที่ยอมรับได้หรือไม่ ถ้าค่าความผิดพลาดนั้นยอมรับได้ให้จบกระบวนการ แต่ถ้าค่าความผิดพลาดเฉลี่ยมากกว่าค่าที่ยอมรับได้ให้ตรวจสอบว่าได้ทำการเรียนรู้ครบจำนวนที่กำหนดไว้หรือไม่ ถ้าครบให้จบการเรียนรู้ แต่ถ้าไม่ครบให้กลับไปทำข้อ 2.4.2.4 ใหม่ซึ่งก็คือเริ่มต้นการเรียนรู้รอบใหม่

การหาค่าผิดพลาดรวมเฉลี่ยหาได้ดังสมการที่ 2.33


$$E = \frac{1}{Q} \sum_{q=1}^Q e^{(q)} \quad (2.33)$$

### 2.4.3 Recurrent Neural Networks

Recurrent Neural Network เป็นโครงสร้างสำหรับใช้กับข้อมูลที่มีลักษณะเป็นลำดับ (Sequence) ซึ่งมาจากการปรับรูปแบบของ Neural Networks เพื่อให้สามารถนำ state หรือความรู้ก่อนหน้ามารวมกับ Input Data ตัวใหม่ที่เพิ่งรับเข้ามา โดยที่ส่วนสำคัญจะประกอบด้วย [16]

1.Hidden State ก่อนหน้า

2.Input Data ณ เวลาปัจจุบัน



รูปที่ 2.9 โครงสร้างของ Recurrent Neural Networks

โดยที่  $A = \text{hidden layer}$

และ  $h_t = \text{output จาก RNN ที่เวลา } t$

และ  $x_t = \text{input data ที่เวลา } t$

และ  $y_t = \text{hidden state ที่เวลา } t$

จากรูปที่ 2.9 จะเห็นว่ามี loop ที่วนกลับเข้ามายัง Hidden layer ของ Neural Network เนื่องจากว่าสิ่งสำคัญของ Recurrent Neural Networks นี้ก็คือ hidden state ก่อนหน้าและ input data ณ ปัจจุบัน ดังนั้นประโยชน์ของ loop นี้ก็เพื่อนำ Hidden state ก่อนหน้ากลับมาใช้งาน และสามารถเขียนสมการได้ดังนี้

$$h_t = f_h(U_h h_{t-1} + W_h x_t + b_h) \quad (2.34)$$

$$y_t = f_y(W_y h_t + b_y) \quad (2.35)$$

โดยที่  $f_h$  คือ activation function ของ hidden layer (เช่น tanh หรือ sigmoid function)

$f_y$  คือ activation function ของ output layer (เช่น softmax function)

$W_h$  คือ weight matrix ของ hidden layer

$U_h$  คือ hidden-state-to-hidden-state matrix ( หรือ transition matrix)

## 2.5 Correlation Coefficient

เป็นการดูทิศทางความสัมพันธ์ระหว่างตัวแปร 2 ตัว โดยมี Correlation Coefficient ( $r$ ) หรือ ค่าสัมประสิทธิ์สหสัมพันธ์ เป็นตัวบ่งชี้ถึงความสัมพันธ์นี้ ซึ่งค่าสัมประสิทธิ์สหสัมพันธ์นี้จะมีค่าอยู่ระหว่าง -1.0 ถึง +1.0 ซึ่งหากมีค่าใกล้ -1.0 นั้นหมายความว่าตัวแปรทั้งสองตัวมีความสัมพันธ์กันอย่างมากในเชิงตรงกันข้าม หากมีค่าใกล้ +1.0 นั้นหมายความว่า ตัวแปรทั้งสองมีความสัมพันธ์กันโดยตรงอย่างมาก และหากมีค่าเป็น 0 นั้นหมายความว่า ตัวแปรทั้งสองตัวไม่มีความสัมพันธ์ต่อกัน สำหรับการพิจารณาค่าสัมประสิทธิ์สหสัมพันธ์โดยทั่วไปอาจใช้เกณฑ์ดังนี้

ค่า $r$	ระดับของความสัมพันธ์
.90 - 1.00	มีความสัมพันธ์กันสูงมาก
.70 - .90	มีความสัมพันธ์กันในระดับสูง
.50 - .70	มีความสัมพันธ์กันในระดับปานกลาง
.30 - .50	มีความสัมพันธ์กันในระดับต่ำ
.00 - .30	มีความสัมพันธ์กันในระดับต่ำมาก


เครื่องหมาย +, - หน้าตัวเลขสัมประสิทธิ์สหสัมพันธ์จะบอกถึงทิศทางของความสัมพันธ์ โดยที่หาก

$r$  มีเครื่องหมาย + หมายถึงการมีความสัมพันธ์กันไปในทิศทางเดียวกัน (ตัวแปรหนึ่งมีค่าสูงอีกตัวหนึ่งจะมีค่าสูงไปด้วย)

$r$  มีเครื่องหมาย - หมายถึงการมีความสัมพันธ์กันไปในทิศทางตรงกันข้าม (ตัวแปรหนึ่งมีค่าสูงตัวแปรอีกตัวหนึ่งจะมีค่าต่ำ)

ซึ่งค่า Correlation Coefficient นี้จะคำนวณได้จากสมการที่ 2.36

$$r = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}} \quad (2.36)$$



รูปที่ 2.10 รูปแบบกราฟของข้อมูลที่มีค่า  $r$  เท่ากับ -0.90, -0.50, 0.00, 0.50, 0.90, 1.00

## 2.6 งานวิจัยที่เกี่ยวข้อง

2.6.1 Long-term asynchronous decoding of arm motion using electrocorticographic signals in monkeys. (Zenas C. Chao, Yasuo Nagasaka and Naotaka Fujii) [17]

เทคโนโลยี Brain – machine interface (BMI) เป็นการจับสัญญาณสมองเพื่อไปใช้ควบคุมอุปกรณ์เทียมหรือการสื่อสารโดยมีเป้าหมายเพื่อช่วยเหลือผู้ป่วยที่มีข้อจำกัด หรือไม่มีความสามารถในการเคลื่อนไหวด้วยตนเองได้ ซึ่งสัญญาณ Subdural electrocorticography (sECoG) เป็นรูปแบบที่มีแนวโน้มเหมาะสมสำหรับนำไปใช้งาน

ด้านการวิเคราะห์สัญญาณได้มีการคำนวณหา Time–frequency representation เพื่อนำไปใช้ทำนายการเคลื่อนไหวของลิง โดยใช้ Partial least squares regression สำหรับการทำนายค่าตำแหน่งการเคลื่อนไหวในแกน x,y และ z และใช้ค่า Correlation Coefficient (r) เป็นตัววัด Performance ของผลการทดลอง

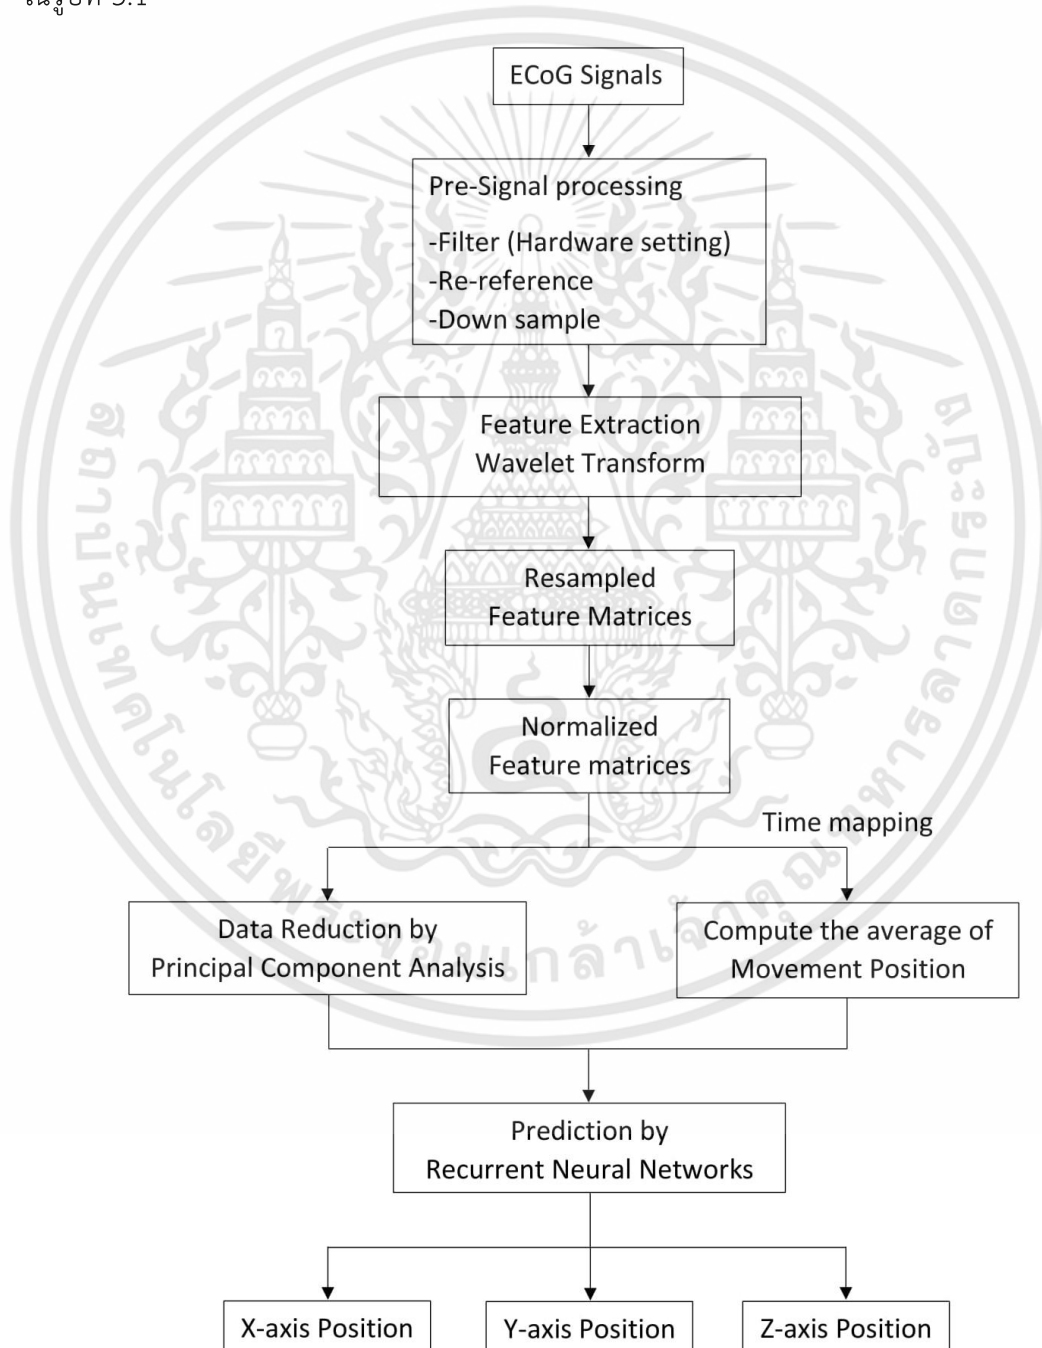
2.6.2 Decoding three-dimensional reaching movements using electrocorticographic signals in humans. (David T Bundy, Mrinal Pahwa, Nicholas Szrama and Eric C Leuthardt) [18]

สัญญาณ ECoG ไม่เพียงแต่สามารถใช้ออตรหัสตำแหน่งการเคลื่อนไหวที่ได้ ยังสามารถถอดรหัส kinematics (speed, velocity, and position) การเคลื่อนที่ของแขนใน 3 มิติได้ โดยในการทดลองจะเก็บข้อมูลจากผู้ป่วยที่เป็นโรคลมชักห้าคนแล้วทำการวิเคราะห์สัญญาณแบบออฟไลน์โดยใช้ Logistic Regression model และ Partial Least Squares Regression model ในการสร้าง machine learning และใช้ค่า Correlation Coefficient (r) แสดง Performance ของการทดลอง

### บทที่ 3

## วิธีดำเนินงานวิจัย

บล็อกไดอะแกรมพื้นฐานของการวิเคราะห์สัญญาณในงานวิจัย Prediction of arm motion using electrocorticographic signals in monkeys ประกอบด้วยสัญญาณอินพุต (ECoG), Pre-processing, Data Reduction, Position processing, Recurrent Neural Networks ดังที่แสดงในรูปที่ 3.1



รูปที่ 3.1 Prediction processing diagram

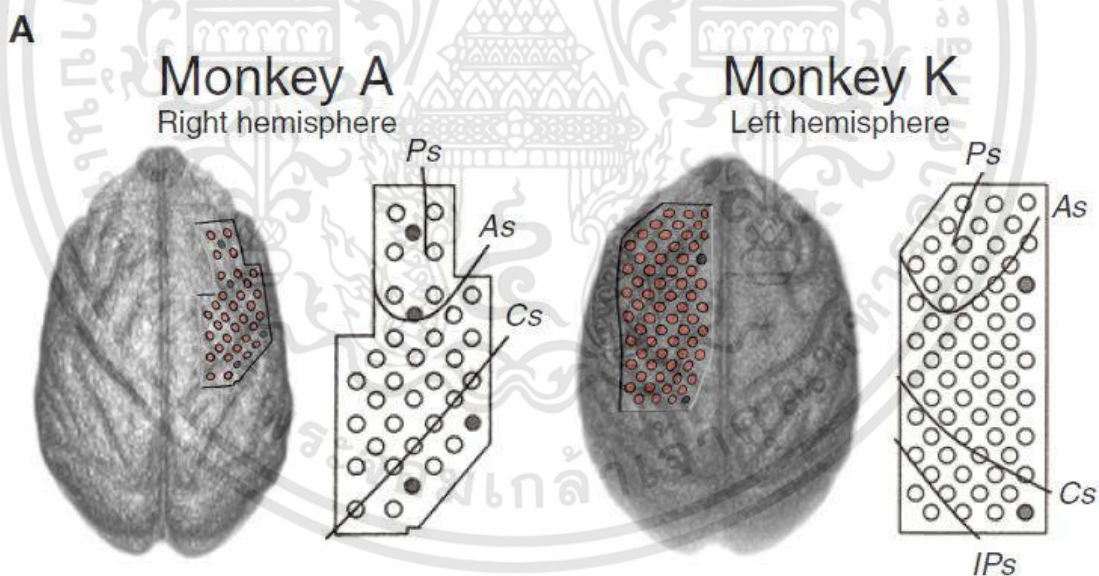
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.1 Data Set

ในงานวิจัยนี้ได้ทำการหีบยกข้อมูลจาก Neurotycho (Chao ZC, Nagasaka Y, Fujii N.)[15] . มาประกอบการวิจัย ซึ่งสัญญาณนั้นได้มาจากลิงสองตัว โดยใช้ขั้วอิเล็กโทรด ECoG 32,64 Channel (Unique-Medical,Japan) ที่มีอิเล็กโทรดแพลตตินัม ขนาดเส้นผ่าศูนย์กลาง 2.1 มม. (เส้นผ่าศูนย์กลาง 1 มม. สัมผัสจากแผ่นซิลิโคน) 3.5 มิลลิเมตร ปลูกฝังอย่างถาวรในพื้นที่ Sub-epidural ของสมองซีกซ้ายที่ครอบคลุมพื้นที่จากเยื่อหุ้มสมอง prefrontal (PFC) ไปยังเยื่อหุ้มสมอง somatosensory หลัก (S1)[19]


ซึ่งคลื่นสัญญาณ ECoG และข้อมูลการเคลื่อนไหวของมือจะถูกบันทึกระหว่างการทดลอง โดยที่ข้อมูลของสัญญาณ ECoG จะถูกบันทึกด้วยอัตราการสุ่มตัวอย่าง 1 kHz และข้อมูลการเคลื่อนไหวจะถูกบันทึกด้วยอัตราการสุ่มตัวอย่าง 120 Hz

ในการทดลองแต่ละครั้งลิงจะถูกจัดให้นั่งบนเก้าอี้และหันหน้าไปทางผู้ทดลอง ลิงแต่ละตัวได้รับการฝึกฝนให้หีบอาหาร ซึ่งเคลื่อนไหวในรูปแบบ 3 มิติ ระยะเวลาของการทดสอบแต่ละครั้งคือ 15 นาที โดยที่ข้อมูลใน 10 นาทีแรกจะถูกใช้สำหรับการฝึกอบรรูปแบบการถอดรหัส (ข้อมูลการฝึกอบรร) และข้อมูลในระยะเวลา 5 นาทีสุดท้ายจะใช้สำหรับการตรวจสอบความถูกต้อง (ข้อมูลการตรวจสอบความถูกต้อง)

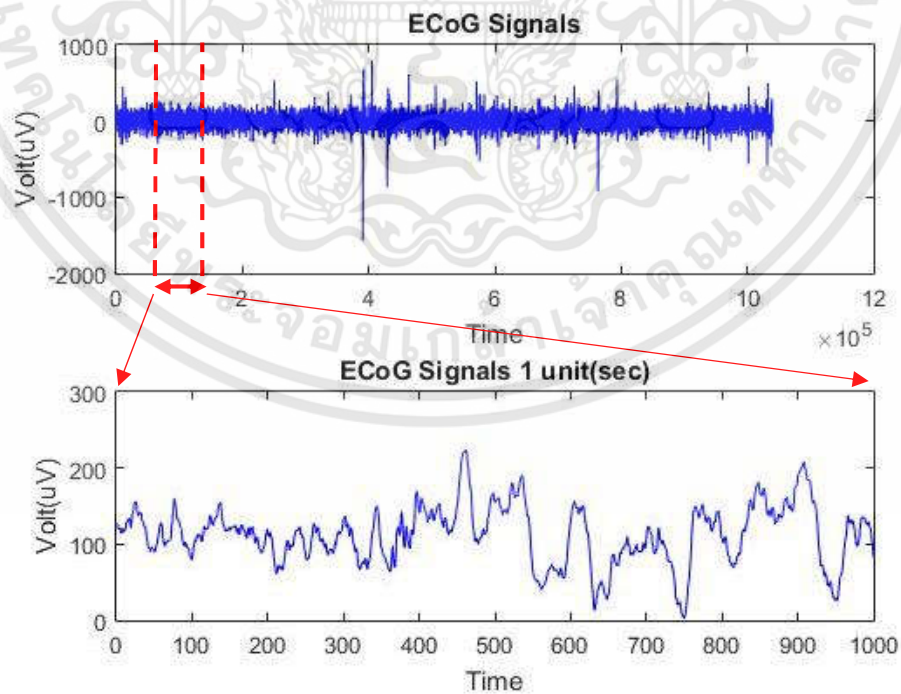


รูปที่ 3.2 ตำแหน่งอิเล็กโทรดบนสมองของลิงสองตัว (A และ K)

B

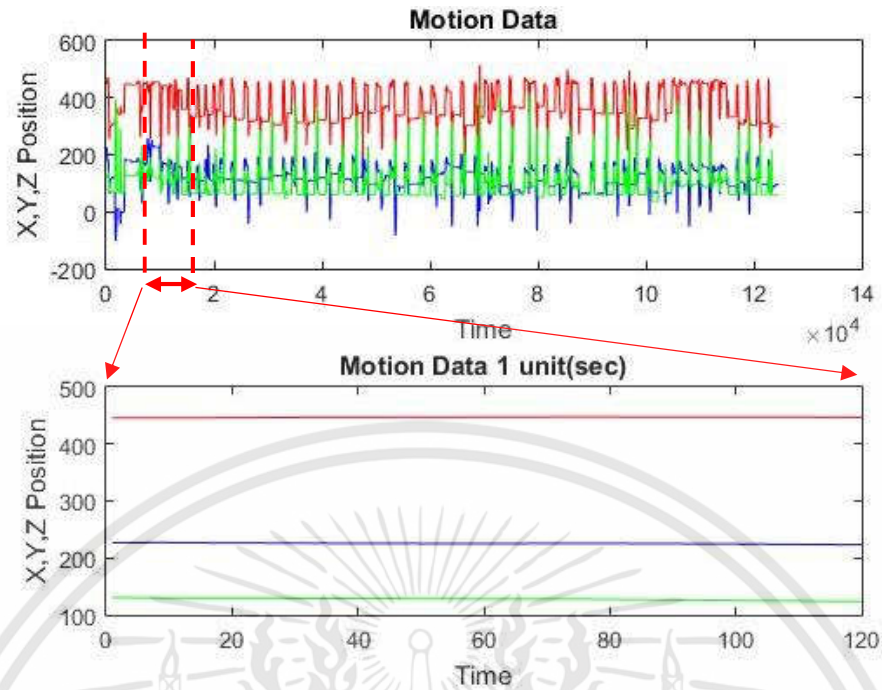


รูปที่ 3.3 พิกัดที่อยู่ตรงกลางของร่างกายสำหรับการวัดตำแหน่งมือ 3D ด้วยมุมมองจากด้านบน ข้อมูลทางการเคลื่อนไหวถูกบันทึกด้วยอัตราการสุ่มตัวอย่าง 120 Hz ในขณะที่สัญญาณ ECoG ถูกบันทึกด้วยอัตราการสุ่มตัวอย่าง 1 kHz นั้นแปลว่าใน 1 unit ของการเคลื่อนที่ซึ่งนับเป็นช่วงเวลา 1 sec จะมีค่าสัญญาณ ECoG 1000 ค่า และมีข้อมูลทางการเคลื่อนไหว 120 ค่า แต่เนื่องจากว่าข้อมูลทางการเคลื่อนไหวเป็นตำแหน่งของการเคลื่อนที่ใน 3 มิติ ดังนั้นใน 1 unit หรือ 1 sec จะมี 3 Dimension สำหรับแทนค่าในแกน x,y และ z



รูปที่ 3.4 สัญญาณ ECoG มี 1000 ค่า ใน 1 unit หรือ 1 sec

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.5 Motion Data มี 120 ค่าใน 1 unit หรือ 1 sec

### 3.2 Pre-Processing

สัญญาณ ECoG ถูกบันทึกด้วยอัตราการสุ่มตัวอย่าง 1 kHz ต่อช่องสัญญาณและกรองด้วยฟิลเตอร์ band-pass ตั้งแต่ 0.1-600Hz สัญญาณ ECoG แบบ Raw ถูกอ้างอิงใหม่ด้วยวิธี common average reference (CAR) เพื่อเป็นการเพิ่มค่า Signal to noise ratio ของสัญญาณ

3.2.1 วิธี CAR จะคำนวณค่าเฉลี่ยของทุกช่องสัญญาณและลบค่านี้ออกจากช่องสัญญาณที่เลือก [20] ซึ่งคำนวณตามสมการนี้

$$V_i^{CAR} = V_i^{ER} - \frac{1}{n} \sum_{j=1}^n V_j^{ER} \quad (3.1)$$

เมื่อ  $V$  คือ สัญญาณ ECoG

และ  $i$  คือ ลำดับของอิเล็กโทรด

และ  $n$  คือ จำนวนโหนดของอิเล็กโทรด

3.2.2 Down sample : 4 times เพื่อลดภาระทางการคำนวณ

ซึ่งจากเดิมสัญญาณ ECoG ถูกบันทึกด้วยอัตราการสุ่มตัวอย่าง 1 kHz หลังจากการ downsample จะได้ผลลัพธ์เป็นสัญญาณ ECoG ที่มีอัตราการสุ่มตัวอย่าง 250 Hz

ส่วนข้อมูลที่ระบุตำแหน่งการเคลื่อนไหวของลิงจะมีวิธีการเคลื่อนที่ใน 3 มิติ (X: ซ้าย - ขวา, Y: ข้างหน้า - ข้างหลัง, Z: ขึ้น - ลง) โดยอ้างอิงตำแหน่งข้อมือของมือที่หยิบอาหารด้วย *Sagittal Plane* (รูปที่ 3.3)

### 3.3 Feature Extraction

#### 3.3.1 Discrete Wavelet Transform (DWT)

ในงานวิจัยชิ้นนี้ได้ทำการหดยิบยกการแปลงเวฟเล็ตแบบเต็มหน่วยมาใช้ในขั้นตอน Feature Extraction เพียงอย่างเดียว และได้นำค่า Wavelet Coefficient มาใช้เป็น Feature สำหรับการวิเคราะห์ ซึ่งจะคำนวณหาได้จากสมการที่ 3.2

$$DWT(m, n) = \frac{1}{\sqrt{2^m}} \sum_k f(k) \varphi \frac{n-k2^m}{2^m} \quad (3.2)$$

เมื่อ  $m, n, k$  เป็นเลขจำนวนเต็มโดยที่

$n$  คือ จำนวนข้อมูล

$m$  คือ เลขแสดงการเปลี่ยนแปลงของสเกล

$k$  คือ เลขแสดงการเลื่อนตำแหน่ง

โดยแทนที่  $f(k)$  ด้วยสัญญาณ ECoG และกำหนดค่า scale level = 3 ซึ่งจะได้ Frequency bin เท่ากับ 8 สเกล โดย Mother wavelet ที่ใช้เป็นชนิดที่เรียกว่า Morlet Wavelet ในการแปลงเวฟเล็ตนั้นฟังก์ชันเวฟเล็ตจะทำหน้าที่คล้ายคลึงกับฟังก์ชันหน้าต่างของ STFT ส่วนสเกลก็จะทำหน้าที่คล้ายกับความถี่ ซึ่งผลที่ได้ออกมาใน 1 unit จะมีข้อมูลจากการสเกล 8 สเกล

#### 3.3.2 Resampled and Normalized Feature matrices

จากการ Down Sample จนเหลือ Sampling Rate = 250 Hz จากหัวข้อที่ 3.2.2 หมายความว่าใน 1 unit หรือ 1 sec จะมี 250 ค่าและเมื่อผ่าน DWT จะได้ข้อมูลจากการสเกล 8 สเกล ดังนั้น Coefficient Matrices จะมีขนาด 8x250

เนื่องจาก Feature ที่คำนวณได้จาก DWT ยังคงมีจำนวนข้อมูลที่มากจึงได้ทำการ resampled ค่าทางเวลาด้วยการคำนวณหา Simple Moving Average (SMA) เป็นเวลา 25 time lags ต่อ 1 unit(sec)

นั่นหมายความว่า หลังจากการ resampled แล้ว Feature ทางเวลาจะเหลือเพียงแค่ 25 ค่า ในช่วง 1 unit หรือ 1 sec รวมกับข้อมูลจากการสเกล 8 สเกล จึงกลายเป็น Feature เมทริกซ์ที่มีขนาด 8x25 โดยจะคำนวณได้ตามสูตรที่ 3.3

$$SMA = \frac{A_1 + A_2 + \dots + A_N}{N} \quad (3.3)$$

โดยที่  $A_N$  เป็นค่าเฉลี่ยในช่วงเวลาที่  $N$

$N$  เป็นจำนวนของช่วงเวลาที่ต้องการคำนวณ

จากนั้น Resampled Matrices นี้จะถูกนอร์มอลไรซ์โดยการคำนวณ Z Standard Score ที่แต่ละช่องความถี่ ดังนั้นจึงมีการซ้อนทับกันกับช่องความถี่ที่แตกต่างกัน ตามที่ 3.4

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นอนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะโดยใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$z = \frac{x - \bar{x}}{s} \quad (3.4)$$

โดยที่  $x$  คือข้อมูลที่จะทำการนอร์มอลไรซ์

และ  $\bar{x}$  คือค่าเฉลี่ยของข้อมูล

และ  $s$  คือ Standard Deviation (ค่าเบี่ยงเบนมาตรฐาน)

### 3.4 Principal Component Analysis

เนื่องจากข้อมูลที่ว่า จะทำการ resampled จนมิติของข้อมูลใน 1 unit มีขนาดลดลงเหลือเป็นเมทริกซ์ขนาด  $8 \times 25$  แล้ว ซึ่งข้อมูลชุดต้นแบบการเรียนรู้ที่ถูกบันทึกเป็นเวลา 10 นาที (1 Channel) จะมีค่าเป็น  $8 \times 15000$  แต่เพราะอิเล็กทรอนิกส์ที่ใช้เป็นแบบ 32,64 Channel เมทริกซ์ข้อมูลจึงกลายเป็น  $256 \times 15000$  และ  $512 \times 15000$  ตามลำดับ ดังนั้นข้อมูลที่ได้ยังคงเป็น high-dimensional data ดังนั้นเพื่อไม่ให้เป็นการคำนวณและลดการเกิด over fitting ในขั้นตอน prediction (Neural Networks) จึงต้องลดจำนวนข้อมูลลง

ในงานวิจัยฉบับนี้ได้นำเอาวิธี Principal Component Analysis มาใช้ โดยมีวิธีอยู่ว่าจะต้องคำนวณหาค่า Eigenvalues และ Eigenvectors ของข้อมูลเพื่อนำไปใช้งาน ซึ่งได้มาจากการคำนวณค่าของ Resampled Matrices มีขั้นตอนการคำนวณดังต่อไปนี้

ขั้นตอนที่ 1. รับค่า Resampled Matrices ที่คำนวณได้จากสัญญาณ  $I_1, I_2, \dots, I_M$  (ข้อมูลต้นแบบการเรียนรู้) และแสดงให้ในรูปเวกเตอร์  $\Gamma_i$

ขั้นตอนที่ 2. คำนวณหาเวกเตอร์ของค่าเฉลี่ย  $\Psi$  ของแต่ละ Channel ตามสมการที่

$$\Psi = \frac{1}{M} \sum_{i=1}^M \Gamma_i \quad (3.5)$$

ขั้นตอนที่ 3. นำเวกเตอร์  $\Gamma_i$  ของข้อมูลมาลบด้วยค่าเฉลี่ย  $\Psi$

$$\phi_i = \Gamma_i - \Psi \quad (3.6)$$

ขั้นตอนที่ 4. คำนวณหาเมทริกซ์โควาเรียนซ์  $C$

$$C = \frac{1}{M} \sum_{n=1}^M \phi_n \phi_n^T = AA^T \quad (3.7)$$

เมื่อ  $A = [\phi_1 \ \phi_2 \ \dots \ \phi_M]$  (3.8)

$$\text{หรือก็คือ } C = \begin{pmatrix} \text{cov}(x, x) & \text{cov}(x, y) & \text{cov}(x, z) \\ \text{cov}(y, x) & \text{cov}(y, y) & \text{cov}(y, z) \\ \text{cov}(z, x) & \text{cov}(z, y) & \text{cov}(z, z) \end{pmatrix} \quad (3.9)$$

ขั้นตอนที่ 5. คำนวณหา Eigenvectors  $v_i$  ของเมทริกซ์  $AA^T$  (เมทริกซ์  $AA^T$  มีขนาดที่ใหญ่เกินไป ไม่ควรนำไปใช้งานจริง)

$$A^T A v_i = u_i v_i \quad (3.10)$$

ขั้นตอนที่ 6. เก็บเฉพาะค่า Eigenvectors  $K$  (เป็น EigenValues ที่ชี้เฉพาะค่าเฉพาะ) [14]

เมื่อได้ Eigenvalues มาแล้วจึงนำมาคำนวณ Percent Confident เพื่อที่จะเลือกเฉพาะ Eigenvalues ที่มีผลต่อภาพรวม เนื่องจากค่าปลายๆของ Eigenvalues จะมีค่าน้อยมากๆ ซึ่งค่าเหล่านี้จะไม่มีผลต่อข้อมูลในภาพรวม จึงสามารถทำการตัดทิ้งได้โดยไม่ส่งผลกระทบต่อ

ในงานวิจัยนี้ได้เลือกใช้ค่า Percent Confident ที่ 95% ค่า Eigen ของข้อมูลที่ได้มาจะกลายเป็น Eigen basis ข้อมูลต้นแบบการเรียนรู้ การลดจำนวนข้อมูลจะทำได้โดยการนำข้อมูลตั้งต้นมาทำการโปรเจกชันกับ Eigen basis ที่ได้ตามสมการที่ ผลลัพธ์ที่ออกมาจะเป็นเมทริกซ์ของข้อมูลผ่านการ Reduction แล้ว ซึ่งจะทำให้นำข้อมูลนี้ไปใช้ในขั้นตอนการทำนายต่อไป

$$proj_v u = \left( \frac{u \cdot v}{\|v\|^2} \right) v \quad (3.11)$$


เมื่อ  $u$  คือสัญญาณที่จะนำมา Project

$v$  คือ EigenValues

### 3.5 Movement Position

เนื่องจากว่าในกระบวนการก่อนหน้านี้สัญญาณ ECoG ได้ผ่านการ Down sample มาแล้ว ดังนั้นข้อมูลทางการเคลื่อนไหวจึงต้องมีการ mapping เวลาใหม่ โดยจะ mapping ตามเวลาที่ถูกลดทอนของสัญญาณ ECoG

จากที่กล่าวไว้ข้างต้นว่า Sampling Rate ของสัญญาณ ECoG และ Motion Data นั้นมีค่าไม่เท่ากัน เพื่อให้ง่ายต่อการ predict ในงานวิจัยชิ้นนี้จึงได้ทำการปรับให้ Output ใน 1 unit(sec) มีอัตราส่วนที่เท่ากับ Input โดยที่ Input คือข้อมูลผ่านการ Reduct จาก PCA แล้ว ส่วน Output นั้นได้ทำการคำนวณใหม่ด้วยการหา Simple Moving Average ซึ่งคำนวณได้จากสูตรที่ 3.3



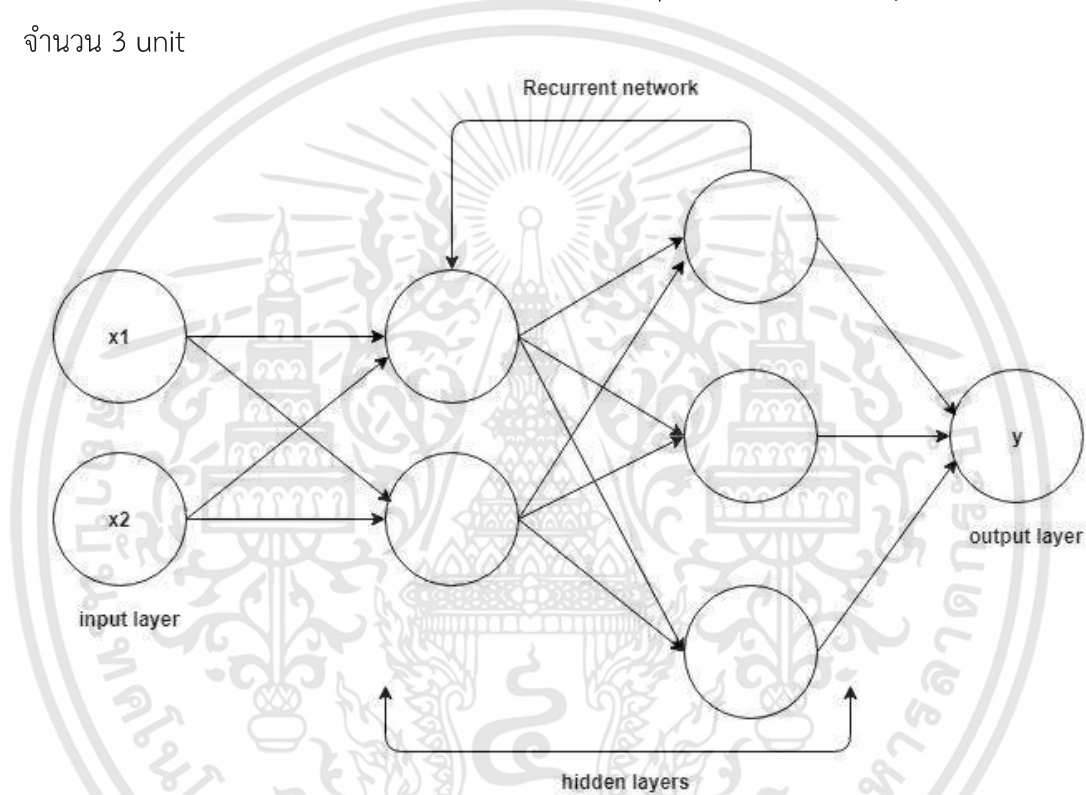
รูปที่ 3.6 ค่า Movement Position ของแกน x,y และ z

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.6 Recurrent Neural Network

สำหรับขั้นตอน Prediction ซึ่งขั้นตอนการ predict โดยใช้ข้อมูล ECoG มาทำนายการเคลื่อนไหวของลิงที่ทดสอบการหยิบจับอาหาร ซึ่งข้อมูลส่วน input ของต้นแบบการเรียนรู้จะเป็นข้อมูลของสัญญาณ ECoG ที่ผ่านกระบวนการก่อนหน้านี้นี้มาแล้ว

ก่อนจะสามารถ predict ค่าใดๆได้จำเป็นต้องทำการฝึกสอน (Training) เพื่อสร้างระบบที่สามารถเรียนรู้และตัดสินใจได้เอง ในงานวิจัยชิ้นนี้ได้นำเอาอัลกอริทึมของ Recurrent Neural Networks มาใช้ โดยได้ทำการแยก Neuron สำหรับการ predict ค่าในแกน x,y และ z แยกกันเป็นจำนวน 3 unit



รูปที่ 3.7 Recurrent Neural Networks

จากรูปที่ 3.7 ค่าที่ใส่เข้าไปในส่วนของ input layer จะเป็น output ที่ได้จาก PCA ค่า n จะเท่ากับจำนวน Eigen basis ที่ได้จาก PCA และเนื่องจากข้อมูลที่เราต้องการให้ predict เป็นข้อมูลตำแหน่งการเคลื่อนไหว 3 มิติจึงต้องมีข้อมูล Output เป็น 3 factor แต่เพื่อให้ Neuron ทำงานได้อย่างมีประสิทธิภาพจึงทำการแยก Neuron สำหรับการ predict ค่าในแต่ละแกน

ซึ่งถ้าใช้ input เป็นข้อมูลของสัญญาณที่ได้จาก PCA เพียงอย่างเดียวจะหมายความว่า Neural Networks ใช้ input จากในปัจจุบันเท่านั้น ซึ่ง RNN จะมีการนำผลลัพธ์ในอดีตมารวมด้วย หรือก็คือ output จาก state ก่อนหน้า ในที่นี้จะเป็นค่า Position ของแกน x,y และ z

โดยค่าที่นำมาใช้จากในอดีตย้อนกลับไป 1 state จะเรียกว่า 1 timestep โดยที่เราสามารถย้อนกลับไปมากกว่า 1 timestep ก็ได้ เนื่องจากว่า output ในอดีตจะช่วยส่งผลให้การ predict ผลลัพธ์ในอนาคตได้ดีมากยิ่งขึ้น และสามารถคำนวณผลลัพธ์ของ RNN ได้จากสมการต่อไปนี้

$$h_t = f_h(U_h h_{t-1} + W_h x_t + b_h) \quad (3.12)$$

$$y_t = f_y(W_y h_t + b_y) \quad (3.13)$$

โดยที่  $f_h$  คือ activation function ของ hidden layer (เช่น tanh หรือ sigmoid function)

$f_y$  คือ activation function ของ output layer (เช่น softmax function)

$W_h$  คือ weight matrix ของ hidden layer

$U_h$  คือ hidden-state-to-hidden-state matrix ( หรือ transition matrix)

หลังจาก Training แล้วจึงเป็นการนำโมเดลไปใช้งานซึ่งก็คือการ Test โดยอินพุทที่ใช้จะเป็นสัญญาณ ECoG ที่ผ่านการ Processing ตามขั้นตอนที่กล่าวไปก่อนหน้านี้และส่วนของ Movement Position จะเป็นการสุ่มขึ้นมาเพื่อจำลองเป็นค่าของสองสเตจก่อนหน้าซึ่งก็คือค่าของเวลา t-1 และ t-2 เมื่อใส่อินพุทเข้าไปในโมเดลผลที่ได้ออกมาก็จะเป็นส่วนของ Internal stage ที่จะนำไปใช้เพื่อทำนายค่าของช่วงเวลาถัดไป

จากนั้นคำนวณหาค่า Correlation Coefficient ( $r$ ) ของข้อมูลชุดต้นแบบการเรียนรู้กับข้อมูลที่ทำนายได้ เพื่อดูว่าสิ่งที่ทำนายออกมาเป็นไปในทิศทางเดียวกับต้นแบบหรือไม่ โดยคำนวณตามสมการที่ 3.14

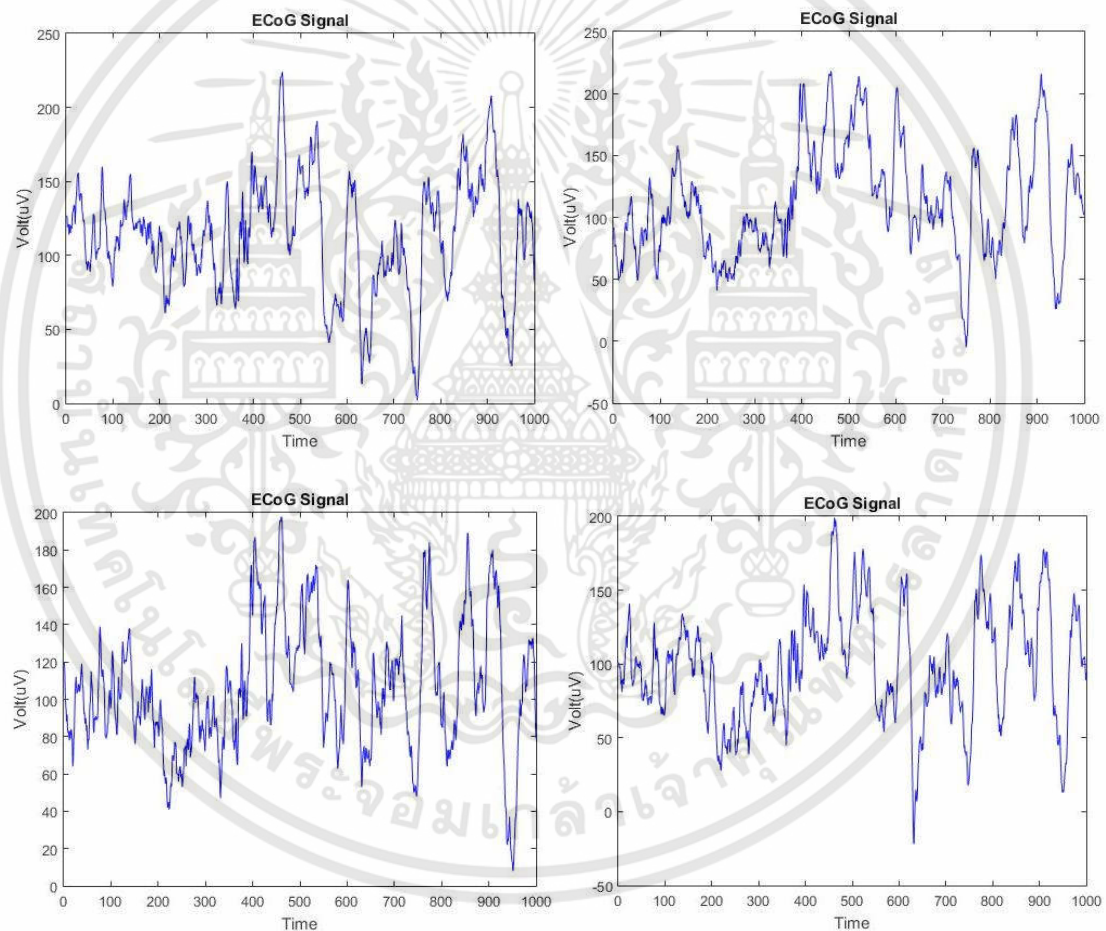
$$r = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}} \quad (3.14)$$

## บทที่ 4

### ผลการทดลอง

#### 4.1 Electrocorticographic (ECoG)

ข้อมูลสัญญาณ ECoG ของลิงระหว่างการทดลองที่ถูกบันทึกด้วยด้วยอัตราการสุ่มตัวอย่าง 1 kHz ต่อช่องสัญญาณและกรองด้วยฟิลเตอร์ band-pass ตั้งแต่ 0.1-600Hz (เป็นการตั้งค่าด้วยอุปกรณ์เก็บข้อมูล) โดยใช้อิเล็กทรอนิกส์ 32, 64 Channel ซึ่งตัวอย่างของสัญญาณ ECoG ที่บันทึกได้สามารถดูได้จากในรูปที่ 4.1



รูปที่ 4.1 ตัวอย่างข้อมูลสัญญาณ ECoG ที่บันทึกได้จาก 4 ช่องสัญญาณใน 1 unit(sec)

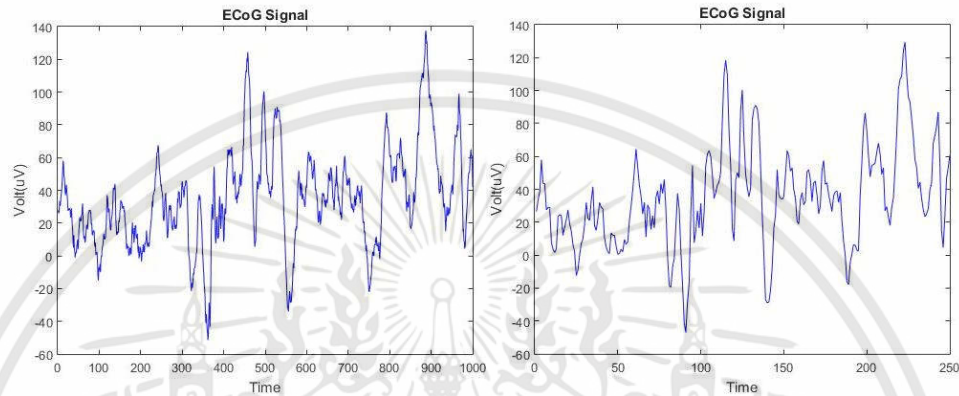
#### 4.2 Pre-Processing

##### 4.2.1 Signal to noise ratio

เพื่อเป็นการลดคลื่นรบกวน (Noise) จึงต้องเพิ่มอัตราส่วนของสัญญาณต่อสัญญาณรบกวน ดังนั้นสัญญาณจะถูกอ้างอิงใหม่ด้วยวิธี common average reference (CAR)

#### 4.2.2 Down Sample

เนื่องจากว่าสัญญาณคลื่นสมองถูกบันทึกด้วยด้วย Sampling rate 1 kHz นั้นแปลว่าในเวลา 1 sec จะมีข้อมูลของสัญญาณ 1,000 ค่า โดยที่ใช้ข้อมูลใน 10 นาทีแรกเป็นข้อมูลต้นแบบการเรียนรู้ทั้งหมด 600,000 ค่า ซึ่งมากเกินไปและอาจสร้างภาระในการคำนวณ จึงต้องลดจำนวนด้วยการ Down Sample จนเหลือ Sampling rate เท่ากับ 250 Hz แทน หมายความว่าข้อมูลจะเหลือแค่ 250 ต่อ 1 unit (sec)

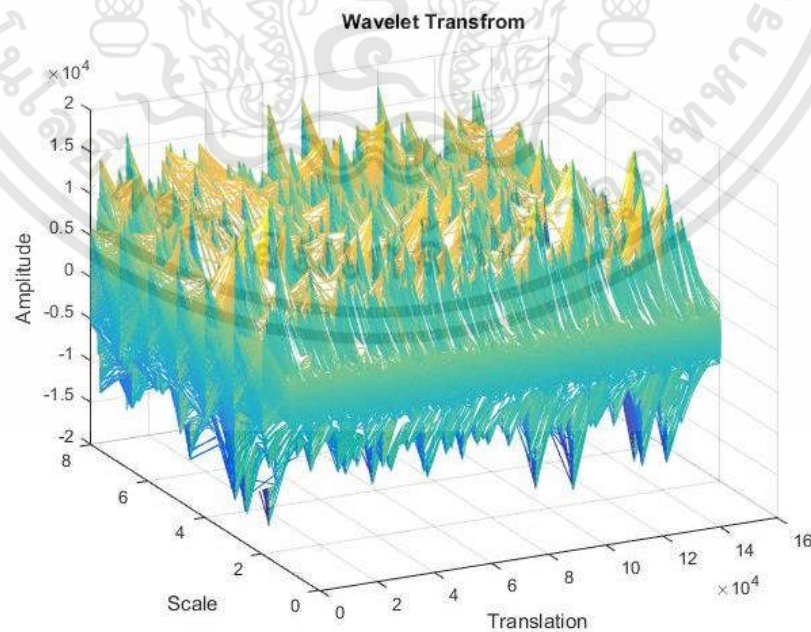


รูปที่ 4.2 สัญญาณ ECoG ใน 1 unit(sec) ที่ผ่าน CAR และ Down sample ตามลำดับ

#### 4.3 Feature Extraction

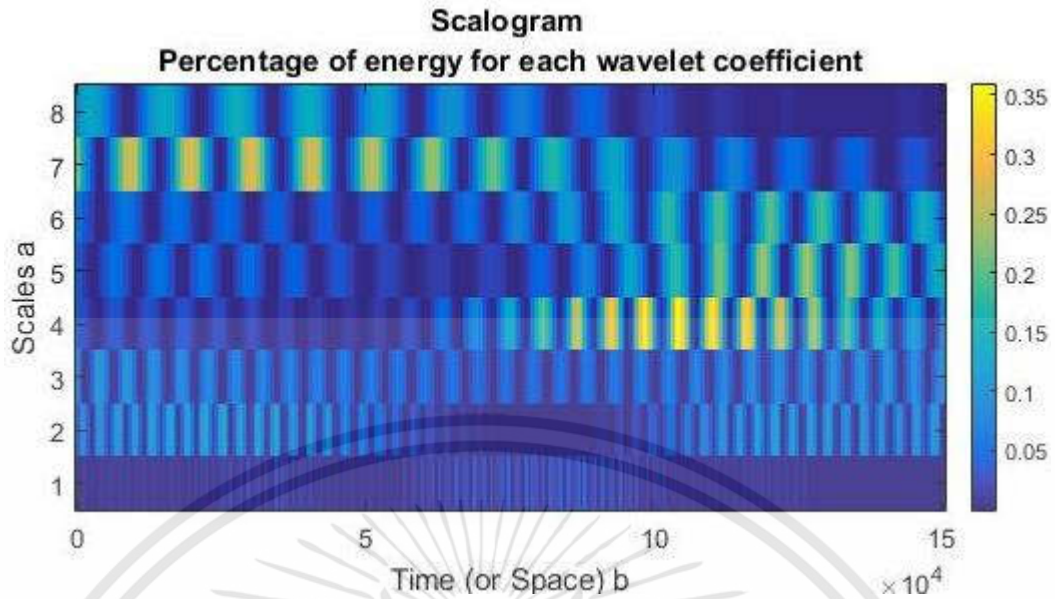
##### 4.3.1 Discrete Wavelet Transform (DWT)

การแปลงเวฟเล็ตแบบเต็มหน่วยโดยใช้ Mother wavelet ชนิด Morlet wavelet และ กำหนดค่า scale level = 3 ซึ่งจะได้ Frequency bin เท่ากับ 8 สเกล ได้ผลลัพธ์ในออกมาเป็น Wavelet Coefficient ดังรูปที่ 4.3 และ 4.4



รูปที่ 4.3 Wavelet Transform ของสัญญาณ 1 Channel

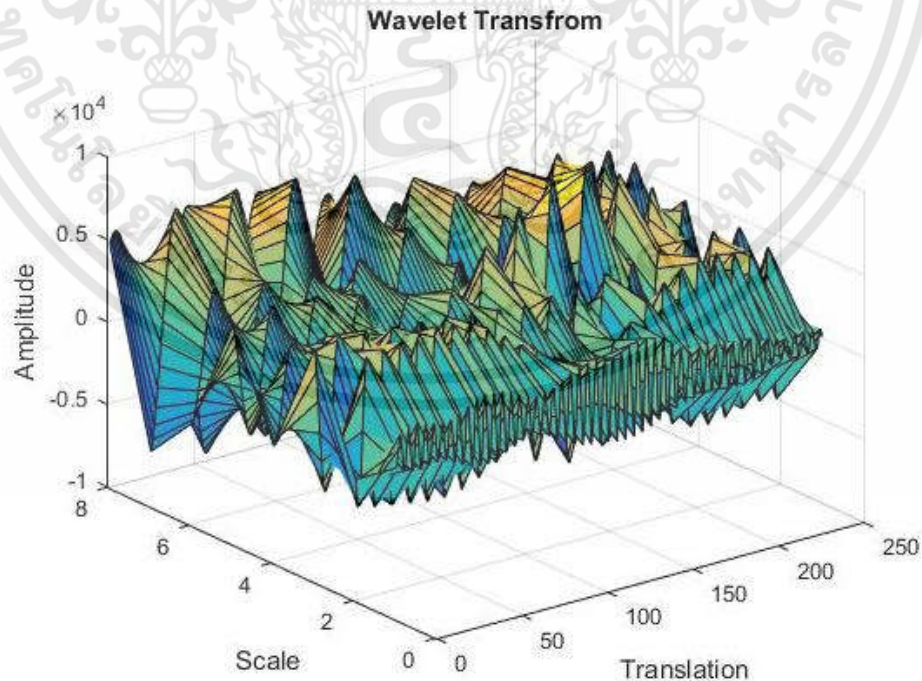
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.4 Wavelet Scalogram 1 unit(sec) ของสัญญาณ 1 Channel

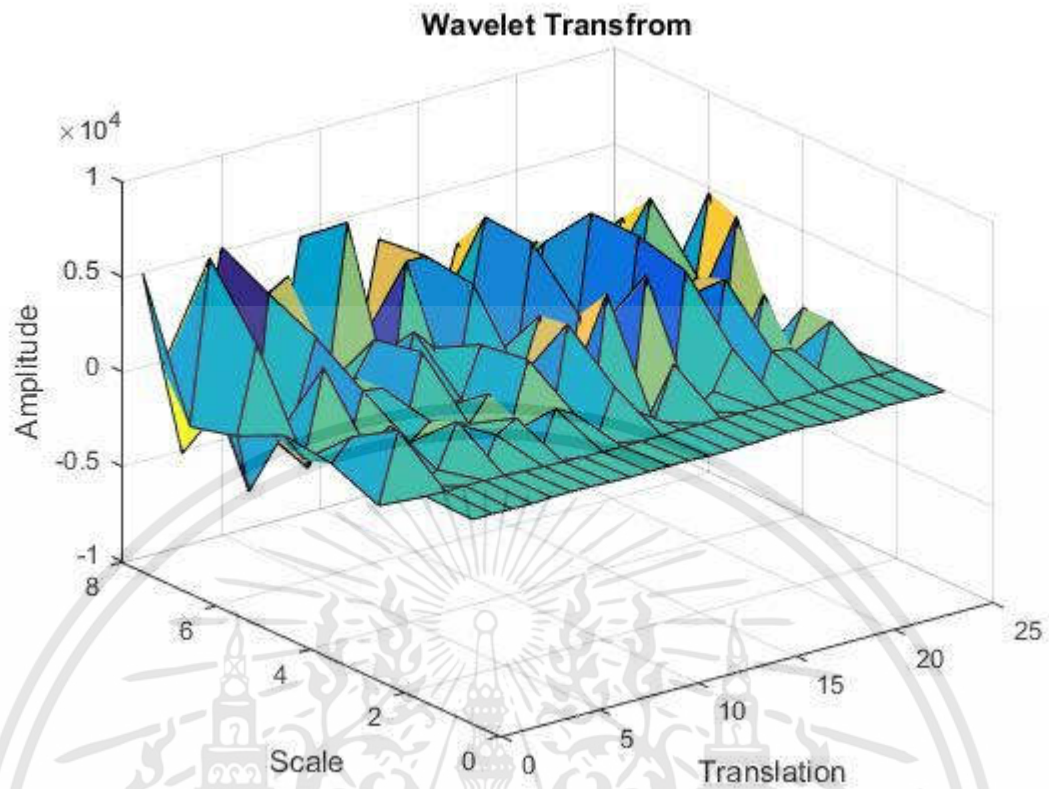
#### 4.3.2 Resampled at 25 time lags

จาก DWT ในหัวข้อที่ 4.3.1 จะได้ผลลัพธ์ใน 1 unit(sec) เป็น Amplitude ที่มีค่าจากการสเกล 8 ค่าและมีค่าทางเวลา 250 ค่า ดังในรูปที่ 4.5 การ Resampled at 25 time lags ของสัญญาณใน 1 unit หรือ 1 sec ทำได้ด้วยการหา Simple Moving Average โดยผลลัพธ์ที่ได้ออกมาเป็นเมทริกซ์ที่มีขนาด 8x25 ตามรูปที่ 4.6 ซึ่งเมื่อแสดงเป็นภาพ Scalogram จะมีลักษณะดังในรูปที่ 4.6 และเมื่อทำการนอร์มอลไรซ์ด้วยการคำนวณ Z Standard Score จะได้ผลลัพธ์เป็นรูปที่ 4.7

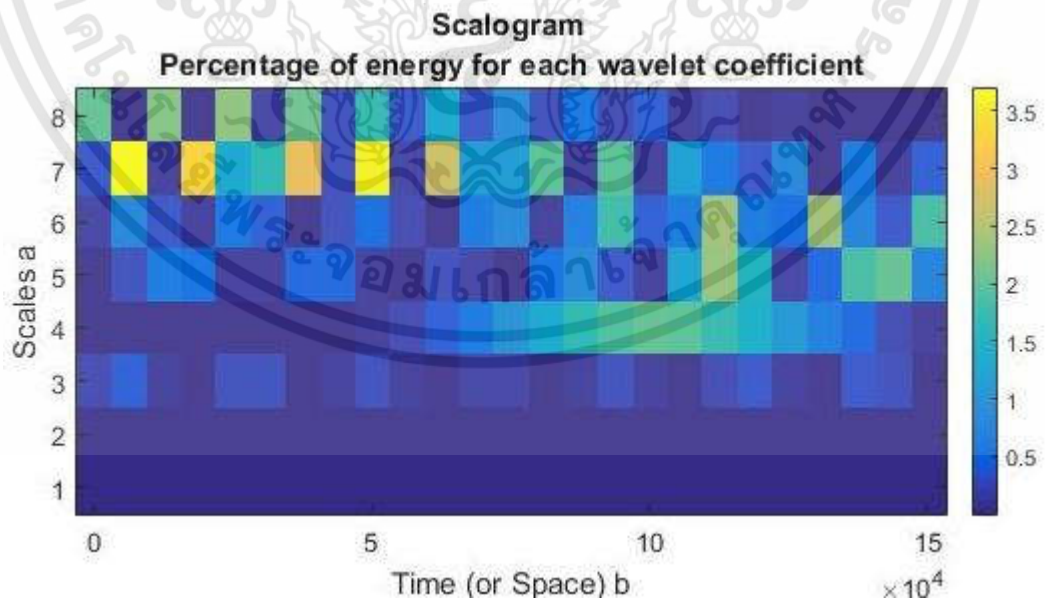


รูปที่ 4.5 Wavelet Coefficient 1 unit(sec) ของสัญญาณ 1 Channel

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

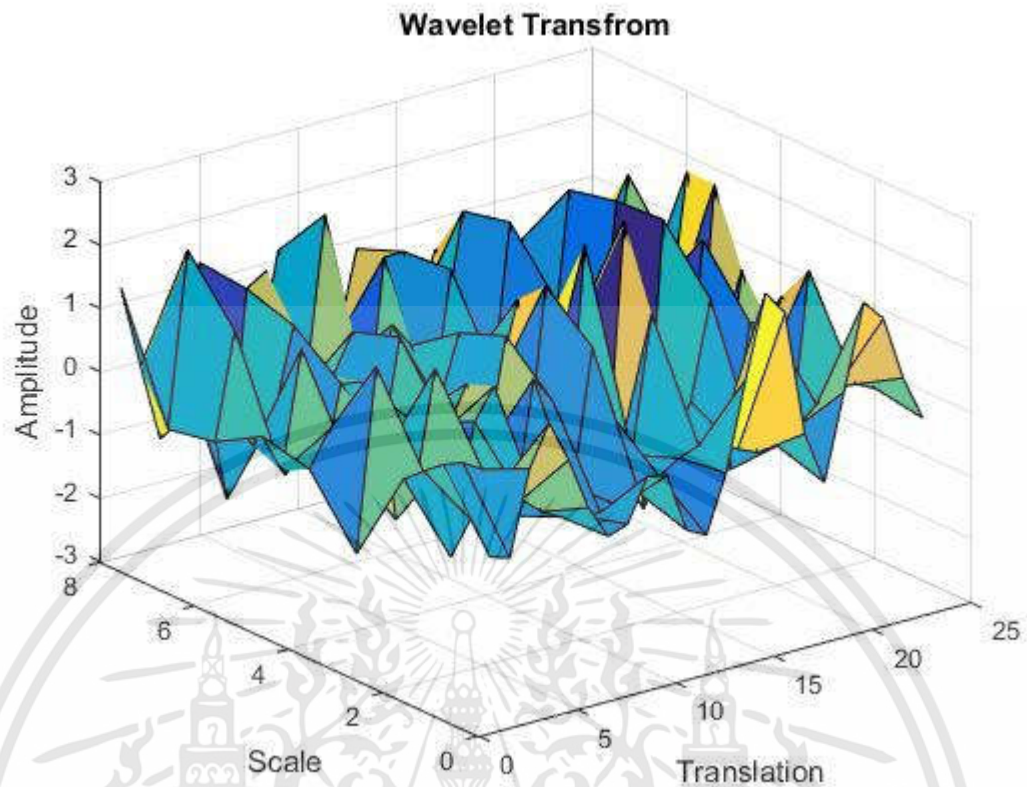


รูปที่ 4.6 Wavelet Coefficient 1 unit(sec) ที่ผ่านการ Resampled แล้วของสัญญาณ 1 Channel




รูปที่ 4.7 Wavelet Scalogram 1 unit(sec) ที่ผ่านการ Resampled แล้วของสัญญาณ 1 Channel

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.8 Wavelet Coefficient 1 unit(sec) ที่ถูกนอร์มอลไรซ์แล้วของสัญญาณ 1 Channel

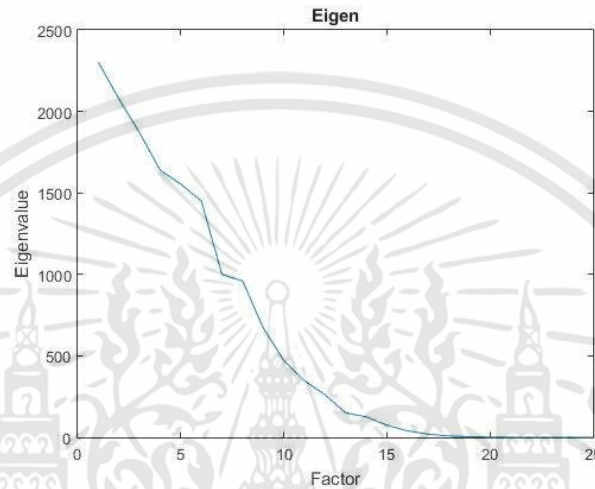


รูปที่ 4.9 Wavelet Coefficient 1 unit(sec) ที่ถูกนอร์มอลไรซ์แล้วของสัญญาณ 1 Channel

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

#### 4.4 Data Reduction

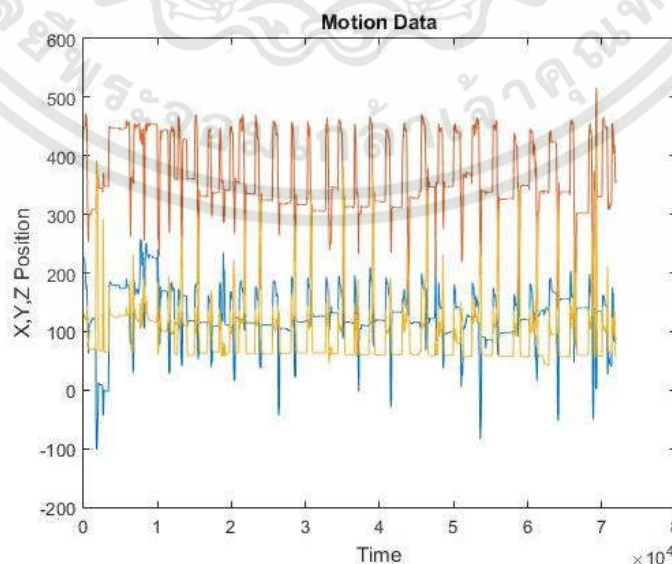
แม้ว่าจะทำการ Down sample และ Resampled สัญญาณมาแล้วก่อนหน้านี้ แต่เนื่องด้วยสัญญาณ ECoG นั้นถูกบันทึกด้วยอิเล็กทรอนิกส์หลายช่องสัญญาณจึงทำให้มีลักษณะข้อมูลเป็น high-dimensional data โดยมี Feature ใน 1 unit เมทริกซ์ขนาด  $8 \times 25$  ซึ่งเป็น Feature ทางความถี่และเวลาตามลำดับ จึงต้องลดจำนวนข้อมูลด้วยวิธี PCA ซึ่งต้องคำนวณหาค่า Eigen โดยที่คำนวณ Eigen เฉพาะของแต่ละช่องสัญญาณ



รูปที่ 4.10 Eigenvalues ที่คำนวณได้ของสัญญาณ 1 Channel

เมื่อได้ค่า Eigenvalues ออกมาแล้วจึงนำไปคิดค่า Percent Confident ที่ 95% ซึ่งจากการคำนวณจะได้ค่า Eigen ถึงค่าที่ 10 หมายความว่า Eigen basis ที่ได้จะมีได้เมนชั้นเป็น 10 มิติ จากนั้นนำข้อมูลแต่ละ Channel มา projected ลงบน Eigen basis ของแต่ละ Channel สุดท้ายจะเหลือ Feature เป็นเมทริกซ์ขนาด  $8 \times 10$  โดยลด Feature ทางเวลาจาก 25 factor เหลือเพียงแค่ 10 factor


#### 4.5 Movement Position



รูปที่ 4.11 Motion Data sampling rate = 120 Hz

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ในหัวข้อที่ 4.2.2 ก่อนหน้านี้สัญญาณ ECoG ผ่านการ Down sample ลง 4 ครั้ง ข้อมูลทางการเคลื่อนไหวจึงต้อง mapping เวลาใหม่และเนื่องจากสัญญาณ ECoG ผ่าน Data Reduction จนใน 1 unit หรือ 1 sec เหลือเพียง 10 factor ทางเวลา ข้อมูลทางการเคลื่อนไหวที่ต้องมีการ mapping ทางเวลาจึงต้องลดจำนวนลงเพื่อให้ง่ายต่อการเปรียบเทียบ จากเดิมที่มี 120 ค่าต่อ 1 unit(sec) จะถูก Resampled ใหม่ด้วยการคำนวณหา Simple Moving Average จนเหลือเพียง 10 ค่าต่อ 1 unit(sec) ได้ผลออกมาตามรูปที่ 4.12



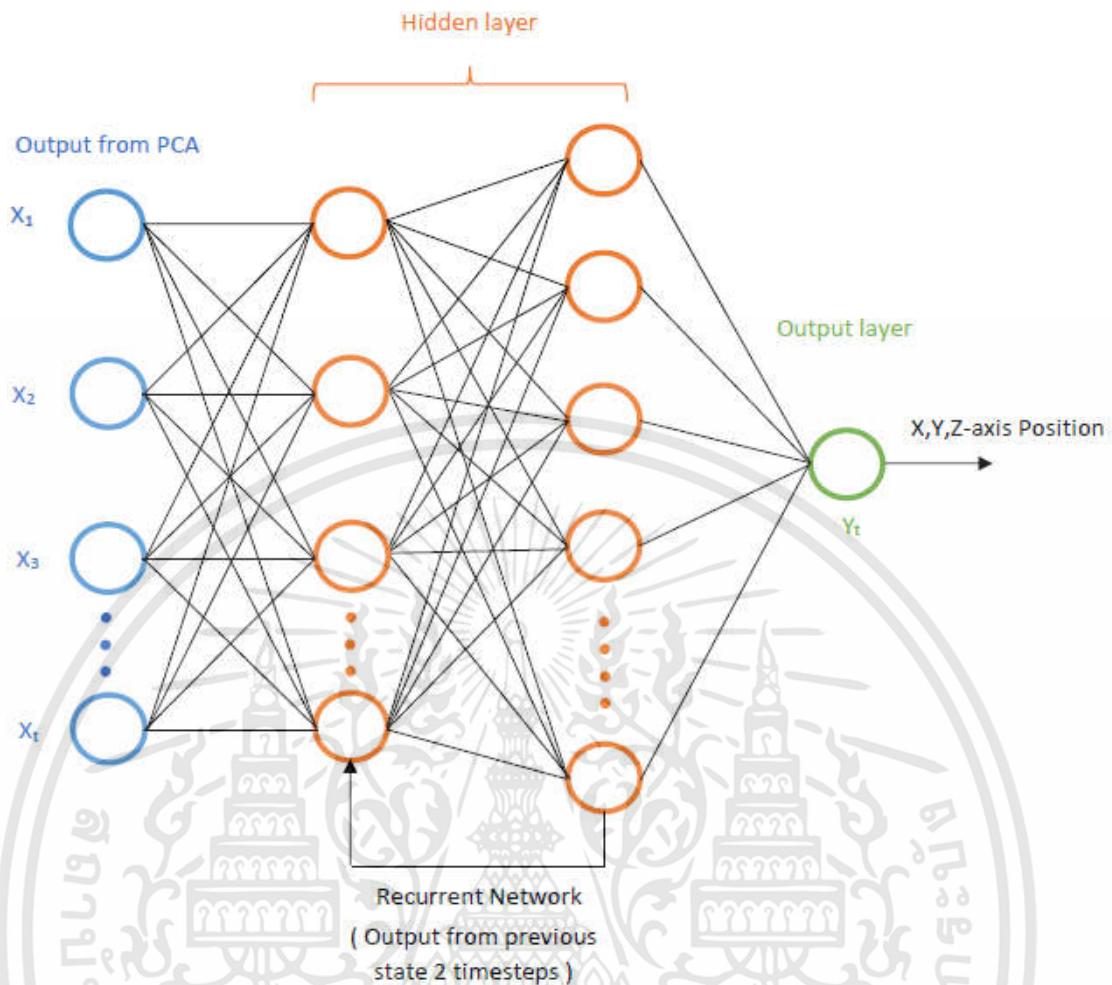
รูปที่ 4.12 Motion Data ที่ผ่านการ Resampled ตามเวลาของสัญญาณ ECoG

## 4.6 Prediction

### 4.6.1 Training Recurrent Neural Networks

การจะ predict ค่าใดๆจำเป็นต้องทำการฝึกสอน (Training) เพื่อสร้างอัลกอริทึมให้กับระบบก่อน ในงานวิจัยชิ้นนี้ได้นำเอาอัลกอริทึมของ Recurrent Neural Networks มาใช้ โดยการนำข้อมูลที่ได้จาก PCA ซึ่งเป็น input ในปัจจุบันร่วมกับ input จากอดีตซึ่งก็คือ Position ของ state ก่อนหน้า

และในงานวิจัยชิ้นนี้ได้แยก Neuron ออกเป็น 3 unit สำหรับ predict ค่าของแกน x,y และ z แยกกันแกนละ unit

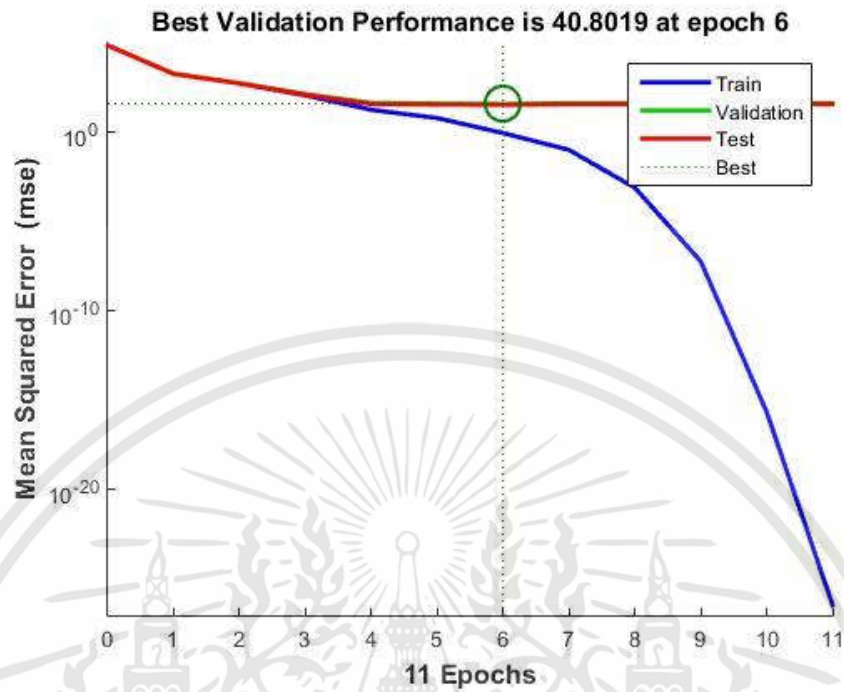


รูปที่ 4.13 Recurrent Neural Networks ที่มี input จาก PCA และ state ก่อนหน้า 2 timesteps


Input ในปัจจุบัน Feature จาก DWT ที่ทำการ projected ลงบน Eigen basis เรียบร้อยแล้วและมีขนาดเมทริกซ์ใน 1 unit หรือ 1 sec เป็น  $8 \times 10$  ต่อ 1 ช่องสัญญาณ เพราะฉะนั้นถ้าเป็นอิเล็กทรอนิกส์ 64 Channel ในเวลา 10 นาทีจะมีข้อมูลต้นแบบการเรียนรู้ทั้งหมดเท่ากับ  $512 \times 6000$  หมายความว่า input 512 node

Input จากอดีตคือ Position ของ state ก่อนหน้ามีทั้งหมด 3 factor (แกน x,y และ z) ซึ่งแยก Neuron สำหรับการ predict ค่าของแต่ละแกน โดยในงานวิจัยนี้ได้เลือกใช้ Input จากอดีตย้อนกลับไป 2 state หรือก็คือ 2 timesteps แปลว่าจะมีค่า Input ที่มาจากอดีตทั้งหมด 2 ค่าหรือ 2 node ดังนั้น input รวมที่ถูกใส่เข้าไปใน RNN จะมี 514 node และเท่ากันทั้ง 3 Neuron ของการ predict

Output ที่ได้จะเป็นค่า x,y และ z position แยกกันทั้ง 3 แกน ดังนั้นแต่ละ Neuron จะมี Output 1 ค่าสำหรับการ predict ค่าของแต่ละแกน




รูปที่ 4.14 Performance การ predict ของ RNN ในแกน X




รูปที่ 4.15 Performance การ predict ของ RNN ในแกน Y

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.16 Performance การ predict ของ RNN ในแกน Z

ซึ่งเมื่อทำการฝึกสอนให้กับ RNN เรียบร้อยแล้วจะได้ Performance ของแกน x, y, z ออกมาดังรูปที่ 4.14, 4.15, 4.16 ตามลำดับ โดยจะแสดงผลด้วยค่า mean squared error (mse) ซึ่งเส้นกราฟสีแดงจะแทนค่าของข้อมูลฝึกสอนส่วนสีฟ้าจะแทนค่าของข้อมูลทดสอบ นอกจากนี้ยังมี Error Histogram ในรูปที่ 4.17, 4.18, 4.19 โดยที่ Histogram กราฟสีฟ้าจะแสดงถึงข้อมูลต้นแบบ การเรียนรู้ที่ใช้สำหรับฝึกอบรม (Training), กราฟสีเขียวแสดงถึงข้อมูลที่ใช้สำหรับการตรวจสอบความถูกต้อง (Validation data) และกราฟสีแดงเป็นส่วนข้อมูลทดสอบที่ Neural ทำการทดสอบ อัลกอริทึมของมันเอง (Testing data)




รูปที่ 4.17 Error Histogram การ predict ค่าในแกน X

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

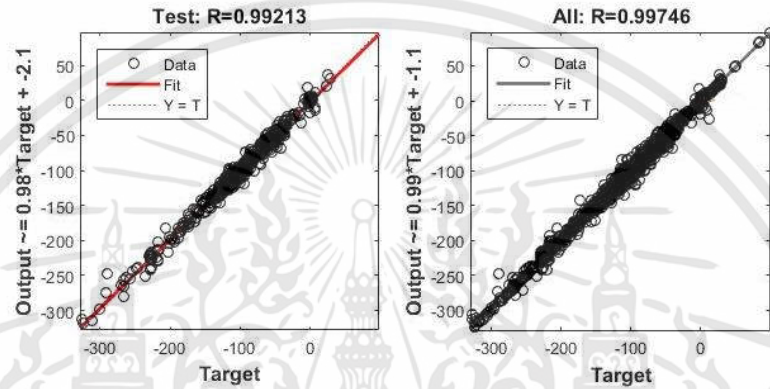
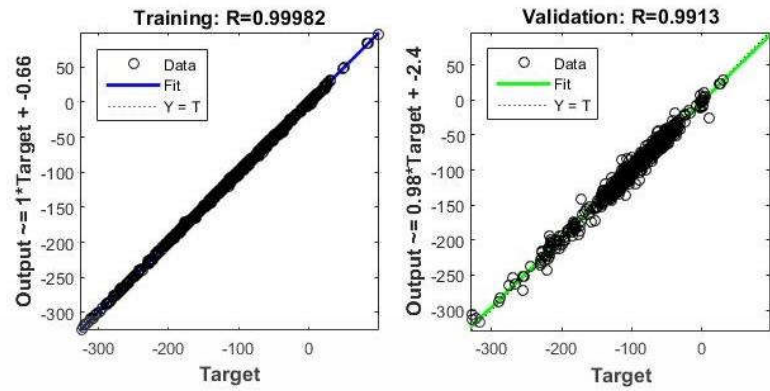


รูปที่ 4.18 Error Histogram การ predict ค่าในแกน Y




รูปที่ 4.19 Error Histogram การ predict ค่าในแกน Z

และกราฟ Regression ที่แสดงแนวโน้มของข้อมูลชุดฝึกสอน ข้อมูลชุดทดสอบ และข้อมูลทดสอบโดยที่มีค่า Correlation Coefficient ( $R$ ) ระบุไว้ในรูปดังที่แสดงในรูปที่ 4.20, 4.21, 4.22




รูปที่ 4.20 Regression plot ของแกน X จากข้อมูลฝึกอบรม ชุดตรวจสอบ และชุดทดสอบ




รูปที่ 4.21 Regression plot ของแกน Y จากข้อมูลฝึกอบรม ชุดตรวจสอบ และชุดทดสอบ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.22 Regression plot ของแกน Z จากข้อมูลฝึกอบรม ชุดตรวจสอบ และชุดทดสอบ  
4.6.2 ผลการทดลอง

เมื่อนำ RNN ที่ผ่านการฝึกสอนแล้วมาใช้งาน จะได้ผลการ predict ของค่า Movement Position ตามแนวแกน x,y และ z ตามในรูปที่ 4.23, 4.24, 4.25 ตามลำดับ ซึ่งข้อมูลต้นแบบจะแทนด้วยสีน้ำเงิน และข้อมูลที่ predict ได้ซึ่งก็คือ output จาก RNN แทนด้วยสีแดง

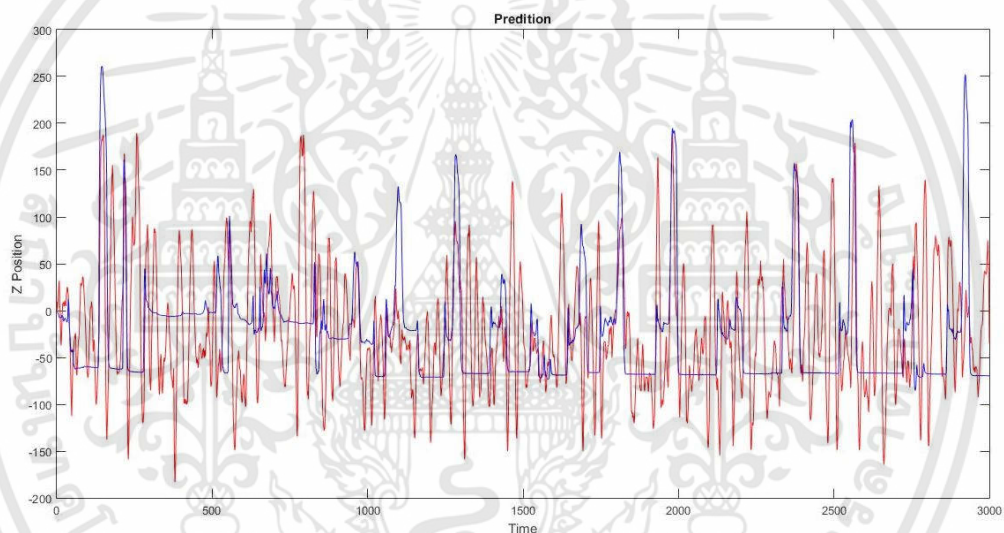


รูปที่ 4.23 ผลของการทำนายตำแหน่งของการเคลื่อนไหวของมือในแนวแกน X

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.24 ผลของการทำนายตำแหน่งของการเคลื่อนไหวของมือในแนวแกน Y



รูปที่ 4.25 ผลของการทำนายตำแหน่งของการเคลื่อนไหวของมือในแนวแกน Z

ตารางที่ 4.1 เปรียบเทียบค่า Correlation Coefficient ( $r$ ) ของการทำนายตำแหน่งในแกน x, y, z

Correlation Coefficient ( $r$ )			
Prediction Model	Position		
	X axis	Y axis	Z axis
RNN	$0.46 \pm 0.2$	$0.41 \pm 0.27$	$0.41 \pm 0.21$
LR and PLS*	$0.46 \pm 0.17$	$0.28 \pm 0.2$	$0.36 \pm 0.19$
PLS**	$0.71 \pm 0.11$	$0.71 \pm 0.13$	$0.75 \pm 0.08$

\*ข้อมูลเฉลี่ยจากคนไข้ 5 คน [18]

\*\*n= 35 experiments [16]

## บทที่ 5

### อภิปรายผลการทดลอง

งานวิจัยฉบับนี้ได้ทำการออกแบบอัลกอริทึมสำหรับการทำนายการเคลื่อนไหวของแขนโดยใช้สัญญาณ ECoG ในลิง ซึ่งจะมีข้อมูลสองประเภทหลักๆคือข้อมูลสัญญาณ ECoG และข้อมูลตำแหน่งการเคลื่อนไหวของลิง

สำหรับสัญญาณ ECoG ที่ถูกบันทึกด้วยอัตราการสุ่มตัวอย่าง 1 kHz ต่อช่องสัญญาณแปลว่าใน 1 unit หรือ 1 sec จะมีข้อมูล 1000 ค่า จะทำการอ้างอิงใหม่ด้วยวิธี common average reference (CAR) จากนั้นจึงทำการ Down sample 4 times เพื่อเป็นการลดภาระการคำนวณลง ซึ่งจะทำให้ข้อมูลมีอัตราการสุ่มตัวอย่างลดลงเหลือ 250 Hz แล้วจึงทำการ Feature Extraction ด้วย Discrete Wavelet Transform กำหนดค่า scale level = 3 ซึ่งจะได้ Frequency bin เท่ากับ 8 สเกล เพื่อให้ได้ Wavelet Coefficient ออกมา และทำการ Resampled at 25 time lags ข้อมูลจนกลายเป็นเมทริกซ์  $8 \times 25$  ต่อ 1 unit(sec) พร้อมกับนอร์มอลไรซ์ ( Z Standard Score ) แต่เนื่องด้วยข้อมูลของสัญญาณ ECoG เป็น high-dimensional data ซึ่งยังถือว่ามีข้อมูลจำนวนมากและอาจทำให้เกิดการ over fitting ในการฝึกสอนของ Neural Networks ดังนั้นจึงต้องทำ Data Reduction และในที่นี้ได้เลือกวิธี Principal Component Analysis มาใช้ซึ่งจะได้เมทริกซ์ของข้อมูลใหม่ที่มีมิติเมแกนซ์น้อยลงตาม Eigen basis ที่คำนวณหาได้

ในส่วนของคุณข้อมูล Movement Position เนื่องจากสัญญาณ ECoG ได้มีกระบวนการ Down sample และ Resampled เพื่อให้ง่ายต่อการ Mapping เวลาและ Prediction จึงต้องมีการ Resampled ข้อมูลเพื่อให้จำนวนข้อมูลตรงกันใน 1 unit(sec) ซึ่งทำได้โดยการใช้ Simple Moving Average โดยจะเหลือเป็น 10 ค่าต่อ 1 unit(sec) แต่เนื่องด้วย Movement Position เป็นข้อมูลใน 3 มิติ ฉะนั้นใน 1 unit(sec) ข้อมูลการเคลื่อนไหวจะเป็นข้อมูลเมทริกซ์ขนาด  $3 \times 10$

และสำหรับการ Predict ในงานวิจัยนี้ใช้ Recurrent Neural Networks โดยที่อินพุตจะแบ่งเป็นข้อมูลจากในปัจจุบันและข้อมูลจากในอดีต อินพุตส่วนที่เป็นปัจจุบันคือข้อมูลที่ได้จาก PCA ส่วนอินพุตที่ได้จากอดีตคือข้อมูลเอาต์พุตของสเตจก่อนหน้าโดยที่จะย้อนกลับไป 2 timesteps และเมื่อฝึกสอน RNN แล้วจึงนำโมเดลที่ได้มาใช้งานเพื่อ Predict การเคลื่อนไหวของลิงด้วยสัญญาณ ECoG ได้ผลลัพธ์ออกมาแล้วนำไปหาค่า Correlation Coefficient ( $r$ ) =  $0.46 \pm 0.2$ ,  $0.41 \pm 0.27$ ,  $0.41 \pm 0.21$  ของแกน x, y และ z ตามลำดับ

## เอกสารอ้างอิง

- [1] Yinghua Wang, Jiaqing Yan, Xiaoli Li. An Intracranial Electroencephalography (iEEG) Brain Function Mapping Tool with an Application to Epilepsy Surgery Evaluation. *Neuroinform* 2016;10:15.
- [2] Engel Jr J, Bragin A, Staba R, Mody I. High-frequency oscillations: what is normal and what is not. *Epilepsia* 2009;50:598–604.
- [3] EEG Signal. Retrieved from <http://louisobe.com/brainwaves-and-metaphysics/>
- [4] Leuthardt EC, Schalk G, Wolpaw JR, Ojemann JG, Moran DW. A brain-computer interface using electrocorticographic signals in humans. *J Neural Eng* 2004;1:63–71.
- [5] Schalk G, Miller KJ, Anderson NR, et al. Two-dimensional movement control using electrocorticographic signals in humans. *J Neural Eng* 2008;5:75–84.
- [6] EEG, ECoG Signal. Retrieved from <https://minghsiehece.usc.edu/wp-content/uploads/2017/11/62-Hamidreza-Abbaspourazad-1.pdf>
- [7] Ball T, Kern M, Mutschler I, Aertsen A and Schulze-Bonhage A 2009 Signal quality of simultaneously recorded invasive and non-invasive EEG *Neuroimage* 46 708–16
- [8] Jason Godlove, Tanuj Gulati, Ben Dichter, Edward Chang, Karunesh Ganguly. Muscle synergies after stroke are correlated with perilesional high gamma. *Annals of Clinical and Translational Neurology* 2016.
- [9] Lang, W. Christopher; Forinash, K.: Time-frequency analysis with the continuous wavelet transform. *American Journal of Physics* 67 (Feb 1999), 934–935.
- [10] Paul S Addison “Wavelet transforms and the ECG: a review” *Physiol. Meas.* 26 (2005) R155–R199.
- [11] Jonathon Shlens, "A Tutorial on Principal Component Analysis", Systems Neurobiology Laboratory, Ver.2, 2005
- [12] What is PCA. Retrieved from <https://medium.com/ingenio/https-medium-com-ingenio-principal-components-analysis-pca-factor-analysis-2-571165d67f78>

- [13] Statistics calculated in PCA. Retrieved from <http://konecth.blogspot.com/2017/11/principal-components-analysis.html>
- [14] Megha A. Kamble, Dr. Sanjay L. Nalbalwar, Prof. Swarali P. Sheth “Kernel Eigenfaces Framework for Feature Extraction and Face Recognition” ISSN 2250-2459, ISO 9001:2008 Certified Journal, Vol. 5, Issue 6, June 2015
- [15] Patrick Henry Winston. Artificial Intelligence. 1992, 443-469
- [16] What is LSTM, RNN. Retrieved from <https://medium.com/@sinart.t/long-short-term-memory-lstm-e6cb23b494c6>
- [17] Zenas C. Chao, Yasuo Nagasaka and Naotaka Fujii. Long-term asynchronous decoding of arm motion using electrocorticographic signals in monkeys. 2010 vol.3
- [18] David T Bundy, Mrinal Pahwa, Nicholas Szrama and Eric C Leuthardt. Decoding three-dimensional reaching movements using electrocorticographic signals in humans. *J. Neural Eng.* 13 (2016)
- [19] Nagasaka Y, Shimoda K and Fujii N 2011 Multidimensional Recording (MDR) and Data Sharing: An Ecological Open Research and Educational Platform for Neuroscience *PLoS One*
- [20] Dennis J. McFarland\*, Lynn M. McCane, Stephen V. David, Jonathan R. Wolpaw “Spatial Filter Selection for EEG-based communication” *Electroencephalography and clinical Neurophysiology* 103 (1997) 386-394.



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## โค้ด Matlab ในส่วนของการ Pre-Signal Processing

```
% CMR (Common Median Reference)
mECoG=ECoG-ones(nCH,1)*median(ECoG);

%downsample 4 times
for i=1:1:nCH
    dwnndata(:,i) = downsample(fdmdata(:,i),4);
    dwnTime = downsample(ECoGTime,4);
end
nT=dwnTime(end)-dwnTime(1);
```

## โค้ด Matlab ในส่วนของ Data Reduction

```
%Compute EigenVectors and EigenValues
for i=1:1:nCH
    CoV = Zscore*transpose(Zscore);
    [Ve,Va] = eig(CoV);
    [Va, idx] = sort(diag(Va));
    Va = Va(end:-1:1)';
    Val(i,:)=Va;
end
%Percent Confident
for k=1:1:size(Val,1)
    ei=1;
    pcon=0;
    while pcon<(0.7*sum(Val(k,:)))
        pcon=pcon+Val(k,ei);
        ee=ei;
        ei=ei+1;
    end
    eignum(k)=ee;
end
eignum = mode(eignum); %max frequency of ei
```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## Prediction of arm motion using electrocorticographic signals in monkeys

Pakakul Wilaiprasitporn<sup>1</sup> Yuttana Kitjaidure<sup>1</sup>

<sup>1</sup>Faculty of Engineering

King Mongkut's Institute of Technology Ladkrabang, Bangkok, 10520, Thailand

Tel : +66(0) 2329 8000 E-mail : miwilipkk@gmail.com

### Abstract

Brain-machine interfaces (BMIs) is a direct communication pathway between brain and an external device. BMIs are often directed at researching, mapping, assisting, or repairing human cognitive or sensory-motor functions. Electrocorticographic (ECoG) signals have been contain reliable information about the direction of arm movements. These findings indicate that the ECoG is a potential basis for a brain-machine interface (BMI) for application in paralyzed patients. Determining a person's intent, e.g., where and when to move, from brain signals rather than from muscles would have important applications in clinical or other domains. Detecting the onset and direction of actual movements are a first step in this direction. This paper also demonstrates in a simulation that the information encoded in ECoG from monkeys about these movements may improve performance in a targeting task. In summary, the results in this paper suggest that detection of intended movement is possible, and may serve useful functions.

### Introduction

Some people who suffer neurological diseases can become severely impaired and have strongly reduced motor functions but still have some cognitive abilities. One of their possible way to communicate with their environment is by using their brain activities. Brain-Computer interfaces (BCI) research aim at developing systems to help such disabled people communicating with other people through machines. A major aspect of brain-machine interface (BMI) technology is the decoding of human intention from brain activity to generate commands for controlling motor neuroprosthetic devices [1]. The technology can help to substitute motor functions in individuals with an inability or restricted ability to perform voluntary movements, including patients suffering from amyotrophic lateral sclerosis, stroke, spinal cord injury or other neurological disorders [1–3]. Electrocorticography

(ECoG) has been employed to record brain activity for BMI applications [4–6].

### Data set

In this work, we focus on Subdural ECoG food tracking task from Neurotycho (*Chao ZC, Nagasaka Y, Fujii N.*) [7]. The signals composing the dataset, have been acquired from two monkey which customized 32, 64-channel ECoG electrode arrays. (Unique-Medical, Japan) ECoG and motion data were sampled at 1KHz and 120Hz, respectively, with time stamps synchronized.

The monkey was tracking food rewards with the hand contralateral to the implant side. ECoG data and motion data were recorded simultaneously during the task (details in the reference). There was no eye tracking. In each experiment, the monkey was seated in a primate chair facing the experimenter with head movement restricted. Each monkey was trained to retrieve food fed in 3D space. The length of each experiment was 15 min: the first 10 min of data were used for training the decoding model (training data) and the last 5 min of data were used for validation (validation data).




Fig. 1. Locations of electrodes in monkey A and in monkey K

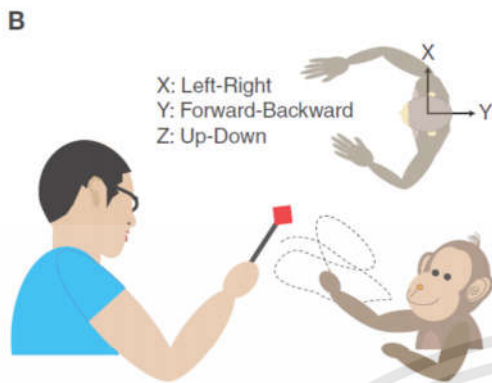


Fig.2 The body-centered coordinates for measuring 3D hand positions from the top-down viewpoint.

### Decoding Paradigm and Data Analysis

#### Signal processing

ECoG signals were recorded with a sampling rate of 1 kHz per channel and were filtered with band-pass filters from 0.1-600Hz. Raw ECoG signals were re-referenced to a common average reference (CAR) to increase the signal-to-noise ratio in the preprocessing phase. The CAR method calculates the mean of all channels, and subtracts this value from the selected output channels [8].

Body-centered 3D hand trajectories (X: left-right, Y: forward-backward, Z: up-down) were calculated by referencing the wrist position of the reaching hand with the sagittal plane (Fig. 2.).




Fig. 3. Raw ECoG data from one channel in 30 sec

### Wavelet Transformation

Time-frequency representation, or the scalogram, of the ECoG signals for each electrode was generated by Morlet wavelet transformation at 10 different center frequencies (10-120 Hz, arranged in a logarithmic scale) with the half length of the Morlet analyzing wavelet set at the coarsest scale of seven samples.

Wavelet transform is used for many BCI data analysis applications to extract feature(s) [9]. It has an advantage over other feature extraction methods that operate in only one domain, such as the Fourier transform, or autoregressive modeling. Its basic use includes time-scale signal analysis, signal decomposition and signal compression.

The discrete wavelet transform (DWT) has a window size that varies frequency scale. The set of wavelet functions is usually derived from dilation and translation of the initial (mother) wavelet  $\Psi_{a,b}(t)$  [10] where  $b$  and  $a$  are the scaling factor and shifting factor respectively and normalized so that [11]

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) \quad (1)$$

The scalogram of time  $t$  was calculated from the ECoG signals from  $t - 1.1$  s to  $t$ . The scalogram was then resampled at 10 time lags ( $t - 100$  ms,  $t - 200$  ms, ..., and  $t - 1$  s) to form a  $10 \times 10$  scalogram matrix of time  $t$ . Considering edge effects in the scalogram calculation, ECoG signals from 100 ms before  $t - 1$  s to 100 ms after  $t - 100$  ms were used to avoid distorted data at time lags  $t - 1$  s and  $t - 100$  ms. The  $10 \times 10$  scalogram matrix of time  $t$  was then normalized by calculating the standard z score at each frequency bin; thus, the same scale was shared across different frequency bins.

### Principal Component Analysis

Many algorithms for dimensionality reduction have been developed to accomplish these tasks. However, since the need for such analysis arises in many areas of study, contributions to the field have come from many disciplines. While all of these methods have a similar goal, approaches to the problem are different.

Principal components analysis (PCA) is a very popular technique for dimensionality reduction. The goal of principal component analysis is to identify the most meaningful basis to re-

express a data set. The hope is that this new basis will filter out the noise and reveal hidden structure.




Fig. 4. Wavelet and scalogram




Fig. 5. Wavelet and scalogram 10x10

The key idea of the PCA method is to transform the signal into a small set of characteristics feature, called eigenspace, which are the principal components of the initial training set of the signal. In recognition process a test signal is projected into the lower-dimension feature spanned by the eigenspace. [12]

Step1 : obtain features signal  $I_1, I_2, \dots, I_M$  (training data) and represent every features as a vector  $\Gamma_i$

Step2 : compute the average vector  $\Psi$

$$\Psi = \frac{1}{M} \sum_{i=1}^M \Gamma_i \quad (2)$$

Step3 : subtract the mean

$$\phi_i = \Gamma_i - \Psi \quad (3)$$

Step4 : compute the covariance matrix  $C$

$$C = \frac{1}{M} \sum_{n=1}^M \phi_n \phi_n^T = AA^T \quad (4)$$

$$\text{where } A = [\phi_1 \phi_2 \dots \phi_M] \quad (5)$$

Step5 : compute the eigenvectors  $V_i$  of  $AA^T$  (The matrix  $AA^T$  is very large  $\rightarrow$  not practical)

$$A^T A v_i = u_i v_i \quad (6)$$

Step6 : keep only  $K$  eigenvectors ( corresponding to the  $K$  largest eigenvalues ) [13]

### Recurrent Neural Network

Artificial neural networks are computing systems made up of large number of simple, highly interconnected processing elements (called nodes or artificial neurons) that abstractly emulate the structure and operation of the biological nervous system. Learning in ANNs is accomplished through special training algorithms developed based on learning rules presumed to mimic the learning mechanisms of biological systems.

Recurrent Neural Networks are algorithm for sequential data. The information cycles through a loop. When it makes a decision, it takes into consideration the current input and also what it has learned from the inputs it received previously.




Fig. 6. Recurrent Neural Network

A loop allows information to be passed from one step of the network to the next. A recurrent neural network can be thought of as multiple copies of the same network, each passing a message to a successor. This chain-like nature reveals that recurrent neural networks are intimately related to sequences and lists.

In case, Recurrent Neural Network forecast movement of monkeys. Ideas of RNN is to make use of sequential information Each member of the output is produced using the same update rule applied to the previous outputs. Therefore inputs are normalized parameters at that time including output at previous time (t-1, t-2 for this project).

Result




Fig. 7. regression plots show the network outputs with respect to targets for training, validation, and test sets.




Fig. 8. Example of prediction of X-positions of hand movements during 5 minute. (Blue represent observed and Red represent predicted.)




Fig. 9. Example of prediction of Y-positions of hand movements during 5 minute. (Blue represent observed and Red represent predicted.)




Fig. 10. Example of prediction of Z-positions of hand movements during 5 minute. (Blue represent observed and Red represent predicted.)

Conclusion

This paper can decoding of arm motion using electrocorticographic (ECoG) which is Pre-Processing by Wavelet Scalogram and Data Reduction with Principal Component Analysis then using the Recurrent Neural Network to predict movement Which predictions are sequential because the results of t-1 and t-2 (two time steps) are used to predict.

Acknowledgement

Foremost, I would like to express my appreciation to Dr. Yuttana kitjaidure for his patience, immense knowledge, valuable and constructive suggestions during the planning and development of this research work. His guidance helped me in all the time of research and writing of this thesis.

References

- [1] Wolpaw J R, Birbaumer N, McFarland D J, Pfurtscheller G and Vaughan T M 2002 Brain-computer interfaces for communication and control *Clin. Neurophysiol.* 113 767–91
- [2] Birbaumer N, Ghanayim N, Hinterberger T, Iversen I, Kotchoubey B, Kubler A, Prelmouter J, Taub E and Flor H 1999 A spelling device for the paralysed *Nature* 398 297–8
- [3] Wolpaw J R and McFarland D J 2004 Control of a two-dimensional movement signal by a noninvasive brain-computer interface in humans *Proc. Natl Acad. Sci. USA* 101 17849–54

- [4] Leuthardt E C, Schalk G, Wolpaw J R, Ojemann J G and Moran D W 2004 A brain-computer interface using electrocorticographic signals in humans *J. Neural Eng.* 1 63–71
- [5] Schalk G, Miller K J, Anderson N R, Wilson J A, Smyth M D, Ojemann J G, Moran D W, Wolpaw J R and Leuthardt E C 2008 Two-dimensional movement control using electrocorticographic signals in humans *J. Neural Eng.* 5 75–84
- [6] Yanagisawa T, Hirata M, Saitoh Y, Goto T, Kishima H, Fukuma R, Yokoi H, Kamitani Y and Yoshimine T 2011 Real-time control of a prosthetic hand using human electrocorticography signals *J. Neurosurg.* 114 1715–22
- [7] Chao Z C, Nagasaka Y and Fujii N 2010 Long-term asynchronous decoding of arm motion using electrocorticographic signals in monkeys *Front. Neuroeng.*
- [8] Dennis J. McFarland\*, Lynn M. McCane, Stephen V. David, Jonathan R. Wolpaw “Spatial Filter Selection for EEG-based communication” *Electroencephalography and clinical Neurophysiology* 103 (1997) 386-394.
- [9] Abdulhamit Subasi, EEG signal classification using wavelet feature extraction and a mixture of expert model. *Expert Systems with Applications* 32 (2007) 1084–1093.
- [10] Ales Prochazka ; Jaromir Kukul ; Oldrich Vysata “Wavelet transform use for feature extraction and EEG signal segments classification” 2008 3rd International Symposium on Communications, Control and Signal Processing.
- [11] Lung Chuin Cheong, Rubita Sudirman, Siti Suraya Hussin, “Feature extraction of EEG signal using wavelet transform for autism” Vol.10, No.19, 2006-2015 Asian Research Publishing Network (ARPN).
- [12] Jonathon Shlens, "A Tutorial on Principal Component Analysis", *Systems Neurobiology Laboratory*, Ver.2, 2005
- [13] Megha A. Kamble, Dr. Sanjay L. Nalbalwar, Prof. Swarali P. Sheth “Kernel Eigenfaces Framework for Feature Extraction and Face Recognition” ISSN 2250-2459, ISO 9001:2008 Certified Journal, Vol. 5, Issue 6, June 2015

ECTI-CARD 2019  
@ Ubon Ratchathani

## ประวัติผู้เขียน

ชื่อ-นามสกุล	นางสาวภคกุล วิไลประสิทธิ์พร
วัน เดือน	ปีเกิด 30 มีนาคม 2538 ที่กรุงเทพมหานคร
ประวัติการศึกษา	2559 วิศวกรรมศาสตรบัณฑิต สาขาวิชาอิเล็กทรอนิกส์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
ความชำนาญเฉพาะด้าน	1.) การวิเคราะห์ข้อมูลจากคลื่นสัญญาณ 2.) การเขียน Algorithm ของ Machine Learning
ประสบการณ์การทำงานและผลงานวิจัย	
พ.ศ.2560	ได้รับรางวัลการชนะเลิศ Best Electronics Engineering Award การประกวด แข่งขันในงาน KMITL Engineering Project Day 2017 ในระดับอุดมศึกษา
พ.ศ.2562	ผลงานวิจัย Prediction of arm motion using electrocorticographic signals in monkeys