



รายงานการวิจัยฉบับสมบูรณ์

การปรับปรุงประสิทธิภาพ Transfer learning โดยใช้ Kalman filter Stochastic  
Gradient Descent

Improve transfer learning performance by using Kalman-based Stochastic  
Gradient Descent

นางพัชรินทร์ คำสิงห์

ได้รับทุนสนับสนุนงานวิจัยจากเงินรายได้ ประจำปีงบประมาณ 2561

วิทยาลัยอุตสาหกรรมการบินนานาชาติ

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



## รายงานการวิจัยฉบับสมบูรณ์

การปรับปรุงประสิทธิภาพ Transfer learning โดยใช้ Kalman filter Stochastic  
Gradient Descent

Improve transfer learning performance by using Kalman-based Stochastic  
Gradient Descent

นางพัชรินทร์ คำสิงห์

ได้รับทุนสนับสนุนงานวิจัยจากเงินรายได้ ประจำปีงบประมาณ 2561

วิทยาลัยอุตสาหกรรมการบินนานาชาติ

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Research Title: Improve transfer learning performance by using Kalman-based Stochastic Gradient Descent.....

Researcher:..... Patcharin Kamsing, Ph.D.....

Faculty: ..... International Academy of Aviation Industry.....

Department:..... Department of Aeronautical Engineering.....

### Abstract

วิธีการในการระบุวัตถุโดยอัตโนมัติ เป็นปัญหาวิจัยที่ยังต้องการการพัฒนาและศึกษา ซึ่งตัวอย่างในอุตสาหกรรมการบินก็สามารถนำระบบการระบุวัตถุอัตโนมัติมาใช้ เช่น ในกรณีของการระบุวัตถุในภาพถ่ายดาวเทียมเป็นเครื่องบินหรือไม่ เพราะสามารถนำเอาผลการศึกษาวิจัยมาใช้ในการตรวจสอบและควบคุมภายในสนามบิน เพื่อให้การใช้พื้นที่ในสนามบินเกิดประสิทธิภาพอย่างสูงสุด นอกจากนี้ยังสามารถนำไปใช้ในทางทหารได้ด้วย ในงานวิจัยนี้ได้นำเอาวิธีการที่เรียกว่า Deep Convolutional Neural Networks (CNN) มาใช้ในการระบุวัตถุ ซึ่งเป็นวัตถุที่เป็นเครื่องบิน และไม่ใช่อุปกรณ์ โดยใช้อุปกรณ์จากภาพถ่ายดาวเทียมที่เป็นข้อมูลมาตรฐานและได้รับการ clean เรียบร้อยแล้ว โดยข้อมูลนี้มีชื่อว่า planesnet ในการวิจัยนี้ใช้เทคนิคที่เรียกว่า transfer learning ซึ่งเป็นเทคนิคที่มีจุดประสงค์เพื่อกำจัดอุปสรรคของการใช้งาน CNN แบบเก่า ซึ่งได้แก่ข้อจำกัดในเรื่องของการคำนวณที่ใช้เวลานาน โดยใช้วิธีการเพิ่มชั้นหรือ layer บนสุดของโครงสร้างโมเดลที่เรียก pre-trained โดยเพิ่มชั้นของ a fully connected layer และ softmax layer เพื่อเป็นการเพิ่มข้อมูลและ class ของข้อมูลที่สนใจ แล้วจึงทำการ re-train อีกครั้ง การออกแบบการทดลองสำหรับการใช้งาน pre-trained model นั้น ได้มีการออกแบบให้ทำการทดสอบกับหลายๆ optimizer เพื่อเปรียบเทียบผลการทดลอง โดยในการทดลองได้ใช้ optimizer ทั้งหมด 4 ตัว ได้แก่ Stochastic Gradient Descent optimizer, Adam Optimizer, PowerSign optimizer, AddSign optimizer ซึ่ง Stochastic Gradient Descent optimizer และ Adam Optimizer เป็นวิธีการที่เป็นที่นิยมประยุกต์ใช้งานในหลายๆงาน ส่วน PowerSign optimizer และ AddSign optimizer เป็นวิธีการในการลดความผิดพลาด ซึ่งคิดค้นโดยใช้ Recurrent neural network (RNN) and Reinforcement Learning ผลการทดลองแสดงให้เห็นว่าเทคนิค transfer learning ทำงานควบคู่กับ Adam optimizer สามารถให้ผลลัพธ์ที่ดีในการระบุวัตถุ(เครื่องบิน) จากภาพถ่ายดาวเทียม

Keywords : Transfer Knowledge, Pre-trained model, Optimizer, Deep Learning, CNN

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## กิตติกรรมประกาศ

การวิจัยครั้งนี้ได้รับทุนสนับสนุนการวิจัยจากสถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง จากแหล่งทุนเงินรายได้ของวิทยาลัยอุตสาหกรรมการบินนานาชาติ ประจำปีงบประมาณ พ.ศ. 2561 ผู้วิจัย ขอขอบคุณแหล่งข้อมูลภาพถ่ายดาวเทียมที่นำมาใช้ในการทำวิจัยในครั้งนี้



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญ

Abstract .....	I
กิตติกรรมประกาศ .....	II
สารบัญ .....	III
สารบัญรูปภาพ.....	IV
สารบัญตาราง .....	V
บทที่ 1 บทนำ.....	1
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง .....	3
ข้อจำกัดของ Kalman Filter.....	3
Pre-trained model and Transfer Learning.....	3
Stochastic Gradient Descent Optimizer.....	4
Adam Optimizer.....	4
AddSign Optimizer and PowerSign Optimizer.....	5
บทที่ 3 วิธีดำเนินการวิจัย .....	7
Dataset and Data preparation .....	7
Experiment .....	8
บทที่ 4 ผลการวิจัย .....	10
บทที่ 5 สรุปผลการวิจัยและข้อเสนอแนะ.....	12
บทที่ 6 สรุปผลผลิตงานวิจัย .....	13
บรรณานุกรม .....	14
ภาคผนวก .....	15
IEEE International Geoscience and Remote Sensing Symposium ในฐานข้อมูล Scopus .....	15
รายละเอียดขั้นตอนการตอบรับเพื่อแสดงผลงาน .....	17
สรุปค่าใช้จ่ายการดำเนินโครงการวิจัย.....	20
ประวัตินักวิจัย.....	22

## สารบัญรูปภาพ

รูปที่ 1 โครงสร้างของ Inception-v3 pre-trained model.....	4
รูปที่ 2 ตัวอย่างภาพวัตถุที่เป็นเครื่องบิน [6].....	7
รูปที่ 3 ตัวอย่างภาพวัตถุที่ไม่ใช่เครื่องบิน [6].....	7
รูปที่ 4 ขั้นตอนการสร้างโมเดล.....	8
รูปที่ 5 ขั้นตอนการทดลอง [7].....	9
รูปที่ 6 ความสามารถในการลดค่า cross entropy ในแต่ละรอบของการประมวลผล.....	11



## สารบัญตาราง

ตาราง 1 ภาพวัตถุเครื่องบินจำนวนห้ารูป และไม่ใช่เครื่องบินจำนวนห้ารูปที่ใช้แสดงผลการใช้งานโมเดล.....	10
ตาราง 2 แสดงผลการใช้งานโมเดลที่ใช้ optimizer ทั้งสี่ชนิด โดยรูปภาพวัตถุทั้งสิบรูป .....	10



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บทที่ 1 บทนำ

ในปัจจุบัน Artificial Intelligent หรือ AI ได้รับการพัฒนาและใช้งานในหลายๆงาน . Neural Network และ Deep Learning ก็เป็นที่นิยมประยุกต์ใช้ทั้งในงานที่ข้อมูลมีโครงสร้างที่มีรูปแบบและข้อมูลที่โครงสร้างที่ไม่มีรูปแบบเนื่องจาก Neural Network และ Deep Learning ไม่ต้องกระบวนการในการเลือกคุณลักษณะ (feature extraction) เหมือนวิธีการหรือ algorithm ของ machine learning ตัวอื่นๆ ที่ต้องมีกระบวนการนี้ ซึ่งเป็นกระบวนการที่ต้องกระทำโดยใช้ visualization หรือใช้มนุษย์ในการคัดเลือกคุณลักษณะนั้นๆ Deep Learning สามารถทำงานได้ทั้งระบบหรือข้อมูลที่เป็น static และ dynamic นอกจากนี้ Deep Learning ยังมีสถาปัตยกรรมที่หลากหลาย ที่ถูกพัฒนาขึ้นมาเพื่อการเลือกใช้อย่างเหมาะสมกับประเภทของงานและข้อมูล เช่น Convolutional Neural Network (CNN), Recurrent Neural Networks(RNN), และ Long short-term memory(LSTM) สถาปัตยกรรมแบบ CNN จะเป็นที่นิยมเป็นอย่างมากในการแบ่งแยกวัตถุจากรูปภาพ

ในการระบุวัตถุในภาพถ่ายดาวเทียมที่ใช้ CNN แบบปกติซึ่งมีกระบวนการ training และ testing ร่วมกับข้อมูลที่น่ามาใช้ในการศึกษามีขนาดใหญ่จึงมีความท้าทายในการดำเนินการทดลองเนื่องจากต้องมีการใช้ระบบประมวลผลเป็นอย่างมากและใช้เวลานาน และยังมีเรื่องของการเพิ่มจำนวนหรือประเภทหรือ Classes ในกรณีที่ต้องการระบุชนิดของวัตถุมากกว่าที่ได้ทำการสร้างโมเดลไว้แล้ว ซึ่งโดยวิธีการ CNN แบบปกติจะต้องมีการกำหนดจำนวน classes ก่อนทำการกระบวนการ training และ testing ตามลำดับ ถ้าหากต้องการเพิ่มหรือลดจำนวน classes ในภายหลังผู้พัฒนาโปรแกรมจำเป็นจะต้องเริ่มต้นกระบวนการใหม่เสมอ นำมาซึ่งค่าใช้จ่ายในการประมวลผลและระยะเวลาที่ใช้ในการดำเนินงาน

เทคนิค transfer learning เป็นการถ่ายทอดความรู้ของโมเดลจากที่มีมาก่อนเพื่อสร้างโมเดลที่เหมาะสมกับสถานการณ์และข้อมูลที่น่ามาพิจารณา pre-trained โมเดลที่มีชื่อว่า Inception-v3 [1] ซึ่งเป็นโมเดลที่ถูกสร้างขึ้นโดย CNN โดยใช้ข้อมูลรูปภาพทั่วไปหลายๆ รูปภาพเพื่อนำมาให้โมเดลนี้ได้เรียนรู้คุณสมบัติ คุณลักษณะหรือ feature ที่สำคัญของแต่ละรูปภาพ ซึ่งถือว่าเป็นความรู้หรือ knowledge ที่สำคัญที่จะถูกถ่ายทอดในการสร้างโมเดลที่ต้องการ โดยใช้เวลาและการประมวลผลที่สั้นลงมากเมื่อเทียบกับการใช้ CNN แบบปกติ

ในกระบวนการของ CNN แบบปกติ หรือ Inception-v3 pre-trained model จำเป็นต้องมี optimizer เพื่อลดความผิดพลาดที่เกิดขึ้นในกระบวนการประมวลผล optimizer เป็นกุญแจสำคัญในการเพิ่มประสิทธิภาพของ Deep Learning ในทุกๆสถาปัตยกรรม ข้อมูลแต่ละชนิดหรือแต่ละประเภทก็มีผลต่อการเลือก optimizer ที่เหมาะสม Stochastic Gradient Descent (SGD) เป็น optimizer พื้นฐานที่ถูกนำไปใช้ในหลายๆงาน ส่วน Adam optimizer [2] สามารถทำงานเร็วกว่า Stochastic Gradient Descent (SGD) ในสถานการณ์ที่ Deep

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Learning มีสถาปัตยกรรมที่ซับซ้อนมากกว่า นอกจากนี้ยังมี AddSign optimizer และ PowerSign Optimizer [2] ที่ถูกคิดค้นขึ้นโดยวิธีการขั้นสูงที่เรียกว่า Reinforcement Learning โดยผู้คิดค้นได้ train ตัวควบคุม RNN เพื่อสร้างสมการทางคณิตศาสตร์เช่น gradient, running average of the gradient เป็นต้น โดยในแต่ละรอบของการ train ตัวควบคุมจะถูก train โดยใช้ Reinforcement Learning เพื่อเพิ่มประสิทธิภาพการทำงาน



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

### ข้อจำกัดของ Kalman Filter


เนื่องจาก Kalman filter เป็นเทคนิคที่ใช้ในการทำนายหรือ predict ค่าของข้อมูลที่เป็น time series จึงมีความเป็นไปได้ที่จะนำมาทำนายค่า initial ต่างๆของ Deep learning เพื่อให้มีการอัปเดตเป็นค่าที่เหมาะสมในทุกๆครั้งหรือรอบของการ training (update on fly) แต่อย่างไรก็ตามเนื่องจาก transfer learning เป็นการนำโมเดลที่เรียกว่า pre-trained มาใช้ในกระบวนการทำงาน จึงทำให้รอบของการประมวลผลโดยใช้ข้อมูล planesnet มีจำนวนที่น้อยลงเพื่อให้ได้ประสิทธิภาพที่เหมาะสม ซึ่งจำนวนรอบดังกล่าวไม่เพียงพอที่จะประมวลผลร่วมกับ Kalman filter เนื่องจาก Kalman filter จะมีความแม่นยำมากขึ้นในทุกๆรอบของการประมวลผล จากการศึกษาดังกล่าว จึงทำให้งานวิจัยนี้ไม่สามารถใช้ Kalman filter ร่วมกับ transfer learning ได้

### Pre-trained model and Transfer Learning

Inception-v3 pre-trained model ถูกสร้างโดยการเรียนรู้คุณสมบัติ หรือคุณลักษณะ (feature) จากข้อมูลรูปภาพทั่วไปที่ถูกนำมาใช้ในกระบวนการ train โดยใช้ข้อมูลรูปภาพที่มีชื่อว่า ImageNet ในปี 2012 โดย pre-trained model ดังกล่าวสามารถแบ่งแยก classes ได้ 1000 classes เช่น ม้าลาย, สุนัขดัลเมเซียน, หรือ เครื่องล้างจาน [3] เป็นต้น

การใช้ Pre-trained models สามารถลดข้อจำกัดในเรื่องของทรัพยากรและระยะเวลาในการประมวลผล รวมถึงปัญหาในเรื่องของการขยายหรือ scale up ระบบให้ใหญ่ขึ้นในอนาคต เนื่องจาก Pre-trained models ใช้คุณสมบัติ หรือคุณลักษณะ (feature) จากภาพหลายๆภาพที่ได้รับการเรียนมาก่อนแล้ว เป็นจุดเริ่มต้นในการทำ training ความรู้หรือ Knowledge ที่อยู่ใน Pre-trained models จะหมายรวมถึง เครือข่าย(network) และ น้ำหนัก(weights) จากโมเดลที่ถูก train ก่อนหน้าแล้วถูกทำการ frozen โดยที่ชั้น(layer) บนสุดมีชื่อเรียกว่า Bottleneck ซึ่งจะถูกใช้เป็นชั้นที่ต่อกับข้อมูลเพื่อทำการสร้างโมเดลที่ต้องการในภายหลัง กระบวนการดังกล่าวนี้เรียกว่า transfer learning

เนื่องจาก Inception-v3 pretrained model เป็น CNN ชนิดหนึ่งที่ประกอบด้วย convolution layer และ pooling เหมือนสถาปัตยกรรมแบบอื่นๆของ CNN โครงสร้างของ Inception-v3 pre-trained model ถูกออกแบบมาเพื่อสร้างโมเดลที่เกิดประสิทธิภาพมากที่สุดซึ่งโครงสร้างดังกล่าวแสดงได้ตามรูปที่ 1 ข้อดีของ pre-trained model ได้ถูกกล่าวไปในข้างต้นแล้ว ส่วนข้อเสียของ Inception-v3 pretrained model คือเรื่องของจำนวนของ classes ที่ถูกจำกัดไว้ที่ 1000 classes [3] เท่านั้น ซึ่งเป็นข้อจำกัดที่สามารถแก้ไขด้วยการทำระบบให้เป็นการประมวลผล pre-trained model แบบคู่ขนาน หรือ pre-trained models in parallel processing



รูปที่ 1 โครงสร้างของ Inception-v3 pre-trained model

### Stochastic Gradient Descent Optimizer

Stochastic Gradient Descent Optimizer (SGD) เป็น optimizer ที่เป็นที่นิยมนำไปประยุกต์ใช้ในหลายๆ งาน เพื่อการลดความผิดพลาดหรือ error ที่เกิดขึ้นใน neural networks โดยมีสมการดังนี้ [4]

$$w_{(n+1)} = w_n - Lr \times \hat{g} \quad \text{สมการ 1}$$

โดยที่:  $w_n$  คือค่าของตัวแปรที่ถูกอัปเดตที่เวลา  $n$  และ  $Lr$  คืออัตราการเรียนรู้หรือ learning rate และตัวแปร  $\hat{g}$  คือ gradient vector ในแต่ละรอบของประมวลผลของ neural networks มีจุดประสงค์เพื่อลดความผิดพลาด (error) ซึ่งในหลายๆการประยุกต์ใช้งานหรือในงานวิจัยจะถูกกำหนดโดยค่า cross entropy ค่าตัวแปร  $w_n$  จะถูกอัปเดตโดยใช้ค่าตัวแปร  $w_{n-1}$  หรือตัวแปรก่อนหน้าลบกับผลลัพธ์ของอัตราการเรียนรู้  $Lr$  คูณกับ gradient vector ( $\hat{g}$ )

### Adam Optimizer

Adaptive Moment Estimation หรือ Adam optimizer เป็น optimizer ตัวหนึ่งทำงานโดยใช้โมเมนต์ที่หนึ่งและสอง ในแต่ละรอบของการประมวลผล Adam optimizer จะประมวลผลตามสมการ 2 [5] [4]

$$w_{(n+1)} = w_n - \frac{Lr}{\sqrt{\hat{v}_n + \epsilon}} \hat{m}_n \quad \text{สมการ 2}$$

$$\hat{m}_n = \frac{\beta_1 m_{n-1} + (1 - \beta_1) \hat{g}_n}{1 - \beta_1^n} \quad \text{สมการ 3}$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$\hat{v}_n = \frac{\beta_2 v_{n-1} + (1 - \beta_2) \hat{g}_n^2}{1 - \beta_2^n}$$

สมการ 4

โดยที่  $w_n$  คือค่าของตัวแปรที่ถูกอัปเดตที่เวลา  $n$  และ  $Lr$  คืออัตราการเรียนรู้หรือ learning rate และตัวแปร  $\hat{g}$  คือ gradient vector ค่าประมาณโมเมนต์ที่หนึ่ง ของ gradient หรือค่าเฉลี่ย (mean) และ  $v_n$  คือโมเมนต์ที่สองของ gradient หรือค่า variance โดยทั่วไปค่าเริ่มต้นสำหรับ  $\beta_1$  คือ 0.9 และ  $\beta_2$  คือ 0.999 และ  $\epsilon$  คือ  $10^{-8}$  สำหรับ Adam optimizer นั้นโดยส่วนมากจะให้ประสิทธิภาพที่ดีและสามารถแก้ไขปัญหาได้ดีใน deep learning ที่ประยุกต์ใช้กับข้อมูลขนาดใหญ่

#### AddSign Optimizer and PowerSign Optimizer

AddSign and PowerSign optimizer ถูกสร้างขึ้นจากการใช้ RNN และ Reinforcement Learning โดยใช้ RNN เป็นตัวควบคุมหรือ controller เพื่อสร้างสมการทางคณิตศาสตร์เพื่อใช้เป็นตัวอัปเดตฟังก์ชันการทำงาน โดย RNN controller จะใช้ Reinforcement Learning ในการเพิ่มประสิทธิภาพของโมเดลในแต่ละรอบของการประมวลผล [2] ข้อมูล CIFAR-10 ถูกใช้ในกระบวนการสร้างหรือวิจัย AddSign และ PowerSign optimizer ซึ่งให้ผลลัพธ์ที่ดีกว่าเมื่อเทียบกับ optimizer ตัวอื่นๆ เช่น Adam หรือ SGD optimizer สำหรับ AddSign optimizer สามารถแสดงได้ตามสมการ 5

$$w_{(n+1)} = w_{(n)} - Lr \times \hat{g} \times \left(1 + \alpha \times f_n \times \text{sign}(\hat{g}) \times \text{sign}(\hat{m}_n)\right)$$

สมการ 5

สมการของ PowerSign optimizer สามารถแสดงได้ดังสมการ 6

$$w_{(n+1)} = w_n - Lr \times \hat{g} \times \alpha^{f_n \times \text{sign}(\hat{g}) \times \text{sign}(\hat{m}_n)}$$

สมการ 6

โดยที่  $w_n$  คือค่าของตัวแปรที่ถูกอัปเดตที่เวลา  $n$  และ  $Lr$  คืออัตราการเรียนรู้หรือ learning rate และตัวแปร  $\hat{g}$  คือ gradient vector และ  $f_n$  มีค่าเท่ากับ 1 หรือเป็น internal decay function (linear decay, cyclical หรือ restart decays) ของรอบการประมวลผลของกระบวนการ training ที่เวลา  $n$  และค่าเริ่มต้นของ  $\alpha$  มีค่าเท่ากับ 0.01 [2] นอกจากนี้  $\hat{m}_n$  จะมีค่าอ้างอิงตามสมการ 7

$$\hat{m}_n = \text{Maximum} [\beta \times m + \text{eps}, \text{abs}(\hat{g})]$$

สมการ 7

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดยที่  $\beta$  ถูกกำหนดค่าเท่ากับ 0.5 และ  $eps$  เท่ากับ  $10^{-7}$  และค่า  $m$  เป็นค่าประมาณของโมเมนต์อันดับหนึ่งหรือค่าเฉลี่ย(mean) ของ gradient ในส่วนต่อไปของรายงานเป็นการอธิบายวิธีการวิจัยและทดลองซึ่งจะเป็นการใช้งาน pre-trained model ร่วมกับ optimizer จำนวนสี่ตัวเพื่อเปรียบเทียบผลการทดลอง




เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### บทที่ 3 วิธีดำเนินการวิจัย


#### Dataset and Data preparation

ภาพถ่ายจากดาวเทียมถูกนำมาใช้เพื่อการวิเคราะห์ในหลายๆด้าน เช่น ทางด้านกลไกกรรม ทางด้านการทหาร ทางด้านพลังงาน และทางด้านการเงิน เป็นต้น Planet และ BlackSky เป็นผู้ให้บริการภาพถ่ายดาวเทียมรายหนึ่งที่ใช้ระบบ constellations ของดาวเทียมขนาดเล็กเพื่อเพิ่มประสิทธิภาพและจำนวนของภาพถ่ายดาวเทียมในทุกๆวัน ในการวิจัยนี้ใช้ข้อมูลภาพถ่ายดาวเทียมที่ชื่อว่า planesnet [6]

ข้อมูลดังกล่าวสามารถใช้ในการระบุวัตถุที่เป็นเครื่องบินจากภาพถ่ายดาวเทียม ซึ่งสามารถนำไปพัฒนาต่อไปในการระบุตำแหน่งของเครื่องบิน และการตรวจสอบหรือควบคุม(monitoring) สนามบิน เพื่อให้การใช้งานสนามบินเป็นไปอย่างมีประสิทธิภาพ รวมทั้งใช้ในการจัดการจราจรทางอากาศหรือทางการทหารได้อีกด้วย ข้อมูล planesnet แบ่งออกเป็น 2 classes ได้แก่ วัตถุที่เป็นเครื่องบิน และไม่ใช่อุปกรณ์บิน ซึ่งประกอบไปด้วยภาพจำนวนทั้งหมด 24,000 ภาพ สำหรับภาพวัตถุที่เป็นเครื่องบินจะมีลักษณะและมองเห็นเป็นเครื่องบินหนึ่งลำที่มีลำตัวของเครื่องบินและปีกทั้งสองข้าง หางของเครื่องบิน และส่วนหน้าของเครื่องบิน สำหรับภาพวัตถุที่ไม่ใช่เครื่องบินเป็นภาพที่สุ่มตัวอย่างจาก ส่วนอื่นๆ(land-cover)ในภาพถ่ายดาวเทียมเช่น ภาพของพื้นที่ที่เป็นน้ำ ดิน เป็นต้น ตัวอย่างภาพวัตถุของทั้งสอง classes แสดงให้เห็นในรูปที่ 2 และรูปที่ 3 ตามลำดับ



รูปที่ 2 ตัวอย่างภาพวัตถุที่เป็นเครื่องบิน [6]




รูปที่ 3 ตัวอย่างภาพวัตถุที่ไม่ใช่เครื่องบิน [6]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ข้อมูลดังกล่าวมีภาพวัตถุที่เป็นเครื่องบินจำนวน 7,995 ภาพ และ 23,995 ภาพเป็นวัตถุที่ไม่ใช่เครื่องบิน ซึ่งในกระบวนการ training จะใช้ข้อมูลจำนวน 10% ของข้อมูลทั้งหมดในแต่ละ class และอีก 90% ในแต่ละ class เป็นข้อมูลในการ test โมเดล นอกจากนี้ยังมีข้อมูลอีก 10 รูปภาพที่ใช้ในการแสดงผลการทำงานของโมเดล ที่ได้รับการ train และ test เรียบร้อยแล้ว

## Experiment

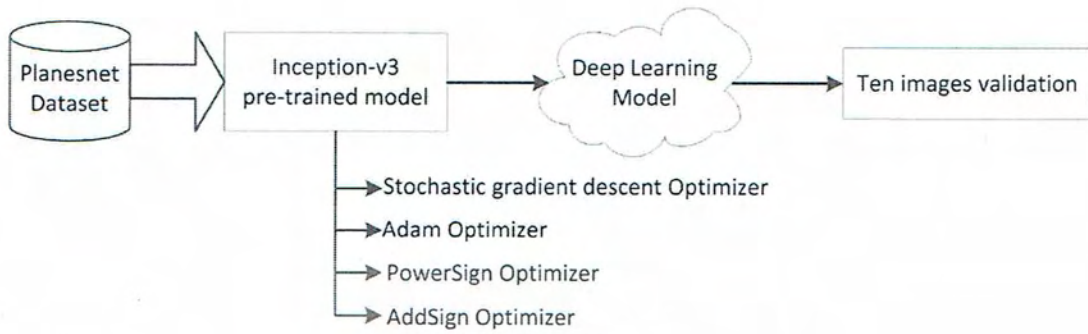
ขั้นตอนการสร้างโมเดลถูกออกแบบตามรูปที่ 4 โดยในการทำงาน inception-v3 pre-trained model จะถูกเพิ่มชั้นการทำงาน(layer) ข้างบนสุดที่มีชื่อเรียกว่า fully-connected layer และ softmax layer สำหรับ training อีกครั้งซึ่งจะมีการกระบวนการในการระบุ classes(plane และ no-plane) ใหม่ในกระบวนการนี้ด้วย ซึ่งในกระบวนการ training ดังกล่าว pre-trained model จะมีการนำเอาความรู้(knowledge) ที่เก็บอยู่ในรูปแบบของเครือข่าย(network) และน้ำหนัก(weights) มาใช้งาน และผู้พัฒนาหรือผู้ใช้งานสามารถกำหนดค่าตัวแปรเริ่มต้นต่างๆเพื่อใช้ในการ training ได้ปกติ



รูปที่ 4 ขั้นตอนการสร้างโมเดล

การทดลองแบ่งออกเป็นสองขั้นตอน ขั้นตอนหนึ่งจะเป็นการ training inception-v3 pre-trained model โดยใช้ optimizer ทั้งสี่ชนิดได้แก่ Stochastic Gradient Descent optimizer, Adam optimizer, AddSign optimizer, และ PowerSign optimizer ซึ่งขั้นตอนการทำงานดังกล่าวแสดงในรูปที่ 5

ขั้นตอนที่สองของการทดลองคือการวัดผลโมเดลแต่ละโมเดลที่ถูกสร้างขึ้นในขั้นตอนแรกโดยใช้ optimizer ทั้งสี่ชนิด นอกจากนี้ยังมีการแสดงผลการทำงานของแต่ละโมเดลที่ใช้ภาพวัตถุที่เป็นเครื่องบินจำนวนห้ารูป และภาพวัตถุที่ไม่ใช่เครื่องบินจำนวนห้ารูป



รูปที่ 5 ขั้นตอนการทดลอง [7]



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บทที่ 4 ผลการวิจัย

ในการทดลองใช้ Tensorflow opensource software library ที่กำหนดให้อัตราการเรียนรู้(learning rate) มีค่า 0.001 และขนาด batch ของกระบวนการ train และ test ถูกกำหนดให้มีค่า 100 สำหรับ AddSign optimizer และ PowerSign optimizer มีการกำหนดค่าของ  $\alpha$  เท่ากับ 0.01 และ  $\beta$  เท่ากับ 0.5 ค่าความแม่นยำของข้อมูล testing (final test accuracy) เมื่อทดสอบ inception-v3 pre-trained model กับ Stochastic Gradient Descent optimizer มีค่าเท่ากับ 83.0% ในขณะที่ Adam optimizer ให้ผลลัพธ์ดังกล่าวเท่ากับ 91.8% และ AddSign optimizer และ PowerSign optimizer ให้ค่าดังกล่าวเท่ากับ 82.9% และ 84.1% ตามลำดับ

จากผลการทดลองข้างต้นจะเห็นได้ว่า Adam optimizer ให้ค่าความแม่นยำสูงสุดกับข้อมูล planesnet ตามมาด้วย PowerSign optimizer และ Stochastic Gradient Descent optimizer นอกจากนี้ข้อมูลภาพวัตถุที่เป็นเครื่องบินและไม่ใช้เครื่องบินจำนวนสิบรูปแสดงตามตาราง 1 ซึ่งจะใช้ในการแสดงการทำงานของโมเดลที่ได้จากการ train inception-v3 pre-trained model ร่วมกับ optimizer ทั้งสี่ชนิด ซึ่งรูปภาพทั้งสิบแบ่งออกเป็น ภาพวัตถุเครื่องบินจำนวนห้ารูป และไม่ใช้เครื่องบินจำนวนห้ารูป

ตาราง 1 ภาพวัตถุเครื่องบินจำนวนห้ารูป และไม่ใช้เครื่องบินจำนวนห้ารูปที่ใช้แสดงผลการใช้งานโมเดล

เครื่องบิน #1	เครื่องบิน #2	เครื่องบิน #3	เครื่องบิน #4	เครื่องบิน #5
				
ไม่ใช่เครื่องบิน #1	ไม่ใช่เครื่องบิน #2	ไม่ใช่เครื่องบิน #3	ไม่ใช่เครื่องบิน #4	ไม่ใช่เครื่องบิน #5
				

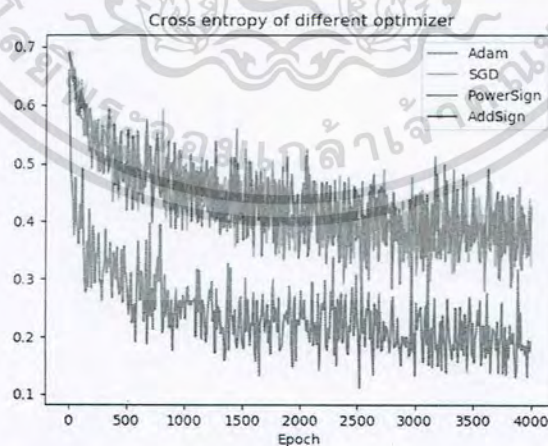
ตาราง 2 แสดงผลการใช้งานโมเดลที่ใช้ optimizer ทั้งสี่ชนิด โดยรูปภาพวัตถุทั้งสิบรูป

	Accuracy (%)			
	SGD	Adam	AddSign	PowerSign
เครื่องบิน #1	58.540	94.632	58.148	57.907

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เครื่องบิน #2	61.013	72.621	60.730	61.052
เครื่องบิน #3	79.819	98.360	79.897	77.604
เครื่องบิน #4	77.733	57.907	77.774	78.742
เครื่องบิน #5	67.561	75.179	66.949	71.612
ไม่ใช่เครื่องบิน #1	98.493	99.992	98.511	98.851
ไม่ใช่เครื่องบิน #2	90.635	99.501	90.864	92.440
ไม่ใช่เครื่องบิน #3	84.785	99.946	84.314	87.459
ไม่ใช่เครื่องบิน #4	88.382	99.986	88.127	90.584
ไม่ใช่เครื่องบิน #5	95.596	99.822	95.682	96.007

ตาราง 2 แสดงผลการใช้งานโมเดลที่ใช้ optimizer ทั้งสี่ชนิด โดยรูปภาพวัตถุทั้งสิบรูป Adam optimizer แสดงค่าความแม่นยำมากกว่า optimizer ชนิดอื่นๆ และแสดงผลการทำงานได้ดีที่สุดในรูปเครื่องบิน#1 ในขณะที่ optimizer ชนิดอื่นๆ แสดงผลความแม่นยำที่ประมาณ 58% เท่านั้น อย่างไรก็ตาม Adam optimizer ไม่สามารถให้ผลลัพธ์ที่ดีในรูป เครื่องบิน#4 แต่ PowerSign optimizer ให้ผลลัพธ์ที่ดีกว่า เมื่อพิจารณาประสิทธิภาพโดยรวมจากผลการแสดงผลการทำงานของโมเดลจากภาพวัตถุทั้งสิบภาพแสดงให้เห็นว่า Adam optimizer ให้ผลลัพธ์ที่ดีซึ่งสอดคล้องกับรูปที่ 6 ซึ่งเป็นการแสดงความสามารถในการลดค่าความผิดพลาดหรือ cross entropy ในแต่ละรอบของการประมวลผลซึ่ง Adam optimizer แสดงผลดีกว่า optimizer ชนิดอื่นๆ



รูปที่ 6 ความสามารถในการลดค่า cross entropy ในแต่ละรอบของการประมวลผล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### บทที่ 5 สรุปผลการวิจัยและข้อเสนอแนะ

ในการศึกษาวิจัยนี้ได้นำ inception-v3 pre-trained model มาใช้โดยมีการทดสอบและเปรียบเทียบประสิทธิภาพเมื่อทำงานร่วมกับ optimizer สี่ชนิดได้แก่ (1)Stochastic Gradient Descent optimizer, (2)Adam optimizer, (3)AddSign optimizer,(4)PowerSign optimizer และใช้ข้อมูล planesnet ในการทดลอง ซึ่งในการนำไปใช้งานจริงไม่จำเป็นต้องใช้ในการระบุชนิดของวัตถุใน class ของเครื่องบินหรือไม่ใช่เครื่องบินเพียงเท่านั้น แต่สามารถประยุกต์ใช้ได้กับงานหลายๆประเภทขึ้นอยู่กับจุดประสงค์ของการใช้งาน ในการวิจัยนี้ Adam optimizer ให้ผลลัพธ์ที่ดีที่สุดเมื่อเทียบกับ optimizer ชนิดอื่นๆ งานวิจัยนี้สามารถนำไปเป็นพื้นฐานในการวิจัยในอีกหลายๆเรื่อง เช่น การเพิ่มประสิทธิภาพของ optimizer โดยอาจมีการทำงานร่วมกับวิธีการที่สามารถนำมาใช้ในการประมาณค่าเช่น state estimation เป็นต้น



## บทที่ 6 สรุปผลผลิตงานวิจัย

งานวิจัยในครั้งนี้ มีผลผลิตจำนวน 1 รายการ เป็นการนำเสนอผลงานในการประชุมวิชาการระดับนานาชาติ 39th, 2019 IEEE International Geoscience and Remote Sensing Symposium ระหว่างวันที่ 28 กรกฎาคม – 2 สิงหาคม พ.ศ. 2562 ณ เมืองโยโกฮาม่า ประเทศญี่ปุ่น ซึ่งถูกจัดอยู่ในฐานข้อมูล Scopus และมีรายละเอียดขั้นตอนการตอบรับคั้งแสดงในภาคผนวก



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บรรณานุกรม

- [1] V. V. S. I. J. S. a. Z. W. C. Szegedy, "Rethinking the Inception Architecture for Computer Vision," in *2016, IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, 2016.
- [2] B. Z. V. V. Q. V. L. Irwan Bello, "Neural Optimizer Search with Reinforcement Learning," in *Proceedings of the 34th International Conference on Machine Learning*, Sydney, Australia, 2017.
- [3] "Image Recognition," [Online]. Available: [tensorflow.org/tutorials/images/image](https://www.tensorflow.org/tutorials/images/image).
- [4] S. Ruder, "An overview of gradient descent optimization algorithms," *CoRR, abs/1609.04747*, 2016.
- [5] J. B. Diederik P. Kingma, "Adam: A Method for Stochastic Optimization," in *The 3rd International Conference for Learning Representations*, San Diego, 2015 .
- [6] "Imagery, Planes in Satellite," [Online]. Available: <https://www.kaggle.com/rhammell/planesnet>.
- [7] "Advanced Guide to Inception v3 on Cloud TPU,," [Online]. Available: [cloud.google.com/tpu/docs/inception-v3-advanced](https://cloud.google.com/tpu/docs/inception-v3-advanced).



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### Scopus Preview

## Source details

# International Geoscience and Remote Sensing Symposium (IGARSS)

Scopus coverage years: from 1982 to 1983, from 1985 to 2018

Subject area: [Earth and Planetary Sciences: General Earth and Planetary Sciences](#)

[Computer Science: Computer Science Applications](#)

CiteScore 2018 **0.59** ⓘ

SJR 2018 **0.271** ⓘ

SNIP 2018 **0.286** ⓘ

[View all documents >](#)

CiteScore CiteScore rank & trend CiteScore presets Scopus content coverage

CiteScore 2018 Calculated using data from 30 April, 2019 CiteScore rank ⓘ

CiteScore	Citation Count	Documents	Category	Rank	Percentile
0.59	2,877 Citations >	4,837 Documents >	Earth and Planetary Sciences	#113/182	37th
0.12	665 Citations to date >	5,685 Documents to date >	Computer Science	#455/569	19th

\*CiteScore includes all available document types [View CiteScore methodology >](#) [CiteScore FAQ >](#)

CiteScore Tracker 2019 ⓘ Last updated on 30 April, 2019 Updated monthly

[View CiteScore trends >](#) [Add CiteScore to your site ⓘ](#)

Metrics displaying this icon are compiled according to Snowball Metrics, a collaboration between industry and academia.

### About Scopus

- What is Scopus
- Content coverage
- Scopus blog
- Scopus API
- Privacy matters

### Language

- 日本語に切り替える
- 切换到简体中文
- 切换到繁體中文
- Русский язык

### Customer Service

- Help
- Contact us

ELSEVIER

[Terms and conditions >](#) [Privacy policy >](#)

Copyright © 2019 Elsevier B.V. All rights reserved. Scopus® is a registered trademark of Elsevier B.V. We use cookies to help provide and enhance our service and tailor content. By continuing, you agree to the use of cookies.

RELX

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



July 28 - August 2, 2019 • Yokohama, Japan  
Pacifico Yokohama

## Paper Submission Status

**Paper Number:** 1266

**Paper Title:** Deep Convolutional Neural Networks for plane identification on Satellite imagery by exploiting transfer learning with a different optimizer

**Primary Review Category:** ST.3: Special Themes - Big data and machine learning

**Student Paper Contest:** Not entered in the contest.

**Initial Submission Time Stamp:** 12/27/2018 2:44:46 AM

**Revised Submission Time Stamp:** 4/29/2019 4:51:17 AM

**Current Server Time:** 5/31/2019 2:09:57 AM

**Request Paper Withdraw:** [Click Here \(PaperWithdraw.asp\)](#)

Status	Item	Result
COMPLETE	Copyright Form	Copyright form has been received.
COMPLETE	Proposal Upload	Document has been uploaded.
COMPLETE	Proposal Inspection	Document passed inspection.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

COMPLETE	Technical Committee Review	Document has been accepted into the technical program.
COMPLETE	Final Paper Upload	Document has been uploaded.
IN PROGRESS	Final Paper Inspection	Document is currently being inspected. Please allow 7-10 days after the submission deadline. No action is required by you at this time.
<b>Paper Status</b>		
INCOMPLETE	The paper submission/review is not complete. Please check above to see if any items need to be completed by you.	

### Active Final Paper

**Current Submitted Final Paper:** [Download \(Uploads/FinalPapers/PaperNum/1266/2019041394117\\_204888\\_1266.pdf\)](#) Date: 4/13/2019 9:41:17 AM

Previous Final Paper Uploads (Not Active)

Archived Paper: [Download \(Uploads/FinalPapers/PaperNum/1266/2019041393036\\_221244\\_1266.pdf\)](#) Date: 4/13/2019 9:30:36 AM

### Active Paper

**Current Submitted Paper :** [Download \(Uploads/Proposals/PaperNum/1266/20181227030431\\_970498\\_1266.pdf\)](#) Date: 12/27/2018 3:04:31 AM

For questions about this page, or for technical support, contact [papers@igarss2019.org](mailto:papers@igarss2019.org) (<mailto:papers@igarss2019.org>).

©2019 IEEE GRSS (<http://grss-ieee.org>)  
Last updated Thursday, January 03, 2019

Web Host: <http2://cmsworldwide.com> (<http2://cmsworldwide.com>)  
Support: [webmaster@igarss2019.org](mailto:webmaster@igarss2019.org) (<mailto:webmaster@igarss2019.org>)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



สรุปค่าใช้จ่ายการดำเนินโครงการวิจัย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สัญญาเลขที่ 2562-02-18006

โครงการ Improve transfer learning performance by using Kalman-based Stochastic  
Gradient Descent

ชื่อหัวหน้าโครงการวิจัย ผู้รับทุน.....ดร.พัชรินทร์ คำสิงห์.....  
รายงานในช่วงตั้งแต่วันที่ 17 เดือนธันวาคม พ.ศ. 2561 ถึงวันที่ 16 เดือน มิถุนายน พ.ศ.2562

จำนวนเงินที่ได้รับ รายจ่าย และจำนวนเงินคงเหลือ (ให้รายงานแบบสะสมทุกงวด)

งวดที่ / รายการ	รายรับ (บาท)		รายจ่าย (บาท)	คงเหลือ (บาท)
	จำนวนเงินที่ได้รับ	วันที่ได้รับ		
ค่าตอบแทน	0	2 พ.ค. 2562	80,000	-80,000
1	68,000	24 พ.ค.2562	0	-12,000
2	0	0	0	-12,000
รวมจำนวนเงินที่ ได้รับทั้งสิ้น	68,000	รวมรายจ่ายทั้งสิ้น	80,000	-12,000

จำนวนเงินคงเหลือ...-12,000...บาท ประกอบด้วย เงินฝากธนาคาร...0 บาท เงินสดในมือ -12,000 บาท

.....  
ลงนามหัวหน้าโครงการวิจัยผู้รับทุน

.....  
ลงนามเจ้าหน้าที่การเงินโครงการ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## ประวัตินักวิจัย

### ประสบการณ์ทำงาน

อาจารย์ (พฤศจิกายน 2561 - ปัจจุบัน)

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง - กรุงเทพมหานคร, ประเทศไทย  
ภาควิชาวิศวกรรมการบิน วิทยาลัยอุตสาหกรรมการบินนานาชาติ

วิศวกร (กันยายน 2553 – สิงหาคม 2554)

บริษัท แอดวานซ์ อินโฟร์ เซอร์วิส จำกัด (มหาชน) - กรุงเทพมหานคร, ประเทศไทย  
แผนก International Roaming Network

วิศวกร (เมษายน 2552 – สิงหาคม 2553)

บริษัท แอดวานซ์ อินโฟร์ เซอร์วิส จำกัด (มหาชน) - กรุงเทพมหานคร, ประเทศไทย  
แผนก SIM and Handset

### ประวัติการศึกษา

ปริญญาเอก (กันยายน 2556 – พฤษภาคม 2559)

มหาวิทยาลัยบัณฑิตวิทยาศาสตร์แห่งสาธารณรัฐประชาชนจีน (Chinese Academy of Sciences: CAS)– ปักกิ่ง, สาธารณรัฐประชาชนจีน

สถาบัน: Institute of Remote Sensing and Digital Earth, สาธารณรัฐประชาชนจีน

สาขา: Cartology and Geographic Information Sciences

หัวข้อวิจัย: Applied a state estimation technique and machine learning in remote sensing

ทุนการศึกษาจาก the Chinese Academy of Sciences (CAS) and The World Academy of Sciences (TWAS) president's fellowship

ปริญญาโท (กันยายน 2554 – มิถุนายน 2556)

มหาวิทยาลัยการบินและอวกาศแห่งกรุงปักกิ่ง (Beihang University)– ปักกิ่ง, สาธารณรัฐประชาชนจีน

แผนกวิชาวิศวกรรมอิเล็กทรอนิกส์และสารสนเทศ

สาขา: วิศวกรรมกรรมการสื่อสารผ่านดาวเทียม (Satellite Communication)

หัวข้อวิจัย: Joint iterative channel estimation and decoding under pulsed radio frequency interference condition

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ทุนการศึกษาจากองค์การความร่วมมือทางด้านอวกาศเอเชียแปซิฟิก(Asia-Pacific Space Cooperation Organization, APSCO)

ปริญญาตรี (พฤษภาคม 2546 – เมษายน 2550)

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง - กรุงเทพมหานคร, ประเทศไทย

สาขา: วิศวกรรมโทรคมนาคม(เกียรตินิยมอันดับ 2)

หัวข้อวิจัย: Wireless sensor for water quality monitoring system by using TRW-2.4G

### ผลงานวิจัยในวารสารระดับนานาชาติ

Patcharin Insom; Chunxiang Cao; Pisit Boonsrimuang; Peerapong Torteeka; Di Liu; Sornkitja Boonprong; Wei Chen, “Dynamics of Wetland Cover Change using State Estimation technique applied to Time-series Remote Sensing Imagery,” in Geomatics, Natural Hazards & Risk, vol.8, no.2, pp.1662-1677, Oct.2017.doi: 10.1080/19475705.2017.1370025.

Insom, P.; Chunxiang Cao; Boonsrimuang, P.; Di Liu; Saokarn, A.; Yomwan, P.; Yunfei Xu, “A Support Vector Machine-Based Particle Filter Method for Improved Flooding Classification,” in Geoscience and Remote Sensing Letters, IEEE , vol.12, no.9, pp.1943-1947, Sept. 2015. doi: 10.1109/LGRS.2015.2439575.

Patcharin Insom; Piyakiat Insom; and Pisit Boonsrimuang, “Joint iterative channel estimation and decoding under impulsive interference condition,” in ICACT Transactions on the Advanced Communications Technology (TACT), GIRI (Global IT Research Institute), Vol. 4, Issue 4, pp.636-643, July 2015. ISSN: 2288-0003.

### ผลงานงานวิจัยในการประชุมวิชาการระดับนานาชาติ

Patcharin Insom, Chunxiang Cao, Pisit Boonsrimuang, Shanning Bao, Wei Chen, Xiliang Ni, “A support vector machine-Based Particle Filter for improved land cover classification applied to MODIS data,” in Geoscience and Remote Sensing Symposium (IGARSS), 2016 IEEE International, Beijing, China, 10-15 July 2016, doi: 10.1109/IGARSS.2016.7729195.

P. Insom, Rongke Liu, Ruifeng Duan, Yi Hou and P. Boonsrimuang, “Joint iterative channel estimation and decoding under pulsed radio frequency interference condition,” Advanced

Communication Technology (ICTACT), 2014 16th International Conference on, Pyeongchang, 2014, pp. 983-988. doi: 10.1109/ICTACT.2014.6779105

Patcharin Insom, Chunxiang Cao and Pisit Boonsrimuang, "Flood classification by nearest neighbor based on NDWI of HJ-satellite data," in The 4th International Workshop on Diagnosis of Environmental Health by Remote Sensing (DEHRS) and Technology Forum on Remote Sensing, 2014.



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

# Deep Convolutional Neural Networks for plane identification on Satellite imagery by exploiting transfer learning with a different optimizer

Patcharin Kamsing<sup>†\*</sup>, Peerapong Torteeka<sup>‡</sup>, Soemsak Yooyen<sup>†</sup>

<sup>†</sup>Department of Aeronautical Engineering and Commercial Pilot, International Academy of Aviation Industry  
King Mongkut's Institute of Technology Ladkrabang, Bangkok 10520, Thailand

<sup>‡</sup>National Astronomical Research Institute of Thailand, ChiangMai 50180, Thailand.

\*Email: insom.patcharin@gmail.com

**Abstract**—Object identification is on an available problem. Automating plane identification on Satellite imagery can be applied for activity and traffic patterns to monitoring airports, and including defense intelligence issues. This paper implements Deep Convolutional Neural Networks(CNN) to classify a plane in the planesnet dataset. Pre-trained model and transfer learning are deployed to overcome a limitation of computation resources by adding new top layer consists of a fully-connected layer and softmax layer to identify the new classes and re-train it. Besides, the experimental designs for testing an implementation of a pre-trained model with some kinds of the optimizer to comparing a result. There are four types of optimizer. The first two are well-known optimizer namely Stochastic Gradient Descent optimizer and Adam Optimizer, while others are PowerSign and AddSign optimizer. PowerSign and AddSign optimizer are methods to minimize cost, which discover by using Recurrent neural network(RNN) and Reinforcement Learning. A result demonstrates that a plane identification on Satellite imagery can be achieved by implementing the pre-trained model and obtains an exceptional result with Adam optimizer.

**Index Terms**—Transfer Knowledge, Pre-trained model, Optimizer, Deep Learning, CNN

## I. INTRODUCTION

Recently, Artificial Intelligent(AI) has been developing and deployment in many applications. Neural Network and Deep Learning have been widely applied for both pattern and non-pattern dataset because there is no feature extraction process as other kinds of machine learning, which needs a human work for this processing. Deep Learning can deal with both static and dynamic dataset. It has many architectures for a developer to select a proper structure for their environment and dataset such as Convolutional Neural Network(CNN), Recurrent Neural Networks(RNN), Long short-term memory(LSTM). In the context of image classification, CNN architecture is extended to apply in several applications.

In image identification processes, two major problems of implementing Deep Learning are 1)limited in computing resources and 2)limited in increase/decrease categories or classes. Typically, developers have to define the number of classes before other processes of Deep Learning modeling. If

the number of class is increased/decreased later, a developer has to re-run all processes of Deep Learning modeling from scratch again. It is not only time consuming, but also it has to spend computational resources.

Transfer learning is a technique for transfer previous knowledge to a current one. Inception-v3 [4] is a Deep Convolutional Neural Networks pre-trained model, which created to solve another previous problem. Instead of building a model from scratch to solve a target problem, one uses the model trained on another problem as a starting point and then transfer learned feature to target feature. Although a pre-trained model may not by providing 100% accuracy for any application, it can save a huge of effort for building model from scratch.

Every Deep Learning architectures need an optimizer to minimize error in their operation. An optimizer is a significant factor for the increased performance of Deep Learning model. The different dataset also impacts on the selection of an optimizer. A researcher presents several optimizers by using different mathematical equations. Stochastic Gradient Descent(SGD) often deploys and work well in many applications, more advanced optimizer such as Adam optimizer can work faster, primarily, in very deep networks [1]. Others two method that is created by Reinforcement Learning also are interesting [1]. The researchers train RNN controller to generate a string in a domain of mathematics language such as the gradient, running average of the gradient. In each epoch, the controller is trained by Reinforcement Learning to maximize performance. They obtain the great optimizer namely, AddSign optimizer and PowerSign Optimizer.

The rest of this paper is structured as follow. Section II is the related work containing re-trained model and transfer learning, SGD optimizer, Adam optimizer, AddSign, and PowerSign optimizer. Section III consist of Dataset, Data preparation and experimental designed. Section IV describes a result which comparing a final test accuracy of all concentrated optimizer. A result of testing ten images of plane classes(five images) and no-plane classes(five images) with the models that generated by different optimizer also included in this section. A conclusion is drawn in the last section.

This work was supported by King Mongkut's Institute of Technology Ladkrabang, Bangkok 10520, Thailand.

## II. RELATED WORKS

### A. Pre-trained model and Transfer Learning

Inception-v3 pre-trained model has been generated by learning various kinds of a feature from other previous trained data. Inception-v3 is trained for the large visual recognition challenge using the data from 2012, the ImageNet. This is a standard task in computer vision, where models try to classify entire images into 1000 classes, like “Zebra”, “Dalmatian”, and “Dishwasher” [5].

Pre-trained models can overcome a limitation of computation resources and limitation of scale up a model because it is adopting a learning feature from many previous images as a starting point of training, which helps to reduce implementing time and not much complexity to add more categories. Knowledge(network and weights) from previous training model are frozen, and the last top layer is “Bottleneck” layer, which it will use for connecting to a target dataset in order to rebuild it again which it is called transfer learning.

Same as other deep CNN architectures, Inception-v3 pre-trained model consists of convolution layer, pooling, etc. Structure of Inception-v3 pre-trained model is designed in order to reach the maximum performance which expresses as Fig 1. Although a pre-trained model can reduce the cost of the training process, it has limitation at 1,000 categories [5]. If an application wishes to have more than 1,000 categories, it may deploy many pre-trained models in parallel.

### B. Stochastic Gradient Descent Optimizer

Stochastic Gradient Descent Optimizer(SGD) is one of widely and most popular algorithm to implement for an optimizer to reduce a cost and optimize neural networks [7].

$$w_{(n+1)} = w_{(n)} - Lr * \hat{g} \quad (1)$$

where:

$w_{(n)}$  is variable update at time  $n$

$Lr$  is learning rate

$\hat{g}$  is a gradient vector

Processing in each epoch of neural networks has an aim to reduce an error which many of work are defined in term of cross entropy. SGD will perform a variable update in every epoch to minimize the error. The equation of SGD demonstrates as (1). The variable will update by using prior time step variable minus with a result from learning rate multiple with a gradient vector.

### C. Adam Optimizer

Adaptive Moment Estimation or Adam optimizer is another advance competitive optimizer by taking a consider of first and second moment. In each time step, Adam optimizer will perform its task as follow the equation (2) [2] [7]:

$$w_{(n+1)} = w_{(n)} - \frac{Lr}{\sqrt{\hat{v}_n} + \epsilon} \hat{m}_n \quad (2)$$

and:

$$\hat{m}_n = \frac{\beta_1 m_{n-1} + (1 - \beta_1) \hat{g}_n}{1 - \beta_1^n} \quad (3)$$

$$\hat{v}_n = \frac{\beta_2 v_{n-1} + (1 - \beta_2) \hat{g}_n^2}{1 - \beta_2^n} \quad (4)$$

where:

$w_{(n)}$  is variable update at time  $n$

$Lr$  is learning rate

$\hat{g}$  is a gradient vector

$m_n$  is an estimation of the first moment (the mean) of the gradients

$v_n$  is the second moment (the uncentered variance) of the gradients

By the default values of 0.9 for  $\beta_1$ , 0.999 for  $\beta_2$ , and  $10^{-8}$  for  $\epsilon$ . Adam optimizer is straightforward to implement and can efficiently solve practical deep learning problems with using large dataset.

### D. AddSign Optimizer and PowerSign Optimizer

AddSign and PowerSign optimizer are built with the aim to use RNN and Reinforcement Learning to generate a new optimizer. They train RNN to be a controller to generate a string that describes a mathematical update equation based on a list of primitive functions. The RNN controller is trained with Reinforcement Learning to maximize the performance of a model after a few epochs [1]. In their research paper, which implements with CIFAR-10 dataset mentions that the results are outperforming than commonly used optimizer, such as Adam or SGD optimizer.

AddSign optimizer illustrates as the equation(5):

$$w_{(n+1)} = w_{(n)} - Lr * \hat{g} * (1 + \alpha * f_n * \text{sign}(\hat{g}) * \text{sign}(\hat{m}_n)) \quad (5)$$

PowerSign optimizer is shown as the equation(6):

$$w_{(n+1)} = w_{(n)} - Lr * \hat{g} * \alpha^{f_n * \text{sign}(\hat{g}) * \text{sign}(\hat{m}_n)} \quad (6)$$

where:

$w_{(n)}$  is variable update at time  $n$

$Lr$  is learning rate

$\hat{g}$  is a gradient vector

$f_n$  is either 1 or an internal decay function of the training step  $n$  (linear decay, cyclical or restart decays) and by default value of 0.01 for  $\alpha$  [1]. In addition,  $\hat{m}_n$  refer to the equation(7)

$$\hat{m}_n = \text{Maximum}[\beta * m + \text{eps}, \text{abs}(\hat{g})] \quad (7)$$

where  $\beta$  is set to 0.5 and  $\text{eps}$  is  $10^{-7}$ .  $m$  is an estimation of the first moment (the mean) of the gradients. The next section provides the experimental method, which will deploy the pre-trained model with four kinds mentioned optimizer.

## III. METHOD

### A. Dataset and Data preparation

Satellite imagery provides unique insights into various fields, for example, agriculture, defense and intelligence, energy, and finance. New commercial imagery providers, such as Planet and BlackSky, are using constellations of small satellites to exponentially increase the number of images of the



Fig. 1. Schematic diagram of Inception V3 [6]

earth captured every day. In the experiment, planes in Satellite Imagery or planesnet dataset [3] are used. This dataset aims to help address the difficult task of detecting the location of airplanes in satellite images, which can be applied to many issues including monitoring airports for activity and traffic patterns, and defense intelligence.

The dataset contains two categories namely “plane” class includes 8,000 images and “no-plane” class includes 24,000 images. For images in plane class has single airplane body with the majority of the plane’s wings, tail, and nose also visible. For images in no-plane class are random simple from difference land-cover feature, which consist of water, vegetation, bare earth, buildings, etc. Example of the two classes is shown in Fig. 2 and Fig. 3, respectively. There




Fig. 2. Example of images in “plane” class [3].



Fig. 3. Example of images in “no-plane” class [3].

are 7,995, and 23,995 images from a plane and no-plane class respectively are used in training model process which they separate for training and testing dataset by setting 10% as the

testing dataset and keep other 90% as training dataset. Other ten images from both classes are held for validating the model.

### B. Experiment




Fig. 4. Experimental design

An experimental design demonstrates as Fig. 4. The Inception-v3 pre-trained model is added by the top-layer with a fully-connected layer and softmax layer for re-training and identifies the new classes(plane and no-plane). A pre-trained model has held some variables for re-training such as weights, and the user can set up all the gradients for the backward pass.

The experiment separates into two parts. The first one is re-training Inception-v3 pre-trained model by implementing with four focused optimizers namely Stochastic Gradient Descent optimizer, Adam optimizer, AddSign optimizer, and PowerSign optimizer shown as Fig. 5. The second part is about an evaluation of each model which using different optimizer. Result validation performs with ten images divided to a plane category for five images, and other five images belong to a no-plane category. Validation work-flow illustrates as Fig. 5.

## IV. RESULTS AND DISCUSSIONS

All experiments have been done by using Tensorflow open-source software library with setting learning rate equal to 0.001. Train and test batch size during the training process are set at 100. For AddSign optimizer and PowerSign optimizer are set value of 0.01 for  $\alpha$  and 0.5 for  $\beta$ . Final test accuracy of implementing Inception-v3 pre-trained model with Stochastic Gradient Descent optimizer is 83.0%, with

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




Fig. 5. Schematic diagram of Inception V3 [6]

Adam optimizer provides 91.8%, with AddSign optimizer and PowerSign optimizer give 82.9% and 84.1%, respectively. As a result, Adam optimizer outperforms than others in a planesnet dataset and follow with PowerSign optimizer and Stochastic Gradient Descent optimizer. Also, there are ten images in Table I, which use to validate the model from the different optimizer. There are five images for plane class and five images for no-plane class. The accuracy of these ten images for different optimizer demonstrates in Table II. In both plane

TABLE I  
TESTING IMAGES OF BOTH PLANE AND NO PLANE CLASSES

Plane1	Plane2	Plane3	Plane4	Plane5
No Plane1	No Plane2	No Plane3	No Plane4	No Plane5

TABLE II  
ACCURACY OF USING DIFFERENCE OPTIMIZER FOR TESTING IMAGES

Test Img No.	Accuracy(%)			
	Gradient descent	Adam	AddSign	PowerSign
Plane1	58.540	<b>94.632</b>	58.148	57.907
Plane2	61.013	<b>72.621</b>	60.730	61.052
Plane3	79.819	<b>98.360</b>	79.897	77.604
Plane4	77.733	57.907	77.774	<b>78.742</b>
Plane5	67.561	<b>75.179</b>	66.949	71.612
No Plane1	98.493	99.992	98.511	<b>98.851</b>
No Plane2	90.635	99.501	90.864	92.440
No Plane3	84.785	99.946	84.314	87.459
No Plane4	88.382	99.986	88.127	<b>90.584</b>
No Plane5	95.596	99.822	95.682	96.007

class and no-plane class, Adam optimizer express a better performance than others, and it shows the exceptional result in the first image of plane class, whereas other optimizers retain an accuracy around 58%. However, Adam optimizer has a rough performance in the third image of plane class comparing with others, while PowerSign optimizer performs well in this testing image. The overall performance of the ten testing image demonstrates that Adam optimizer provides an excellent result corresponding to Fig. 6, which can reduce cross entropy in every epoch better than other optimizers.

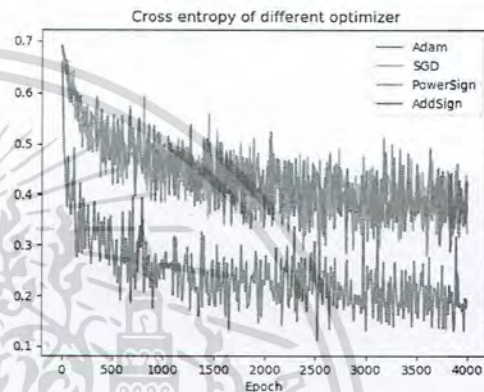


Fig. 6. Cross entropy over each iteration entire dataset

## V. CONCLUSION

Inception-v3 pre-trained model with different optimizer is implemented for plane identification. Adam optimizer can provide the exceptional performance planesnet dataset. This method is not limited to only plane identification, but it can be applied for other applications which include both human-made and natural objects. Further research would be creating an optimizer based on state estimation technique with an aim to obtain higher accuracy and make a distinct optimizer calculation.

## REFERENCES

- [1] Irwan Bello and Barret Zoph and Vijay Vasudevan and Quoc V. Le, "Neural Optimizer Search with Reinforcement Learning," Proceedings of the 34th International Conference on Machine Learning, vol.70, pp. 459-468, Aug 2017.
- [2] Diederik P. Kingma, Jimmy Ba, "Adam: A Method for Stochastic Optimization," The 3rd International Conference for Learning Representations, San Diego, 2015
- [3] Planes in Satellite Imagery, <https://www.kaggle.com/rhannell/planesnet>
- [4] C. Szegedy, V Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, "Rethinking the Inception Architecture for Computer Vision," 2016, IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, 2016, pp. 2818-2826.
- [5] Image Recognition, [tensorflow.org/tutorials/images/image\\_recognition](https://www.tensorflow.org/tutorials/images/image_recognition), December 12, 2018.
- [6] Advanced Guide to Inception v3 on Cloud TPU, [cloud.google.com/tpu/docs/inception-v3-advanced](https://cloud.google.com/tpu/docs/inception-v3-advanced), December 18, 2018.
- [7] Sebastian Ruder, "An overview of gradient descent optimization algorithms", CoRR, abs/1609.04747, 2016.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สัญญาเลขที่ 2562-02-18006

โครงการ Improve transfer learning performance by using Kalman-based Stochastic Gradient Descent

รายงานสรุปการเงินรอบ 6 เดือน

ชื่อหัวหน้าโครงการวิจัย ผู้รับทุน ดร.พีชรินทร์ คำสิงห์

รายงานในช่วงตั้งแต่วันที่ 17 เดือนธันวาคม พ.ศ. 2561 ถึงวันที่ 16 เดือนมิถุนายน พ.ศ. 2562

สรุปงบประมาณค่าใช้จ่ายที่ใช้นับตั้งแต่เริ่มทำการวิจัยถึงปัจจุบัน

หมวดค่าใช้จ่าย	รายจ่ายสะสมจากรายงานครั้งก่อน 1	ค่าใช้จ่ายงวดปัจจุบัน 2	รวมรายจ่ายสะสมจนถึงปัจจุบัน 3 = 1 + 2	งบประมาณตั้งไว้ (สะสมจนถึงปัจจุบัน) 4	งบประมาณคงเหลือ (หรือเกิน) 5 = 4 - 3
งบบุคลากร : ค่าจ้างชั่วคราว	0	0	0	0	0
งบดำเนินงาน					
ค่าตอบแทน	0	80,000	80,000	80,000	0
ค่าใช้สอย	0	0	0	0	0
ค่าวัสดุ	0	0	0	0	0
ค่าสาธารณูปโภค	0	0	0	0	0
งบลงทุน: ค่าครุภัณฑ์	0	0	0	0	0
รวม	0	80,000	80,000	80,000	0

จำนวนเงินที่ได้รับ รายจ่าย และจำนวนเงินคงเหลือ (ให้รายงานแบบสะสมทุกงวด)

งวดที่ / รายการ	รายรับ (บาท)		รายจ่าย (บาท)	คงเหลือ (บาท)
	จำนวนเงินที่ได้รับ	วันที่ได้รับ		
1	68,000	24 พ.ศ. 2562	80,000	-12,000
2	-	-	-	-12,000
ดอกเบียร์ครั้งที่ 1	0	0	0	0
รายได้ <sup>๓</sup>	0	0	0	0
ฯลฯ	0	0	0	0
รวมจำนวนเงินที่ได้รับทั้งสิ้น	68,000	รวมรายจ่ายทั้งสิ้น	80,000	12,000

จำนวนเงินคงเหลือ....-12,000...บาท ประกอบด้วย เงินฝากธนาคาร...๐...บาท เงินสดในมือ .....-12,000.....บาท

ลงนามหัวหน้าโครงการวิจัยผู้รับทุน

ลงนามเจ้าหน้าที่การเงินโครงการ

หน้า 1 จาก 1

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สัญญาเลขที่ 2562-02-18006

## โครงการ Improve transfer learning performance by using Kalman-based Stochastic Gradient Descent

## รายงานความก้าวหน้าของโครงการในรอบ 6 เดือน

ชื่อโครงการ การปรับปรุงประสิทธิภาพ Transfer learning โดยใช้ Kalman filter Stochastic Gradient Descent

ระยะเวลาโครงการ 6 เดือน

ชื่อหัวหน้าโครงการวิจัยผู้รับทุน ดร.พัชรินทร์ คำสิงห์

รายงานในช่วงตั้งแต่วันที่ 17 เดือน ธันวาคม พ.ศ. 2561 ถึงวันที่ 16 เดือน มิถุนายน พ.ศ. 2562

## การรายงานความก้าวหน้า

1. ตารางแสดงความก้าวหน้าของโครงการ ณ ช่วงรายงานเมื่อเทียบกับแผนการดำเนินงานทั้งโครงการ (การรายงานความก้าวหน้าอาจแสดงรายละเอียดของแต่ละเดือนหรือทุก 2 เดือน ก็ได้แล้วแต่พิจารณา)

รายละเอียดกิจกรรม	ความก้าวหน้าของโครงการ / เดือน					
	1	2	3	4	5	6
1. การเตรียมงานวิจัย/การศึกษาเอกสาร	←→					
2. กำหนดแผนการ/วิธีการดำเนินงาน	←→	←→				
3. ดำเนินงานวิจัย/เก็บข้อมูล			←→	←→		
4. การวิเคราะห์ต่างๆ				←→	←→	
5. จัดทำรายงานและเผยแพร่					←→	←→

←→ แผนงานทั้งโครงการที่วางไว้ ←-----▶ ผลการดำเนินงานจนถึงปัจจุบัน

หมายเหตุ ข้อมูลรายละเอียดกิจกรรม แผนงาน/รูปแบบตาราง เปลี่ยนแปลง หรือปรับได้ตามความเหมาะสม

2. รายละเอียดทางวิชาการที่ได้รับจากการวิจัย

- ต้องแสดงรายละเอียดความก้าวหน้างานวิจัย โดยแสดงข้อมูลที่ชัดเจนและเข้าใจง่าย ซึ่งประกอบด้วย ข้อมูลเชิงวิทยาศาสตร์ กราฟ ตาราง หรือภาพประกอบ (ถ้ามี).....
- ในกรณีที่มีความก้าวหน้า สามารถตีพิมพ์เผยแพร่ได้ อาจจะเขียนรายงานความก้าวหน้าในลักษณะของ "ร่าง" ต้นฉบับสำหรับตีพิมพ์ (manuscript) ก็ได้ หรือกรณีที่มีผลงานเผยแพร่แล้ว ให้แนบ

บทความความก้าวหน้าทางวิชาการของแผนงานวิจัย / โครงการวิจัย ระหว่างที่ทำการวิจัยที่เคยพิมพ์  
ในวารสารทางวิชาการแล้วด้วยจำนวน 1 ชุด.....

งานวิจัยในครั้งนี้ มีผลผลิตจำนวน 1 รายการ เป็นการนำเสนอผลงานในการประชุมวิชาการ  
ระดับนานาชาติ 39th, 2019. IEEE International Geoscience and Remote Sensing  
Symposium ระหว่างวันที่ 28 กรกฎาคม – 2 สิงหาคม พ.ศ. 2562 ณ เมืองโยโกฮาม่า ประเทศญี่ปุ่น  
ซึ่งถูกจัดอยู่ในฐานข้อมูล Scopus.....

3. สรุปผลการดำเนินงาน

เป็นไปตามแผน  ไม่เป็นตามแผน เนื่องจาก .....

4. ความก้าวหน้าการดำเนินงานโครงการวิจัยที่ดำเนินการไปแล้ว คิดเป็นร้อยละ ..... 100.....

5. รายละเอียดแผนงานที่จะดำเนินการต่อไป.....

6. ปัญหา /อุปสรรค.....

7. ข้อเสนอแนะ / แนวทางแก้ปัญหา.....

8. กำหนดเวลาส่งรายงานผลการวิจัยฉบับสมบูรณ์ เดือน มิถุนายน พ.ศ. 2562

10. ข้าพเจ้าขอรับรองว่าข้อความดังกล่าวไว้ในข้างต้นเป็นจริงทุกประการ

ลงนาม.....

(หัวหน้าโครงการวิจัยผู้รับทุน

สัญญาเลขที่ 2562-02-18006

โครงการ Improve transfer learning performance by using Kalman-based Stochastic Gradient Descent

รายงานสรุปการเงินรอบ 6 เดือน

ชื่อหัวหน้าโครงการวิจัย ผู้รับทุน ดร.พัชรินทร์ คำสิงห์

รายงานในช่วงตั้งแต่วันที่ 17 เดือน ธันวาคม พ.ศ. 2561 ถึงวันที่ 16 เดือน มิถุนายน พ.ศ. 2562

สรุปงบประมาณค่าใช้จ่ายที่ใช้ นับตั้งแต่เริ่มทำการวิจัยถึงปัจจุบัน

หมวดค่าใช้จ่าย	รายจ่ายสะสมจากรายงานครั้งก่อน	ค่าใช้จ่ายงวดปัจจุบัน	รวมรายจ่ายสะสมจนถึงปัจจุบัน	งบประมาณตั้งไว้ (สะสมจนถึงปัจจุบัน)	งบประมาณคงเหลือ (หรือเกิน)
	1	2	3 = 1 + 2	4	5 = 4 - 3
งบบุคลากร : ค่าจ้างชั่วคราว	0	0	0	0	0
งบดำเนินงาน					
ค่าตอบแทน	0	80,000	80,000	80,000	0
ค่าใช้จ่าย	0	0	0	0	0
ค่าวัสดุ	0	0	0	0	0
ค่าสาธารณูปโภค	0	0	0	0	0
งบลงทุน: ค่าครุภัณฑ์	0	0	0	0	0
รวม	0	80,000	80,000	80,000	0

จำนวนเงินที่ได้รับ รายจ่าย และจำนวนเงินคงเหลือ (ให้รายงานแบบสะสมทุกงวด)

งวดที่ / รายการ	รายรับ (บาท)		รายจ่าย (บาท)	คงเหลือ (บาท)
	จำนวนเงินที่ได้รับ	วันที่ได้รับ		
1	68,000	24 พ.ค. 2562	80,000	-12,000
2	-	-	-	-12,000
ดอกเบี้ยรับครั้งที่ 1	0	0	0	0
รายได้ @	0	0	0	0
อื่นๆ	0	0	0	0
รวมจำนวนเงินที่ได้รับทั้งสิ้น	68,000	รวมรายจ่ายทั้งสิ้น	80,000	12,000

จำนวนเงินคงเหลือ...-12,000...บาท ประกอบด้วย เงินฝากธนาคาร...0...บาท เงินสดในมือ .....-12,000.....บาท

ลงนามหัวหน้าโครงการวิจัยผู้รับทุน

ลงนามเจ้าหน้าที่การเงินโครงการ

หน้า 3 จาก 3

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้