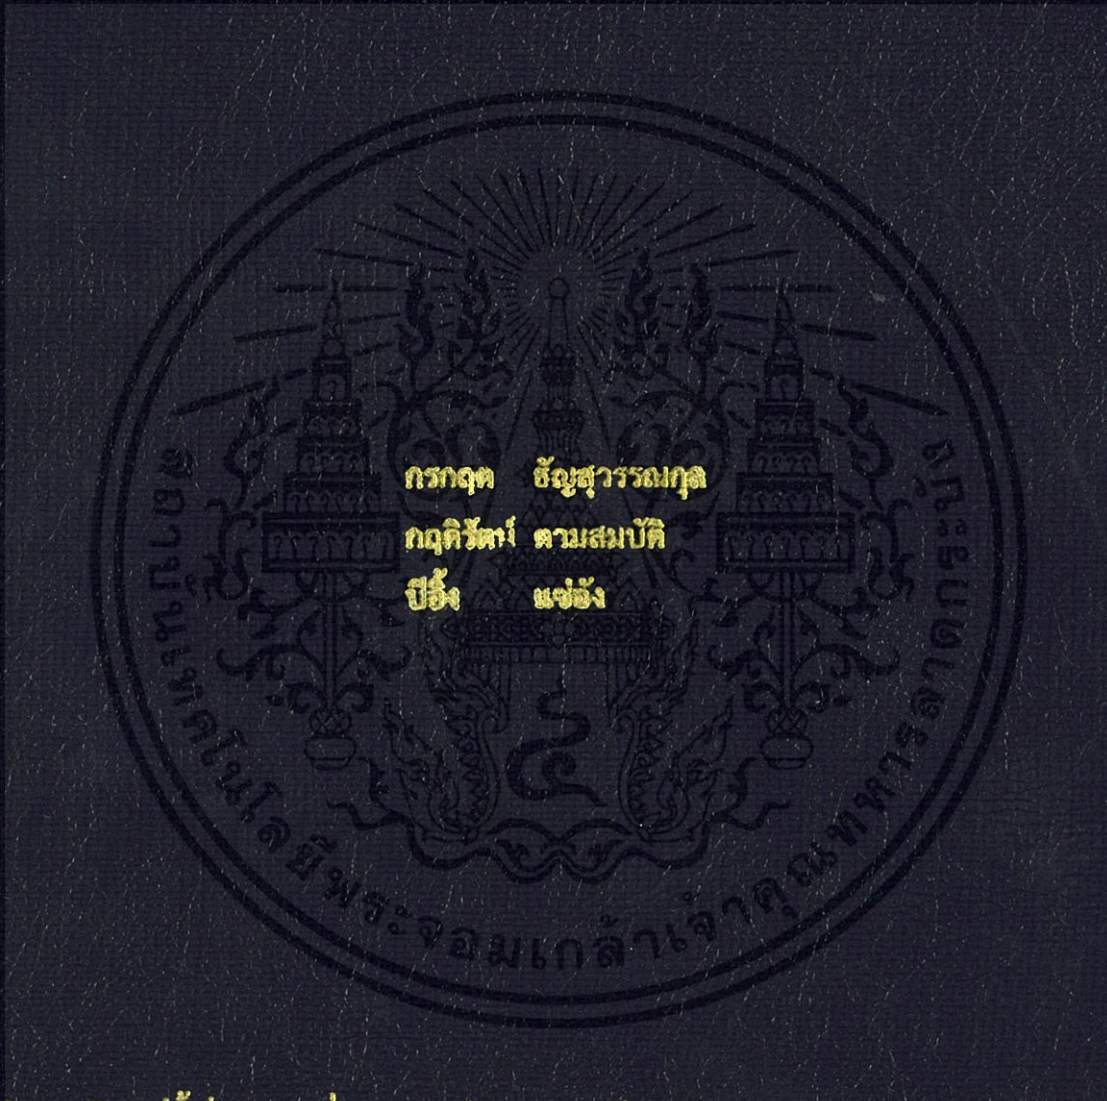


การศึกษาการตรวจจับใบหน้าโดยวิธีการประมวลผลภาพ

FACE DETECTION WITH IMAGE PROCESSING THEORY



กรกฤต อัญสุวรรณกุล
กฤติวิทย์ ตามสมบัติ
ปิธีง แซ่อึ้ง

ปริญญาานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาดำเนินการตามหลักสูตรปริญญาวิทยาศาสตรบัณฑิต

สาขาวิชาวิศวกรรมแมคคาทรอนิกส์

คณะวิศวกรรมศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

ปีการศึกษา 2555

การศึกษาการตรวจจับใบหน้าโดยวิธีการประมวลผลภาพ
FACE DETECTION WITH IMAGE PROCESSING THEORY



ปริญญาานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรบัณฑิต
สาขาวิชาวิศวกรรมแมคคาทรอนิกส์
คณะวิศวกรรมศาสตร์
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
ปีการศึกษา 2555

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

FACE DETECTION WITH IMAGE PROCESSING THEORY



KORNKRIT THANSUWANKUL
KRITDIRAT TAMSOMBAT
BEE-ING SAE-ANG

THIS THESIS IS SUBMITTED IN PARTIAL FULFILLMENT
OF THE REQUIREMENTS FOR THE DEGREE OF
BACHELOR OF ENGINEERING IN MECHATRONICS ENGINEERING
FACULTY OF ENGINEERING

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

ACADEMIC YEAR 2012

เอกสารนี้เป็นเอกสารลิขสิทธิ์การดำเนินงานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปเผยแพร่ ใช้งานด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาสาระของเอกสารทุกครั้งที่มีการนำไปใช้

ปริญญาานิพนธ์ปีการศึกษา 2555

สาขาวิชาวิศวกรรมการวัดและควบคุม คณะวิศวกรรมศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

เรื่อง การศึกษาการตรวจจับใบหน้าโดยวิธีการประมวลผลภาพ
FACE DETECTION WITH IMAGE PROCESSING THEORY

ผู้จัดทำ นายกรกฤต ธีญสุวรรณกุล 52010012
นายกฤติรัตน์ ตามสมบัติ 52010021
นางสาวปวีณา แซ่อึ้ง 52010630


..... อาจารย์ที่ปรึกษา
(ผู้ช่วยศาสตราจารย์ ดร. นนทวัฒน์ จุลเดชะ)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การศึกษาการตรวจจับใบหน้าโดยวิธีการประมวลผลภาพ

โดย

นายกรกฤต ธีธสุวรรณกุล 52010012

นายกฤดิรัตน์ ตามสมบัติ 52010021

นางสาวบีอิ่ง แซ่อั้ง 52010630

อาจารย์ที่ปรึกษา

ผู้ช่วยศาสตราจารย์ ดร. นนทวัฒน์ จุลเดชะ

ปีการศึกษา 2555

บทคัดย่อ

ปฏิญานพนธ์นี้ อธิบายถึงวิธีแยกแยะภาพใบหน้าด้วยเทคนิคของ Haar-like features โดยที่เทคนิคนี้ ประกอบด้วยสามขั้นตอนหลักคือ ขั้นตอนแรกการทำใบหน้าโดยการแปลงรูปให้เป็นแบบ integral image ซึ่งใช้ features ที่มีแนวคิดจาก Haar-wavelet ในการค้นหาภาพใบหน้า ขั้นตอนที่สองสร้างกระบวนการจำแนกโดยใช้เทคนิค Adaboost ที่เป็น machine learning แบบหนึ่ง และขั้นตอนสุดท้ายจะเรียงตัวจำแนกข้อมูลเป็นแบบ cascade ซึ่งในปฏิญานพนธ์นี้จะกล่าวถึงเฉพาะสองส่วนแรกโดยละเอียดเท่านั้น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

FACE DETECTION WITH IMAGE PROCESSING THEORY

By

Mr. Kornkrit Thansuwankul 52010012

Mr. Kritdirat Tamsombat 52010021

Mrs. Bee-ing Sae-ang 52010630

Advisor

Asst.Prof. Dr. Nontawat Chuladaycha

Academic Year 2012

ABSTRACT

This thesis describes how to recognize faces with Haar-like features technique. There are three parts for this technique .The first is converted the origin picture to the integral image from the concept of Haar-wavelet for searching face in the picture. The second is recognition process aided by the machine learning techniques name Adaboost. And the final is a cascade sequence data classification. In this thesis will cover only two parts, which are integral image and Adaboost.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

กิตติกรรมประกาศ

การจัดทำปริยฐานิพนธ์ฉบับนี้ สามารถสำเร็จลุล่วงไปได้ด้วยดี เพราะได้รับความช่วยเหลือเป็นอย่างดี จาก ผศ.ดร.นนทวัฒน์ จุลเดชะ ที่ได้กรุณาให้คำปรึกษาแนะนำที่ดีมาโดยตลอดตั้งแต่ต้น กลุ่มผู้จัดทำรู้สึกซาบซึ้งและขอกราบขอบพระคุณอย่างสูง

ขอบคุณเพื่อนๆทุกคนที่ให้ความสนใจ สนับสนุนอุปกรณ์ที่ขาดเหลือ กระตุ้นเตือน รวมทั้งคอยถามไถ่ความคืบหน้าของโครงการนี้อย่างสม่ำเสมอ

สุดท้ายนี้ผู้จัดทำขอกราบขอบพระคุณบิดา มารดา และครอบครัว ที่คอยเป็นกำลังใจที่ดีตลอดมา รวมถึงการสนับสนุนในเรื่องของงบประมาณที่ขาดเหลือ ตลอดจนเป็นแรงบันดาลใจที่ดีที่สุดที่ทำให้โครงการสำเร็จสมบูรณ์ลงได้ด้วยดี

ผู้จัดทำ

นายกรกฤต

ชญ์สุวรรณกุล

นายกฤติรัตน์

ตามสมบัติ

นางสาวปวี้ง

แซ่อึ้ง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ

	หน้า
บทคัดย่อ	I
บทคัดย่อภาษาอังกฤษ	II
กิตติกรรมประกาศ	III
สารบัญ	IV
สารบัญรูป	V
สารบัญตาราง	VI
บทที่ 1 บทนำ	
1.1 บทนำ	1
1.2 วัตถุประสงค์ในการทำปริญญานิพนธ์	2
1.3 ประโยชน์ที่คาดว่าจะได้รับ	2
1.4 รายละเอียดของปริญญานิพนธ์	2
บทที่ 2 ทฤษฎีและความรู้ที่เกี่ยวข้อง	
2.1 บทนำ	3
2.2 การประมวลผลภาพ (Image Processing)	3
2.3 ทฤษฎีและหลักการของ Paul Viola และ Michael J. Jones	3
2.4 การค้นหาตำแหน่งภาพใบหน้าโดย Haar-Like Features	4
2.4.1 Integral Image	4
2.4.2 Haar-Like Features	7
2.4.2.1 ความหมายและลักษณะ	7
2.4.2.2 กระบวนการทำงาน	8
2.5 Machine Learning	9
2.5.1 นิยามและความหมาย	9
2.5.1.1 กระบวนการทำงานของ Machine Learning	10
2.5.1.2 ตัวอย่างแสดงกระบวนการทำงานของ Machine Learning	10
2.5.2 โมเดลการเรียนรู้ (Machine Learning)	12
2.5.2.1 The Consistency Model	12
2.5.2.2 PAC : The Probably Approximately Correct Model	19
2.5.2.3 EC : Expected Correct Model	25
บทที่ 3 บทวิจารณ์และสรุป	
3.1 ปัญหาที่พบและแนวทางแก้ไข	27
3.2 ข้อเสนอแนะและแนวทางในการค้นคว้าต่อ	27

เอกสารอ้างอิง

ภาคผนวก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญรูป

รูปที่	หน้า
2.1 แบบแผนการตรวจจับวัตถุของ Viola และ Jones	4
2.2 ตัวอย่างภาพที่แสดงค่า pixel ดั้งเดิม	5
2.3 ตัวอย่างภาพที่แสดงค่า pixel ใหม่ที่ได้หลังจาก Integral Image	5
2.4 ตัวอย่างการ Integral Image พื้นที่ภายในกรอบสี่เหลี่ยม	6
2.5 กราฟ Haar-Like Wavelet	7
2.6 Haar-Like Feature รูปแบบต่างๆ	7
2.7 ภาพแสดงการหาบริเวณลักษณะสำคัญบนใบหน้าโดย Features รูปแบบต่างๆ	8
2.8 การสร้างตัวจำแนกแบบหยาบแล้วเรียงตัวจำแนกนั้นแบบ cascade	9
2.9 แผนผังการทำงานของ Machine Learning	10
2.10 ชุดข้อมูลที่แยกข้อมูลกลุ่มบวกและลบ	14
2.11 คอนเซ็ปคลาสในรูปแบบ k-CNF	15
2.12 คอนเซ็ปคลาสในรูปแบบ k-term DNF	16
2.13 หลักการแบ่งกลุ่มตัวอย่างบวกและลบ โดยใช้กรอบสี่เหลี่ยม	17
2.14 หลักการแบ่งกลุ่มตัวอย่างบวกและลบ โดยใช้เส้นแบ่งเขต	17
2.15 เส้นแบ่งจำนวนจริงที่เป็นบวกกับจำนวนจริงที่เป็นลบ	20
2.16 ช่วงพื้นที่ที่เกิดความผิดพลาด (error)	21
2.17 กำหนดขอบเขตที่น่าจะเกิดความผิดพลาด (error)	21
2.18 พื้นที่ความผิดพลาด (error) ทางฝั่งบวก	22
2.19 การกำหนดพื้นที่ความผิดพลาด (error) ทางฝั่งบวก	22
2.20 ปัญหาแบบเป็นช่วง	23
2.21 การกำหนดขอบเขตช่วงความผิดพลาด	24
2.22 การกำหนดช่วงความผิดพลาดในรูปพื้นที่สองมิติ	24
2.23 โมเดลแสดงการแปลงกลับไปมาของ EC Model กับ PAC Model	26

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญตาราง

ตารางที่	หน้า
2.1 ตัวอย่าง Train Example แบบที่ 1	10
2.2 ตัวอย่าง Train Example แบบที่ 2	11



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 1

บทนำ

1.1 บทนำ

ในปัจจุบันนี้ มีเทคโนโลยีตรวจจับวัตถุที่สร้างความสะดวกในการทำงานมากขึ้น และยกระดับความก้าวหน้าในด้านต่างๆมากมาย หนึ่งในนั้นคือเทคโนโลยีการตรวจจับภาพใบหน้า ซึ่งใช้กันอย่างแพร่หลายในหลายปีที่ผ่านมา เช่น การตรวจจับภาพใบหน้าของกล้องถ่ายรูป ที่จะช่วยโฟกัสไปที่ใบหน้าในการถ่ายรูป เพิ่มความสะดวกและความง่ายในการถ่ายรูปมากขึ้น หรือ การตรวจจับและจดจำใบหน้า ที่ใช้ในระบบรักษาความปลอดภัย ที่ช่วยให้การรักษาความปลอดภัยเป็นไปอย่างเข้มงวดมากขึ้น ทั้งนี้ มีเทคนิคในการตรวจจับภาพใบหน้ามากมาย ที่พัฒนามาเรื่อยๆโดยอาศัยความรู้เรื่องการประมวลผลภาพมาประยุกต์ใช้ในการตรวจจับใบหน้า [1].

ในไม่กี่ปีมานี้ มีวิธีการจับภาพใบหน้ามากมาย อาทิเช่น การตรวจจับขอบรูป ที่ประมวลผลภาพทีละ pixel ซึ่งใช้เวลาหลายนาที่ในการตรวจจับที่ใช้ในอดีต และต่อมามีการพัฒนาเรื่อยๆ และมีเทคนิคการตรวจจับภาพที่นิยมคือ Neural Network-Based Face Detection, A Human Face Detection System Based on Schneiderman-Kanade Method และ Probabilistic Modeling of Local Appearance and Spatial Relationships for Object Recognition และในปี 2001 มานี้ Paul Viola และ Michael Jones ได้คิดค้นเทคนิค Haar-like ขึ้นมา และใช้เวลาประมวลผลน้อยที่สุด [2].

จากการศึกษาเทคนิคดังกล่าวที่ผ่านมา เทคนิคนี้ ใช้การค้นหาแบบพื้นที่ ไม่ใช่โดยทีละ pixel ซึ่งจะช่วยให้ประหยัดเวลาในการประมวลผลมากขึ้น และมีขั้นตอนหลักอยู่สามขั้นตอน ขั้นตอนแรกคือการค้นหาภาพใบหน้าโดยการแปลงรูปให้เป็น Integral image แล้วใช้ feature ซึ่งมีหลายรูปแบบในการค้นหา ขั้นตอนที่สองคือการสร้างกระบวนการจำแนก โดยใช้เทคนิค Adaboost [3] ซึ่งย่อมาจาก adaptive boosting ที่เป็น Machine Learning แบบหนึ่ง และขั้นตอนสุดท้าย คือการจัดเรียงตัวจำแนกแบบ cascade ที่ช่วยเพิ่มความเร็วในการทำงานมากขึ้น

เนื่องด้วยระยะเวลาที่จำกัด ขอบเขตการศึกษาจึงจำกัดเพียงแค่สองขั้นแรกเท่านั้น และเป็นการศึกษาทฤษฎีของเทคนิคดังกล่าวโดยละเอียด เพื่อที่ต่อไป จะสามารถความรู้ที่ได้ ไปใช้ประยุกต์เข้ากับงานอื่นๆได้อย่างมีประสิทธิภาพ

สำหรับในปริญญาโทฉบับนี้จะ ประกอบด้วย ส่วนของการอธิบายทฤษฎีในขั้นตอนแรกในการค้นหาภาพใบหน้า และขั้นตอนที่สอง การสร้างกระบวนการจำแนกข้อมูลอย่างละเอียด ทั้งนี้ในส่วนขั้นตอนที่สอง จะกล่าวถึงวิชา Machine learning เบื้องต้นโดยละเอียด ที่ได้ศึกษามา

1.2 วัตถุประสงค์ในการทำปฏิญานินพนธ์

- 1.2.1 เพื่อศึกษาการค้นหตำแหน่งใบหน้าด้วยวิธีการ Haar-like feature
- 1.2.2 เพื่อศึกษากระบวนการตรวจจับใบหน้า(Face Detection)
- 1.2.3 เพื่อศึกษาวิธีการ Machine Learning
- 1.2.4 เพื่อหาวิธีลดเวลาในการประมวลผลที่น้อยที่สุด

1.3 ประโยชน์ที่คาดว่าจะได้รับ

- 1.3.1 มีความรู้ความเข้าใจในการประมวลผลภาพ เพื่อค้นหาสิ่งที่ต้องการสนใจ
- 1.3.2 มีความรู้ความเข้าใจเรื่องทฤษฎีการตรวจจับใบหน้าที่เป็นที่นิยมใช้
- 1.3.3 มีความรู้ความเข้าใจเรื่อง Machine learning
- 1.3.4 มีความรู้ความสามารถในการไปค้นคว้าต่อได้ในอนาคต

1.4 รายละเอียดของปฏิญานินพนธ์

เนื้อหาที่จะกล่าวในปฏิญานินพนธ์ฉบับประกอบด้วย

บทที่ 1 บทนำ กล่าวถึงถึง วัตถุประสงค์ ประโยชน์ที่คาดว่าจะได้รับ รายละเอียดของปฏิญานินพนธ์

บทที่ 2 ทฤษฎีและความรู้ที่เกี่ยวข้อง กล่าวถึงการประมวลผลภาพ วิธีการค้นหตำแหน่งใบหน้าโดย Haar-like feature และ กระบวนการทำงาน Machine Learning

บทที่ 3 บทวิจารณ์และสรุป กล่าวถึงปัญหาที่พบในการทำโครงงาน แนวทางการแก้ไข และ ข้อเสนอแนะและแนวทางในการค้นคว้าต่อในอนาคต

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 2

ทฤษฎีและความรู้ที่เกี่ยวข้อง

2.1 บทนำ

ระบบตรวจจับใบหน้าเป็นหัวข้อที่ได้รับความสนใจจากนักวิจัยหลายแขนง ทั้งในด้านคอมพิวเตอร์วิทัศน์ (Computer vision) ระบบปฏิสัมพันธ์ระหว่างมนุษย์กับคอมพิวเตอร์ (Human Computer Interaction) หรือใช้ในการระบุตัวบุคคลจากภาพใบหน้า (Face Identifications System) เป็นต้น ทำให้การพัฒนาประสิทธิภาพการทำงานของระบบก้าวหน้าไปอย่างรวดเร็ว ถูกพัฒนามาอย่างต่อเนื่อง และมีประสิทธิภาพการทำงานที่ให้ผลลัพธ์เป็นที่น่าพอใจ ซึ่งระบบตรวจจับใบหน้ามีจุดเด่นอยู่ที่รูปแบบการรับค่าของระบบที่ไม่ต้องการการสัมผัสทางกายภาพของบุคคลที่เราสนใจกับอุปกรณ์รับค่า ทำให้ระบบสามารถนำไปใช้ในที่สาธารณะได้โดยง่าย หรืออาจนำไปใช้ร่วมกับระบบยืนยันตัวตนบุคคลวิธีอื่นๆ เพื่อเพิ่มประสิทธิภาพการทำงานได้

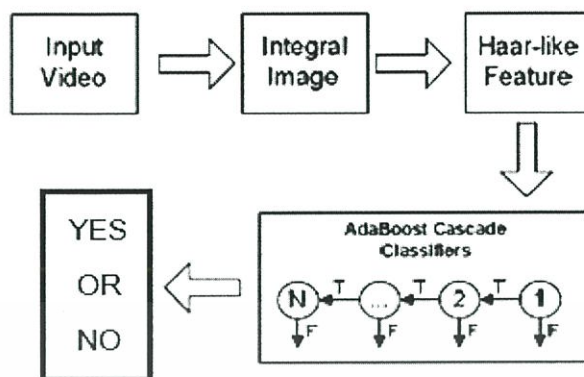
2.2 การประมวลผลภาพ (Image Processing)

การประมวลผลภาพ (Image Processing) คือการให้คอมพิวเตอร์ประมวลผลภาพ เพื่อให้ทราบภาพนั้นคือภาพอะไร หรือมีสิ่งที่น่าสนใจอยู่ในภาพหรือไม่โดยไม่ต้องใช้สายตาของคนมาช่วยตัดสินใจ การคิดคำนวณนั้นมีหลายวิธีซึ่งแต่ละวิธีก็มีประโยชน์แตกต่างกันไป ไม่ว่าจะเป็นการนำเอาสีแต่ละจุดมาคิด, การคิดคำนวณเป็นบริเวณหลายๆ จุดรวมๆ กัน เช่น การดูพื้นผิว, การดูรูปร่าง, การวิเคราะห์หารูปร่าง หรือการวิเคราะห์แบบอื่นๆ เพื่อหาค่าที่สามารถระบุได้ว่า ภาพนั้นมีลักษณะอย่างไร ซึ่งจะนำไปสู่การตัดสินใจได้ว่าสิ่งนั้นเป็นสิ่งที่กำลังค้นหาหรือสนใจอยู่หรือไม่

2.3 ทฤษฎีและหลักการของ Paul Viola และ Michael J. Jones

ทฤษฎีที่คิดค้นโดย Paul Viola และ Michael J. Jones เมื่อปี ค.ศ.2001 เป็นเทคนิคการตรวจจับใบหน้าที่มีความเร็วและมีความถูกต้องในการตรวจจับสูง ทำให้เทคนิคนี้เป็นที่ยอมรับและเป็นที่รู้จักในงานวิจัยเป็นอย่างมาก ซึ่งหลักการพื้นฐานของเทคนิคนี้คือการนำภาพใบหน้ามาจัดการแบ่งซอยเป็นภาพย่อยๆ แล้วนำภาพย่อยที่มีขนาดแตกต่างกันออกไป มาพิจารณาเพื่อตรวจจับสิ่งที่เราสนใจอยู่ในภาพย่อยนั้นหรือไม่ การแบ่งซอยพิจารณาภาพเป็นส่วนๆ แบบนี้ช่วยให้การตรวจจับใบหน้าหลายๆ รอบนั้นใช้เวลาในการวิเคราะห์รวดเร็วและคงที่อีกด้วยโดยแบ่งขั้นตอนในการทำงานของระบบทั้งหมดออกเป็น 3 ส่วนหลัก คือ

1. การค้นหาตำแหน่งรูปภาพใบหน้า
2. การใช้การเรียนรู้ของเครื่อง (Machine Learning) ที่ชื่อ Adaboost ช่วยในการตัดสินใจ
3. การนำตัวจำแนกแบบหยาบมาเรียงแบบ cascade



รูปที่ 2.1 แบบแผนการตรวจจับวัตถุของ Viola และ Jones

ในปริณิญาฉบับนี้จะกล่าวถึงขั้นตอนแรกและขั้นตอนที่สอง ซึ่งจะกล่าวถึงทฤษฎีเบื้องต้นของ Machine Learning เท่านั้น โดยจะไม่กล่าวถึง Adaboost และขั้นตอนที่สาม เนื่องด้วยเวลาที่จำกัดในการศึกษาและจัดทำปริณิญาฉบับนี้

2.4 การค้นหาตำแหน่งภาพใบหน้าโดย Haar-Like Features

2.4.1 Integral Image

ในขั้นตอนนี้ เพื่อความรวดเร็ว จึงมีการ Preprocessing โดยการแปลงภาพต้นฉบับให้กลายเป็น integral image

วิธีการแปลงเป็น integral image

ให้ค่าในแต่ละ pixel ของรูป $p = (x, y)$ แปลงเป็นค่า ของ integral image ได้ดังสมการนี้

$$I(p) = \sum_{1 \leq i \leq x \wedge 1 \leq j \leq y} P(i, y) \quad (2.1)$$

จากสมการ ค่าความเข้มแสงในแต่ละ pixel ของ integral image คือ ผลรวมของค่าความเข้มแสงในแต่ละ pixel ของภาพต้นฉบับ ดังนี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Variable Editor - a

a <4x4 double>

	1	2	3	4	5
1	1	2	3	4	2
2	5	2	4	1	
3	1	2	1	3	
4	4	5	2	1	
5					
6					

รูปที่ 2.2 ตัวอย่างภาพที่แสดงค่าความ pixel ดั้งเดิม

เมื่อแปลงเป็น integral image จะได้

Variable Editor - b

b <4x4 double>

	1	2	3	4	5
1	1	3	6	8	
2	6	10	17	20	
3	7	13	21	27	
4	11	22	32	39	
5					


รูปที่ 2.3 ตัวอย่างภาพที่แสดงค่า pixel ใหม่ที่ได้หลังจากทำ Integral Image

ตัวอย่างเช่น หากต้องการค่าความเข้มแสงที่จุด pixel (2,3) ของ integral image จะได้ว่า

$$\begin{aligned}
 I(2,3) &= P(1,1)+P(2,1)+P(1,2)+P(2,2)+P(1,3)+P(2,3) \\
 &= 1+3+6+10+7+13 = 13
 \end{aligned}
 \tag{2.2}$$

ข้อดีของ Integral image คือ หากต้องการผลรวมของค่าความเข้มแสงของพื้นที่ที่ต้องการ สามารถทำได้โดยใช้เพียง 4 จุดในการคำนวณเท่านั้น ดังนี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.4 ตัวอย่างการ Integral Image พื้นที่ภายในกรอบสี่เหลี่ยม

จากรูป 2.4 ต้องการผลรวมในบริเวณที่ถูกรอบสี่เหลี่ยม คำนวณได้จาก

$$I = C - B - D + A \quad (2.3)$$

เมื่อ I คือผลรวมของค่าความเข้มแสงของ pixel ของรูปต้นฉบับในบริเวณที่แรเงา และ A, B, C, D คือค่าความเข้มแสงของ pixel จุดมุมของบริเวณแรเงา ใน integral image จากตัวอย่างนี้ จะเห็นว่า ในการหาค่าผลรวมความเข้มแสงของ pixel ในบริเวณใด ไม่ว่าจะ เป็นพื้นที่บริเวณใหญ่หรือพื้นที่บริเวณเล็ก จะใช้เพียงค่าความเข้มแสงของ 4 จุด pixel มุมใน integral image เท่านั้น


เมื่อแปลงรูปภาพเป็น Integral image แล้ว จะเข้าสู่ขั้นตอนการประมวลผล โดย Haar-like features ที่จะตรวจหาใบหน้า ในขั้นตอนถัดไปนี้ จะใช้ features เพื่อดึงข้อมูลจากภาพ และนำข้อมูลนั้นไปประมวลผลอีกครั้งในขั้นตอนที่สอง (การใช้ Adaboost ช่วยในการตัดสินใจ) และขั้นตอนที่สาม (การเรียงตัวจำแนกแบบหยาบแบบ cascade) ต่อไป

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.4.2 Haar-Like Features

2.4.2.1 ความหมายและลักษณะ


Haar-like features มีแนวคิดมาจาก Haar wavelet ซึ่ง Haar wavelet มีลักษณะดังนี้



รูปที่ 2.5 แสดงลักษณะกราฟ Haar Wavelet

รูปที่ 2.5 Haar wavelet จะมีค่า 1 และ -1 เพื่อประมาณค่าสัญญาณ เมื่อนำมาประยุกต์กับการประมวลผลภาพ จะได้ Haar-like features ซึ่งมีค่า 0 และค่าความเข้มแสงสูงสุดในกรณีที่รูป gray scale มี resolution เท่ากับ 8 บิต จะมีค่าของ Haar-like features เท่ากับ 0 และ 255 และมีลักษณะเป็นรูปสี่เหลี่ยม ที่มีสีขาวกับสีดำหลายๆ รูปแบบดังรูปที่ 2.6

1. Edge features



2. Line features



3. Center-surround features



รูปที่ 2.6 Haar-Like Feature รูปแบบต่างๆ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.4.2.2 กระบวนการทำงาน


เลือกรูปแบบและขนาดของ Features ในการทำการเปรียบเทียบค่าความเข้มแสงบริเวณต่างๆ ในรูป เพื่อที่จะนำไปสร้างตัวจำแนกแบบหยาบซึ่ง features ที่รูปแบบต่างๆ จะใช้ในการตรวจหาที่ไม่เหมือนกัน ดังเช่น พื้นที่บริเวณสันจมูกและดวงตา พื้นที่บริเวณตาจะมีค่าความเข้มแสงน้อยกว่า พื้นที่บริเวณสันจมูก จึงใช้ features ที่มีลักษณะเป็น Line features หรือพื้นที่บริเวณตาและแก้ม พื้นที่บริเวณตาจะมีค่าความเข้มแสงรวมน้อยกว่าพื้นที่บริเวณแก้ม จึงใช้ features ที่มีลักษณะเป็น Edge features และอื่นๆ เป็นต้น ดังรูป 2.7



รูปที่ 2.7 ภาพแสดงการหาบริเวณลักษณะสำคัญบนใบหน้าโดย Features รูปแบบต่างๆ

จากนั้นนำเอา features ที่ได้ไปสร้างตัวจำแนกแบบหยาบ ดังรูป 2.7 และเรียงตัวจำแนกเหล่านี้เป็นแบบ cascade เพื่อให้มีความรวดเร็ว และใช้อัลกอริทึม Adaboost ซึ่งเป็นการเรียนรู้ของเครื่อง (Machine Learning) ช่วยในการตัดสินใจว่าเป็นตำแหน่งของภาพบริเวณนั้นคือภาพใบหน้าหรือไม่ ต่อไป

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.8 การสร้างตัวจำแนกแบบหยาบแล้วเรียงตัวจำแนกนั้นแบบ Cascade

2.5 การใช้การเรียนรู้ของเครื่อง (Machine Learning) ที่ชื่อ Adaboost ช่วยในการตัดสินใจ

ในหัวข้อนี้ จะอธิบายพื้นฐานของ Machine Learning โดยจะกล่าวถึง โมเดลการเรียนรู้สามโมเดลคือ The Consistency Model, PAC : The Probably Approximately Correct Model และ EC : Expected Correct Model

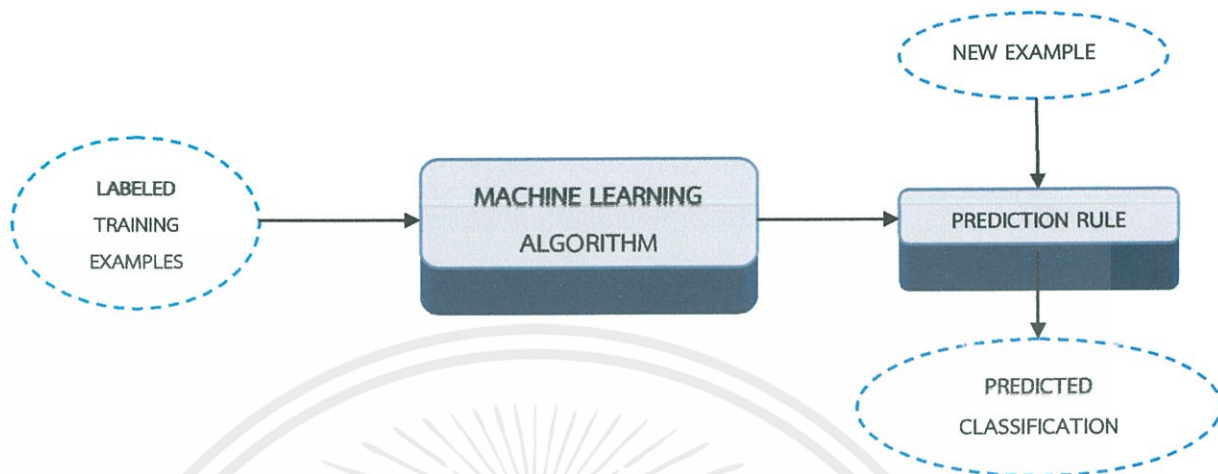
2.5.1 นิยามและความหมาย [4]

ในอดีต การตัดสินใจของเครื่องเกิดจากกฎที่มนุษย์เป็นคนคิดและป้อนให้กับเครื่อง ผลที่ได้คือกฎนั้นเป็นสิ่งตายตัว สามารถใช้ได้ในสถานการณ์ใดสถานการณ์หนึ่งเท่านั้น หากสถานการณ์นั้นได้เปลี่ยนแปลงไป มนุษย์ต้องเปลี่ยนกฎตามเพื่อให้สามารถใช้กับสถานการณ์ที่เปลี่ยนไป หากต้องการให้กฎเปลี่ยนแปลงได้เองโดยที่มนุษย์ไม่เข้าไปเกี่ยวข้อง เครื่องจำเป็นต้องฉลาดและตัดสินใจได้เทียบเคียงกับมนุษย์ และหากต้องการให้เครื่องมีความฉลาด เครื่องจำเป็นต้องมีการเรียนรู้ ซึ่งเปรียบเทียบกับมนุษย์ที่ต้องมีการเรียนรู้ จึงจะเกิดความฉลาดและมีประสบการณ์ความสามารถในการตัดสินใจได้อย่างถูกต้องมากขึ้น

จากที่กล่าวมาข้างต้น จึงทำให้สรุปได้นิยามที่ว่า การเรียนรู้ของเครื่องคือการศึกษาการสร้างอัลกอริทึมที่จะสร้างกฎเพื่อใช้ในการทำงาน โดยให้ข้อมูลอัลกอริทึม เช่น ตัวอย่าง ประสบการณ์ คำสอน เป็นต้น ซึ่งโดยทั่วไปจะใช้ตัวอย่าง กฎที่ได้นี้จะเปลี่ยนแปลงไปตามข้อมูลที่ให้มาโดยอัตโนมัติ และไม่มีมนุษย์เข้าไปเกี่ยวข้อง

จึงกล่าวได้ว่า Machine learning นั้น เป็นการสร้างโปรแกรมโดยตัวอย่าง เพื่อหากฎที่ดีที่สุดที่สามารถใช้ตัดสินใจว่าถูก ผิด หรือ ใช่ ไม่ใช่ ได้อย่างถูกต้องในสถานการณ์ที่เปลี่ยนแปลงไป

2.5.1.1 กระบวนการทำงานของ Machine Learning [4]



รูปที่ 2.9 แผนผังการทำงานของ Machine Learning

รูป 2.9 แสดงการทำงานของ Machine learning โดยที่เมื่อป้อนชุดข้อมูลตัวอย่างที่ระบุคำตอบไว้แล้วให้กับอัลกอริทึม อัลกอริทึมจะสร้างกฎที่ใช้ตัดสินใจ กฎที่ว่านี้ สามารถใช้จำแนกข้อมูลที่ไม่ทราบคำตอบ ที่ไม่ใช่ข้อมูลที่ป้อนให้กับอัลกอริทึมในก่อนหน้านี้ได้ โดยข้อมูลตัวอย่างที่ไม่ทราบคำตอบนั้น จะต้องสอดคล้องกับข้อมูลตัวอย่างที่ป้อนให้กับอัลกอริทึมเพื่อสร้างกฎ

2.5.1.2 ตัวอย่างแสดงกระบวนการทำงานของ Machine Learning

- ตัวอย่างที่ 1

ตารางที่ 2.1 ตัวอย่าง Train Example แบบที่ 1

EXAMPLE	LABEL
<u>Train</u>	
Ant	-
Bat	+
Dolphin	-
Leopard	+
Sea lion	-
Zebra	+
Shark	-
Mouse	+
Chicken	-
<u>Test</u>	
Tiger	
Tuna	
platypus	

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้เพื่อการศึกษานานัน ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเอกสารทุกครั้งที่มีการนำไปใช้

จากตารางที่ 2.1 คือชุดตัวอย่างที่จะป้อนให้กับอัลกอริทึม โดยได้ระบุไว้แล้วว่าอยู่กลุ่มบวก(ใช่) หรืออยู่กลุ่มลบ (ไม่ใช่) จากชุดตัวอย่างที่เป็นชื่อสัตว์และการระบุ ทำให้อัลกอริทึมสร้างกฎเพื่อจำแนกขึ้นมาว่าถ้าเป็นสัตว์เลี้ยงลูกด้วยนมและอาศัยอยู่บนบกจะถือว่าอยู่ในกลุ่มบวกหรือใช้นั้นเอง นอกจากนั้นจะถือว่าอยู่กลุ่มลบ หรือไม่ใช่ เมื่อนำกฎที่ได้ไปใช้จำแนกตัวอย่างจากภายนอกหรือ test example กฎจะแยกเสือโคร่งอยู่ในกลุ่มบวก ปลาห่าน่าอยู่ในกลุ่มลบ แต่ตุนปากเปิดนั้น อัลกอริทึมไม่สามารถแยกให้อยู่ในกลุ่มบวกหรือกลุ่มลบได้ เนื่องจาก ตุนปากเปิดเป็นสัตว์เลี้ยงลูกด้วยนมอาศัยอยู่บนบก แต่ออกลูกเป็นไข่ กฎที่ได้ในตอนแรกไม่ได้ระบุว่าเป็นสัตว์เลี้ยงลูกด้วยนมอาศัยอยู่บนบก ออกลูกเป็นตัว หรือออกลูกเป็นไข่ เนื่องจากไม่มีตัวอย่างของสัตว์เลี้ยงลูกด้วยนมออกลูกเป็นไข่ที่ได้ระบุไว้แล้วป้อนให้กับอัลกอริทึมกฎที่ได้จึงไม่ครอบคลุมเพียงพอ

- ตัวอย่างที่ 2

ตารางที่ 2.2 ตัวอย่าง Train Example แบบที่ 2

	EXAMPLE										LABEL
Train											
Aardvark	-	1	1	18	4	22	1	18	11		-
Cow	-	3	15	23							+
Giraffe	-	7	9	18	1	6	6	5			-
Termite	-	20	5	18	13	9	20	5			-
Oyster	-	15	25	19	20	5	18				+
Dove	-	4	15	22	5						-
Spider	-	19	16	9	4	5	18				+
Dog	-	4	15	7							+
Elephant	-	5	12	5	16	8	1	14	20		+
Test											
Rabbit	-	18	1	2	2	9	20				
Frog	-	6	18	15	7						
Kangaroo	-	11	1	14	7	1	18	15	15		

จากตารางข้างต้น แสดงชุดตัวอย่างชื่อสัตว์ที่ระบุไว้แล้ว และยังไม่ได้ระบุ ดังเช่นตัวอย่างที่ 1 แต่ตัวอย่างนี้เป็นกฎการจำแนกจะแตกต่างออกไป อัลกอริทึมได้สร้างกฎการแยกสำหรับตัวอย่างนี้คือ หากตัวอักษรที่ 3 ของชื่อสัตว์มีลำดับเป็นเลขคี่ ให้ถือว่าอยู่กลุ่มบวก นอกเหนือจากนั้นให้ถือว่าอยู่กลุ่มลบ ซึ่งกฎที่ได้นี้สามารถใช้จำแนก test example ได้อย่างชัดเจน และมีความผิดพลาดน้อย แต่ข้อเสียคือ เป็นกฎการจำแนกที่ซับซ้อนเกินไป ซึ่งต้องแปลงจากอักษร เป็นลำดับอักษรก่อน จึงจะใช้กฎนี้ได้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากสองตัวอย่างข้างต้นนี้ สามารถสรุปได้ว่า การเรียนรู้ของเครื่องนั้น หากจะดีที่สุดต้อง

1. มีข้อมูลเพียงพอ เพื่อให้อัลกอริทึมสร้างกฎที่ครอบคลุมที่สุด
2. กฎที่ได้ควรจะมีข้อผิดพลาดน้อยที่สุด
3. กฎที่ได้ควรจะมีข้อสั้นน้อยที่สุด ซึ่งเป็นไปตามทฤษฎีของ “Occam’s razor” [7]

ซึ่งในความเป็นจริงแล้ว หากต้องการใช้กฎที่ง่ายขึ้น ก็จะมีข้อผิดพลาดเยอะขึ้นตามไปด้วย จึงต้องหาจุดสมดุลระหว่างเงื่อนไขข้อ 2 และ ข้อ 3

2.5.2 โมเดลการเรียนรู้ (Learning models) [5]

ในการศึกษาให้ง่ายต่อความเข้าใจ และเป็นรูปธรรมมากขึ้น และรู้ถึงประสิทธิภาพของโปรแกรม จึงศึกษาในเชิงคณิตศาสตร์ และนิยามปัญหาต่างๆ ซึ่งจะนิยามในรูปของโมเดลการเรียนรู้ โมเดลการเรียนรู้ควรครอบคลุมปัญหาที่ต้องการให้โปรแกรมเรียนรู้ แต่ง่ายเพียงพอที่จะศึกษาในเชิงคณิตศาสตร์

โมเดลการเรียนรู้ควรบอกได้ว่า ปัญหาที่ต้องการให้เครื่องเรียนรู้คือปัญหาอะไร จะได้ข้อมูลจากไหน ข้อมูลที่ได้มาจะป้อนให้กับอัลกอริทึมเพื่อเรียนรู้ทีเดียว หรือป้อนให้อัลกอริทึมและเรียนรู้ไปทีละครั้ง และเป้าหมายของโมเดลการเรียนรู้นั้นคืออะไร

ก่อนจะเข้าสู่โมเดลแรก มีนิยามและความหมายของคำต่างๆ ดังนี้

ตัวอย่าง: ข้อมูลทั้งหมดที่ใช้ รวมถึงข้อมูลที่ใช้สร้างกฎ และข้อมูลที่ใช้ทดสอบกฎ

» ตัวอย่างระบุ: ข้อมูลที่ทราบคำตอบแล้ว ป้อนให้กับอัลกอริทึม เพื่อสร้างกฎ

» ตัวอย่างทดสอบ: ข้อมูลที่ยังไม่ทราบคำตอบ กฎที่ได้จากอัลกอริทึมจะมาใช้เพื่อหาคำตอบจากข้อมูล

ตัวแปร : ใช้เพื่อบอกลักษณะสำคัญของข้อมูล เช่น หากตัวอย่างมีคนผู้ชาย จะมีตัวแปรอย่างเช่น ตัวแปร Z_1 คือ ไม่มีหน้าอก หรือ ตัวแปร Z_2 คือ มีกล้ามเนื้อมากกว่า เป็นต้น

คอนเซ็ป : กฎที่สร้างโดยอัลกอริทึมจากตัวอย่างที่ระบุ เมื่อไปใช้กับตัวอย่างทดสอบ ซึ่งเป็นสมาชิกของคอนเซ็ปคลาส

คอนเซ็ปคลาส : รูปแบบของคอนเซ็ปหรือกฎที่ใช้จำแนก เช่น รูปแบบ Boolean Logic หรือ Geometry เป็นต้น

2.5.2.1 The Consistency Model [5]

โมเดลนี้เป็นโมเดลพื้นฐานในการเริ่มต้นศึกษา Machine Learning เป็นโมเดลที่ง่ายแต่ค่อนข้างเป็นอุดมคติ ซึ่งมีสาระสำคัญ คือ กฎที่ได้จะต้องให้คำตอบตรงกับคำตอบของตัวอย่างระบุ

นิยาม หากคอนเซ็ปคลาส C ซึ่งเป็นรูปแบบของกฎใดๆ สามารถเรียนรู้ไวเวตโมเดลนี้ อัลกอริทึม A หนึ่งอัลกอริทึม จะหาคอนเซ็ปหนึ่งคอนเซ็ปได้ในคอนเซ็ปคลาส C คอนเซ็ปที่ได้นี้จะให้คำตอบข้อมูลตรงกับคำตอบที่ใส่ระบุไว้ ดังนี้

$$c(x_i) = y_i \text{ เมื่อ } x_i \in X \quad ; X \text{ คือ เซตของข้อมูลที่ระบุแล้ว}$$

$$y_i \in \{0,1\} \quad ; y_i \text{ คือ คำตอบไบนารีที่จะมีค่าจริงหรือเท็จ}$$

หรืออัลกอริทึม A นั้นสามารถบอกได้ว่าไม่มีคอนเซ็ปที่จะให้คำตอบตรงกับคำตอบที่ใส่ระบุไว้แล้ว ในบางครั้ง หากต้องการหาคำตอบจากชุดข้อมูลหนึ่ง ต้องใช้มากกว่าหนึ่งคอนเซ็ป Machine Learning จะหาอัลกอริทึมหลายอัลกอริทึม เพื่อที่จะได้คอนเซ็ปหลายคอนเซ็ปที่อยู่ในคลาสเดียวกัน และควรหาคอนเซ็ปในจำนวนที่เหมาะสม เพราะในทางปฏิบัติไม่สามารถทดสอบคอนเซ็ปที่มีจำนวนมากเกินได้

ในการหาคอนเซ็ปนั้น จำเป็นต้องรู้ว่าปัญหานั้นมีรูปแบบไหน ซึ่งก็คือคอนเซ็ปคลาส เพื่อที่จะสร้างอัลกอริทึมในการหาคอนเซ็ปได้อย่างเหมาะสม ดังเช่น ปัญหาดังต่อไปนี้

» Boolean Logic [5]

คอนเซ็ปคลาส C เป็นแบบ Monotone Conjunction คือ นิพจน์ทุกนิพจน์ต้องมีค่าเป็นจริง และนำมา And กัน ให้ $X = \{0,1\}^n$ คือข้อมูลที่มีย n ตัวแปร แต่ละตัวแปร มีค่า 0 หรือ 1

ตัวอย่างที่ 1 กำหนด ตัวแปร

$$Z_1 = \text{เป็นสัตว์ปีก}$$

$$Z_2 = \text{เป็นสัตว์เลี้ยงลูกด้วยนม}$$

$$Z_3 = \text{อาศัยอยู่บนบก}$$

คอนเซ็ปที่ได้อาจเป็น $Z_1 \wedge Z_2, Z_1 \wedge Z_3, Z_2 \wedge Z_3, Z_1 \wedge Z_2 \wedge Z_3$ ซึ่งหากนำไปทดสอบกับชุดข้อมูลในตัวอย่าง “ตุ่นปากเป็ด” จะได้คอนเซ็ป c ที่ใช้ได้คือ $Z_2 \wedge Z_3$ เป็นสัตว์เลี้ยงลูกด้วยนมและอาศัยอยู่บนบก

การหาคอนเซ็ป c โดยการนำตัวแปรทุกชนิดมา and กัน และทดสอบทุกคอนเซ็ปที่ได้นั้น เป็นวิธีการที่ยุ่งยากในทางปฏิบัติ หากตัวแปรมากขึ้น จำนวนคอนเซ็ปที่ต้องนำมาทดสอบก็จะมากเป็นทวีคูณ จึงมีอีกวิธีที่จะหาคอนเซ็ป c ในปัญหาลักษณะนี้ คือ

1. แยกข้อมูลตัวอย่างระบุเป็นกลุ่มบวกและกลุ่มลบ
2. ให้ c คือนิพจน์ที่เป็นจริงของตัวอย่างกลุ่มบวก แล้วนำมา and กัน
3. ทดสอบ c ที่ได้กับตัวอย่างกลุ่มลบ และ c ต้องให้คำตอบเป็นเท็จ หากไม่มีแล้ว จะไม่มีคอนเซ็ป c ที่จะให้คำตอบตรงกับคำตอบที่ระบุไว้ก่อนหน้า

ในตัวอย่างแรก ได้แสดงตัวอย่างคอนเซ็ปที่จะได้จากชุดข้อมูล ในตัวอย่างถัดไป จะแสดงการหาคอนเซ็ปหรือกฎในการแยกข้อมูลที่ใช่ และไม่ใช่

ตัวอย่างที่ 2 กำหนดชุดข้อมูล

01101	+
11011	+
11001	+
00101	-
11000	-

รูปที่ 2.10 ชุดข้อมูลที่แยกข้อมูลกลุ่มบวกและกลุ่มลบ

ตัวอย่างนี้ได้ทำการแยกข้อมูลกลุ่มบวก (ใช่) และกลุ่มลบ (ไม่ใช่) ไว้แล้ว จากชุดข้อมูลกลุ่มบวก จะได้คอนเซ็ป $c = z_2 \wedge z_5$ เมื่อนำไปทดสอบกับข้อมูลกลุ่มลบ และให้ค่าเป็นเท็จ ดังนั้นจะได้คอนเซ็ป $c = z_2 \wedge z_5$ ใช้กับข้อมูลชุดนี้ได้ ซึ่งอัลกอริทึมไม่จำเป็นต้องหาคอนเซ็ปที่สั้นที่สุด เมื่อวัดโดยจำนวนตัวแปร ที่ให้คำตอบตรงกับคำตอบที่ระบุไว้ และเนื่องจากอัลกอริทึมสามารถหาคอนเซ็ป c ที่ให้คำตอบตรงกับคำตอบที่ระบุไว้แล้ว หรือสามารถบอกได้ว่าไม่มีคอนเซ็ป c ที่ให้คำตอบตรงกับคำตอบที่ระบุไว้ คอนเซ็ปคลาสแบบ Monotone Conjunction จึงสามารถเรียนรู้ได้ใน Consistency Model

สองตัวอย่างแรกที่กล่าวมา เป็นตอนเซ็ปคลาส Boolean Logic ที่เป็นแบบ Monotone หากเป็นคอนเซ็ปคลาสที่เป็น Boolean Logic แบบอื่นๆ และต้องการใช้อัลกอริทึมเดิม สามารถที่จะแก้ไขเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้เอง ดังนี้

1. คอนเซ็ปคลาส C แบบ Monotone Disjunction
ตัวอย่างคอนเซ็ปคลาส

$$c = z_2 \vee z_5 \vee z_7 \quad (2.4)$$

คอนเซ็ปคลาสนี้สามารถใช้กฎ De Morgan's Law ได้โดย

$$z_2 \vee z_5 \vee z_7 = \overline{\overline{z_2} \wedge \overline{z_5} \wedge \overline{z_7}} \quad (2.5)$$

จะได้คอนเซ็ปใหม่เป็น $c = \overline{\overline{z_2} \wedge \overline{z_5} \wedge \overline{z_7}}$ ซึ่งเป็นแบบ Monotone conjunction และสามารถนำอัลกอริทึมเดิมมาประยุกต์ใช้กับคอนเซ็ปคลาสแบบนี้ได้

2. คอนเซ็ปคลาส C แบบ Conjunction ซึ่งอาจจะไม่ใช่ Monotone หรือ ตัวแปรที่มีค่าเป็นจริงหรือเท็จก็ได้ ตัวอย่างคอนเซ็ปคลาส $c = z_1 \wedge z_3 \wedge z_5$ มีค่าตัวแปรแต่ละตัวเป็น $z_1 = 1, z_3 = 0, z_5 = 1$ กรณีนี้ เพียงแค่แทนตัวแปรที่เป็นเท็จด้วยนิเสธของตัวเอง จะได้คอนเซ็ป c ที่เป็นแบบ Monotone Conjunction ดังนี้

$$c = z_1 \wedge \overline{z_2} \wedge z_3 \quad (2.6)$$

3. คอนเซ็ปคลาส C เป็นแบบ k-CNF (k-literals Conjunction Normal Form) และแบบ k-terms DNF (k-term Disjunction Normal Form) คอนเซ็ปคลาสนี้จะมีรูปฟอร์มดังนี้

k-CNF

$$\underbrace{(\dots \vee \dots \vee \dots)}_{k \text{ literals}} \wedge \underbrace{(\dots \vee \dots \vee \dots)}_{k \text{ literals}} \dots$$

รูปที่ 2.11 คอนเซ็ปคลาสในรูปแบบ k-CNF

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากฟอร์มข้างต้นจะมีจำนวน k literals หรือน้อยกว่าในแต่ละ clause มี n clause ซึ่งหากแทนแต่ละ clause นั้นด้วยตัวแปรเดียว จะสามารถมองเป็นคอนเซ็ปคลาสแบบ Conjunction หรือ Monotone Conjunction ได้ และสามารถใช้อัลกอริทึมเดิมได้

k-term DNF

$$\underbrace{(\dots \wedge \dots \wedge \dots) \vee (\dots \wedge \dots \wedge \dots)}_{k \text{ terms}} \dots$$

รูปที่ 2.12 คอนเซ็ปคลาสในรูปแบบ k-term DNF

จากรูปฟอร์มข้างต้น k-term DNF ก็คือ หนึ่ง clause ของ k-CNF ดังนั้น k-term DNF จึงเป็นสับเซตของ k-CNF

ในกรณีนี้ จะเกิดเหตุการณ์ที่ไม่สามารถแก้ปัญหาได้ หากว่าจำนวนตัวแปรไม่จำกัด เมื่อพิจารณาตัวอย่างที่ 2 จากชุดข้อมูลกลุ่มบวกจะได้คอนเซ็ปเป็น

$$c = (\bar{z}_1 \wedge z_2 \wedge z_3 \wedge \bar{z}_4 \wedge z_5) \vee (z_1 \wedge z_2 \wedge \bar{z}_3 \wedge z_4 \wedge z_5) \vee (z_1 \wedge z_2 \wedge \bar{z}_3 \wedge \bar{z}_4 \wedge z_5) \quad (2.7)$$


จะเห็นว่าคอนเซ็ปมีความยาวเพิ่มขึ้นเมื่อตัวแปรหรือตัวอย่างเพิ่มขึ้น ซึ่งจะเป็นปัญหา คอนเซ็ปคลาสแบบนี้จึงเรียนรู้ได้ไม่ตื้นัก เนื่องจากจะมีปัญหาในกรณีที่ตัวแปรและตัวอย่างมีจำนวนมากๆ

ปัญหาแบบ Boolean Logic มีวิธีการหาคอนเซ็ปอย่างทีกล่าวมา ถ้าเป็นปัญหาอื่น จะพิจารณาได้ดังนี้

» Geometry [5]

ปัญหาแบบเรขาคณิต จะยกตัวอย่างสองแบบคือ เมื่อ X เป็นโดเมนของ R^2 และ X เป็นโดเมนของ R^n ไม่ว่ากรณีใดก็ตามมีให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- เมื่อ $X = R^2$




รูปที่ 2.13 หลักการแบ่งกลุ่มตัวอย่างบวกและลบ โดยใช้กรอบสี่เหลี่ยม

จากรูป หากต้องการเซตของคอนเซ็ป C ที่เป็นสี่เหลี่ยมผืนผ้า ซึ่งหากจุดใดอยู่ในกรอบสี่เหลี่ยมนี้ จะถือว่าเป็นบวกและหากอยู่นอกกรอบสี่เหลี่ยมจะถือว่าเป็นลบ สำหรับคอนเซ็ปคลาสแบบนี้ จะได้อัลกอริทึมการเรียนรู้ที่ง่ายดังนี้ เมื่อด้านทั้ง 4 ของกรอบสี่เหลี่ยมผืนผ้าคือเส้นจำนวนจริง จุดมุมของกรอบสี่เหลี่ยมผืนผ้านี้คือ จุดสูงสุดและจุดต่ำสุดของแต่ละเส้น ซึ่งจะเป็นจุดกำหนดขอบเขตพื้นที่บริเวณจุดบวกและจุดลบ เมื่อได้ขอบรูปสี่เหลี่ยมผืนผ้าแล้ว สามารถประยุกต์วิธีการหาคอนเซ็ปของคอนเซ็ปคลาสแบบ Monotone conjunction โดยที่คอนเซ็ปสี่เหลี่ยมผืนผ้าจากตัวอย่างระบูกกลุ่มบวกต้องอยู่ในขอบเขตสี่เหลี่ยมผืนผ้า นั้น และคอนเซ็ปที่ได้นี้ต้องนำไปทดสอบกับตัวอย่างระบูกกลุ่มลบ หรือจุดที่อยู่ภายนอกขอบเขตสี่เหลี่ยมผืนผ้า แล้วให้ผลเป็นลบ

หากเป็นปัญหาที่ X เป็นโดเมนของ R^n พิจารณาได้จากตัวอย่างข้างล่างนี้

- เมื่อ $X = R^n$

เพื่อให้ง่ายต่อความเข้าใจ ตัวอย่างนี้ จะยกตัวอย่างคอนเซ็ปคลาสที่ง่ายที่สุด คอนเซ็ป c ที่ต้องการคือเส้นที่แบ่งจำนวนบวกและจำนวนลบ ดังรูป



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

รูปที่ 2.14 หลักการแบ่งกลุ่มตัวอย่างบวกและลบ โดยใช้เส้นแบ่งเขต

ในตัวอย่างนี้ อัลกอริทึมในการหาคอนเซ็ปต์ c นั้น สามารถหาได้หลายวิธี วิธีแรกคือ วาดเส้นแบ่งหลายๆ เส้น และทดสอบเส้นแบ่งนั้น จนได้เส้นที่สามารถแยกจำนวนบวกและจำนวนลบได้ตรงกับคำตอบที่ระบุไว้แล้ว และนั่นคือคอนเซ็ปต์ c ที่ต้องการ แต่เนื่องจากเป็นเส้นตรง จึงใช้ได้ในกรณีที่มี $n=2$ เท่านั้น เพื่อแก้ไขปัญหานี้ วิธีที่สองคือ การหากรูมก่อนตัวอย่างระบุที่เป็นจำนวนบวกและจำนวนลบใน n แล้วให้คอนเซ็ปต์ c คือสเปซใน n มิติที่ใช้แบ่งกรูมก่อนจำนวนบวกและจำนวนลบนี้ วิธีดังกล่าวนี้สามารถใช้ได้ใน n มิติ แต่การหากรูมก่อนจำนวนบวกและจำนวนลบใน n มิตินั้นเป็นเรื่องยุ่งยาก ดังนั้นวิธีที่สามที่แก้ไขปัญหานี้ จึงใช้เวกเตอร์ n มิติ เพื่อแบ่งกรูมจำนวนบวกและกรูมจำนวนลบ ซึ่งสามารถใช้ได้ใน n มิติ และมีความยุ่งยากน้อยลงเนื่องจากสามารถเขียนเป็นสมการเส้นตรงได้ดังนี้

$$w \cdot x_i > b \text{ ถ้า } y_i = 1 \text{ (เป็นจุดบวก)} \quad (2.8)$$

$$w \cdot x_i < b \text{ ถ้า } y_i = 0 \text{ (เป็นจุดลบ)} \quad (2.9)$$

เมื่อ w คือยูนิตเวกเตอร์ (normalized) ใน n มิติ

และ b คือค่าคงที่ที่เป็น Threshold ในการแบ่ง

จากที่กล่าวมาทั้งหมด เป็นการหาคอนเซ็ปต์ c ในคอนเซ็ปต์คลาส C แบบต่างๆ โดยพยายามสร้างอัลกอริทึมการเรียนรู้ปัญหาในคอนเซ็ปต์คลาสต่างๆ อย่างมีประสิทธิภาพมากที่สุดคือ มีจำนวนคอนเซ็ปต์ที่ใช้ทดสอบและความยาวของคอนเซ็ปต์ควรเพิ่มไม่มากเกินไปเมื่อจำนวนตัวอย่างระบุ หรือตัวแปรเพิ่มขึ้น แต่อย่างไรก็ตามใน Consistency Model มีข้อเสียอยู่หลายประการคือ

1. โมเดลนี้ไม่ได้กล่าวถึงประสิทธิภาพการเรียนรู้และการนำไปใช้กับตัวอย่างที่ไม่ได้ระบุหรือตัวอย่างทดสอบ อีกทั้งยังไม่ทราบผลที่แน่ชัด หากนำไปใช้กับตัวอย่างทดสอบ ดังนั้น กฎที่ได้จึงใช้กับตัวอย่างทดสอบไม่ได้

2. เนื่องจากอัลกอริทึมนี้หาคอนเซ็ปต์ที่เฉพาะตัวอย่างระบุคำตอบที่เป็นบวกเท่านั้น จึงไม่สามารถบอกได้ว่าจะนำไปใช้กับตัวอย่างทดสอบได้ดีเพียงใด และหากต้องการให้ได้ผลที่ดีขึ้น ก็ไม่ได้ต้องการจำนวนตัวอย่างระบุเพิ่มขึ้นอย่างเป็นเหตุเป็นผลกัน

3. โมเดลนี้ในบางครั้งสามารถเรียนรู้คอนเซ็ปต์คลาสได้ แต่ไม่สามารถเรียนรู้คอนเซ็ปต์คลาสที่เป็นสับเซตได้ดังเช่นตัวอย่าง k -CNF และ k -terms DNF โมเดลนี้สามารถเรียนรู้ k -CNF ได้ แต่ k -terms DNF ซึ่งเป็นสับเซตของ k -CNF ไม่สามารถเรียนรู้ได้ ซึ่งเป็นการขัดแย้งซึ่งกันและกัน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามเผยแพร่ลงเนื้อหาใดๆ ของเอกสารทบทวนนี้ การนำไปใช้
ให้กับอัลกอริทึมของโมเดลนี้ ต้องถูกระบุไว้อย่างถูกต้องทุกข้อมูล ห้ามผิดพลาดแม้แต่ข้อมูลเดียว

ไม่เช่นนั้น กฎที่ได้จะให้ผลผิดพลาดไปด้วย ซึ่งไม่สามารถทราบได้ว่า จะให้ผลที่มีความผิดพลาดเท่าไร

ข้อเสียที่กล่าวมาทั้งสี่ประการนั้น แสดงให้เห็นว่า The consistency Model นั้น ยังมีความเป็นอุดมคติอยู่ ในทางปฏิบัติ ไม่สามารถที่จะนำข้อมูลตัวอย่างระบุทั้งหมดมาสร้างกฎ และใช้กฎนั้นกับข้อมูลตัวอย่างระบุเท่านั้น และในบางครั้ง ข้อมูลตัวอย่างที่ระบุมาอาจจะผิดพลาด ไม่ถูกต้องเสมอไป โมเดลนี้ จึงไม่สามารถใช้กับปัญหาในโลกความเป็นจริงได้ เพื่อแก้ไขปัญหานี้ จึงมีโมเดล PAC: Probably Approximately Correct Model ซึ่งจะกล่าวถึงในหัวข้อต่อไป

2.5.2.2 PAC: The Probably Approximately Correct Model [6]

เนื่องจากปัญหาจาก Consistency Model ซึ่งมีความเป็นอุดมคติ อัลกอริทึมการเรียนรู้ควรจะสร้างกฎการทำนาย เพื่อใช้กับข้อมูลที่ไม่ได้เห็นมาก่อนหรือข้อมูลตัวอย่างทดสอบ ในโมเดล PAC จึงมีข้อสมมุติฐาน h ซึ่งเป็นกฎการทำนาย เพื่อใช้กับตัวอย่างทดสอบ โดยที่ข้อสมมุติฐาน h เป็นสมาชิกของคลาสของข้อสมมุติฐาน H และเพื่อให้ง่ายและเป็นพื้นฐาน จะมีข้อสมมุติดังนี้

- ตัวอย่างระบุและตัวอย่างทดสอบ มาจากตัวกระจาย D เดียวกัน กล่าวคือ ข้อมูลตัวอย่างระบุและตัวอย่างทดสอบ มาจากแหล่งที่มาเดียวกัน มีลักษณะคล้ายคลึงกัน เช่น หากต้องการแยกเพศชายกับเพศหญิงและตัวอย่างระบุที่ป้อนให้กับอัลกอริทึมเป็นมนุษย์ ตัวอย่างทดสอบก็ควรจะเป็นมนุษย์ด้วย ไม่ควรเป็นอย่างอื่น เช่น สัตว์ เป็นต้น
- คำตอบของข้อมูลจะได้จากคอนเซ็ปต์ ซึ่งไม่ทราบว่าเป็นคอนเซ็ปต์ใด แต่ทราบว่าเป็นคอนเซ็ปต์คลาสแบบใด

ข้อสมมุติฐานที่สร้างเพื่อใช้ทำนายอาจจะให้คำตอบไม่ตรงกับคอนเซ็ปต์ซึ่งเป็นกฎที่ให้คำตอบที่ถูกต้องโดยให้ความน่าจะเป็นที่จะเกิดความผิดพลาดจากข้อสมมุติฐาน h ให้คำตอบไม่ตรงกับคอนเซ็ปต์ c คือ

$$err_D(h) = \Pr[h(x) \neq c(x)] \quad (2.10)$$

เป้าหมายของโมเดล PAC คือ หาข้อสมมุติฐาน h ที่ทำให้เกิด $err_D(h)$ น้อยๆ มีความเป็นไปได้มากถ้า $\Pr[err_D(h) \text{ มีค่าน้อย}]$ จะมีค่ามาก ซึ่ง h ที่ได้นั้นจะถือว่าเป็น Probably Approximately Correct นั่นเอง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

นิยาม หากคอนเซ็ปคลาสใดๆ สามารถเรียนรู้ได้ในโมเดล PAC โดยคลาสของข้อสมมุติฐาน \mathcal{H} อัลกอริทึม A สำหรับคอนเซ็ปทุกคอนเซ็ป $c \in \mathcal{C}$, ทุกตัวกระจาย D และทุกค่า $\epsilon > 0, \delta > 0$ เมื่อได้รับข้อมูลตัวอย่างระบุจำนวน

$$m = \text{poly}\left(\frac{1}{\epsilon}, \frac{1}{\delta}, \dots\right) \quad (2.11)$$

ซึ่งก็คือ เซต

$$S = \langle (x_1, c(x_1)), \dots, (x_m, c(x_m)) \rangle \quad (2.12)$$


แล้วสร้าง ข้อสมมุติฐาน $h \in \mathcal{H}$ ที่ทำให้

$$\Pr[\text{err}_D(h) \leq \epsilon] \geq 1 - \delta \quad (2.13)$$

ข้อสมมุติฐานนั้นจะเป็น ϵ -good โดยที่ ϵ คือ Error Parameter และ δ คือ Confidence Parameter ซึ่งสามารถกำหนดได้

โมเดลนี้สามารถบอกความผิดพลาดที่เกิดขึ้นเชิงความน่าจะเป็น ในทางกลับกัน หากต้องการกำหนดค่าความผิดพลาดที่ต้องการไว้ จะต้องใช้ตัวอย่างระบุในการสร้างข้อสมมุติฐานเท่าไร ซึ่งต่อไปจะแสดงการหาจำนวนตัวอย่างระบุที่อย่างน้อยที่สุดที่ต้องป้อนให้กับอัลกอริทึมในปัญหาต่างๆ เพื่อให้มีค่าความผิดพลาดตามที่กำหนดได้


ปัญหาที่ 1



รูปที่ 2.15 เส้นแบ่งจำนวนจริงที่เป็นบวกกับจำนวนจริงที่เป็นลบ

จากรูปให้ x คือเส้นจำนวนจริง และคอนเซ็ปคลาส \mathcal{C} คือเซตของเส้นที่แบ่งจำนวนจริงบวกกับจำนวนจริงลบ ซึ่งหากอยู่ฝั่งขวาของเส้นแบ่ง จะถือว่าเป็นจำนวนจริงบวก และหากอยู่ฝั่งซ้ายของเส้น

เอกสารนี้เป็นเอกสารที่จัดทำขึ้นเพื่อใช้ในการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.16 ช่วงพื้นที่ที่เกิดความผิดพลาด (error)

อัลกอริทึมสร้างสมมุติฐาน h ซึ่งให้ผลอาจจะไม่ตรงกับคอนเซ็ปต์ c ทุกครั้ง และมีความผิดพลาดจากรูป พื้นที่ของความผิดพลาด (Region of error) สมมุติฐาน h จะให้คำตอบเป็นลบในขณะที่คอนเซ็ปต์ c จะให้คำตอบเป็นบวก หากต้องการให้มีความแม่นยำมากขึ้น ความน่าจะเป็นที่จะอยู่ในพื้นที่ของความผิดพลาดต้องน้อยกว่าค่าที่กำหนดไว้ (ϵ) ซึ่งรูปนี้ จะแทนระยะทางระหว่างคอนเซ็ปต์ c และสมมุติฐาน h ในเชิงความน่าจะเป็นหรือโอกาสที่จะเกิดความผิดพลาด ไม่ใช่ค่าผลต่างระหว่างเส้นแบ่ง c และ h

กำหนดขอบเขตให้ความน่าจะเป็นที่จะเกิดความผิดพลาด ϵ ดังรูป 2.15



รูปที่ 2.17 กำหนดขอบเขตที่นำจะเกิดความผิดพลาด (error)


เส้นขอบดังรูป คือเส้นขอบของโอกาสที่จะเกิดความผิดพลาดมากที่สุด ϵ หาก

สมมุติฐาน h ใดๆ อยู่เกินช่วง พื้นที่ ϵ ในฝั่งขวา สมมุติฐาน h นั้นคือ $b+$

สมมุติฐาน h ใดๆ อยู่เกินช่วง พื้นที่ ϵ ในฝั่งซ้าย สมมุติฐาน h นั้นคือ $b-$


โดยที่ $b+$ และ $b-$ คือเหตุการณ์เลวร้ายในฝั่งบวกและฝั่งลบตามลำดับ ในปัญหานี้มีความสมมาตรกัน จึงสามารถพิจารณาเฉพาะข้างเดียวได้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.18 พื้นที่ความผิดพลาด (error) ทางฝั่งบวก

รูปที่ 2.15 กำหนดให้พื้นที่ของความผิดพลาดฝั่งบวกคือ R^+ หากมีจุดที่เป็นบวกใดๆ อยู่ในพื้นที่ R^+ จุดนั้นต้องอยู่ด้านซ้ายของ c เนื่องจากเป็นจุดบวก และจะอยู่ซ้ายของ h ด้วย เนื่องจากได้คำตอบจาก h ว่าจุดนั้นเป็นจุดบวก กล่าวคือ h จะอยู่ด้านซ้ายของจุดนั้นๆ ดังรูปที่ 2.19



รูปที่ 2.19 การกำหนดพื้นที่ความผิดพลาด (error) ทางฝั่งบวก

เมื่อจุดบวกจุดนั้นอยู่ในพื้นที่ R^+ และ h อยู่ฝั่งซ้ายของจุดนั้น จึงไม่มี h ตัวไหนที่จะเป็น b^+ เว้นเสียแต่ว่า จุดนั้นจะไม่ได้อยู่ในพื้นที่ R^+ ดังรูปที่ 2.19 จะได้

$$\begin{aligned} \Pr[b^+] &\leq \Pr[x_1 \notin R^+ \wedge \dots \wedge x_m \notin R^+] \\ &= \Pr[x_1 \notin R^+] \cdot \Pr[x_2 \notin R^+] \dots \Pr[x_m \notin R^+] \\ &= (1 - \epsilon)^m \end{aligned} \tag{2.14}$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่ว่าจะในรูปแบบใดก็ตาม หากมีข้อผิดพลาดประการใด ขออภัยเป็นอย่างสูงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

และสมมติให้ x_i ทุกตัว เป็น i.i.d (Independent and Identically Distributed) เมื่อรวม $\Pr[b^+]$ และ $\Pr[b^-]$ ทั้งหมด จะได้

$$\begin{aligned}\Pr[h \in -\text{bad}] &\leq \Pr[b^+] \vee \Pr[b^-] \\ &\leq \Pr[b^+] + \Pr[b^-]\end{aligned}\quad (2.15)$$

เนื่องจาก b^+ และ b^- สมมาตรกัน จะได้

$$\Pr[h \in -\text{bad}] \leq 2e^{-\epsilon m} \quad (2.16)$$

และต้องการให้

$$\Pr[h \in -\text{bad}] \leq \delta$$

จะได้

$$2e^{-\epsilon m} \leq \delta$$

$$m \geq \frac{1}{\epsilon} \ln \frac{2}{\delta} \quad (2.17)$$

ดังนั้น จำนวนตัวอย่างน้อยที่สุดที่ต้องป้อนให้กับอัลกอริทึมนี้จะเป็นไปตาม $m \geq \frac{1}{\epsilon} \ln \frac{2}{\delta}$ และมีโอกาสเกิดความผิดพลาด $1 - \delta$ แก่หาค่าความผิดพลาดได้


$$\text{err}_D(h) = \frac{1}{m} \ln \frac{2}{\delta} \quad (2.18)$$

ปัญหาที่ 2



รูปที่ 2.20 ปัญหาแบบเป็นช่วง

ปัญหานี้คล้ายกับปัญหาแรก แต่เป็นคอนเซ็ปคลาสที่อยู่ในช่วงดังรูปที่ 2.16 จะเป็นจำนวนบวก เอกสารนี้เป็นนอกเหนือจากนั้นเป็นจำนวนลบ ใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.21 การกำหนดขอบเขตช่วงความผิดพลาด

ซึ่งในปัญหานี้ จะต้องมียกเว้นสองคอนเซ็ปต์ และมีสมมติฐานสองสมมติฐาน เนื่องจากคล้ายกับปัญหาแรก เพียงแต่เพิ่มคอนเซ็ปต์และสมมติฐาน หากต้องการให้มีค่าความผิดพลาดมากที่สุด ϵ เหมือนปัญหาแรก ในแต่ละพื้นที่ความผิดพลาดทั้งฝั่งบวกและฝั่งลบ จึงต้องมีค่าความผิดพลาดไม่เกิน $\epsilon/2$ และเมื่อนำไปแทนค่า จะได้ว่า ตัวอย่างระบุจำนวนน้อยที่สุดที่ต้องใช้คือ $m \geq \frac{2}{\epsilon} \ln \frac{4}{\delta}$

ปัญหาที่ 3



รูปที่ 2.22 การกำหนดช่วงความผิดพลาดในรูปพื้นที่สองมิติ

ในการทำงานเดียวกันกับปัญหาที่ 2 จากรูปเป็นการกำหนดช่วงจำนวนบวกและจำนวนลบ แต่เป็นพื้นที่ในสองมิติ ซึ่งต้องมีคอนเซ็ปต์คอนเซ็ปต์และสมมติฐานสี่สมมติฐาน และเช่นกันคือ ในการคิดพื้นที่ความผิดพลาดแต่ละพื้นที่ จะต้องมียกเว้นค่าความผิดพลาดไม่เกิน $\epsilon/4$ และได้จำนวนตัวอย่างระบุที่น้อยที่สุดคือ $m \geq \frac{4}{\epsilon} \ln \frac{8}{\delta}$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สำหรับปัญหาทั่วไป

หากว่าปัญหาใดๆ สามารถเรียนรู้ได้ในโมเดล PAC จะสามารถคำนวณจำนวนตัวอย่างระบุอย่างน้อยที่สุดดังนี้

ทฤษฎี หากว่าคลาสของข้อสมมุติฐานนั้นเป็นสเปซจำกัด (i. e. $|\mathcal{H}| < \infty$) จะได้อัลกอริทึมหนึ่งอัลกอริทึม จะหาข้อสมมุติฐานหนึ่งข้อสมมุติฐาน $h_A \in \mathcal{H}$ ที่ให้ผลตรงกับคำตอบที่ระบุไว้แล้วของตัวอย่างที่ระบุจำนวน m เมื่อ $m \geq \frac{1}{\epsilon} |\mathcal{H}| + \ln \frac{1}{\delta}$ และข้อสมมุติฐานนั้นจะถือว่าเป็น $\epsilon - good$ คือ

$$\Pr[err_D(h_A) > \epsilon] \leq \delta \quad (2.19)$$

โมเดล PAC นั้นจะบอกค่าความผิดพลาดในเชิงความน่าจะเป็น ซึ่งหากเกิดความผิดพลาดขึ้น ค่าผลต่างความผิดพลาดนั้น จะมากหรือน้อย ไม่อาจจะทราบได้ ดังนั้น โมเดลต่อไปจะกล่าวถึงความผิดพลาดที่เป็นผลต่างระหว่างค่าที่ถูกต้องกับค่าที่ผิดพลาดไป

2.5.2.3 EC: Expected Correct Model [6]

นิยาม หากคอนเซ็ปคลาสใดๆ สามารถเรียนรู้ได้ในโมเดล EC โดยคลาสของข้อสมมุติฐาน \mathcal{H} อัลกอริทึม A สำหรับคอนเซ็ปทุกคอนเซ็ป $c \in \mathcal{C}$, ทุกตัวกระจาย D และทุกค่า $\alpha > 0$ เมื่อได้รับข้อมูลตัวอย่างระบุจำนวน

$$m = \text{poly}\left(\frac{1}{\alpha}, \dots\right) \quad (2.20)$$

ซึ่งก็คือ เซ็ต

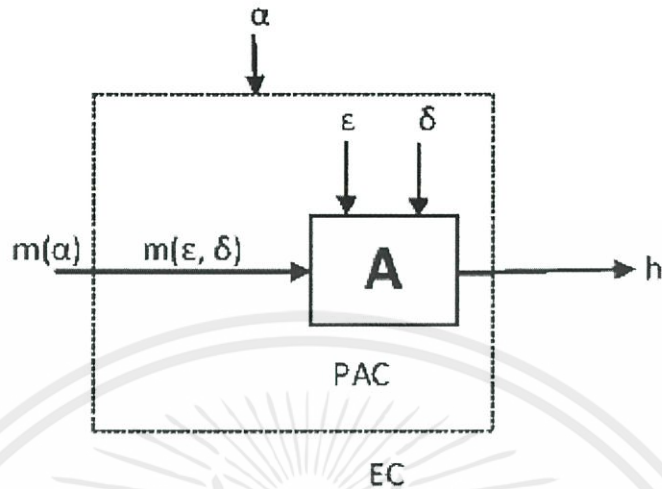
$$S = \langle (x_1, c(x_1)), \dots, (x_m, c(x_m)) \rangle \quad (2.21)$$

แล้วสร้าง ข้อสมมุติฐาน $h \in \mathcal{H}$ ที่ทำให้

$$E[err_D(h)] \leq \alpha \quad (2.22)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานในกรณีฉุกเฉินเท่านั้น ไม่ควรนำออกจากรั้วมหาวิทยาลัย และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้ โดยที่ α คือค่า Value error ซึ่งสามารถกำหนดได้

โมเดล EC นี้มีความสมมูลกับโมเดล PAC สามารถแปลงกลับไปกลับมาได้ โดย



รูปที่ 2.23 โมเดลแสดงการแปลงกลับไปมาของ EC Model กับ PAC Model

สมการการแปลงกลับไปกลับมาจากโมเดล PAC เป็นโมเดล EC คือ

$$\begin{aligned}
 E[err] &= \Pr[err > \epsilon]E[err|err > \epsilon] + \Pr[err \leq \epsilon]E[err|err \leq \epsilon] \\
 &\leq \delta + \epsilon
 \end{aligned}
 \tag{2.23}$$

สรุป

เทคนิคการตรวจจับภาพใบหน้า Haar-like features นั้น มีความรวดเร็วเนื่องจากประมวลผลเป็นเชิงบริเวณพื้นที่ ซึ่งจะมีความเร็วกว่าการประมวลผลทีละ pixel นอกจากนี้ยังมีการแปลงเป็น integral image เพื่อที่จะได้ข้อมูลความเข้มแสงรวมในพื้นที่ใดๆ ได้เร็วขึ้น การประมวลผลเชิงบริเวณนั้น จะทำให้มีความละเอียดน้อย หรือตรวจหาแบบหยาบๆ จึงอาศัยการเรียนรู้ของเครื่อง (Machine Learning) เพื่อช่วยในการตัดสินใจ การเรียนรู้ของเครื่องนั้น อาศัยการสร้างกฎจากข้อมูลตั้งที่ได้กล่าวมา ในการศึกษาครั้งนี้ ทำให้ทราบว่า หากต้องการค่าความผิดพลาดตามที่กำหนด จะสามารถคำนวณจำนวนข้อมูลตัวอย่างอย่างน้อยที่สุดที่ต้องป้อนให้กับอัลกอริทึมได้ในเชิงคณิตศาสตร์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 3

บทวิจารณ์และสรุป

3.1 ปัญหาที่พบและแนวทางแก้ไข

ในการศึกษาครั้งนี้ได้ทราบวิธีการค้นหาตำแหน่งรูปภาพ ซึ่งได้ใช้ความรู้หลายอย่างมาประกอบกัน ดังเช่น การประมวลผลภาพ (image processing) การเรียนเรียนรู้ของเครื่อง(machine learning) นอกจากนี้จากการศึกษาค้นคว้าพบว่า แนวทางในการทำ Image processing มีมากมายหลายแบบ ไม่ว่าจะเป็น วิธีแบบ Neural Network-based Face Detection, วิธีแบบ Probabilistic Modeling หรือ วิธีแบบ Haar-Like Feature ซึ่งได้ใช้เวลาทำการศึกษาในส่วนนี้ไปมากพอสมควรว่าจะใช้วิธีไหนมาทำการทดลองต่อไป สุดท้ายจึงได้เลือกวิธีแบบ Haar-Like Feature เนื่องจากเป็นวิธีที่ใช้เวลาในการประมวลผลรวดเร็วที่สุด และสามารถใช้ได้ทั้งภาพสีและขาว-ดำ จึงสามารถใช้กล้องขาว-ดำแทนกล้องสีซึ่งมีราคาแพงกว่าได้ แต่เนื่องจากเวลาที่ใช้ในการศึกษานั้นมีเวลาที่จำกัดอยู่ ทำให้ยังไม่สามารถสร้างระบบตรวจจับใบหน้าได้ เพราะได้ทำการศึกษาไปได้ 2 ใน 3 ส่วนเท่านั้นก็คือในส่วนของ Features และ Adaboost ซึ่งถ้าหากต้องการจะสร้างระบบตรวจจับใบหน้าขึ้นมาได้เอง ต้องทำการศึกษาในส่วนที่เหลือเสียก่อน คือในส่วนของ Cascade Classifier จึงจะสามารถเขียนโปรแกรมและสร้างระบบตรวจจับใบหน้าได้ด้วยความเข้าใจจริงๆ

3.2 ข้อเสนอแนะและแนวทางในการค้นคว้าต่อ

ในการศึกษาเทคนิค Haar-Like Feature ต้องมีพื้นฐานด้านคณิตศาสตร์ในเรื่องของ สถิติ ความน่าจะเป็นเสียก่อน โดยเฉพาะอย่างยิ่งในส่วนของ Machine Learning นั้นได้นำความรู้ทางคณิตศาสตร์มาประยุกต์ใช้อย่างมากมาย และนั่นเป็นหนึ่งในสาเหตุที่ทำให้งานวิจัยนี้ใช้เวลาไปมาก เพราะต้องกลับไปศึกษาใหม่ว่า สมการทางคณิตศาสตร์นี้หมายถึงอะไร และนำไปใช้ต่ออย่างไร จึงแนะนำให้ทำการศึกษาพื้นฐานทั่วไปของคณิตศาสตร์เรื่อง สถิติและความน่าจะเป็นมาก่อน นอกจากนี้ศึกษาการใช้ MATLAB เพื่อให้ง่ายต่อการเขียนโปรแกรมและนำมาใช้ เพื่อเห็นการประมวลผลจริงได้ดียิ่งขึ้น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เอกสารอ้างอิง

- [1] Mahdi Rezaei, **Face and Eye Detection**, July 2011.
- [2] Paul Viola and Michael Jones, **Robust Real-time Object Detection.**, In Second International Workshop On Statistical And Computational Theories Of Vision – Modeling, Learning, Computing, And Sampling., Vancouver, Canada, JULY 13, 2001.
- [3] Yoav Freund and Robert E. Schapire, **A decision-theoretic generalization of on-line learning and an application to boosting.**, The proceedings of the Second European Conference on Computational Learning Theory, Eurocolt '95., Springer-Verlag, March, 1995.
- [4] Rob Schapire, **Theoretical Machine Learning Lecture #1.**, February 4, 2008.
- [5] Rob Schapire, **Theoretical Machine Learning Lecture #2.**, February 6, 2008.
- [6] Rob Schapire, **Theoretical Machine Learning Lecture #3.**, February 11, 2008.
- [7] BLUMER Anselm, EHRENFUCHT Andzej, HÄUSSLER David, **Occam's Razor**, Information Processing Letters 24 (1987) pp.337-380.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภาคผนวก

พิสูจน์สมการใน Machine Learning

1. การพิสูจน์สมการที่ 2.19

$$\begin{aligned}
\Pr[h_A \epsilon - \text{bad}] &= \Pr[h_A \text{ consistent} \wedge h_A - \text{bad}] \\
&\leq \Pr[\exists h \in \mathcal{H}: h \text{ consistent} \wedge \epsilon - \text{bad}] \\
&= \Pr[\exists h \in \mathcal{B}: h \text{ consistent}] \\
&= \Pr\left[\bigvee_{h \in \mathcal{B}} h \text{ consistent}\right] \\
&\leq \sum_{h \in \mathcal{B}} \Pr[h \text{ consistent}] \\
&= \sum_{h \in \mathcal{B}} \Pr[h(x_1) = c(x_1) \wedge \dots \wedge h(x_m) = c(x_m)] \\
&= \sum_{h \in \mathcal{B}} \prod_{i=1}^m \Pr[h(x_i) = c(x_i)] \\
&\leq \sum_{h \in \mathcal{B}} (1 - \epsilon)^m \\
&= |\mathcal{B}|(1 - \epsilon)^m \\
&\leq |\mathcal{H}|(1 - \epsilon)^m \\
&\leq |\mathcal{H}|e^{-\epsilon m} \\
&\leq \delta
\end{aligned}$$

2. การพิสูจน์สมการที่ 2.14

$$\begin{aligned}
\Pr[\text{err}(h_s) > \epsilon | h_s \text{ consistent}] &= \frac{\Pr[\text{err}(h_s) > \epsilon \wedge h_s \text{ consistent}]}{\Pr[h_s \text{ consistent}]} \\
&= \Pr[\text{err}(h_s) > \epsilon \wedge h_s \text{ consistent}] \\
&= \Pr[h_s \text{ consistent} | \text{err}(h_s) > \epsilon] \Pr[\text{err}(h_s) > \epsilon] \\
&\leq \Pr[h_s \text{ consistent} | \text{err}(h_s) > \epsilon] \\
&= \Pr[h_s(x_1) = c(x_1) \wedge \dots \wedge h_s(x_m) = c(x_m) | \text{err}(h_s) > \epsilon]
\end{aligned}$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับใช้ภายในของมหาวิทยาลัยเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามนำเอกสารทุกครั้งที่มีการนำไปใช้

$$\begin{aligned}
&= \prod_{i=1}^m \Pr[h_s(x_i) = c(x_i) \mid \text{err}(h_s) > \epsilon] \\
&\leq (1 - \epsilon)^m \\
&\leq e^{-\epsilon m}
\end{aligned}$$



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้