

การพยากรณ์การเกิดภัยแล้งในประเทศไทยด้วยวิธีการเรียนรู้ของเครื่อง

วีรภัทรา เจริญกิจสุพัฒน์

สารนิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมข้อมูลขนาดใหญ่

วิทยาลัยนวัตกรรมด้านเทคโนโลยีและวิศวกรรมศาสตร์

มหาวิทยาลัยธุรกิจบัณฑิตย์

พ.ศ.2564

**A LARGE-SCALE DROUGHT FORECASTING WITH
MACHINE LEARNING**

WEERAPATRA CHAROENKITSUPAT

**A Thematic Paper Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Engineering
Department of Big Data Engineering,
College of Innovative Technology and Engineering
Dhurakij Pundit University**

2021




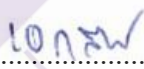
ใบรับรองงานสารนิพนธ์

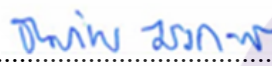
วิทยาลัยนวัตกรรมการด้านเทคโนโลยีและวิศวกรรมศาสตร์ มหาวิทยาลัยธุรกิจบัณฑิตย์

ปริญญา วิศวกรรมศาสตรมหาบัณฑิต


หัวข้อสารนิพนธ์ การพยากรณ์การเกิดภัยแล้งในประเทศไทยด้วยวิธีการเรียนรู้ของเครื่อง
เสนอโดย วีรภัทรา เจริญกิจสุพัฒน์
สาขาวิชา วิศวกรรมข้อมูลขนาดใหญ่
อาจารย์ที่ปรึกษาสารนิพนธ์ ดร.เอกสิทธิ์ พัทธวงศ์ศักดิ์ดา
ได้พิจารณาเห็นชอบโดยคณะกรรมการสอบสารนิพนธ์แล้ว


.....ประธานกรรมการ
(ดร.สรรพฤทธิ์ มฤคทัต)


.....กรรมการและอาจารย์ที่ปรึกษา
(ดร.เอกสิทธิ์ พัทธวงศ์ศักดิ์ดา)


.....กรรมการ
(ดร.ธนภัทร ชังคะจิตร)

วิทยาลัยนวัตกรรมการด้านเทคโนโลยีและวิศวกรรมศาสตร์รับรองแล้ว


.....
(ดร.ชัยพร เขมะภาดะพันธ์)

คณบดีวิทยาลัยนวัตกรรมการด้านเทคโนโลยีและวิศวกรรมศาสตร์

วันที่ 31 เดือน กรกฎาคม พ.ศ. 2564

หัวข้อสารนิพนธ์	การพยากรณ์การเกิดภัยแล้งในประเทศไทยด้วยวิธี การเรียนรู้ของเครื่อง
ชื่อผู้เขียน	วีรภัทรา เจริญกิจสุพัฒน์
อาจารย์ที่ปรึกษา	ดร.เอกสิทธิ์ พัทธวงษ์ศักดิ์ดา
สาขาวิชา	วิศวกรรมข้อมูลขนาดใหญ่
ปีการศึกษา	2563

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์ เพื่อพยากรณ์การเกิดภัยแล้งของแต่ละตำบลในประเทศไทย และหาแบบจำลองที่ดีที่สุดที่ใช้ในการพยากรณ์การเกิดภัยแล้ง โดยทำการหาแบบจำลองที่สามารถพยากรณ์การเกิดภัยแล้งที่มีค่าความถูกต้องของการเกิดและไม่เกิดภัยแล้งใกล้เคียงกัน จากข้อมูลปริมาณน้ำฝนและดัชนีเสี่ยงภัยแล้ง(DRI) ด้วยการใช้แบบจำลองNeural Network, Gradient Boosted Trees และ Random Forest ด้วย RapidMiner และ Automated machine learning (AutoML) ของ H₂o.ai ผลงานวิจัยพบว่า แบบจำลอง Neural Network ที่ Learning Rate 0.01, Training cycle 50, momentum 0.1 และใช้แอตทริบิวต์ 28 ตัว มีประสิทธิภาพดีกว่าทุกแบบจำลองที่ทำการทดลอง พบว่าค่าความถูกต้องของการเกิดภัยแล้ง 64.43% และ ไม่เกิดภัยแล้ง 65.29%

Thematic Paper Title	A LARGE-SCALE DROUGHT FORECASTING WITH MACHINE LEARNING
Author	Weerapatra Charoenkitsupat
Thematic Paper Advisor	Dr. Eakasit Pacharawongsahda
Department	Big Data Engineering
Academic Year	2020

ABSTRACT


The objective of this research is to predict the occurring of drought in each sub-district in Thailand and to build the best model for predicting it. The best model is created by finding the highest recall where the corrected prediction of drought happening and not happening has the closest gap between two numbers. According to rainfall data and drought risk index (DRI) along with using machine learning models, Neural Network, Gradient Boosted Trees and Random Forest with RapidMiner and Automated machine learning (AutoML) from H2o.ai. The research results showed that the Neural Network model having the learning rate at 0.01, Training cycle at 50, momentum at 0.1 with 28 attributes had the best performance comparing with other models in the experiments. With the use of the best model, the recall of correct prediction of the drought occurring was 64.43% and the drought not occurring was 65.29%.

กิตติกรรมประกาศ

สารนิพนธ์ฉบับนี้สำเร็จลุล่วงไปได้โดยการให้ความช่วยเหลือของ ดร.เอกสิทธิ์ พัทธรวงศ์ ศักดา ซึ่งเป็นอาจารย์ที่ปรึกษาสารนิพนธ์ ที่ได้กรุณาให้คำแนะนำ ตรวจสอบ และแก้ไขข้อบกพร่องต่าง ๆ มาโดยตลอดเพื่อให้สารนิพนธ์ฉบับนี้สมบูรณ์ ผู้เขียนจึงขอกราบขอบพระคุณไว้ ณ โอกาสนี้

ผู้เขียนขอกราบขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.สรรพฤทธิ์ มฤคทัต ที่กรุณาให้เกียรติเป็นประธาน โดยมี ดร.ชนภัทร ฆังคะจิตร เป็นกรรมการในการสอบสารนิพนธ์ซึ่งได้กรุณาตรวจแก้ไขสารนิพนธ์ฉบับนี้ให้ถูกต้องสมบูรณ์ยิ่งขึ้น และนางสาวกุลธิดา รอดบุญ รวมถึงเจ้าหน้าที่บัณฑิตมหาวิทยาลัยธุรกิจบัณฑิตทุกท่านที่ให้อำนวยความสะดวกและประสานงาน ในการทำสารนิพนธ์ให้กับผู้เขียน ทำให้สารนิพนธ์นี้สำเร็จลุล่วงไปได้ด้วย

วีรภัทรา เจริญกิจสุพัฒน์



สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ฅ
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญตาราง.....	ซ
สารบัญภาพ.....	ฌ
บทที่	
1. บทนำ.....	1
1.1 ที่มาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของงานวิจัย.....	1
1.3 ขอบเขตงานวิจัย.....	2
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	2
1.5 นิยามศัพท์.....	2
1.6 เครื่องมือที่ใช้ในการทำงานวิจัย.....	3
2. ทฤษฎีและผลงานที่เกี่ยวข้อง.....	4
2.1 ภัยแล้ง (Drought).....	4
2.2 ค่าดัชนีความเสี่ยงภัยแล้ง.....	4
2.3 การแทรกค่า (Interpolation) ด้วยวิธี IDW.....	7
2.4 Feature Selection ด้วยวิธี Information Gain.....	8
2.5 โครงข่ายประสาทเทียม.....	8
2.6 Gradient Boosted Trees.....	10
2.7 Random Forest.....	11
2.8 Automated machine learning (AutoML).....	12

สารบัญ (ต่อ)

บทที่	หน้า
3. ระเบียบวิธีการวิจัย.....	13
3.1 ประชากร และตัวอย่าง.....	13
3.2 การเตรียมข้อมูล.....	15
3.3 วิธีการวิเคราะห์ข้อมูล.....	16
4. ผลการทดลอง.....	19
4.1 ผลของการหาค่าถ่วงน้ำหนักด้วย information gain.....	19
4.2 ผลจากการทดสอบด้วยแบบจำลองต่างๆ.....	21
4.3 การแสดงผล.....	24
5 บทสรุป และ ข้อเสนอแนะ.....	26
5.1 สรุปผลการศึกษา.....	26
5.2 ข้อเสนอแนะ.....	26
บรรณานุกรม.....	27
ภาคผนวก.....	30
ภาคผนวก ก ตารางผลของแบบจำลองโครงข่ายประสาทเทียมที่มีการทดสอบ Confusion Matrix.....	31
ภาคผนวก ข ตารางผลของแบบจำลองจาก RapidMiner.....	54
ภาคผนวก ค ตารางผลของแบบจำลอง Automated machine learning (AutoML) ของ H2o.....	55
ประวัติผู้เขียน.....	63

สารบัญตาราง

ตารางที่	หน้า
3.1 ผลตัวอย่างจากการใช้แบบจำลอง Gradient Boosted Trees.....	16
3.2 ผลตัวอย่างจากการใช้แบบจำลอง Random Forest.....	16
3.3 ผลตัวอย่างจากการใช้แบบจำลองโครงข่ายประสาทเทียม.....	17
4.1 ค่าถ่วงน้ำหนักด้วยวิธีการ information gain ของ แต่ละแอตทริบิวต์เรียงจาก มากไปน้อย.....	19
4.2 ผลที่มีค่าเฉลี่ยของค่าความถูกต้องที่ดีที่สุดของแต่ละแบบจำลอง.....	21
4.3 ตาราง Confusion Matrix ของแบบจำลองมีประสิทธิภาพดีที่สุด.....	22
4.4 ตารางแสดง layer ของแบบจำลองโครงข่ายประสาทเทียมที่ดีที่สุด.....	22

สารบัญภาพ

ภาพที่	หน้า
2.1 ตัวอย่างการแบ่งระดับค่าดัชนี.....	6
2.2 ระยะทางระหว่างจุดที่ไม่ทราบค่ากับจุดที่ทราบค่าในบริเวณใกล้เคียงกัน.....	7
2.3 โครงสร้างของโครงข่ายประสาทเทียม.....	9
2.4 กระบวนการทำงานของ Gradient Boosted Trees.....	10
2.5 กระบวนการทำงานของ Random forest.....	11
3.1 ภาพข้อมูลประวัติการเกิดภัยแล้งจากกรมป้องกันและบรรเทาสาธารณภัย บางส่วน.....	13
3.2 ภาพข้อมูลปริมาณน้ำในจากสถานบันสารสนเทศทรัพยากรน้ำรายวัน บางส่วน.....	13
3.3 ภาพข้อมูลดัชนีเสี่ยงภัยแล้ง (DRI) รายสัปดาห์.....	14
3.4 ผลตัวอย่างจากการแปลงข้อมูลดัชนีเสี่ยงภัยแล้ง.....	15
3.5 โครงสร้างของแบบจำลองโครงข่ายประสาทเทียมที่ดีที่สุด.....	17
3.6 ผลตัวอย่างจาก Automated machine learning (AutoML) ของ H ₂ O.....	19
4.1 การแสดงผลของแบบจำลองแบบไม่ได้เลือกพื้นที่.....	24
4.2 การแสดงผลแบบเลือกพื้นที่จากแผนที่.....	25

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญของปัญหา

ภัยแล้งเป็นภัยธรรมชาติที่เกิดจากการขาดแคลนน้ำเป็นระยะเวลานาน ส่งผลกระทบอย่างมากต่อการดำรงชีวิต ในประเทศไทยส่วนใหญ่เกิด 2 ช่วง ได้แก่ ช่วงฤดูหนาวต่อเนื่องถึงฤดูร้อน เริ่มจากครึ่งหลังของเดือนตุลาคมเป็นต้นไป บริเวณประเทศไทยตอนบน และช่วงกลางฤดูฝน ประมาณปลายเดือนมิถุนายนถึงเดือนกรกฎาคม จะมีฝนทิ้งช่วงเกิดขึ้น ส่งผลกระทบกับการเกษตรและการอุปโภคบริโภค เช่น การที่น้ำประปาเค็ม ขาดแคลนแหล่งน้ำ ฯลฯ

งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อพัฒนาแบบจำลองที่ใช้ในการพยากรณ์การเกิดภัยแล้ง เป็นผู้ช่วยให้หน่วยงานที่รับผิดชอบสามารถเฝ้าระวังและแจ้งเตือนกับผู้ที่อาจจะได้รับผลกระทบจากภัยนี้ได้ทัน โดยประยุกต์แบบจำลองประเภทการจำแนกประเภท (Classification) หาแบบจำลองที่ดีที่สุดในการพยากรณ์การเกิดหรือไม่เกิดภัย ด้วย Automated machine learning (AutoML) ของ H₂O.ai และการสุ่มเปลี่ยนค่าต่างๆในแบบจำลองประเภทการจำแนกประเภท

ผลที่ได้จากการวิจัยนี้ทำให้สามารถเฝ้าระวังการเกิดภัยแล้ง และเตรียมรับมือกับภัยแล้งที่จะเกิดขึ้น ให้กับหน่วยงานที่รับผิดชอบ

1.2 วัตถุประสงค์ของงานวิจัย

1. พยากรณ์การเกิดภัยแล้งของตำบลในประเทศไทย
2. เพื่อพัฒนาแบบจำลองที่ใช้ในการพยากรณ์การเกิดภัยแล้งให้มีประสิทธิภาพมากที่สุด
3. เป็นส่วนหนึ่งของโครงการเพิ่มประสิทธิภาพระบบเตือนภัยของประเทศ กรมป้องกันและบรรเทาสาธารณภัย(ปภ.) กระทรวงมหาดไทย

1.3 ขอบเขตงานวิจัย

งานวิจัยครั้งนี้เป็นการหาแบบจำลองที่ดีในการพยากรณ์ล่วงหน้าหนึ่งวันของการเกิดภัยแล้งระดับตำบล โดยใช้ข้อมูลดังนี้

1. ข้อมูลประวัติการเกิดภัยแล้งระดับตำบลจากกรมป้องกันและบรรเทาสาธารณภัยในปี 2561 ถึง 2563
2. ข้อมูลปริมาณน้ำฝนรายวันระดับสถานี จากสถานบันสารสนเทศทรัพยากรน้ำปี 2561 ถึง 2563
3. แผนที่ของข้อมูลดัชนีเสี่ยงภัยแล้ง (DRI) รายสัปดาห์ จากสำนักงานพัฒนาเทคโนโลยีอวกาศและภูมิสารสนเทศในปี 2561 ถึง 2563

1.4 ประโยชน์ที่คาดว่าจะได้รับ

1. ได้แบบจำลองในการพยากรณ์การเกิดภัยแล้งที่มีประสิทธิภาพมาก
2. เป็นเครื่องมือช่วยเฝ้าระวังการเกิดภัยธรรมชาติให้กับหน่วยงานที่รับผิดชอบ

1.5 นิยามศัพท์

1. **Accuracy** หรือ ความแม่นยำ คือ ผลการวิเคราะห์ที่มีค่าใกล้เคียงระหว่างค่าที่ทดสอบกับค่าจริง
2. **Precision** หรือ ความเที่ยงตรง คือ ผลการวิเคราะห์ช่วงทำการทดลองหลายครั้งในสถานะเดียวกันและได้ค่าใกล้เคียงกัน หรือคือความแม่นยำของการวัดซ้ำหลายๆครั้ง
3. **Recall** หรือ ค่าความถูกต้อง คือ ค่าที่แบบจำลองทายเป็นคลาสที่กำลังพิจารณาถูก/ค่าเหตุการณ์จริงเป็นคลาสที่กำลังพิจารณาทั้งถูกและผิด
4. **Weight mean recall** คือ ค่าเฉลี่ยของค่าความถูกต้อง
5. **Root Mean Squared Error (RMSE)** คือ รากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง
6. **Mean Squared Error (MSE)** คือ ค่าเฉลี่ยความผิดพลาดกำลังสอง
7. **Drought Risk Index (DRI)** คือ ดัชนีชี้ความเสี่ยงต่อการเกิดความแห้งแล้งหรือภัยแล้งในพื้นที่ใดพื้นที่หนึ่งจากปัจจัยที่มีอิทธิพลให้เกิดความแห้งแล้ง

8. **Neural Network** หรือ โครงข่ายประสาทเทียม คือการสร้างแบบจำลองที่จำลองการทำงานมาจากสมองมนุษย์

9. **Gradient Boosted Trees (GBT)** คือการสร้างแบบจำลองที่สุ่มสร้าง Decision tree หลายร้อยแบบจำลอง ทำซ้ำและประเมินผลแต่ละแบบจำลองจนกว่าจะได้ Decision tree ที่สมบูรณ์.

10. **Random forest (RF)** คือการสร้างแบบจำลองจาก Decision Tree หลายแบบจำลองย่อย โดยให้แต่ละแบบจำลองได้รับชุดข้อมูลย่อยที่ไม่เหมือนกัน แล้วทำการพยากรณ์ข้อมูลในแต่ละ Decision Tree และคำนวณผลด้วยการ vote ที่ถูกเลือกโดย Decision Tree มากที่สุด

11. **Automated machine learning (AutoML)** คือ เครื่องมือที่ช่วยการพัฒนาแบบจำลอง จากหลากหลายแบบจำลอง

1.6 เครื่องมือที่ใช้ในการทำงานวิจัย

1. โปรแกรม RapidMiner Studio
2. โปรแกรม Microsoft Excel
3. โปรแกรม Jupyter Notebook
4. โปรแกรม Power BI

บทที่ 2

ทฤษฎี และผลงานที่เกี่ยวข้อง

2.1 ภัยแล้ง (Drought)

ภัยแล้ง (Drought) ตามนิยามในส่วนของระบบเตือนภัยของกรมป้องกันและบรรเทาสาธารณภัย (ปภ.) ได้แบ่งประเภทของภัยแล้งไว้ 3 ประเภท คือ ฝนทิ้งช่วง ภัยแล้งแบบอุปโภค - บริโภค และภัยแล้งแบบเกษตร ซึ่งในแต่ละประเภทจะมีลักษณะของรูปแบบในการพิจารณาเตือนภัยที่แตกต่างกัน ดังนี้

2.1.1 ฝนทิ้งช่วง คือ สภาวะแล้งที่เกิดขึ้นหากปริมาณน้ำฝนรายวันน้อยกว่า 1 มิลลิเมตร มากกว่า 15 วัน ในช่วงฤดูฝน

2.1.2 แล้งอุปโภค-บริโภค คือ สภาวะภัยแล้งที่จะต้องได้รับการแจ้งเตือนจากกรมป้องกันและบรรเทาสาธารณภัย (ปภ.) และอาสาสมัครป้องกันภัยฝ่ายพลเรือน (อปพร.) ของจังหวัด โดยพิจารณาจากปริมาณการใช้น้ำในการอุปโภค - บริโภคเป็นหลัก

2.1.3 แล้งเกษตร คือ สภาวะภัยแล้งที่มีการขาดแคลนน้ำสำหรับการทำเกษตรกรรม และพื้นที่เกษตรกรรมได้รับความเสียหายจากการขาดแคลนน้ำ

2.2 ค่าดัชนีความเสี่ยงภัยแล้ง

ดัชนีเสี่ยงภัยแล้ง หรือ Drought Risk Index (DRI) เป็นดัชนีชี้ความเสี่ยงต่อการเกิดความแห้งแล้งหรือภัยแล้งในพื้นที่ใดพื้นที่หนึ่งจากปัจจัยที่มีอิทธิพลให้เกิดความแห้งแล้ง อันได้แก่ ปัจจัยด้านความรุนแรงของความแห้งแล้ง (Drought Hazard) และปัจจัยด้านความเปราะบางต่อความแห้งแล้ง (Drought Vulnerability) สร้างโดยอาศัยหลักการคิดค่าคะแนนจากการถ่วงน้ำหนักปัจจัย

$$\text{DRI} = \text{DHI} \times \text{DVI}$$

*****Drought Hazard Index : DHI*****

$$\text{DHI} = \text{SPI} + \text{VHI}$$

SPI : Standardized Precipitation Index

VHI : Vegetation Health Index

*****DVI: Drought Vulnerability Index *****

$$\text{DVI} = \text{QI} + \text{LU}$$

QI : QI-Surface Water Content Index


LU : Landuse

2.2.1 Drought Hazard Index (DHI) ประกอบด้วยปัจจัยย่อย 2 ปัจจัย ทางด้านอุตุนิยมวิทยาและข้อมูลอนุพันธ์ภาพจากดาวเทียม ดังต่อไปนี้

2.2.1.1 ดัชนี SPI (Standardized Precipitation Index) วิเคราะห์ได้จากข้อมูลอุตุนิยมวิทยา ได้แก่ ปริมาณน้ำฝนที่เก็บวัดได้จากสถานีตรวจวัดอากาศของกรมอุตุนิยมวิทยา และของ สทอภ. ที่อยู่ในและโดยรอบพื้นที่ศึกษา ค่า SPI สามารถแบ่งช่วงระดับของความแห้งแล้งและให้ค่าน้ำหนักที่จะก่อให้เกิดภัยแล้งที่แตกต่างกันออกไปได้ หลักการของ SPI อยู่บนพื้นฐานของการวิเคราะห์ข้อมูลปริมาณน้ำฝนที่ช่วงเวลาหนึ่ง ณ พื้นที่หนึ่งๆ โดยวิธีการแปลงค่าอนุกรมเวลาของฝนให้อยู่ในรูปการแจกแจงแกมมา (gamma distribution) แล้วแปลงให้เป็นการกระจายปกติมาตรฐาน พารามิเตอร์ที่เหมาะสมได้จะใช้คำนวณหาการกระจายความน่าจะเป็นสะสม (cumulative probability distribution) ตัวอย่างการประยุกต์เช่น ประเทศสหรัฐอเมริกาใช้ SPI เป็นเครื่องมือหนึ่งในการเตือนภัยแล้ง โดย SPI ถูกออกแบบมาเพื่อให้สามารถหาปริมาณฝนที่ขาดหายไปซึ่งเกี่ยวข้องกับสภาวะความแห้งแล้งและผลกระทบต่อการใช้น้ำในกิจกรรมประเภทต่าง ๆ ซึ่งการเกิดภาวะฝนแล้งในช่วง 1-6 เดือนจะมีผลต่อความชื้นในอากาศและดิน รวมทั้งปริมาณน้ำท่าที่จะส่งผลกระทบต่อเกษตรกร หากภาวะฝนแล้งยาวนานเป็น 6-12 เดือนก็จะมีผลต่อปริมาณน้ำที่ไหลลงอ่างเก็บน้ำและปริมาณน้ำใต้ดิน ดังนั้นสามารถคำนวณ SPI สำหรับช่วง 3, 6, 9, 12, 24 เดือนได้ ค่า SPI ที่คำนวณได้โดยทั่วไปจะถูกแบ่งช่วง 7 ระดับ ซึ่งก็จะมีค่าถ่วงน้ำหนักของปัจจัยที่แตกต่างกัน ในกรณีประยุกต์ใช้สำหรับประเทศไทยภายใต้โครงการฯนี้ เป็นการหา SPI สำหรับช่วง 1 เดือนเพื่อให้สามารถจัดทำแผนที่เสี่ยงภัยรายเดือนได้ตามขอบเขตของการศึกษา

2.2.1.2 ดัชนี VHI ตามแนวทางการวิเคราะห์ที่ใช้ประเมินความแห้งแล้งในระดับประเทศ ที่อยู่บนพื้นฐานของการวิเคราะห์ NDVI แบบอนุกรมเวลา ค่าที่ได้จะบอกสภาพความสมบูรณ์ของพืช

พรรณที่ได้รับอิทธิพลจากความแห้งแล้งในระดับต่าง ๆ ซึ่งสามารถให้ค่าน้ำหนักที่จะก่อให้เกิดภัยแล้งที่แตกต่างกัน



ภาพที่ 2.1 ตัวอย่างการแบ่งระดับค่าดัชนี

ที่มา: gistda

2.2.2. Drought Vulnerability Index (DVI) ประกอบด้วยปัจจัยย่อย 2 ตัว ได้แก่

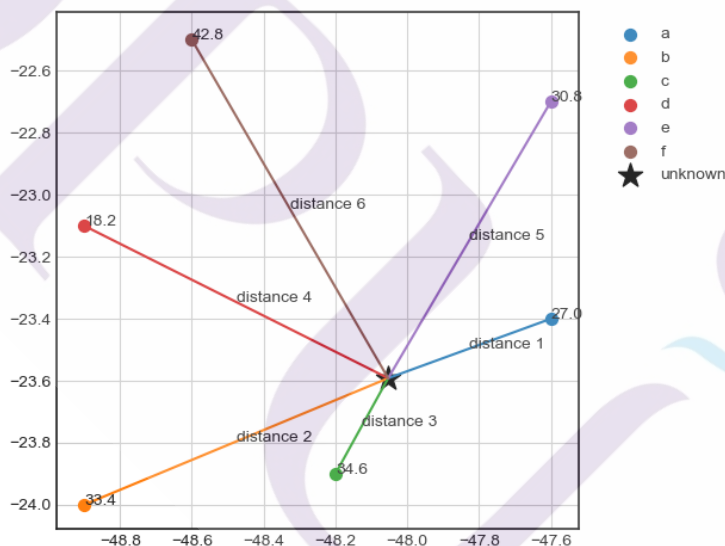
2.2.2.1. ค่า QI เป็นปัจจัยทางด้านอุทกวิทยา สามารถสะท้อนความเปราะบางของพื้นที่ต่อภาวะความแห้งแล้งได้

2.2.2.2. การใช้ประโยชน์ที่ดินหลัก เป็นอีกปัจจัยที่มีหลักการว่า การใช้ที่ดินแต่ละประเภทจะมีความเปราะบางกับความแห้งแล้งที่แตกต่างกัน เช่น พื้นที่เกษตรกรรมแต่ละประเภท ย่านที่อยู่อาศัย และพื้นที่ป่า ล้วนเป็นรูปแบบการใช้ที่ดินที่อ่อนไหวต่อความแห้งแล้งที่แตกต่างกันไป ในที่นี้อาศัยข้อมูล land surface ที่อยู่ในชุดข้อมูลผลผลิตจาก VIIRS level 2 (EDR) เนื่องจากเป็นแบนด์ข้อมูลที่อยู่ในชุดข้อมูลผลิตภัณฑ์จากดาวเทียม Suomi-NPP ที่ สทอภ. รับสัญญาณเรียบร้อยแล้ว จึงถือได้ว่าเป็นข้อมูลที่ทันสมัยและอยู่ในระบบอัตโนมัติได้ดี อย่างไรก็ตามประเภทการใช้ที่ดินตามที่ปรากฏในชุดข้อมูลดังกล่าวยึดตาม IGBP ซึ่งไม่สอดคล้องกับระบบการจำแนกประเภทของประเทศไทยนัก ดังนั้นการสะท้อนความเปราะบางอาจให้ผลไม่ดีเท่าที่ควร ซึ่งในที่นี้จึงได้กำหนดน้ำหนักของปัจจัยตัวนี้ไว้ไม่สูง สำหรับในอนาคตหากเราสามารถจัดทำข้อมูลการใช้ที่ดินในระดับประเทศแบบที่ทันสมัยอยู่เสมอได้ ก็สามารถใช้ชุดข้อมูลที่จัดทำขึ้นนี้แทนชุดข้อมูล VIIRS level 2 ดังกล่าวได้ (nimda, 2560)

2.3 การแทรกค่า (Interpolation) ด้วยวิธี IDW

การประมาณค่าช่วง(Interpolation) คือ การวิเคราะห์พื้นผิว (Surface analysis) เป็นการวิเคราะห์การกระจาย ของค่าตัวแปรหนึ่งซึ่งเปรียบเสมือนเป็นมิติที่ 3 ของข้อมูลเชิงพื้นที่ โดยข้อมูลเชิงพื้นที่ที่มีค่าพิกัดตามแนวแกน X และ Y ส่วนตัวแปรที่นำมา วิเคราะห์เป็นค่า Z ที่มีการกระจายตัวครอบคลุมทั้งพื้นที่ ตัวอย่างของค่า Z ได้แก่ ข้อมูลความสูงของพื้นที่ ความเข้มข้นของ สารเคมี ปริมาณน้ำฝน และอุณหภูมิ เป็นต้น

หลักการของ IDW (Inverse Distance Weight) เป็นการประมาณค่าโดยทำการสุ่มจุดตัวอย่างแต่ละจุดจากตำแหน่งที่ สามารถส่งผลกระทบต่อไปยังเซลล์ที่ต้องประมาณค่าได้ ซึ่งจะมีผลกระทบต่อ น้อยลงเรื่อย ๆ ตามระยะทางที่ไกลออกไป เหมาะกับตัวแปรที่อ้างอิงกับระยะทางในการคำนวณ ยิ่งใกล้ยิ่งมีอิทธิพล มาก เช่น ความดังของเสียง ความเข้มข้นของสารเคมี



ภาพที่ 2.2 ระยะทางระหว่างจุดที่ไม่ทราบค่ากับจุดที่ทราบค่าในบริเวณใกล้เคียงกัน

ที่มา: rafatieppo (2561)

2.4 Feature Selection ด้วยวิธี Information Gain

Feature Select คือ การคัดเลือกแอตทริบิวต์ที่มีความสำคัญ จากแอตทริบิวต์ที่มีอยู่เป็นจำนวนมาก โดยสามารถแบ่งได้ 2 กลุ่มใหญ่ ได้แก่

2.4.1 Filter approach เป็นการคัดเลือกแอตทริบิวต์โดยการคำนวณหาค่าน้ำหนัก เช่น Information Gain, Chi Square

Information gain คือผลต่างระหว่าง entropy ในสถานะปัจจุบันกับ entropy ของสถานะก่อนหน้าหาได้จากสมการ

$$\text{Information Gain} = \text{Entropy}(\text{initial}) - [P(c_1) \times \text{Entropy}(c_1) + P(c_2) \times \text{Entropy}(c_2) + \dots]$$

โดยที่ $\text{Entropy}(c_i) = -P(c_i) \log_2 P(c_i)$


$P(c_i)$ คือ ค่าความน่าจะเป็น (probability) ของ c_i

ยิ่ง Information Gain สูงยิ่งดี

2.4.2 Wrapper approach เป็นการคัดเลือกแอตทริบิวต์ด้วยการสร้างแบบจำลองจากเซตของแอตทริบิวต์ และวัดประสิทธิภาพ โดยเลือกแบบจำลองที่มีประสิทธิภาพมากที่สุด

2.5 โครงข่ายประสาทเทียม

โครงข่ายประสาทเทียม(Neural Network) ที่เป็นการจำลองการทำงานมาจาก สมองมนุษย์ โดยตรง โดยสมองมนุษย์นั้นก็จะมีส่วนที่เป็นหน่วยประมวลผลมากมาย และเชื่อมโยงกันด้วยระบบประมาทมากมาย ช่วยให้เราสามารถวิเคราะห์หรือตัดสินใจได้อย่างรวดเร็วและทันที โดยในโปรแกรม RapidMiner Studio จะใช้กระบวนการ back propagation (multi-layer perceptron)



ภาพที่ 2.3 โครงสร้างของโครงข่ายประสาทเทียม

ที่มา: databricks

2.5.1 ส่วนประกอบของ Neural Network

2.5.1.1 Input Layer มีหน้าที่ในการรับข้อมูลเข้ามาในโครงข่ายประสาท โดย Input Layer จะเพียงชั้นเดียวเท่านั้นและมีหน้าส่งข้อมูลไปยังชั้นถัดไป (Hidden Layer)

2.5.1.2 Hidden Layer มีหน้าที่รับข้อมูลจาก Layer ก่อนหน้า ซึ่ง Hidden Layer สามารถมีจำนวนมากกว่า 1 ได้

2.5.1.3 Output Layer เป็น output layer ที่อยู่ท้ายสุดรองรับค่าจาก hidden layer อันสุดท้าย โดยในชั้น output นั้นแต่ละ neurons จะมีค่าน้ำหนักของคลาอยู่

2.5.2 พารามิเตอร์ที่ใช้ใน โปรแกรม RapidMiner Studio

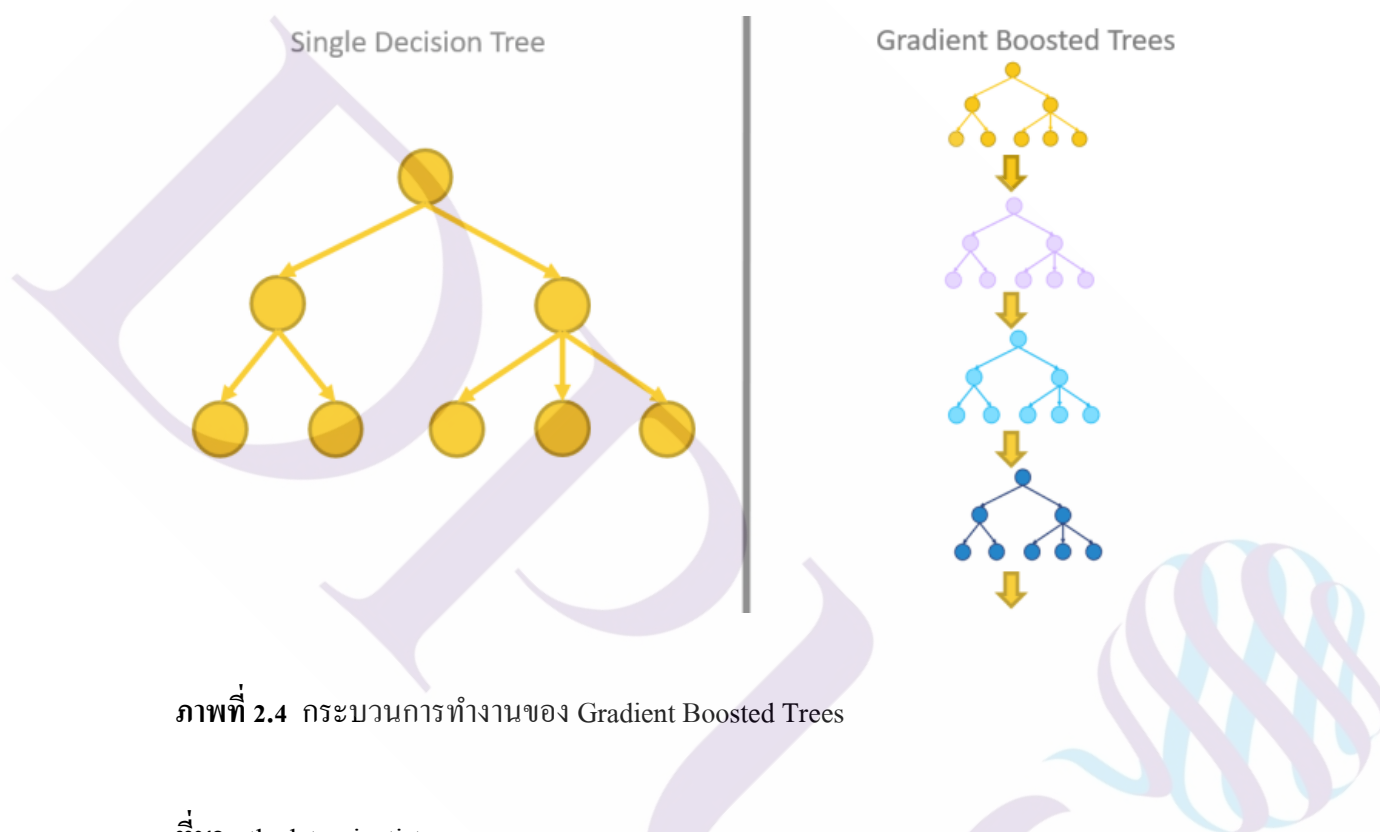
2.5.2.1 training cycles เป็นพารามิเตอร์ที่กำหนดจำนวนรอบที่ใช้ในการฝึกแบบจำลอง

2.5.2.2 learning rate เป็นพารามิเตอร์กำหนดว่าจะเปลี่ยนน้ำหนักในแต่ละขั้นตอนมากน้อยเท่าไร โดยที่ไม่ควรเป็น 0

2.5.2.3 momentum เพิ่ม fraction สำหรับการอัปเดตน้ำหนักก่อนหน้าเป็นค่าปัจจุบัน

2.6 Gradient Boosted Trees

Gradient Boosted Trees (GBT) คือแบบจำลองที่มีพื้นฐานมาจาก Decision tree ซึ่งเป็นการปรับปรุงประสิทธิภาพของแบบจำลองให้มีความสูงขึ้น โดยการสุ่มสร้าง Decision tree หลายร้อยแบบจำลอง ทำซ้ำและประเมินผลแต่ละแบบจำลองจนกว่าจะได้ Decision tree ที่สมบูรณ์



ภาพที่ 2.4 กระบวนการทำงานของ Gradient Boosted Trees

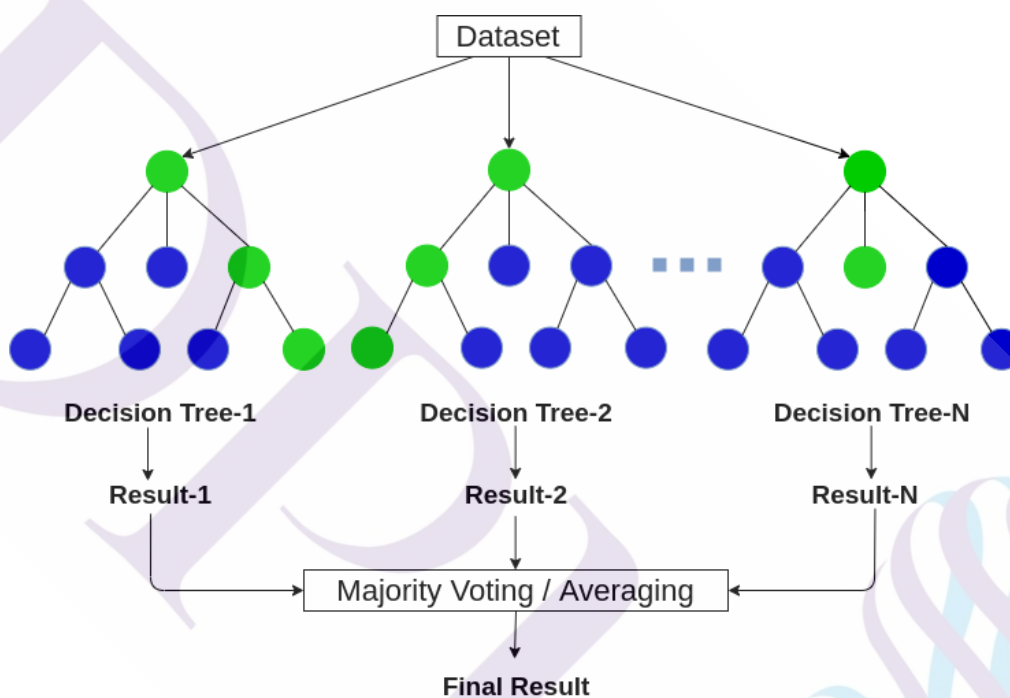
ที่มา: thedatascientist

2.6.1 พารามิเตอร์ที่ใช้ในโปรแกรม RapidMiner Studio

- 2.6.1.1 number of trees เป็นพารามิเตอร์ที่กำหนดจำนวนต้นไม้ที่ในแบบจำลอง
- 2.6.1.2 learning rate เป็นพารามิเตอร์กำหนดอัตราการเรียนรู้
- 2.6.1.3 maximal depth เป็นพารามิเตอร์ที่กำหนดความลึกของต้นไม้

2.7 Random Forest

Random forest (RF) คือการสร้างแบบจำลองจาก Decision Tree หลายแบบจำลองย่อย โดยให้แต่ละแบบจำลองได้รับชุดข้อมูลย่อยที่ไม่เหมือนกัน ซึ่งข้อมูลนี้เป็นส่วนหนึ่งของชุดข้อมูลทั้งหมด แล้วทำการพยากรณ์ข้อมูลในแต่ละ Decision Tree และคำนวณผลด้วยการ vote ที่ถูกเลือกโดย Decision Tree มากที่สุด



ภาพที่ 2.5 กระบวนการทำงานของ Random forest

ที่มา: analyticsvidhya (2563)

2.7.1 พารามิเตอร์ที่ใช้ในโปรแกรม RapidMiner Studio

2.7.1.1 number of trees เป็นพารามิเตอร์ที่กำหนดจำนวนต้นไม้ที่ในแบบจำลอง

2.7.1.2 voting Strategy ระบุวิธีการทำนายในกรณีที่ไม่เห็นด้วยกับการทำนายแบบจำลอง

ประกอบด้วย

2.7.1.2.1 confidence vote เลือกที่มีค่า confidence สะสมสูงสุด

- 2.7.1.2.2 majority vote เลือกที่ทำนายโดยแบบจำลองต้นไม้ส่วนใหญ่
- 2.7.1.3 criterion เลือกเกณฑ์ที่เลือกแอตทริบิวต์สำหรับการแยก ประกอบด้วย
 - 2.7.1.3.1 information gain คำนวนจากเอนโทรปีของแอตทริบิวต์
 - 2.7.1.3.2 gain ratio ตัวแปรของ information_gain ที่ปรับ information_gain สำหรับแต่ละ Attribute เพื่อให้ค่า Attribute มีความกว้างและความสม่ำเสมอ
 - 2.7.1.3.3 gini index การวัดความไม่เท่าเทียมกันระหว่างการกระจายของ label
 - 2.7.1.3.4 accuracy ค่ามากที่สุดของ accuracy จากต้นไม้ทั้งหมด
 - 2.7.1.3.5 least square ค่าน้อยที่สุดของระยะห่างกำลังสองระหว่างค่าเฉลี่ยของค่าในโหนดโดยคำนึงถึงค่าจริง
- 2.7.1.4 maximal depth เป็นพารามิเตอร์ที่กำหนดความลึกของต้นไม้

2.8 Automated machine learning (AutoML)

Automated machine learning (AutoML) คือ เครื่องมือที่ช่วยการพัฒนาแบบจำลองเกี่ยวข้องกับงานที่ซ้ำซากและน่าเบื่อมากมายภายในวงจรการพัฒนาแบบจำลอง (MDLC) เช่น การปรับพารามิเตอร์ ไฮเปอร์พารามิเตอร์การสร้างและการเลือกคุณสมบัติ เป็นไปโดยอัตโนมัติและได้รับแบบจำลองที่มีประสิทธิภาพที่ดี

2.8.1 พารามิเตอร์ที่ใช้ในโปรแกรม Jupyter Notebook

- 2.8.1.1 max model จำนวนแบบจำลองที่ใช้
- 2.8.1.2 balance classes ระบุว่าข้อมูลที่นำมาใช้มีความสมดุลหรือไม่
- 2.8.1.3 sort metric ค่าที่ใช้ในการเรียงลำดับในการแสดงผลของแบบจำลองทั้งหมด

บทที่ 3

ระเบียบวิธีวิจัย

การศึกษาวิจัยครั้งนี้ เป็นการนำเสนอการพยากรณ์พื้นที่ในประเทศไทยที่จะเกิดภัยแล้งใน
ระดับตำบล

3.1 ประชากร และตัวอย่าง

3.1.1 ข้อมูลประวัติการเกิดภัยแล้งจากกรมป้องกันและบรรเทาสาธารณภัยในปี 2561 จนถึงปี 2563

event_date	event_type	event_detail	tambon_na...	province_n...	ampur_name	event_status	no_mooban
Oct 30, 2019	ฝนแล้ง(สภาว...	การเกษตร	นาเชือก	กาฬสินธุ์	ยางตลาด	ยุติเหตุการณ์...	6
Oct 30, 2019	ฝนแล้ง(สภาว...	การเกษตร	เขาพระนอน	กาฬสินธุ์	ยางตลาด	ยุติเหตุการณ์...	9
Jul 27, 2019	ฝนทิ้งช่วง(...	การอุปโภค-...	ดอนแดง	กำแพงเพชร	ชาณุวรลักษ...	ยุติเหตุการณ์...	9
Jul 27, 2019	ฝนทิ้งช่วง(...	การอุปโภค-...	วังชะพลู	กำแพงเพชร	ชาณุวรลักษ...	ยุติเหตุการณ์...	9


ภาพที่ 3.1 ภาพข้อมูลประวัติการเกิดภัยแล้งจากกรมป้องกันและบรรเทาสาธารณภัยบางส่วน

3.1.2 ข้อมูลปริมาณน้ำในจากสถานบันสารสนเทศทรัพยากรน้ำรายวันในปี 2561 จนถึงปี 2563 จากทั้งหมด 35 สถานี

station_id	wd_date	current_val	current_per	max_val
4	Oct 18, 2018 7:00:00 AM ICT	89	84	106
4	Oct 19, 2018 7:00:00 AM ICT	89	84	106
4	Oct 20, 2018 7:00:00 AM ICT	89	84	106

ภาพที่ 3.2 ภาพข้อมูลปริมาณน้ำในจากสถานบันสารสนเทศทรัพยากรน้ำรายวันบางส่วน

3.1.3 ข้อมูลดัชนีเสี่ยงภัยแล้ง(DRI) จากสำนักงานพัฒนาเทคโนโลยีอวกาศและภูมิสารสนเทศรายสัปดาห์ในปี 2561 จนถึงปี 2563



ภาพที่ 3.3 ภาพข้อมูลดัชนีเสี่ยงภัยแล้ง (DRI) รายสัปดาห์

3.2 การเตรียมข้อมูล

3.2.1 การใช้โปรแกรม RapidMiner

3.2.1.1 แปลงข้อมูลปริมาณน้ำฝนเป็นข้อมูลรายวัน โดยเอาค่าน้ำฝนที่สูงสุดในแต่ละวันและเชื่อมกับข้อมูลของแต่ละสถานี แล้วทำการการแทรกค่าด้วยวิธี IDW เพื่อให้มีค่าครบ

3.2.1.2 นำข้อมูลน้ำฝนที่ได้มาทำข้อมูลย้อนหลัง 3, 5, 7, 9, 11, 13 และ 15 วันโดยใช้ค่าสูงสุด ค่าน้อยสุด ค่าเฉลี่ยและผลรวม นำข้อมูลน้ำฝนที่ได้มาเชื่อมกับข้อมูลการเกิดภัยแล้ง

3.2.1.3 แปลงข้อมูลดัชนีเสี่ยงภัยแล้ง (DRI) จากไฟล์ประเภท Geo Raster ที่มีโครงสร้างเป็น 4 band ให้เป็นข้อมูลรายตำบล โดยการเชื่อมโยงกับข้อมูลตำบลในรูปแบบของ shape file เพื่อคำนวณหาค่าน้อยที่สุด ค่าเฉลี่ย และค่ามากที่สุด สำหรับค่าความชื้นสีในแต่ละ band ของแต่ละตำบล สร้างเป็นตารางดังตัวอย่างในภาพ แล้วจึงนำไปเชื่อมโยงกับข้อมูลน้ำฝน

week	year	Tambon_ID	dri_band_1_min	dri_band_1_max	dri_band_1_mean	dri_band_2_min	dri_band_2_max	dri_band_2_mean
1	2021	100112	252	252	252	249	249	249
1	2021	100202	252	252	252	249	249	249
1	2021	100206	0	254	166.889	0	250	166.222
1	2021	100301	0	255	146.431	0	254	151.861
1	2021	100305	0	255	144.812	0	253	151.208
1	2021	100308	0	255	101.500	0	254	104.278
1	2021	100508	0	255	137.062	0	250	126.104

ภาพที่ 3.4 ผลตัวอย่างจากการแปลงข้อมูลดัชนีเสี่ยงภัยแล้ง

3.2.1.4 แบ่งข้อมูลออกเป็น 2 ชุด โดย ชุดสอนเป็นข้อมูลที่เกิดภัยแล้งในปี 2561 และ 2562 ชุดทดสอบเป็นข้อมูลที่เกิดภัยแล้งในปี 2563

3.2.1.5 Under Sampling เพื่อลดปัญหาความ imbalance class โดยลดจำนวนการไม่เกิดภัยแล้ง เท่ากับการเกิดภัยแล้ง

3.2.2 การใช้โปรแกรม Jupyter Notebook

นำข้อมูลที่ได้จากการแบ่งข้อมูลเป็น 2 ชุดจากใน RapidMiner มาใช้

3.3 วิธีการวิเคราะห์ข้อมูล

3.3.1 การใช้โปรแกรม RapidMiner

3.3.1.1 ทำ loop operation การเปลี่ยนแปลงค่าตัวแปรต่างๆที่ใช้ใน การคัดเลือกแอตทริบิวต์ และ ค่าของแบบจำลองซึ่งมีทั้งหมด 3 แบบจำลองคือ โครงข่ายประสาทเทียม, Gradient Boosted Trees และ Random Forest โดยเป็นดังรูปด้านล่าง

3.3.1.1.1 Gradient Boosted Trees เลือกแอตทริบิวต์ในช่วง 21 – 30 แอตทริบิวต์, Number of trees ที่สุ่มค่าในช่วง 50 - 2000 จำนวน 30 ค่า, Maximal depth สุ่มค่าในช่วง 5 – 100 จำนวน 11 ค่า และ Learning rate สุ่มค่าในช่วง 0.1 – 0.99 ทั้งหมด 11 ค่า

ตารางที่ 3.1 ผลตัวอย่างจากการใช้แบบจำลอง Gradient Boosted Trees

Attribute	Number of trees	Maximal depth	Learning rate	Weight mean recall
28	250	5	0.456	0.5403
28	300	5	0.456	0.5403
28	350	5	0.456	0.5403

3.3.1.1.2 Random Forest เลือกแอตทริบิวต์ในช่วง 21 – 30 แอตทริบิวต์, Number of trees ที่สุ่มค่าในช่วง 50 - 2000 จำนวน 21 ค่า, Maximal depth สุ่มค่าในช่วง 5 – 100 จำนวน 11 ค่า และ voting strategy มีทั้งหมด 2 ค่าคือ confidence vote, majority vote และ criterion มีทั้งหมด 4 ค่า ได้แก่ gain ratio, accuracy, gini index และ information gain

ตารางที่ 3.2 ผลตัวอย่างจากการใช้แบบจำลอง Random Forest

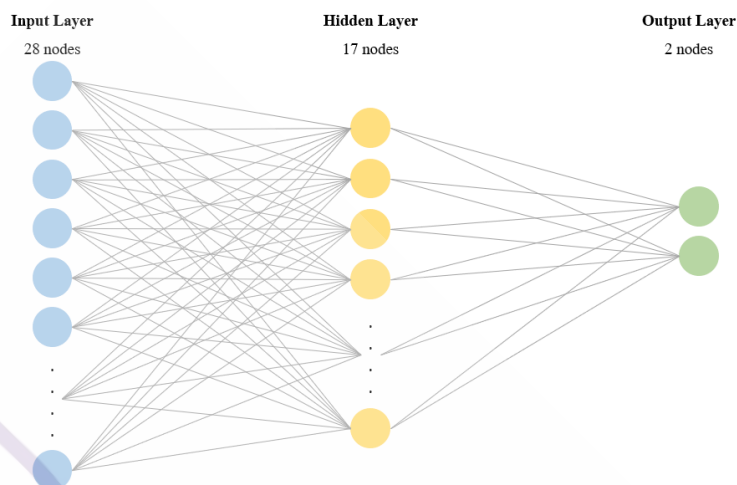
Attribute	number of tree	Maximal depth	voting Strategy	criterion	Weight mean recall
21	343	100	confidence vote	gain ratio	0.6405
21	343	91	confidence vote	gain ratio	0.6402
21	440	81	confidence vote	gain ratio	0.6405

3.3.1.1.3 โครงข่ายประสาทเทียม เลือกแอตทริบิวต์ในช่วง 21 – 30 แอตทริบิวต์, Learning Rate ที่สุ่มค่าในช่วง 0.01 – 0.9 จำนวน 100 ค่า, Training cycle ใช้ 3 ค่า [50,100,200] และ momentum ใช้ 10 ค่า [0,0.1,0.2,0.3,0.4,0.5,0.6,0.7,0.8,0.9,1]

ตารางที่ 3.3 ผลตัวอย่างจากการใช้แบบจำลองโครงข่ายประสาทเทียม

Attribute	learning rate	training cycle	momentum	Weight mean recall
21	0.01	50	0	0.6799
21	0.01	50	0.1	0.6779
21	0.01	50	0.2	0.6750

3.3.1.2 รันแบบจำลองที่ละแบบจำลองโดยพิจารณาจากแบบจำลองที่มี weight mean recall สูงก่อน เพื่อหาว่าแบบจำลองใดให้ค่าของ recall ที่ดีและใกล้เคียงกันที่สุด



ภาพที่ 3.5 โครงสร้างของแบบจำลองโครงข่ายประสาทเทียมที่ดีที่สุด

3.3.2 การใช้โปรแกรม Jupyter Notebook

3.3.2.1 ตั้งค่าแอตทริบิวต์และ label ของข้อมูล

3.3.2.2 ใช้ Automated machine learning (AutoML) ของ H₂O เพื่อช่วยหาแบบจำลองที่ดีที่สุด โดยที่ต้องตั้งเพิ่มว่าข้อมูลเป็น imbalance data ซึ่งได้ผลลัพธ์ดังรูป

model_id	mean per class error	auc	logloss	aucpr	rmse	mse	training time ms	predict time per row ms	algo
GEM_grid_1_AutoML_20210509_122220_model_1	0.4893	0.5628	0.5160	0.9080	0.3442	0.1185	1779	0.0121	GEM
GEM_grid_1_AutoML_20210509_122220_model_30	0.4896	0.5773	0.4597	0.9116	0.3391	0.1150	985	0.0098	GEM
GEM_grid_1_AutoML_20210509_122220_model_5	0.4911	0.5551	0.5418	0.8972	0.3457	0.1195	1676	0.0086	GEM
GEM_grid_1_AutoML_20210509_122220_model_22	0.4917	0.5663	0.5761	0.8981	0.3456	0.1194	1853	0.0095	GEM

ภาพที่ 3.6 ผลตัวอย่างจาก Automated machine learning (AutoML) ของ H₂O

3.3.2.3 พิจารณาค่า recall ของแต่ละแบบจำลอง โดยเริ่มจากที่ mean per class error น้อยก่อน เพื่อหาว่าแบบจำลองไหนให้ค่าของ recall ที่ดีและใกล้เคียงกันที่สุด

บทที่ 4 ผลการศึกษา

4.1 ผลของการหาค่าถ่วงน้ำหนักด้วย information gain

การศึกษาพบว่าข้อมูลมีแอตทริบิวต์ทั้งหมด 34 ตัว ดังนั้นเลือกใช้แอตทริบิวต์ด้วยวิธีการหาค่าถ่วงน้ำหนักด้วยวิธีการ information gain แล้วเลือกใช้ตัวที่มีค่าถ่วงน้ำหนักมากก่อน

ตารางที่ 4.1 ค่าถ่วงน้ำหนักด้วยวิธีการ information gain ของ แต่ละแอตทริบิวต์เรียงจากมากไปน้อย

order	Attribute	Weight by Information Gain
1	avg_rain_15day	0.0310
2	sum_rain_15day	0.0310
3	avg_rain_13day	0.0251
4	sum_rain_13day	0.0251
5	avg_rain_11day	0.0197
6	sum_rain_11day	0.0197
7	sum_rain_9day	0.0188
8	avg_rain_9day	0.0187
9	avg_rain_7day	0.0186
10	sum_rain_7day	0.0186
11	max_rain_15day	0.0171

ตารางที่ 4.1 (ต่อ)

order	Attribute	Weight by Information Gain
12	max_rain_13day	0.0164
13	max_rain_11day	0.0139
14	avg_rain_5day	0.0122
15	sum_rain_5day	0.0122
16	max_rain_9day	0.0112
17	max_rain_7day	0.0100
18	avg_rain_3day	0.0080
19	sum_rain_3day	0.0080
20	max_rain_5day	0.0072
21	median(dri_band_3_mean)	0.0072
22	maximum(dri_band_2_max)	0.0072
23	median(dri_band_2_mean)	0.0070
24	rain - 0	0.0062
25	max_rain_3day	0.0058
26	maximum(dri_band_1_max)	0.0056
27	median(dri_band_4_mean)	0.0039
28	median(dri_band_1_mean)	0.0032
29	maximum(dri_band_3_max)	0.0023
30	maximum(dri_band_4_max)	0.0000
31	minimum(dri_band_1_min)	0
32	minimum(dri_band_2_min)	0
33	minimum(dri_band_3_min)	0
34	minimum(dri_band_4_min)	0

จากตาราง พบว่าในลำดับที่ 31 – 34 ค่า weight by information gain ของแอดทริบิวต์มีค่า 0 ดังนั้นจึงไม่ใช่แอดทริบิวต์เหล่านี้ และค่าดัชนีเสี่ยงเลี้ยงเริ่มต้นที่ลำดับที่ 21 ดังนั้นช่วงของแอดทริบิวต์ที่ใช้ในการรวมคือ 21 – 30 แอดทริบิวต์

4.2 ผลจากการทดสอบด้วยแบบจำลองต่างๆ

จากการทดสอบด้วย RapidMiner ได้แก่ แบบจำลองโครงข่ายประสาทเทียมทั้งหมด 33,330 รอบ Gradient Boosted Trees ทั้งหมด 36,300 รอบ และ Random Forest ทั้งหมด 17,491 รอบ และรันด้วย Jupyter Notebook จาก Automated machine learning (AutoML) ของ H₂O.ai 1 ครั้ง

ตารางที่ 4.2 ผลที่มีค่าเฉลี่ยของค่าความถูกต้องที่ดีที่สุดของแต่ละแบบจำลอง

Model	Max Weight mean recall
โครงข่ายประสาทเทียม	69.20%
Random Forest	64.80%
Gradient Boosting Tree	54.03%
AutoML	51.07%

จากผลการทดลองข้างต้น พบว่าค่าความถูกต้องที่มีประสิทธิภาพมากที่สุดคือจากแบบจำลองโครงข่ายประสาทเทียมดังนั้น เริ่มหา Confusion Matrix จากค่าต่างของแบบจำลองโครงข่ายประสาทเทียมก่อน

ตารางที่ 4.3 ตาราง Confusion Matrix ของแบบจำลองมีประสิทธิภาพดีที่สุด

	True Drought	True No Drought	Class Precision
Pred. Drought	346	1,329	20.66%
Pred. No Drought	191	2,500	92.90%
Class Recall	64.43%	65.29%	

จากตาราง พบว่าค่าเฉลี่ยของค่าความถูกต้องของ Confusion Matrix ที่ได้มาจากแบบจำลองโครงข่ายประสาทเทียม ที่ Learning Rate ที่ 0.01 Training cycle 50 รอบ momentum ที่ 0.1 และใช้แอตทริบิวต์ 28 อันดับแรก มีค่า 64.86% และมีค่า accuracy 65.19% ซึ่งมากกว่า ค่าเฉลี่ยของค่าความถูกต้องของแบบจำลองอื่น

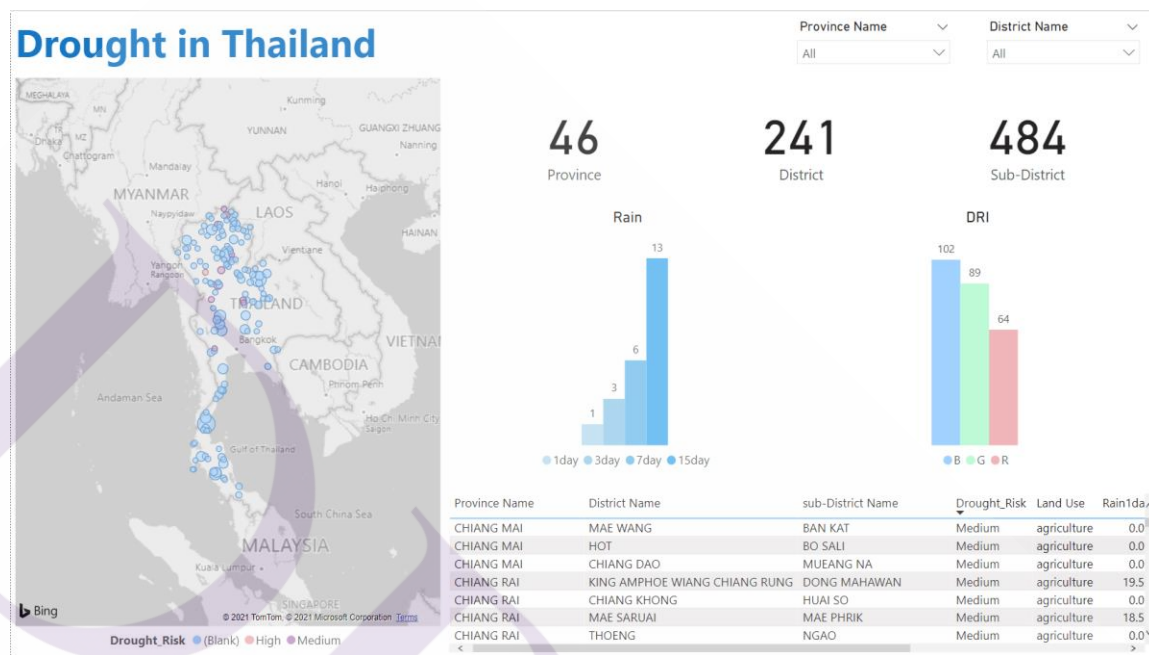
ตารางที่ 4.4 ตารางแสดง layer ของแบบจำลองโครงข่ายประสาทเทียมที่ดีที่สุด

Input Layer	Output Layer
avg_rain_15day	Drought
sum_rain_15day	No Drought
avg_rain_13day	
sum_rain_13day	
avg_rain_11day	
sum_rain_11day	
sum_rain_9day	
avg_rain_9day	
avg_rain_7day	
sum_rain_7day	

ตารางที่ 4.4 (ต่อ)

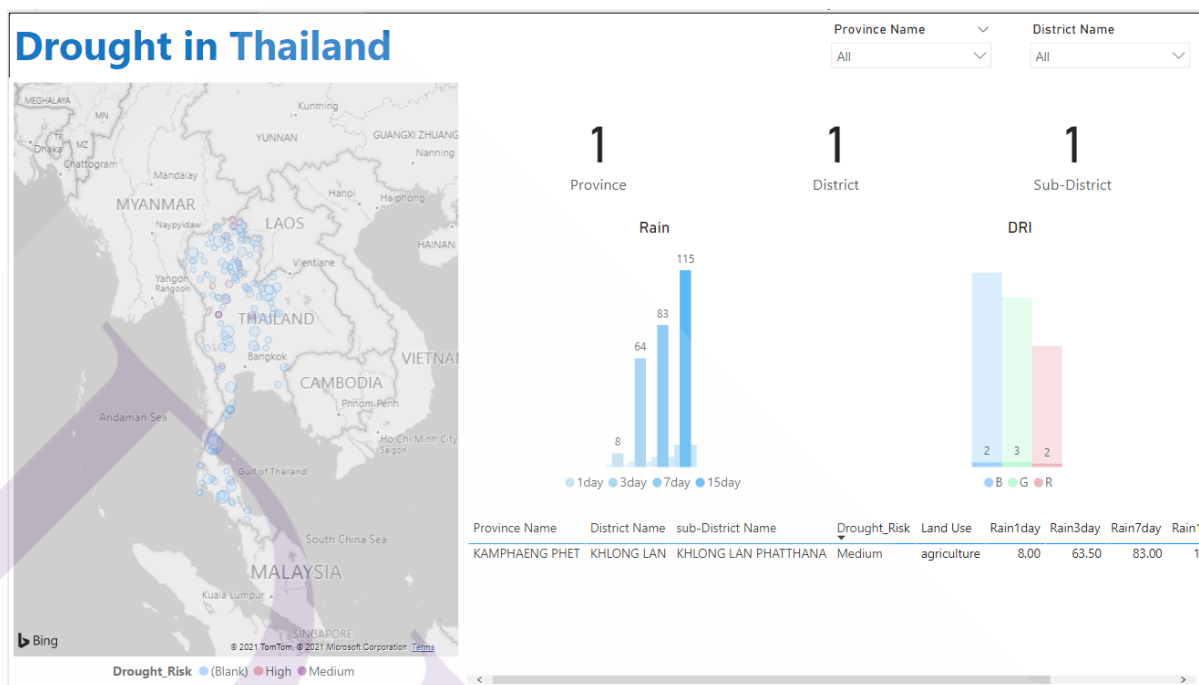
Input Layer
max_rain_15day
max_rain_13day
max_rain_11day
avg_rain_5day
sum_rain_5day
max_rain_9day
max_rain_7day
avg_rain_3day
sum_rain_3day
max_rain_5day
median(dri_band_3_mean)
maximum(dri_band_2_max)
median(dri_band_2_mean)
rain - 0
max_rain_3day
maximum(dri_band_1_max)
median(dri_band_4_mean)
median(dri_band_1_mean)

4.3 การแสดงผล



ภาพที่ 4.1 การแสดงผลของแบบจำลองแบบไม่ได้เลือกพื้นที่

จากผลของแบบจำลองที่มีประสิทธิภาพที่ดีที่สุด นำมาแสดงผลด้วยโปรแกรม Power BI โดยสีในแผนที่แสดงถึงระดับความเสี่ยงแล้งซ้ำซาก สามารถเลือกจังหวัดและอำเภอด้วยตัวเลือกหมุนบนขวามือ กราฟ Rain แสดงข้อมูลปริมาณน้ำฝน ณ วันนั้น ย้อนหลัง 3 วัน 7 วันและ 15 วัน กราฟ DRI แสดงข้อมูลดัชนีความเสี่ยงแล้ง(DRI) ซึ่งสามารถเอาตัวเลขที่ได้ไปเปรียบเทียบกับค่าสี RGB เพื่อหาช่วงค่า DRI ได้ และตารางด้านล่างแสดงข้อมูลทั้งหมดที่สามารถนำไปประกอบการตัดสินใจเพิ่มเติมว่าพื้นที่นั้นจะเกิดภัยแล้ง สามารถบันทึกข้อมูลออกมาในรูปแบบ excel file ได้



ภาพที่ 4.2 การแสดงผลแบบเลือกพื้นที่จากแผนที่

จากภาพพบว่า สามารถดูข้อมูลของแต่ละพื้นที่จากการเลือกในแผนที่ได้

บทที่ 5

บทสรุป และข้อเสนอแนะ

5.1 สรุปผลการศึกษา

แบบจำลองที่มีประสิทธิภาพดีที่สุดในการพยากรณ์ภัยแล้งคือแบบจำลองโครงข่ายประสาทเทียม ด้วย แอตทริบิวต์ 28 ตัว Learning Rate ที่ 0.01 Training cycle 50 รอบ และ momentum ที่ 0.1

ผลการทดลองให้ความแม่นยำในการพยากรณ์ที่ Accuracy 65.19% และมีค่าเฉลี่ยของค่าความถูกต้อง 64.86% โดยค่าความถูกต้องของการเกิดภัยแล้ง 64.43% และค่าความถูกต้องของการไม่เกิดภัยแล้ง 65.19%

5.2 ข้อเสนอแนะ

5.2.1 การเลือกแอตทริบิวต์เข้าแบบจำลองอาจเปลี่ยนตัวที่ใช้ในการหาค่าถ่วงน้ำหนัก

5.2.2 ควรเพิ่มแอตทริบิวต์อื่นที่มีผลกับการเกิดภัยแล้ง

5.2.3 ค่า Precision ของแบบจำลองมีความแตกต่างกันมากเกินไป ควรต้องพัฒนาในส่วนนี้



บรรณานุกรม

บรรณานุกรม

กิตติพงษ์ เนียเจริญ (2564), **Practical Data Visualization with Power BI**. นนทบุรี: ไอดีซีฯ

ชิตพงษ์ กิตตินราคร(2563), **Random Forest**.

<https://guopai.github.io/ml-blog10.html>

ชรัตน์ มงคลสวัสดิ์ , ระบบสารสนเทศพื้นที่เสี่ยงภัยแล้ง.

https://negistda.kku.ac.th/drought/ed_method.htm

วสันต์ อินผิว (2562),เรียนรู้และทำความเข้าใจ **Neural Network Forward Propagation** คืออะไร.

<https://www.glurgeek.com/education/neuralnfp/>

เอกสิทธิ์ พัทธวงศ์ศักดิ์ (2558), **การคัดเลือก feature (feature selection) ด้วยวิธี Information**

Gain. <https://th.linkedin.com/pulse/การคัดเลือก-feature-selection-ด้วยวิธี-information-gain-pacharawongsakda>

เอกสิทธิ์ พัทธวงศ์ศักดิ์ (2563), **Practical Data Mining with RapidMiner Studio 9 @CMU**

(เอกสารประกอบการอบรม). กรุงเทพฯ: เอเชีย ดิจิตอลการพิมพ์

Arnon Puitrakul (2562), **Feature Selection ใน Machine Learning จะเอาอะไรมาใส่ดีนะ**

<https://arnondora.in.th/feature-selection-machine-learning/>

Chengz (2562), **วัดประสิทธิภาพ Model จาก Confusion Matrix**

<https://medium.com/@cheng3374/ประสิทธิภาพ-model-จาก-confusion-matrix-69d391bcd48>

KOR'S BLOG (2559),**Machine Learning #6 | การคำนวณ Entropy และ Information gain**.

<https://khasathan.in.th/archives/1315/machine-learning-6-การคำนวณ-entropy-และ-information-gain/>

Mr.P L(2562), **Deep Learning แบบฉบับคนสามัญชน EP 1 : Neural Network History**

<https://medium.com/mmp-li/deep-learning-แบบฉบับคนสามัญชน-ep-1-neural-network-history-f7789236a9a3>

nimda (2560),**สรุปนิยาม**

<http://droughtv2.gistda.or.th/?q=content/สรุปนิยาม>

nimda (2560), **หลักการวิเคราะห์พื้นที่เสี่ยง**

<http://droughtv2.gistda.or.th/?q=content/หลักการวิเคราะห์พื้นที่เสี่ยง>

unknown (2556), **การประมาณค่าช่วง (Interpolation)**

<http://databasegis.blogspot.com/2014/02/interpolation.html>

Witchapong Daroontham (2561), **เจาะลึก Random Forest !!!— Part 2 of “รู้จัก Decision Tree,**

Random Forest, และ XGBoost!!!”. <https://medium.com/@witchapongdaroontham/เจาะลึก-random-forest-part-2-of-รู้จัก-decision-tree-random-forest-และ-xgboost-79b9f41a1c1c>

ABHISHEK SHARMA(2563), **Decision Tree vs. Random Forest – Which Algorithm Should you**

Use?. <https://www.analyticsvidhya.com/blog/2020/05/decision-tree-vs-random-forest-algorithm/>

Databricks, **Neural Network.**

<https://databricks.com/glossary/neural-network>

Michal Kurka (2564), **AutoML: Automatic Machine Learning**

<https://docs.h2o.ai/h2o/latest-stable/h2o-docs/automl.html>

Rafael Tieppo (2561), **Inverse Distance Weighting (IDW) Interpolation**

https://rafatieppo.github.io/post/2018_07_27_idw2pyr/

RapidMiner (2564), **Gradient Boosted Trees**

https://docs.rapidminer.com/latest/studio/operators/modeling/predictive/trees/gradient_boosted_trees.html

RapidMiner (2564), **Neural Net**

https://docs.rapidminer.com/latest/studio/operators/modeling/predictive/neural_nets/neural_net.html

RapidMiner (2564), **Random Forest**

https://docs.rapidminer.com/latest/studio/operators/modeling/predictive/trees/parallel_random_forest.html

Stylianos (Stelios) Kampakis, **Gradient boosted trees**

<https://thedata scientist.com/gradient-boosted-trees-python/>



ภาคผนวก

ภาคผนวก ก

ตารางผลของแบบจำลองโครงข่ายประสาทเทียมที่มีการทดสอบ

Confusion Matrix



Attribute	Learning Rate	Training Cycle	Momentum	Weight Mean Recall	True Drought Pred Drought	True Drought Pred no Drought	True no Drought Pred Drought	True no Drought Pred no Drought	Recall Drought	Recall no Drought	Precision Drought	Precision no Drought	Accuracy
22	0.01	50	0	69.20%	462	75	1,824	2,005	86.03%	52.36%	20.21%	96.39%	56.50%
22	0.01	50	0.1	68.74%	451	86	1,781	2,048	83.99%	53.49%	20.21%	95.97%	57.24%
21	0.01	50	0	67.99%	487	50	2,095	1,734	90.69%	45.29%	18.86%	97.20%	50.87%
30	0.8021	50	0.9	67.91%	472	65	1,994	1,835	87.90%	47.92%	19.14%	96.58%	52.84%
22	0.01	50	0.2	67.80%	429	108	1,696	2,133	79.89%	55.71%	20.19%	95.18%	58.68%
21	0.01	50	0.1	67.79%	486	51	2,103	1,726	90.50%	45.08%	18.77%	97.13%	50.66%
24	0.01	50	0	67.64%	475	62	2,036	1,793	88.45%	46.83%	18.92%	96.66%	51.95%
30	0.01	50	0	67.52%	472	65	2,024	1,805	87.90%	47.14%	18.91%	96.52%	52.15%
21	0.01	50	0.2	67.50%	487	50	2,132	1,697	90.69%	44.32%	18.59%	97.14%	50.02%
27	0.0723	200	0.4	67.44%	458	79	1,930	1,899	85.29%	49.60%	19.18%	96.01%	53.99%
23	0.01	50	0	67.42%	476	61	2,060	1,769	88.64%	46.20%	18.77%	96.67%	51.42%
27	0.0456	200	0.6	67.40%	436	101	1,776	2,053	81.19%	53.62%	19.71%	95.31%	57.01%
30	0.6152	50	0.7	67.27%	464	73	1,948	1,881	86.41%	49.13%	19.24%	96.26%	53.71%
27	0.01	50	0	67.12%	445	92	1,862	1,967	82.87%	51.37%	19.29%	95.53%	55.25%
24	0.01	50	0.1	67.10%	465	72	2,006	1,823	86.59%	47.61%	18.82%	96.20%	52.40%
27	0.1079	200	0.1	67.10%	471	66	2,049	1,780	87.71%	46.49%	18.69%	96.42%	51.56%
27	0.0545	200	0.5	67.05%	449	88	1,896	1,933	83.61%	50.48%	19.15%	95.65%	54.56%
27	0.099	200	0.2	67.05%	463	74	1,996	1,833	86.22%	47.87%	18.83%	96.12%	52.59%

Attribute	Learning Rate	Training Cycle	Momentum	Weight Mean Recall	True Drought Pred Drought	True Drought Pred no Drought	True no Drought Pred Drought	True no Drought Pred no Drought	Recall Drought	Recall no Drought	Precision Drought	Precision no Drought	Accuracy
27	0.0901	200	0.3	67.00%	461	76	1,985	1,844	85.85%	48.16%	18.85%	96.04%	52.79%
30	0.01	50	0.1	66.99%	455	82	1,943	1,886	84.73%	49.26%	18.97%	95.83%	53.62%
27	0.099	200	0	66.95%	450	87	1,911	1,918	83.80%	50.09%	19.06%	95.66%	54.24%
23	0.01	50	0.1	66.91%	467	70	2,035	1,794	86.96%	46.85%	18.67%	96.24%	51.79%
21	0.01	50	0.3	66.91%	490	47	2,199	1,630	91.25%	42.57%	18.22%	97.20%	48.56%
27	0.0634	200	0.5	66.90%	446	91	1,886	1,943	83.05%	50.74%	19.13%	95.53%	54.72%
27	0.0812	200	0.3	66.89%	462	75	2,001	1,828	86.03%	47.74%	18.76%	96.06%	52.45%
27	0.0634	200	0.4	66.83%	449	88	1,913	1,916	83.61%	50.04%	19.01%	95.61%	54.17%
30	0.7843	100	0.6	66.75%	468	69	2,054	1,775	87.15%	46.36%	18.56%	96.26%	51.37%
27	0.0723	200	0.3	66.71%	448	89	1,915	1,914	83.43%	49.99%	18.96%	95.56%	54.10%
27	0.0901	200	0.1	66.71%	448	89	1,915	1,914	83.43%	49.99%	18.96%	95.56%	54.10%
27	0.099	200	0.1	66.70%	462	75	2,015	1,814	86.03%	47.38%	18.65%	96.03%	52.13%
27	0.0901	200	0.2	66.69%	462	75	2,016	1,813	86.03%	47.35%	18.64%	96.03%	52.11%
27	0.1257	200	0	66.68%	464	73	2,031	1,798	86.41%	46.96%	18.60%	96.10%	51.81%
23	0.01	50	0.2	66.67%	458	79	1,989	1,840	85.29%	48.05%	18.72%	95.88%	52.63%
30	0.3215	100	0.9	66.65%	462	75	2,019	1,810	86.03%	47.27%	18.62%	96.02%	52.04%
27	0.1168	200	0.1	66.62%	464	73	2,036	1,793	86.41%	46.83%	18.56%	96.09%	51.69%
21	0.0189	50	0	66.62%	510	27	2,364	1,465	94.97%	38.26%	17.75%	98.19%	45.24%

Attribute	Learning Rate	Training Cycle	Momentum	Weight Mean Recall	True Drought Pred Drought	True Drought Pred no Drought	True no Drought Pred Drought	True no Drought Pred no Drought	Recall Drought	Recall no Drought	Precision Drought	Precision no Drought	Accuracy
27	0.0812	200	0.2	66.61%	447	90	1,915	1,914	83.24%	49.99%	18.92%	95.51%	54.08%
27	0.1079	200	0	66.60%	461	76	2,016	1,813	85.85%	47.35%	18.61%	95.98%	52.08%
30	0.7665	50	0.7	66.54%	487	50	2,206	1,623	90.69%	42.39%	18.08%	97.01%	48.33%
27	0.1168	200	0	66.53%	467	70	2,064	1,765	86.96%	46.10%	18.45%	96.19%	51.12%
21	0.01	50	0.4	66.49%	498	39	2,288	1,541	92.74%	40.25%	17.88%	97.53%	46.70%
27	0.1079	200	0.2	66.46%	443	94	1,898	1,931	82.50%	50.43%	18.92%	95.36%	54.37%
27	0.0901	200	0	66.42%	426	111	1,780	2,049	79.33%	53.51%	19.31%	94.86%	56.69%
21	0.01	50	0.5	66.39%	509	28	2,374	1,455	94.79%	38.00%	17.66%	98.11%	44.98%
27	0.0723	200	0.2	66.39%	422	115	1,754	2,075	78.58%	54.19%	19.39%	94.75%	57.19%
24	0.01	50	0.2	66.37%	452	85	1,969	1,860	84.17%	48.58%	18.67%	95.63%	52.95%
30	0.8288	100	0.5	66.36%	471	66	2,266	1,563	87.71%	40.82%	17.21%	95.95%	46.59%
30	0.4817	50	0.8	66.35%	498	39	2,299	1,530	92.74%	39.96%	17.80%	97.51%	46.45%
28	0.01	50	0	66.32%	404	133	1,631	2,198	75.23%	57.40%	19.85%	94.29%	59.60%
27	0.0812	200	0.1	66.29%	423	114	1,769	2,060	78.77%	53.80%	19.30%	94.76%	56.87%
27	0.1346	200	0	66.28%	458	79	2,019	1,810	85.29%	47.27%	18.49%	95.82%	51.95%
27	0.0367	200	0.7	66.24%	402	135	1,623	2,206	74.86%	57.61%	19.85%	94.23%	59.73%
27	0.0634	200	0.3	66.23%	419	118	1,745	2,084	78.03%	54.43%	19.36%	94.64%	57.33%
30	0.7576	50	0.7	66.21%	504	33	2,599	1,230	93.85%	32.12%	16.24%	97.39%	39.72%

Attribute	Learning Rate	Training Cycle	Momentum	Weight Mean Recall	True Drought Pred Drought	True Drought Pred no Drought	True no Drought Pred Drought	True no Drought Pred no Drought	Recall Drought	Recall no Drought	Precision Drought	Precision no Drought	Accuracy
21	0.01	100	0	66.12%	480	57	2,188	1,641	89.39%	42.86%	17.99%	96.64%	48.58%
21	0.0189	50	0.1	66.02%	511	26	2,417	1,412	95.16%	36.88%	17.45%	98.19%	44.04%
24	0.1524	50	0.9	66.01%	469	68	2,118	1,711	87.34%	44.69%	18.13%	96.18%	49.93%
21	0.01	50	0.6	65.98%	517	20	2,463	1,366	96.28%	35.68%	17.35%	98.56%	43.13%
27	0.1613	50	0	65.95%	392	145	1,574	2,255	73.00%	58.89%	19.94%	93.96%	60.63%
21	0.0189	50	0.2	65.92%	517	20	2,467	1,362	96.28%	35.57%	17.33%	98.55%	43.04%
27	0.0278	200	0.7	65.90%	395	142	1,599	2,230	73.56%	58.24%	19.81%	94.01%	60.12%
21	0.01	100	0.3	65.84%	506	31	2,395	1,434	94.23%	37.45%	17.44%	97.88%	44.43%
21	0.0189	50	0.3	65.81%	520	17	2,497	1,332	96.83%	34.79%	17.24%	98.74%	42.42%
29	0.0189	50	0.1	65.80%	515	22	2,462	1,367	95.90%	35.70%	17.30%	98.42%	43.11%
27	0.0545	200	0.4	65.80%	412	125	1,728	2,101	76.72%	54.87%	19.25%	94.38%	57.56%
21	0.0278	50	0	65.78%	523	14	2,521	1,308	97.39%	34.16%	17.18%	98.94%	41.94%
21	0.0189	50	0.4	65.77%	525	12	2,536	1,293	97.77%	33.77%	17.15%	99.08%	41.64%
21	0.01	200	0	65.76%	508	29	2,415	1,414	94.60%	36.93%	17.38%	97.99%	44.02%
29	0.01	50	0.4	65.75%	515	22	2,466	1,363	95.90%	35.60%	17.28%	98.41%	43.01%
21	0.01	200	0.1	65.75%	514	23	2,459	1,370	95.72%	35.78%	17.29%	98.35%	43.15%
24	0.0545	50	0.3	65.73%	490	47	2,289	1,540	91.25%	40.22%	17.63%	97.04%	46.50%
21	0.01	50	0.7	65.73%	525	12	2,539	1,290	97.77%	33.69%	17.13%	99.08%	41.57%

Attribute	Learning Rate	Training Cycle	Momentum	Weight Mean Recall	True Drought Pred Drought	True Drought Pred no Drought	True no Drought Pred Drought	True no Drought Pred no Drought	Recall Drought	Recall no Drought	Precision Drought	Precision no Drought	Accuracy
27	0.0278	100	0.8	65.73%	340	197	1,220	2,609	63.31%	68.14%	21.79%	92.98%	67.54%
27	0.0812	100	0.4	65.72%	397	140	1,627	2,202	73.93%	57.51%	19.61%	94.02%	59.53%
30	0.1524	50	0.4	65.71%	400	137	1,649	2,180	74.49%	56.93%	19.52%	94.09%	59.09%
27	0.1435	50	0.1	65.70%	386	151	1,550	2,279	71.88%	59.52%	19.94%	93.79%	61.04%
24	0.0634	50	0.2	65.69%	490	47	2,292	1,537	91.25%	40.14%	17.61%	97.03%	46.43%
24	0.0545	50	0.1	65.69%	486	51	2,264	1,565	90.50%	40.87%	17.67%	96.84%	46.98%
24	0.0723	50	0	65.68%	491	46	2,300	1,529	91.43%	39.93%	17.59%	97.08%	46.27%
29	0.0189	50	0	65.68%	514	23	2,464	1,365	95.72%	35.65%	17.26%	98.34%	43.04%
29	0.01	50	0.2	65.68%	519	18	2,500	1,329	96.65%	34.71%	17.19%	98.66%	42.33%
29	0.0189	50	0.2	65.67%	515	22	2,472	1,357	95.90%	35.44%	17.24%	98.40%	42.88%
27	0.1524	50	0	65.66%	386	151	1,553	2,276	71.88%	59.44%	19.91%	93.78%	60.97%
30	0.1791	50	0.3	65.66%	399	138	1,646	2,183	74.30%	57.01%	19.51%	94.05%	59.14%
24	0.0634	50	0.1	65.65%	489	48	2,288	1,541	91.06%	40.25%	17.61%	96.98%	46.50%
27	0.0723	100	0.5	65.65%	395	142	1,618	2,211	73.56%	57.74%	19.62%	93.97%	59.69%
30	0.2948	50	0.4	65.65%	410	127	1,725	2,104	76.35%	54.95%	19.20%	94.31%	57.58%
24	0.0723	50	0.1	65.64%	490	47	2,296	1,533	91.25%	40.04%	17.59%	97.03%	46.34%
21	0.0278	50	0.1	65.64%	525	12	2,546	1,283	97.77%	33.51%	17.10%	99.07%	41.41%
24	0.0456	50	0.4	65.63%	490	47	2,297	1,532	91.25%	40.01%	17.58%	97.02%	46.31%

Attribute	Learning Rate	Training Cycle	Momentum	Weight Mean Recall	True Drought Pred Drought	True Drought Pred no Drought	True no Drought Pred Drought	True no Drought Pred no Drought	Recall Drought	Recall no Drought	Precision Drought	Precision no Drought	Accuracy
27	0.0367	100	0.7	65.63%	358	179	1,356	2,473	66.67%	64.59%	20.89%	93.25%	64.84%
27	0.0367	200	0.6	65.62%	403	134	1,677	2,152	75.05%	56.20%	19.38%	94.14%	58.52%
24	0.0545	50	0.2	65.62%	487	50	2,276	1,553	90.69%	40.56%	17.63%	96.88%	46.72%
24	0.0456	50	0.3	65.62%	486	51	2,269	1,560	90.50%	40.74%	17.64%	96.83%	46.86%
23	0.4105	50	0.8	65.62%	509	28	2,429	1,400	94.79%	36.56%	17.32%	98.04%	43.72%
30	0.4283	50	0.1	65.62%	384	153	1,542	2,287	71.51%	59.73%	19.94%	93.73%	61.18%
27	0.1079	100	0.2	65.61%	403	134	1,678	2,151	75.05%	56.18%	19.37%	94.14%	58.50%
27	0.1257	50	0.2	65.61%	378	159	1,500	2,329	70.39%	60.83%	20.13%	93.61%	62.00%
24	0.0545	50	0.4	65.60%	488	49	2,285	1,544	90.88%	40.32%	17.60%	96.92%	46.54%
25	0.01	50	0	65.60%	378	159	1,501	2,328	70.39%	60.80%	20.12%	93.61%	61.98%
30	0.8822	100	0.6	65.59%	438	99	1,929	1,900	81.56%	49.62%	18.50%	95.05%	53.55%
27	0.0545	100	0.6	65.59%	383	154	1,537	2,292	71.32%	59.86%	19.95%	93.70%	61.27%
24	0.0456	50	0.2	65.59%	482	55	2,243	1,586	89.76%	41.42%	17.69%	96.65%	47.37%
29	0.01	50	0.5	65.58%	514	23	2,472	1,357	95.72%	35.44%	17.21%	98.33%	42.85%
30	0.4372	50	0.1	65.58%	383	154	1,538	2,291	71.32%	59.83%	19.94%	93.70%	61.25%
24	0.0367	50	0.4	65.57%	484	53	2,259	1,570	90.13%	41.00%	17.64%	96.73%	47.05%
24	0.0634	50	0	65.56%	487	50	2,281	1,548	90.69%	40.43%	17.59%	96.87%	46.61%
24	0.0634	50	0.3	65.56%	487	50	2,281	1,548	90.69%	40.43%	17.59%	96.87%	46.61%

Attribute	Learning Rate	Training Cycle	Momentum	Weight Mean Recall	True Drought Pred Drought	True Drought Pred no Drought	True no Drought Pred Drought	True no Drought Pred no Drought	Recall Drought	Recall no Drought	Precision Drought	Precision no Drought	Accuracy
24	0.0723	50	0.2	65.56%	487	50	2,281	1,548	90.69%	40.43%	17.59%	96.87%	46.61%
24	0.0367	50	0.5	65.55%	490	47	2,303	1,526	91.25%	39.85%	17.54%	97.01%	46.17%
24	0.0812	50	0	65.55%	490	47	2,303	1,526	91.25%	39.85%	17.54%	97.01%	46.17%
21	0.01	100	0.2	65.54%	493	44	2,325	1,504	91.81%	39.28%	17.49%	97.16%	45.74%
27	0.0456	200	0.5	65.54%	406	131	1,705	2,124	75.61%	55.47%	19.23%	94.19%	57.95%
21	0.01	100	0.4	65.54%	513	24	2,468	1,361	95.53%	35.54%	17.21%	98.27%	42.92%
30	0.2058	50	0.1	65.54%	390	147	1,591	2,238	72.63%	58.45%	19.69%	93.84%	60.19%
30	0.7754	200	0.6	65.53%	486	51	2,276	1,553	90.50%	40.56%	17.60%	96.82%	46.70%
29	0.0189	50	0.3	65.53%	515	22	2,483	1,346	95.90%	35.15%	17.18%	98.39%	42.62%
27	0.0634	100	0.5	65.52%	385	152	1,557	2,272	71.69%	59.34%	19.82%	93.73%	60.86%
30	0.4461	50	0.1	65.51%	383	154	1,543	2,286	71.32%	59.70%	19.89%	93.69%	61.13%
27	0.1435	100	0	65.51%	410	127	1,736	2,093	76.35%	54.66%	19.11%	94.28%	57.33%
27	0.099	100	0.3	65.51%	402	135	1,679	2,150	74.86%	56.15%	19.32%	94.09%	58.45%
30	0.4194	50	0.1	65.50%	383	154	1,544	2,285	71.32%	59.68%	19.88%	93.69%	61.11%
27	0.1257	100	0.1	65.50%	406	131	1,708	2,121	75.61%	55.39%	19.21%	94.18%	57.88%
21	0.01	100	0.5	65.50%	520	17	2,521	1,308	96.83%	34.16%	17.10%	98.72%	41.87%
21	0.0189	50	0.5	65.49%	526	11	2,564	1,265	97.95%	33.04%	17.02%	99.14%	41.02%
21	0.0278	50	0.2	65.49%	526	11	2,564	1,265	97.95%	33.04%	17.02%	99.14%	41.02%

Attribute	Learning Rate	Training Cycle	Momentum	Weight Mean Recall	True Drought Pred Drought	True Drought Pred no Drought	True no Drought Pred Drought	True no Drought Pred no Drought	Recall Drought	Recall no Drought	Precision Drought	Precision no Drought	Accuracy
30	0.5084	50	0	65.49%	378	159	1,509	2,320	70.39%	60.59%	20.03%	93.59%	61.80%
21	0.0189	100	0	65.49%	521	16	2,529	1,300	97.02%	33.95%	17.08%	98.78%	41.71%
24	0.0812	50	0.1	65.48%	487	50	2,287	1,542	90.69%	40.27%	17.56%	96.86%	46.47%
27	0.0189	200	0.8	65.48%	371	166	1,460	2,369	69.09%	61.87%	20.26%	93.45%	62.76%
27	0.1168	100	0.1	65.48%	401	136	1,674	2,155	74.67%	56.28%	19.33%	94.06%	58.54%
30	0.7576	50	0.6	65.48%	508	29	2,437	1,392	94.60%	36.35%	17.25%	97.96%	43.52%
30	0.0901	50	0.5	65.47%	398	139	1,653	2,176	74.12%	56.83%	19.41%	94.00%	58.96%
24	0.0456	50	0.5	65.47%	488	49	2,295	1,534	90.88%	40.06%	17.54%	96.90%	46.31%
23	0.277	200	0.9	65.46%	501	36	2,388	1,441	93.30%	37.63%	17.34%	97.56%	44.48%
27	0.1435	50	0	65.46%	377	160	1,504	2,325	70.20%	60.72%	20.04%	93.56%	61.89%
30	0.4995	50	0	65.46%	376	161	1,497	2,332	70.02%	60.90%	20.07%	93.54%	62.02%
30	0.1613	50	0.3	65.46%	398	139	1,654	2,175	74.12%	56.80%	19.40%	93.99%	58.93%
24	0.0278	50	0.6	65.46%	490	47	2,310	1,519	91.25%	39.67%	17.50%	97.00%	46.01%
29	0.01	100	0.1	65.45%	493	44	2,332	1,497	91.81%	39.10%	17.45%	97.14%	45.58%
30	0.1702	50	0.2	65.45%	393	144	1,619	2,210	73.18%	57.72%	19.53%	93.88%	59.62%
29	0.01	50	0.6	65.45%	514	23	2,482	1,347	95.72%	35.18%	17.16%	98.32%	42.62%
27	0.0901	100	0.4	65.45%	398	139	1,655	2,174	74.12%	56.78%	19.39%	93.99%	58.91%
24	0.0545	50	0	65.45%	482	55	2,254	1,575	89.76%	41.13%	17.62%	96.63%	47.11%

Attribute	Learning Rate	Training Cycle	Momentum	Weight Mean Recall	True Drought Pred Drought	True Drought Pred no Drought	True no Drought Pred Drought	True no Drought Pred no Drought	Recall Drought	Recall no Drought	Precision Drought	Precision no Drought	Accuracy
27	0.1168	100	0.2	65.45%	405	132	1,705	2,124	75.42%	55.47%	19.19%	94.15%	57.92%
30	0.5618	200	0.7	65.43%	467	70	2,148	1,681	86.96%	43.90%	17.86%	96.00%	49.20%
27	0.1346	100	0	65.43%	405	132	1,706	2,123	75.42%	55.45%	19.19%	94.15%	57.90%
30	0.0723	50	0.6	65.42%	400	137	1,671	2,158	74.49%	56.36%	19.31%	94.03%	58.59%
24	0.0367	50	0.6	65.42%	491	46	2,320	1,509	91.43%	39.41%	17.47%	97.04%	45.81%
30	0.3037	50	0.4	65.41%	410	127	1,743	2,086	76.35%	54.48%	19.04%	94.26%	57.17%
30	0.1524	50	0.3	65.41%	397	140	1,651	2,178	73.93%	56.88%	19.38%	93.96%	58.98%
24	0.0278	50	0.5	65.40%	480	57	2,243	1,586	89.39%	41.42%	17.63%	96.53%	47.32%
29	0.01	100	0	65.40%	494	43	2,343	1,486	91.99%	38.81%	17.41%	97.19%	45.35%
30	0.2236	50	0.1	65.40%	385	152	1,566	2,263	71.69%	59.10%	19.73%	93.71%	60.65%
27	0.1702	50	0	65.39%	390	147	1,602	2,227	72.63%	58.16%	19.58%	93.81%	59.94%
24	0.0901	50	0	65.39%	487	50	2,294	1,535	90.69%	40.09%	17.51%	96.85%	46.31%
24	0.0189	50	0.7	65.38%	490	47	2,316	1,513	91.25%	39.51%	17.46%	96.99%	45.88%
24	0.0278	50	0.7	65.38%	496	41	2,359	1,470	92.36%	38.39%	17.37%	97.29%	45.03%
30	0.2414	50	0.5	65.38%	411	126	1,753	2,076	76.54%	54.22%	18.99%	94.28%	56.96%
30	0.1435	50	0.3	65.38%	395	142	1,639	2,190	73.56%	57.20%	19.42%	93.91%	59.21%
29	0.01	50	0.1	65.37%	217	20	2,509	1,320	91.56%	34.47%	7.96%	98.51%	37.80%
30	0.5974	50	0.7	65.37%	515	22	2,495	1,334	95.90%	34.84%	17.11%	98.38%	42.35%

Attribute	Learning Rate	Training Cycle	Momentum	Weight Mean Recall	True Drought Pred Drought	True Drought Pred no Drought	True no Drought Pred Drought	True no Drought Pred no Drought	Recall Drought	Recall no Drought	Precision Drought	Precision no Drought	Accuracy
29	0.0367	50	0	65.37%	514	23	2,488	1,341	95.72%	35.02%	17.12%	98.31%	42.49%
24	0.0901	50	0.1	65.37%	483	54	2,267	1,562	89.94%	40.79%	17.56%	96.66%	46.84%
21	0.01	100	0.1	65.37%	481	56	2,253	1,576	89.57%	41.16%	17.59%	96.57%	47.11%
27	0.0634	100	0.6	65.36%	371	166	1,469	2,360	69.09%	61.63%	20.16%	93.43%	62.55%
27	0.099	100	0.2	65.36%	394	143	1,633	2,196	73.37%	57.35%	19.44%	93.89%	59.32%
30	0.0367	50	0.8	65.36%	399	138	1,669	2,160	74.30%	56.41%	19.29%	93.99%	58.61%
29	0.01	100	0.2	65.35%	490	47	2,318	1,511	91.25%	39.46%	17.45%	96.98%	45.83%
29	0.0278	50	0.1	65.35%	513	24	2,482	1,347	95.53%	35.18%	17.13%	98.25%	42.60%
30	0.1079	50	0.5	65.35%	405	132	1,712	2,117	75.42%	55.29%	19.13%	94.13%	57.76%
30	0.1168	50	0.5	65.35%	404	133	1,705	2,124	75.23%	55.47%	19.16%	94.11%	57.90%
30	0.099	50	0.8	65.35%	410	127	1,748	2,081	76.35%	54.35%	19.00%	94.25%	57.05%
30	0.1791	50	0.2	65.35%	393	144	1,627	2,202	73.18%	57.51%	19.46%	93.86%	59.44%
23	0.5796	200	0.8	65.34%	483	54	2,269	1,560	89.94%	40.74%	17.55%	96.65%	46.79%
29	0.01	50	0.3	65.34%	513	24	2,483	1,346	95.53%	35.15%	17.12%	98.25%	42.58%
30	0.3927	50	0.2	65.34%	389	148	1,599	2,230	72.44%	58.24%	19.57%	93.78%	59.99%
27	0.0901	100	0.3	65.34%	394	143	1,635	2,194	73.37%	57.30%	19.42%	93.88%	59.28%
27	0.1346	50	0.1	65.33%	377	160	1,514	2,315	70.20%	60.46%	19.94%	93.54%	61.66%
29	0.0278	50	0	65.33%	512	25	2,477	1,352	95.34%	35.31%	17.13%	98.18%	42.69%

Attribute	Learning Rate	Training Cycle	Momentum	Weight Mean Recall	True Drought Pred Drought	True Drought Pred no Drought	True no Drought Pred Drought	True no Drought Pred no Drought	Recall Drought	Recall no Drought	Precision Drought	Precision no Drought	Accuracy
30	0.0367	50	0.9	65.32%	379	158	1,529	2,300	70.58%	60.07%	19.86%	93.57%	61.36%
30	0.6508	100	0.7	65.32%	491	46	2,328	1,501	91.43%	39.20%	17.42%	97.03%	45.63%
30	0.4016	50	0.1	65.31%	382	155	1,551	2,278	71.14%	59.49%	19.76%	93.63%	60.93%
30	0.4105	50	0.1	65.31%	382	155	1,551	2,278	71.14%	59.49%	19.76%	93.63%	60.93%
30	0.1257	50	0.5	65.31%	397	140	1,658	2,171	73.93%	56.70%	19.32%	93.94%	58.82%
30	0.3126	50	0.4	65.31%	410	127	1,751	2,078	76.35%	54.27%	18.97%	94.24%	56.99%
27	0.0723	100	0.4	65.31%	385	152	1,573	2,256	71.69%	58.92%	19.66%	93.69%	60.49%
30	0.1257	50	0.4	65.30%	399	138	1,673	2,156	74.30%	56.31%	19.26%	93.98%	58.52%
30	0.1969	50	0.2	65.30%	389	148	1,602	2,227	72.44%	58.16%	19.54%	93.77%	59.92%
21	0.0367	50	0	65.30%	526	11	2,579	1,250	97.95%	32.65%	16.94%	99.13%	40.68%
30	0.2147	50	0.1	65.30%	387	150	1,588	2,241	72.07%	58.53%	19.59%	93.73%	60.19%
30	0.5173	50	0	65.30%	379	158	1,531	2,298	70.58%	60.02%	19.84%	93.57%	61.31%
21	0.0278	50	0.3	65.29%	526	11	2,580	1,249	97.95%	32.62%	16.93%	99.13%	40.66%
27	0.0723	200	0.5	65.28%	383	154	1,561	2,268	71.32%	59.23%	19.70%	93.64%	60.72%
24	0.0723	50	0.3	65.27%	481	56	2,260	1,569	89.57%	40.98%	17.55%	96.55%	46.95%
30	0.099	50	0.5	65.27%	401	136	1,690	2,139	74.67%	55.86%	19.18%	94.02%	58.18%
27	0.1346	50	0.2	65.27%	377	160	1,519	2,310	70.20%	60.33%	19.88%	93.52%	61.54%
24	0.0812	50	0.2	65.26%	481	56	2,261	1,568	89.57%	40.95%	17.54%	96.55%	46.93%

Attribute	Learning Rate	Training Cycle	Momentum	Weight Mean Recall	True Drought Pred Drought	True Drought Pred no Drought	True no Drought Pred Drought	True no Drought Pred no Drought	Recall Drought	Recall no Drought	Precision Drought	Precision no Drought	Accuracy
30	0.4639	50	0.1	65.26%	388	149	1,598	2,231	72.25%	58.27%	19.54%	93.74%	59.99%
30	0.1346	50	0.4	65.25%	400	137	1,684	2,145	74.49%	56.02%	19.19%	94.00%	58.29%
21	0.0189	100	0.1	65.25%	522	15	2,554	1,275	97.21%	33.30%	16.97%	98.84%	41.16%
29	0.0278	50	0.2	65.25%	514	23	2,497	1,332	95.72%	34.79%	17.07%	98.30%	42.28%
30	0.1435	50	0.4	65.25%	397	140	1,663	2,166	73.93%	56.57%	19.27%	93.93%	58.70%
24	0.01	50	0.8	65.25%	487	50	2,305	1,524	90.69%	39.80%	17.44%	96.82%	46.06%
30	0.099	50	0.6	65.24%	400	137	1,685	2,144	74.49%	55.99%	19.18%	93.99%	58.27%
30	0.3482	50	0.3	65.24%	400	137	1,685	2,144	74.49%	55.99%	19.18%	93.99%	58.27%
27	0.1257	100	0	65.24%	398	139	1,671	2,158	74.12%	56.36%	19.24%	93.95%	58.54%
30	0.0278	50	0.9	65.23%	403	134	1,707	2,122	75.05%	55.42%	19.10%	94.06%	57.83%
30	0.3571	50	0.3	65.23%	403	134	1,707	2,122	75.05%	55.42%	19.10%	94.06%	57.83%
27	0.1168	50	0.3	65.23%	371	166	1,479	2,350	69.09%	61.37%	20.05%	93.40%	62.32%
30	0.0545	50	0.7	65.23%	400	137	1,686	2,143	74.49%	55.97%	19.18%	93.99%	58.25%
21	0.01	200	0.2	65.23%	515	22	2,506	1,323	95.90%	34.55%	17.05%	98.36%	42.10%
29	0.0367	50	0.1	65.23%	515	22	2,506	1,323	95.90%	34.55%	17.05%	98.36%	42.10%
30	0.455	50	0.1	65.23%	384	153	1,572	2,257	71.51%	58.94%	19.63%	93.65%	60.49%
29	0.01	50	0.7	65.23%	514	23	2,499	1,330	95.72%	34.73%	17.06%	98.30%	42.24%
30	0.3838	50	0.1	65.22%	383	154	1,565	2,264	71.32%	59.13%	19.66%	93.63%	60.63%

Attribute	Learning Rate	Training Cycle	Momentum	Weight Mean Recall	True Drought Pred Drought	True Drought Pred no Drought	True no Drought Pred Drought	True no Drought Pred no Drought	Recall Drought	Recall no Drought	Precision Drought	Precision no Drought	Accuracy
30	0.4728	50	0	65.22%	374	163	1,501	2,328	69.65%	60.80%	19.95%	93.46%	61.89%
24	0.0634	50	0.4	65.22%	481	56	2,264	1,565	89.57%	40.87%	17.52%	96.55%	46.86%
30	0.1168	50	0.4	65.22%	396	141	1,658	2,171	73.74%	56.70%	19.28%	93.90%	58.80%
30	0.2681	50	0.1	65.22%	379	158	1,537	2,292	70.58%	59.86%	19.78%	93.55%	61.18%
30	0.366	50	0.2	65.22%	386	151	1,587	2,242	71.88%	58.55%	19.56%	93.69%	60.19%
30	0.188	50	0.2	65.21%	391	146	1,623	2,206	72.81%	57.61%	19.41%	93.79%	59.48%
24	0.099	50	0	65.21%	483	54	2,279	1,550	89.94%	40.48%	17.49%	96.63%	46.56%
30	0.4906	50	0	65.21%	374	163	1,502	2,327	69.65%	60.77%	19.94%	93.45%	61.86%
27	0.0456	100	0.6	65.21%	364	173	1,431	2,398	67.78%	62.63%	20.28%	93.27%	63.26%
30	0.3838	50	0.2	65.20%	386	151	1,588	2,241	71.88%	58.53%	19.55%	93.69%	60.17%
30	0.1702	50	0.3	65.20%	392	145	1,631	2,198	73.00%	57.40%	19.38%	93.81%	59.32%
29	0.0189	50	0.4	65.20%	514	23	2,501	1,328	95.72%	34.68%	17.05%	98.30%	42.19%
30	0.6063	50	0.7	65.20%	521	16	2,551	1,278	97.02%	33.38%	16.96%	98.76%	41.20%
30	0.0723	50	0.7	65.20%	405	132	1,724	2,105	75.42%	54.98%	19.02%	94.10%	57.49%
30	0.4639	50	0	65.20%	374	163	1,503	2,326	69.65%	60.75%	19.93%	93.45%	61.84%
30	0.4817	50	0	65.20%	374	163	1,503	2,326	69.65%	60.75%	19.93%	93.45%	61.84%
30	0.3482	50	0.2	65.19%	388	149	1,603	2,226	72.25%	58.14%	19.49%	93.73%	59.87%
24	0.0189	50	0.8	65.19%	502	35	2,416	1,413	93.48%	36.90%	17.20%	97.58%	43.86%

Attribute	Learning Rate	Training Cycle	Momentum	Weight Mean Recall	True Drought Pred Drought	True Drought Pred no Drought	True no Drought Pred Drought	True no Drought Pred no Drought	Recall Drought	Recall no Drought	Precision Drought	Precision no Drought	Accuracy
27	0.0545	200	0.6	65.19%	383	154	1,568	2,261	71.32%	59.05%	19.63%	93.62%	60.56%
24	0.0367	50	0.3	65.18%	474	63	2,217	1,612	88.27%	42.10%	17.61%	96.24%	47.78%
30	0.8822	50	0.5	65.18%	503	34	2,424	1,405	93.67%	36.69%	17.18%	97.64%	43.70%
30	0.1969	50	0.3	65.18%	393	144	1,640	2,189	73.18%	57.17%	19.33%	93.83%	59.14%
27	0.01	50	0.1	65.18%	400	137	1,690	2,139	74.49%	55.86%	19.14%	93.98%	58.15%
27	0.1079	100	0.3	65.17%	399	138	1,683	2,146	74.30%	56.05%	19.16%	93.96%	58.29%
27	0.1346	100	0.1	65.17%	406	131	1,733	2,096	75.61%	54.74%	18.98%	94.12%	57.31%
27	0.1168	50	0.2	65.17%	367	170	1,455	2,374	68.34%	62.00%	20.14%	93.32%	62.78%
30	0.2147	50	0.3	65.17%	390	147	1,619	2,210	72.63%	57.72%	19.41%	93.76%	59.55%
30	0.3749	50	0.2	65.16%	386	151	1,591	2,238	71.88%	58.45%	19.52%	93.68%	60.10%
30	0.3571	50	0.1	65.16%	383	154	1,570	2,259	71.32%	59.00%	19.61%	93.62%	60.51%
30	0.0812	50	0.6	65.16%	405	132	1,727	2,102	75.42%	54.90%	19.00%	94.09%	57.42%
22	0.6864	50	0.8	65.16%	481	56	2,269	1,560	89.57%	40.74%	17.49%	96.53%	46.75%
29	0.01	50	0	65.15%	516	21	2,519	1,310	96.09%	34.21%	17.00%	98.42%	41.82%
30	0.7131	50	0.6	65.15%	515	22	2,512	1,317	95.90%	34.40%	17.01%	98.36%	41.96%
30	0.2325	50	0.5	65.15%	407	130	1,742	2,087	75.79%	54.51%	18.94%	94.14%	57.12%
30	0.2859	50	0.4	65.14%	402	135	1,707	2,122	74.86%	55.42%	19.06%	94.02%	57.81%
30	0.366	50	0.1	65.13%	383	154	1,572	2,257	71.32%	58.94%	19.59%	93.61%	60.47%

Attribute	Learning Rate	Training Cycle	Momentum	Weight Mean Recall	True Drought Pred Drought	True Drought Pred no Drought	True no Drought Pred Drought	True no Drought Pred no Drought	Recall Drought	Recall no Drought	Precision Drought	Precision no Drought	Accuracy
24	0.0545	50	0.5	65.13%	481	56	2,271	1,558	89.57%	40.69%	17.48%	96.53%	46.70%
27	0.0456	100	0.7	65.13%	357	180	1,387	2,442	66.48%	63.78%	20.47%	93.14%	64.11%
30	0.2592	50	0.1	65.13%	380	157	1,551	2,278	70.76%	59.49%	19.68%	93.55%	60.88%
27	0.0812	200	0	65.13%	394	143	1,651	2,178	73.37%	56.88%	19.27%	93.84%	58.91%
30	0.188	50	0.3	65.13%	394	143	1,651	2,178	73.37%	56.88%	19.27%	93.84%	58.91%
29	0.0456	50	0	65.12%	515	22	2,514	1,315	95.90%	34.34%	17.00%	98.35%	41.91%
30	0.0545	50	0.8	65.12%	406	131	1,737	2,092	75.61%	54.64%	18.95%	94.11%	57.21%
24	0.0456	50	0.1	65.12%	474	63	2,222	1,607	88.27%	41.97%	17.58%	96.23%	47.66%
21	0.0367	50	0.1	65.12%	526	11	2,593	1,236	97.95%	32.28%	16.86%	99.12%	40.36%
30	0.5262	50	0	65.12%	380	157	1,552	2,277	70.76%	59.47%	19.67%	93.55%	60.86%
30	0.3571	50	0.2	65.11%	386	151	1,595	2,234	71.88%	58.34%	19.49%	93.67%	60.01%
29	0.0278	50	0.3	65.11%	515	22	2,515	1,314	95.90%	34.32%	17.00%	98.35%	41.89%
30	0.2147	50	0.2	65.10%	388	149	1,610	2,219	72.25%	57.95%	19.42%	93.71%	59.71%
30	0.0456	50	0.8	65.10%	403	134	1,717	2,112	75.05%	55.16%	19.01%	94.03%	57.60%
30	0.8644	50	0.5	65.10%	493	44	2,359	1,470	91.81%	38.39%	17.29%	97.09%	44.96%
29	0.0189	50	0.5	65.10%	515	22	2,516	1,313	95.90%	34.29%	16.99%	98.35%	41.87%
30	0.4016	50	0.2	65.09%	391	146	1,632	2,197	72.81%	57.38%	19.33%	93.77%	59.28%
30	0.1079	50	0.6	65.09%	406	131	1,739	2,090	75.61%	54.58%	18.93%	94.10%	57.17%

Attribute	Learning Rate	Training Cycle	Momentum	Weight Mean Recall	True Drought Pred Drought	True Drought Pred no Drought	True no Drought Pred Drought	True no Drought Pred no Drought	Recall Drought	Recall no Drought	Precision Drought	Precision no Drought	Accuracy
30	0.3482	50	0.1	65.09%	382	155	1,568	2,261	71.14%	59.05%	19.59%	93.58%	60.54%
30	0.3749	50	0.1	65.09%	382	155	1,568	2,261	71.14%	59.05%	19.59%	93.58%	60.54%
30	0.01	50	0.2	65.09%	418	119	1,825	2,004	77.84%	52.34%	18.64%	94.39%	55.47%
30	0.277	50	0.2	65.08%	385	152	1,590	2,239	71.69%	58.47%	19.49%	93.64%	60.10%
30	0.2503	50	0.5	65.08%	412	125	1,783	2,046	76.72%	53.43%	18.77%	94.24%	56.30%
27	0.1524	50	0.1	65.08%	381	156	1,562	2,267	70.95%	59.21%	19.61%	93.56%	60.65%
30	0.3393	50	0.2	65.08%	388	149	1,612	2,217	72.25%	57.90%	19.40%	93.70%	59.67%
30	0.188	50	0.6	65.08%	411	126	1,776	2,053	76.54%	53.62%	18.79%	94.22%	56.44%
30	0.2058	50	0.3	65.07%	390	147	1,627	2,202	72.63%	57.51%	19.34%	93.74%	59.37%
27	0.1791	50	0	65.06%	388	149	1,613	2,216	72.25%	57.87%	19.39%	93.70%	59.64%
30	0.2236	50	0.2	65.06%	387	150	1,606	2,223	72.07%	58.06%	19.42%	93.68%	59.78%
30	0.2859	50	0.2	65.06%	386	151	1,599	2,230	71.88%	58.24%	19.45%	93.66%	59.92%
30	0.3304	50	0.2	65.05%	388	149	1,614	2,215	72.25%	57.85%	19.38%	93.70%	59.62%
30	0.0456	50	0.9	65.05%	380	157	1,557	2,272	70.76%	59.34%	19.62%	93.54%	60.74%
30	0.633	100	0.7	65.05%	495	42	2,377	1,452	92.18%	37.92%	17.24%	97.19%	44.59%
30	0.3037	50	0.2	65.05%	387	150	1,607	2,222	72.07%	58.03%	19.41%	93.68%	59.76%
30	0.4728	50	0.1	65.05%	387	150	1,607	2,222	72.07%	58.03%	19.41%	93.68%	59.76%
30	0.8911	50	0.5	65.05%	493	44	2,363	1,466	91.81%	38.29%	17.26%	97.09%	44.87%

Attribute	Learning Rate	Training Cycle	Momentum	Weight Mean Recall	True Drought Pred Drought	True Drought Pred no Drought	True no Drought Pred Drought	True no Drought Pred no Drought	Recall Drought	Recall no Drought	Precision Drought	Precision no Drought	Accuracy
27	0.0723	200	0.1	65.04%	391	146	1,636	2,193	72.81%	57.27%	19.29%	93.76%	59.18%
30	0.0901	50	0.6	65.04%	405	132	1,736	2,093	75.42%	54.66%	18.92%	94.07%	57.21%
30	0.3215	50	0.2	65.04%	388	149	1,615	2,214	72.25%	57.82%	19.37%	93.69%	59.60%
30	0.3215	50	0.4	65.03%	409	128	1,765	2,064	76.16%	53.90%	18.81%	94.16%	56.64%
30	0.3927	50	0.1	65.02%	380	157	1,559	2,270	70.76%	59.28%	19.60%	93.53%	60.70%
30	0.2948	50	0.2	65.02%	386	151	1,602	2,227	71.88%	58.16%	19.42%	93.65%	59.85%
30	0.633	50	0.7	65.02%	507	30	2,465	1,364	94.41%	35.62%	17.06%	97.85%	42.85%
27	0.1524	100	0	65.02%	407	130	1,752	2,077	75.79%	54.24%	18.85%	94.11%	56.89%
21	0.01	100	0.6	65.02%	522	15	2,572	1,257	97.21%	32.83%	16.87%	98.82%	40.75%
30	0.2414	50	0.2	65.02%	383	154	1,581	2,248	71.32%	58.71%	19.50%	93.59%	60.26%
30	0.0634	50	0.8	65.02%	398	139	1,688	2,141	74.12%	55.92%	19.08%	93.90%	58.15%
27	0.0812	100	0.5	65.01%	373	164	1,510	2,319	69.46%	60.56%	19.81%	93.40%	61.66%
27	0.1079	50	0.3	65.01%	365	172	1,453	2,376	67.97%	62.05%	20.08%	93.25%	62.78%
22	0.01	50	0.3	65.01%	362	175	1,432	2,397	67.41%	62.60%	20.18%	93.20%	63.19%
30	0.2325	50	0.2	65.01%	385	152	1,596	2,233	71.69%	58.32%	19.43%	93.63%	59.96%
21	0.0189	50	0.6	65.00%	526	11	2,602	1,227	97.95%	32.04%	16.82%	99.11%	40.15%
27	0.0545	100	0.5	64.99%	369	168	1,483	2,346	68.72%	61.27%	19.92%	93.32%	62.19%
30	0.277	50	0.1	64.99%	376	161	1,533	2,296	70.02%	59.96%	19.70%	93.45%	61.20%

Attribute	Learning Rate	Training Cycle	Momentum	Weight Mean Recall	True Drought Pred Drought	True Drought Pred no Drought	True no Drought Pred Drought	True no Drought Pred no Drought	Recall Drought	Recall no Drought	Precision Drought	Precision no Drought	Accuracy
30	0.2503	50	0.2	64.99%	382	155	1,576	2,253	71.14%	58.84%	19.51%	93.56%	60.35%
21	0.0278	50	0.4	64.99%	526	11	2,603	1,226	97.95%	32.02%	16.81%	99.11%	40.13%
29	0.01	50	0.8	64.98%	515	22	2,525	1,304	95.90%	34.06%	16.94%	98.34%	41.66%
30	0.7665	50	0.6	64.98%	515	22	2,525	1,304	95.90%	34.06%	16.94%	98.34%	41.66%
30	0.2592	50	0.3	64.98%	391	146	1,641	2,188	72.81%	57.14%	19.24%	93.74%	59.07%
30	0.0634	50	0.7	64.98%	405	132	1,741	2,088	75.42%	54.53%	18.87%	94.05%	57.10%
25	0.01	50	0.1	64.97%	356	181	1,392	2,437	66.29%	63.65%	20.37%	93.09%	63.97%
27	0.0812	100	0.3	64.97%	384	153	1,592	2,237	71.51%	58.42%	19.43%	93.60%	60.03%
21	0.0189	100	0.2	64.97%	522	15	2,576	1,253	97.21%	32.72%	16.85%	98.82%	40.66%
30	0.2592	50	0.2	64.96%	382	155	1,578	2,251	71.14%	58.79%	19.49%	93.56%	60.31%
30	0.3126	50	0.2	64.96%	387	150	1,614	2,215	72.07%	57.85%	19.34%	93.66%	59.60%
30	0.5529	50	0	64.96%	378	159	1,550	2,279	70.39%	59.52%	19.61%	93.48%	60.86%
30	0.366	50	0.3	64.96%	401	136	1,714	2,115	74.67%	55.24%	18.96%	93.96%	57.63%
30	0.1079	50	0.8	64.95%	408	129	1,764	2,065	75.98%	53.93%	18.78%	94.12%	56.64%
24	0.0456	50	0	64.95%	469	68	2,199	1,630	87.34%	42.57%	17.58%	96.00%	48.08%
30	0.1969	50	0.6	64.95%	414	123	1,807	2,022	77.09%	52.81%	18.64%	94.27%	55.79%
30	0.2681	50	0.2	64.95%	383	154	1,586	2,243	71.32%	58.58%	19.45%	93.58%	60.15%
27	0.1435	50	0.2	64.95%	374	163	1,522	2,307	69.65%	60.25%	19.73%	93.40%	61.41%

Attribute	Learning Rate	Training Cycle	Momentum	Weight Mean Recall	True Drought Pred Drought	True Drought Pred no Drought	True no Drought Pred Drought	True no Drought Pred no Drought	Recall Drought	Recall no Drought	Precision Drought	Precision no Drought	Accuracy
30	0.1435	50	0.7	64.95%	412	125	1,793	2,036	76.72%	53.17%	18.68%	94.22%	56.07%
30	0.1613	50	0.4	64.95%	396	141	1,679	2,150	73.74%	56.15%	19.08%	93.85%	58.31%
27	0.1257	50	0.1	64.95%	365	172	1,458	2,371	67.97%	61.92%	20.02%	93.24%	62.67%
29	0.0367	50	0.2	64.94%	515	22	2,528	1,301	95.90%	33.98%	16.92%	98.34%	41.59%
30	0.0812	50	0.7	64.94%	407	130	1,758	2,071	75.79%	54.09%	18.80%	94.09%	56.76%
27	0.1257	100	0.2	64.94%	399	138	1,701	2,128	74.30%	55.58%	19.00%	93.91%	57.88%
30	0.2325	50	0.3	64.93%	389	148	1,630	2,199	72.44%	57.43%	19.27%	93.69%	59.28%
27	0.099	50	0.4	64.92%	360	177	1,424	2,405	67.04%	62.81%	20.18%	93.14%	63.33%
30	0.1346	50	0.5	64.91%	400	137	1,710	2,119	74.49%	55.34%	18.96%	93.93%	57.70%
30	0.3037	50	0.1	64.91%	375	162	1,532	2,297	69.83%	59.99%	19.66%	93.41%	61.20%
30	0.3215	50	0.3	64.91%	390	147	1,639	2,190	72.63%	57.20%	19.22%	93.71%	59.09%
30	0.2592	50	0.5	64.91%	413	124	1,803	2,026	76.91%	52.91%	18.64%	94.23%	55.86%
30	0.3304	50	0.1	64.91%	380	157	1,568	2,261	70.76%	59.05%	19.51%	93.51%	60.49%
30	0.3393	50	0.1	64.91%	380	157	1,568	2,261	70.76%	59.05%	19.51%	93.51%	60.49%
30	0.188	50	0.4	64.89%	394	143	1,669	2,160	73.37%	56.41%	19.10%	93.79%	58.50%
30	0.5351	50	0	64.89%	378	159	1,555	2,274	70.39%	59.39%	19.56%	93.46%	60.74%
30	0.4817	50	0.1	64.89%	385	152	1,605	2,224	71.69%	58.08%	19.35%	93.60%	59.76%
29	0.0456	50	0.1	64.89%	515	22	2,532	1,297	95.90%	33.87%	16.90%	98.33%	41.50%

Attribute	Learning Rate	Training Cycle	Momentum	Weight Mean Recall	True Drought Pred Drought	True Drought Pred no Drought	True no Drought Pred Drought	True no Drought Pred no Drought	Recall Drought	Recall no Drought	Precision Drought	Precision no Drought	Accuracy
27	0.188	50	0.2	64.89%	386	151	1,619	2,210	71.88%	57.72%	19.25%	93.60%	59.46%
30	0.3838	50	0	64.88%	374	163	1,527	2,302	69.65%	60.12%	19.67%	93.39%	61.29%
27	0.01	200	0.9	64.88%	335	202	1,249	2,580	62.38%	67.38%	21.15%	92.74%	66.77%
30	0.2236	50	0.3	64.88%	388	149	1,627	2,202	72.25%	57.51%	19.26%	93.66%	59.32%
30	0.1791	50	0.4	64.88%	394	143	1,670	2,159	73.37%	56.39%	19.09%	93.79%	58.47%
30	0.3393	200	0.4	64.88%	463	74	2,162	1,667	86.22%	43.54%	17.64%	95.75%	48.79%
30	0.544	50	0	64.88%	378	159	1,556	2,273	70.39%	59.36%	19.54%	93.46%	60.72%
29	0.0278	50	0.4	64.88%	515	22	2,533	1,296	95.90%	33.85%	16.90%	98.33%	41.48%
30	0.3037	50	0.3	64.87%	392	145	1,656	2,173	73.00%	56.75%	19.14%	93.74%	58.75%
30	0.2325	50	0	64.87%	376	161	1,542	2,287	70.02%	59.73%	19.60%	93.42%	60.99%
27	0.1079	100	0.1	64.87%	391	146	1,649	2,180	72.81%	56.93%	19.17%	93.72%	58.89%
23	0.7754	200	0.7	64.87%	483	54	2,305	1,524	89.94%	39.80%	17.32%	96.58%	45.97%
30	0.2859	50	0.1	64.87%	374	163	1,528	2,301	69.65%	60.09%	19.66%	93.38%	61.27%
21	0.01	50	0.8	64.87%	527	10	2,619	1,210	98.14%	31.60%	16.75%	99.18%	39.78%
21	0.0367	50	0.2	64.87%	526	11	2,612	1,217	97.95%	31.78%	16.76%	99.10%	39.92%
23	0.01	50	0.3	64.87%	433	104	1,949	1,880	80.63%	49.10%	18.18%	94.76%	52.98%
27	0.1346	50	0	64.86%	363	174	1,450	2,379	67.60%	62.13%	20.02%	93.18%	62.80%
30	0.3393	50	0.3	64.86%	393	144	1,664	2,165	73.18%	56.54%	19.11%	93.76%	58.59%

Attribute	Learning Rate	Training Cycle	Momentum	Weight Mean Recall	True Drought Pred Drought	True Drought Pred no Drought	True no Drought Pred Drought	True no Drought Pred no Drought	Recall Drought	Recall no Drought	Precision Drought	Precision no Drought	Accuracy
30	0.2236	50	0	64.86%	377	160	1,550	2,279	70.20%	59.52%	19.56%	93.44%	60.83%
28	0.01	50	0.1	64.86%	346	191	1,329	2,500	64.43%	65.29%	20.66%	92.90%	65.19%
24	0.0456	50	0.6	64.86%	481	56	2,292	1,537	89.57%	40.14%	17.35%	96.48%	46.22%
30	0.455	50	0	64.85%	371	166	1,508	2,321	69.09%	60.62%	19.74%	93.33%	61.66%
30	0.5262	200	0.5	64.85%	446	91	2,167	1,662	83.05%	43.41%	17.07%	94.81%	48.28%
30	0.2147	50	0	64.85%	376	161	1,544	2,285	70.02%	59.68%	19.58%	93.42%	60.95%
30	0.2681	50	0.3	64.85%	391	146	1,651	2,178	72.81%	56.88%	19.15%	93.72%	58.84%
30	0.2414	50	0	64.84%	374	163	1,530	2,299	69.65%	60.04%	19.64%	93.38%	61.22%
30	0.4016	50	0	64.84%	374	163	1,530	2,299	69.65%	60.04%	19.64%	93.38%	61.22%
30	0.277	50	0.4	64.84%	397	140	1,694	2,135	73.93%	55.76%	18.99%	93.85%	57.99%
30	0.2414	50	0.3	64.84%	388	149	1,630	2,199	72.25%	57.43%	19.23%	93.65%	59.25%
30	0.6686	200	0.7	64.84%	485	52	2,322	1,507	90.32%	39.36%	17.28%	96.66%	45.63%
30	0.1791	50	0.6	64.84%	408	129	1,773	2,056	75.98%	53.70%	18.71%	94.10%	56.44%
30	0.3304	50	0.4	64.84%	408	129	1,773	2,056	75.98%	53.70%	18.71%	94.10%	56.44%
24	0.0189	50	0.6	64.84%	469	68	2,208	1,621	87.34%	42.33%	17.52%	95.97%	47.87%
30	0.7576	200	0.6	64.83%	417	120	2,268	1,561	77.65%	40.77%	15.53%	92.86%	45.30%
30	0.5618	50	0	64.82%	377	160	1,553	2,276	70.20%	59.44%	19.53%	93.43%	60.77%
29	0.0545	50	0	64.82%	515	22	2,537	1,292	95.90%	33.74%	16.87%	98.33%	41.39%

Attribute	Learning Rate	Training Cycle	Momentum	Weight Mean Recall	True Drought Pred Drought	True Drought Pred no Drought	True no Drought Pred Drought	True no Drought Pred no Drought	Recall Drought	Recall no Drought	Precision Drought	Precision no Drought	Accuracy
30	0.2503	50	0.3	64.82%	389	148	1,639	2,190	72.44%	57.20%	19.18%	93.67%	59.07%
30	0.2236	50	0.5	64.82%	404	133	1,746	2,083	75.23%	54.40%	18.79%	94.00%	56.96%
27	0.1613	50	0.1	64.81%	379	158	1,568	2,261	70.58%	59.05%	19.47%	93.47%	60.47%
29	0.0189	50	0.6	64.81%	515	22	2,538	1,291	95.90%	33.72%	16.87%	98.32%	41.37%
30	0.2948	50	0.1	64.80%	374	163	1,533	2,296	69.65%	59.96%	19.61%	93.37%	61.15%
30	0.0723	50	0.8	64.80%	396	141	1,690	2,139	73.74%	55.86%	18.98%	93.82%	58.06%
21	0.0456	50	0	64.80%	526	11	2,617	1,212	97.95%	31.65%	16.74%	99.10%	39.81%
24	0.0367	50	0.2	64.80%	464	73	2,175	1,654	86.41%	43.20%	17.58%	95.77%	48.51%

ภาคผนวก ข

ตารางผลของแบบจำลองจาก RapidMiner

สามารถโหลดได้ที่: shorturl.at/mDEY5



ภาคผนวก ค

ตารางผลของแบบจำลอง Automated machine learning (AutoML)

ของ H_2O



model_id	mean per class error	auc	logloss	aucpr	rmse	mse	training time ms	predict time per row ms	algo
GBM_grid__1_AutoML_20210509_122220_model_1	0.4893	0.5628	0.5160	0.9080	0.3442	0.1185	1779	0.0121	GBM
GBM_grid__1_AutoML_20210509_122220_model_30	0.4896	0.5773	0.4597	0.9116	0.3391	0.1150	985	0.0098	GBM
GBM_grid__1_AutoML_20210509_122220_model_5	0.4911	0.5551	0.5418	0.8972	0.3457	0.1195	1676	0.0086	GBM
GBM_grid__1_AutoML_20210509_122220_model_22	0.4917	0.5663	0.5761	0.8981	0.3456	0.1194	1853	0.0095	GBM
GBM_3_AutoML_20210509_122220	0.4929	0.5803	0.4718	0.9100	0.3388	0.1148	1597	0.0179	GBM
GBM_grid__1_AutoML_20210509_122220_model_12	0.4931	0.5353	0.6904	0.9003	0.3539	0.1253	4429	0.0121	GBM
GBM_grid__1_AutoML_20210509_122220_model_41	0.4933	0.5600	0.6132	0.9066	0.3504	0.1228	3099	0.0121	GBM
GBM_grid__1_AutoML_20210509_122220_model_31	0.4935	0.5990	0.3986	0.9167	0.3336	0.1113	900	0.0133	GBM
GBM_4_AutoML_20210509_122220	0.4937	0.5722	0.4968	0.9073	0.3419	0.1169	1480	0.0128	GBM
GBM_grid__1_AutoML_20210509_122220_model_28	0.4939	0.5559	0.5376	0.9061	0.3466	0.1201	1742	0.0309	GBM
StackedEnsemble_BestOfFamily_AutoML_20210509_122220	0.4940	0.5702	0.5354	0.9105	0.3536	0.1250	652	0.0222	StackedEnsemble
GBM_grid__1_AutoML_20210509_122220_model_43	0.4944	0.5721	0.5334	0.9078	0.3429	0.1176	1886	0.0120	GBM
StackedEnsemble_AllModels_AutoML_20210509_122220	0.4947	0.5643	0.5168	0.9091	0.3646	0.1329	2170	0.0463	StackedEnsemble
GBM_grid__1_AutoML_20210509_122220_model_32	0.4948	0.5349	0.5824	0.8959	0.3455	0.1194	1750	0.0110	GBM
GBM_grid__1_AutoML_20210509_122220_model_13	0.4955	0.5486	0.5490	0.8961	0.3458	0.1196	1816	0.0089	GBM
GBM_grid__1_AutoML_20210509_122220_model_24	0.4957	0.5840	0.4612	0.9113	0.3392	0.1151	1074	0.0091	GBM
GBM_grid__1_AutoML_20210509_122220_model_20	0.4963	0.5970	0.5022	0.9142	0.3420	0.1169	1230	0.0076	GBM
GBM_grid__1_AutoML_20210509_122220_model_38	0.4963	0.5991	0.4531	0.9167	0.3387	0.1147	861	0.0075	GBM
GBM_grid__1_AutoML_20210509_122220_model_3	0.4963	0.5878	0.4898	0.9118	0.3406	0.1160	1031	0.0087	GBM

model_id	mean per class error	auc	logloss	aucpr	rmse	mse	training time ms	predict time per row ms	algo
GBM_grid__1_AutoML_20210509_122220_model_27	0.4963	0.5631	0.5324	0.8974	0.3441	0.1184	3087	0.0087	GBM
XRT_1_AutoML_20210509_122220	0.4965	0.5531	0.4730	0.9032	0.3364	0.1131	1064	0.0069	DRF
GBM_grid__1_AutoML_20210509_122220_model_39	0.4965	0.5707	0.4066	0.9114	0.3370	0.1135	925	0.0082	GBM
GBM_grid__1_AutoML_20210509_122220_model_14	0.4972	0.5752	0.4291	0.9104	0.3400	0.1156	1878	0.0090	GBM
GBM_grid__1_AutoML_20210509_122220_model_44	0.4975	0.5691	0.5145	0.9011	0.3422	0.1171	2185	0.0082	GBM
GBM_grid__1_AutoML_20210509_122220_model_8	0.4981	0.5650	0.5010	0.9058	0.3436	0.1181	1780	0.0081	GBM
GBM_grid__1_AutoML_20210509_122220_model_36	0.4981	0.5683	0.4866	0.9051	0.3412	0.1164	1129	0.0084	GBM
GBM_2_AutoML_20210509_122220	0.4981	0.5919	0.4301	0.9166	0.3374	0.1139	1372	0.0086	GBM
GBM_1_AutoML_20210509_122220	0.4991	0.5835	0.4333	0.9178	0.3393	0.1151	1465	0.0085	GBM
GBM_grid__1_AutoML_20210509_122220_model_9	0.4991	0.5911	0.4585	0.9138	0.3385	0.1146	959	0.0075	GBM
GBM_grid__1_AutoML_20210509_122220_model_7	0.4991	0.5672	0.5190	0.9038	0.3431	0.1177	1224	0.0091	GBM
GBM_grid__1_AutoML_20210509_122220_model_25	0.4991	0.5774	0.4074	0.9113	0.3376	0.1140	1027	0.0089	GBM
DeepLearning_grid__2_AutoML_20210509_122220_model_6	0.5000	0.5727	1.6463	0.9129	0.6685	0.4468	97397	0.0044	DeepLearning
GBM_grid__1_AutoML_20210509_122220_model_15	0.5000	0.5851	0.4420	0.9094	0.3371	0.1136	908	0.0079	GBM
GBM_grid__1_AutoML_20210509_122220_model_26	0.5000	0.5787	0.4292	0.9104	0.3389	0.1148	1048	0.0090	GBM
GBM_grid__1_AutoML_20210509_122220_model_45	0.5000	0.5708	0.4914	0.9016	0.3412	0.1164	1271	0.0083	GBM
DeepLearning_grid__3_AutoML_20210509_122220_model_10	0.5000	0.5141	1.0791	0.8966	0.6374	0.4063	59583	0.0047	DeepLearning
GBM_grid__1_AutoML_20210509_122220_model_40	0.5000	0.5411	0.3918	0.9018	0.3358	0.1128	481	0.0066	GBM
GBM_grid__1_AutoML_20210509_122220_model_18	0.5000	0.5735	0.4347	0.9104	0.3402	0.1157	1738	0.0099	GBM

model_id	mean per class error	auc	logloss	aucpr	rmse	mse	training time ms	predict time per row ms	algo
DeepLearning_grid__3_AutoML_20210509_122220_model_3	0.5000	0.4956	1.3297	0.8992	0.7210	0.5199	40042	0.0112	DeepLearning
GBM_grid__1_AutoML_20210509_122220_model_4	0.5000	0.5665	0.4968	0.9042	0.3436	0.1180	1700	0.0093	GBM
DeepLearning_grid__1_AutoML_20210509_122220_model_6	0.5000	0.5241	1.5459	0.9081	0.6549	0.4289	40139	0.0046	DeepLearning
GBM_grid__1_AutoML_20210509_122220_model_34	0.5000	0.6018	0.4520	0.9194	0.3387	0.1147	999	0.0089	GBM
DeepLearning_grid__2_AutoML_20210509_122220_model_8	0.5000	0.5932	0.9393	0.9212	0.5763	0.3321	73008	0.0055	DeepLearning
DeepLearning_grid__3_AutoML_20210509_122220_model_5	0.5000	0.7048	0.7714	0.9458	0.5221	0.2726	81483	0.0054	DeepLearning
GBM_grid__1_AutoML_20210509_122220_model_21	0.5000	0.5827	0.4234	0.9117	0.3377	0.1141	896	0.0086	GBM
GBM_grid__1_AutoML_20210509_122220_model_19	0.5000	0.5618	0.4408	0.9052	0.3402	0.1157	1649	0.0075	GBM
DeepLearning_grid__2_AutoML_20210509_122220_model_9	0.5000	0.6334	1.0014	0.9333	0.6145	0.3776	68504	0.0076	DeepLearning
GBM_grid__1_AutoML_20210509_122220_model_37	0.5000	0.5851	0.4136	0.9120	0.3370	0.1136	986	0.0131	GBM
GBM_grid__1_AutoML_20210509_122220_model_11	0.5000	0.5530	0.4096	0.9035	0.3379	0.1142	830	0.0078	GBM
DeepLearning_grid__3_AutoML_20210509_122220_model_9	0.5000	0.4284	1.0769	0.8724	0.6498	0.4222	63249	0.0069	DeepLearning
DeepLearning_grid__1_AutoML_20210509_122220_model_12	0.5000	0.4493	1.6217	0.8753	0.6578	0.4328	42244	0.0050	DeepLearning
DeepLearning_grid__2_AutoML_20210509_122220_model_7	0.5000	0.5029	1.6521	0.8892	0.7551	0.5702	75354	0.0047	DeepLearning
DeepLearning_grid__2_AutoML_20210509_122220_model_13	0.5000	0.6171	1.2391	0.9204	0.6826	0.4660	55295	0.0048	DeepLearning
DeepLearning_grid__1_AutoML_20210509_122220_model_7	0.5000	0.4018	1.4567	0.8596	0.6231	0.3882	42326	0.0048	DeepLearning
DeepLearning_grid__2_AutoML_20210509_122220_model_5	0.5000	0.5568	0.6945	0.9163	0.4854	0.2356	66161	0.0050	DeepLearning
DeepLearning_grid__1_AutoML_20210509_122220_model_1	0.5000	0.6232	1.5258	0.9183	0.6147	0.3779	80949	0.0063	DeepLearning
GBM_grid__1_AutoML_20210509_122220_model_23	0.5000	0.6037	0.4832	0.9144	0.3396	0.1153	966	0.0096	GBM

model_id	mean per class error	auc	logloss	aucpr	rmse	mse	training time ms	predict time per row ms	algo
DeepLearning_grid__1_AutoML_20210509_122220_model_13	0.5000	0.5775	1.3580	0.9101	0.6786	0.4604	39776	0.0089	DeepLearning
DeepLearning_grid__2_AutoML_20210509_122220_model_3	0.5000	0.6322	1.3120	0.9277	0.7193	0.5174	39176	0.0096	DeepLearning
DeepLearning_grid__3_AutoML_20210509_122220_model_14	0.5000	0.6215	1.0928	0.9269	0.6145	0.3776	270380	0.0107	DeepLearning
DeepLearning_grid__2_AutoML_20210509_122220_model_12	0.5000	0.5925	1.1077	0.9198	0.6435	0.4140	41325	0.0045	DeepLearning
DeepLearning_grid__1_AutoML_20210509_122220_model_15	0.5000	0.4955	1.4423	0.8957	0.6650	0.4423	63327	0.0050	DeepLearning
GBM_grid__1_AutoML_20210509_122220_model_42	0.5000	0.5801	0.4214	0.9117	0.3372	0.1137	874	0.0085	GBM
DeepLearning_grid__3_AutoML_20210509_122220_model_11	0.5000	0.5698	1.0823	0.9070	0.4374	0.1913	373642	0.0127	DeepLearning
GBM_grid__1_AutoML_20210509_122220_model_6	0.5000	0.5587	0.4013	0.9075	0.3368	0.1134	713	0.0070	GBM
GBM_grid__1_AutoML_20210509_122220_model_16	0.5000	0.5678	0.4418	0.9065	0.3408	0.1162	1220	0.0090	GBM
GBM_grid__1_AutoML_20210509_122220_model_10	0.5000	0.5814	0.4449	0.9074	0.3380	0.1142	742	0.0074	GBM
DeepLearning_grid__2_AutoML_20210509_122220_model_14	0.5000	0.5959	0.7902	0.9224	0.5102	0.2603	161722	0.0078	DeepLearning
DeepLearning_grid__2_AutoML_20210509_122220_model_4	0.5000	0.6103	1.1170	0.9247	0.5678	0.3224	229621	0.0084	DeepLearning
DeepLearning_1_AutoML_20210509_122220	0.5000	0.6773	0.5882	0.9404	0.4527	0.2050	450	0.0047	DeepLearning
DeepLearning_grid__3_AutoML_20210509_122220_model_4	0.5000	0.5410	0.7941	0.9054	0.4540	0.2061	382302	0.0118	DeepLearning
DeepLearning_grid__1_AutoML_20210509_122220_model_10	0.5000	0.4622	0.6713	0.8844	0.4745	0.2251	34500	0.0053	DeepLearning
GLM_1_AutoML_20210509_122220	0.5000	0.6637	0.3609	0.9372	0.3277	0.1074	787	0.0042	GLM
GBM_grid__1_AutoML_20210509_122220_model_2	0.5000	0.5559	0.4104	0.9055	0.3370	0.1136	958	0.0079	GBM
DeepLearning_grid__3_AutoML_20210509_122220_model_8	0.5000	0.5850	0.8510	0.9190	0.5242	0.2748	87769	0.0054	DeepLearning
DeepLearning_grid__2_AutoML_20210509_122220_model_10	0.5000	0.5804	1.1685	0.9169	0.6635	0.4403	45661	0.0057	DeepLearning

model_id	mean per class error	auc	logloss	aucpr	rmse	mse	training time ms	predict time per row ms	algo
DeepLearning_grid__1_AutoML_20210509_122220_model_4	0.5000	0.5158	0.7217	0.8938	0.3797	0.1441	81132	0.0057	DeepLearning
DeepLearning_grid__3_AutoML_20210509_122220_model_1	0.5000	0.5047	2.2076	0.8926	0.5999	0.3598	324137	0.0109	DeepLearning
DeepLearning_grid__3_AutoML_20210509_122220_model_7	0.5000	0.6216	0.6356	0.9247	0.4665	0.2176	141179	0.0060	DeepLearning
DeepLearning_grid__3_AutoML_20210509_122220_model_15	0.5000	0.6202	1.1662	0.9225	0.6102	0.3723	129920	0.0067	DeepLearning
DeepLearning_grid__1_AutoML_20210509_122220_model_8	0.5000	0.6620	0.5019	0.9364	0.3822	0.1460	43291	0.0051	DeepLearning
DeepLearning_grid__2_AutoML_20210509_122220_model_11	0.5000	0.5939	0.8061	0.9217	0.4316	0.1863	250291	0.0091	DeepLearning
DRF_1_AutoML_20210509_122220	0.5000	0.5839	0.4332	0.9166	0.3351	0.1123	979	0.0062	DRF
GBM_grid__1_AutoML_20210509_122220_model_35	0.5000	0.5694	0.4257	0.9102	0.3401	0.1157	1333	0.0100	GBM
DeepLearning_grid__2_AutoML_20210509_122220_model_1	0.5000	0.6122	0.9281	0.9154	0.3873	0.1500	180853	0.0101	DeepLearning
DeepLearning_grid__1_AutoML_20210509_122220_model_11	0.5000	0.6231	0.8945	0.9235	0.4570	0.2089	126387	0.0057	DeepLearning
DeepLearning_grid__1_AutoML_20210509_122220_model_14	0.5000	0.4733	0.6589	0.8840	0.4188	0.1754	78295	0.0053	DeepLearning
DeepLearning_grid__2_AutoML_20210509_122220_model_15	0.5000	0.5031	0.6446	0.8853	0.3551	0.1261	106238	0.0054	DeepLearning
DeepLearning_grid__3_AutoML_20210509_122220_model_2	0.5000	0.5006	1.3709	0.8941	0.7283	0.5304	32324	0.0039	DeepLearning
DeepLearning_grid__1_AutoML_20210509_122220_model_2	0.5000	0.5462	1.3443	0.9121	0.6792	0.4613	21700	0.0045	DeepLearning
GBM_grid__1_AutoML_20210509_122220_model_17	0.5000	0.5661	0.5462	0.9016	0.3459	0.1197	1782	0.0090	GBM
DeepLearning_grid__3_AutoML_20210509_122220_model_12	0.5000	0.6384	1.0279	0.9316	0.6319	0.3992	64944	0.0043	DeepLearning
GBM_grid__1_AutoML_20210509_122220_model_33	0.5000	0.5348	0.3939	0.8979	0.3359	0.1128	523	0.0066	GBM
DeepLearning_grid__1_AutoML_20210509_122220_model_3	0.5000	0.6894	0.7733	0.9431	0.5306	0.2815	23076	0.0042	DeepLearning
DeepLearning_grid__2_AutoML_20210509_122220_model_2	0.5000	0.5652	1.1702	0.9094	0.6765	0.4576	41558	0.0038	DeepLearning

model_id	mean per class error	auc	logloss	aucpr	rmse	mse	training time ms	predict time per row ms	algo
GBM_grid__1_AutoML_20210509_122220_model_46	0.5000	0.5654	0.4513	0.9074	0.3412	0.1164	2206	0.0162	GBM
DeepLearning_grid__1_AutoML_20210509_122220_model_5	0.5000	0.5598	1.2412	0.9141	0.6252	0.3909	68782	0.0046	DeepLearning
DeepLearning_grid__3_AutoML_20210509_122220_model_6	0.5000	0.5425	2.0822	0.9124	0.6823	0.4656	73526	0.0053	DeepLearning

ประวัติผู้เขียน

ชื่อ-นามสกุล

นางสาววีรภัทรา เจริญกิจสุพัฒน์

ประวัติการศึกษา

วิทยาศาสตร์บัณฑิต

สาขาคณิตศาสตร์

มหาวิทยาลัยมหิดล

ปีการศึกษา 2559

