

CSC662 ปฏิบัติการ ๖

ตัวกรองที่ใช้ในซอฟต์แวร์ Weka

เขียนโดย ผศ. ดร. กรุง สินอภิรัมย์สราญ

ภาควิชาคณิตศาสตร์ คณะวิทยาศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

เนื้อหาที่ครอบคลุม

- ตัวกรองในซอฟต์แวร์ Weka
- การกำจัดลักษณะประจำ
- ตัวกรองแบบอัตโนมัติ Supervised filter
 - ลักษณะประจำ
 - ระเบียน

- ตัวกรองที่ผู้ใช้กำหนดเอง Unsupervised filter
 - ลักษณะประจำ
 - ระเบียน

2

Weka filter

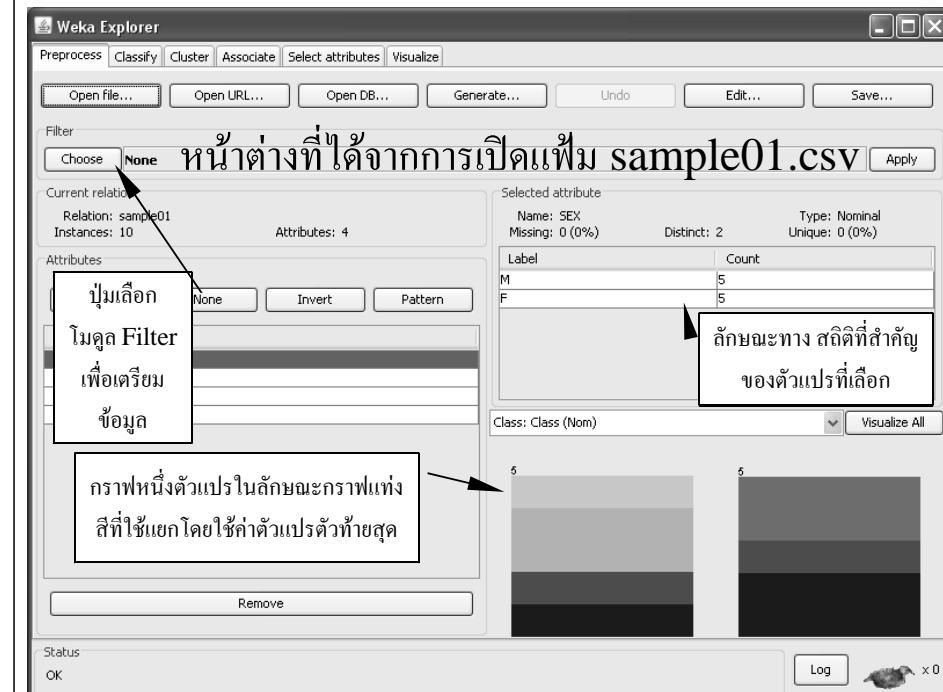
ตัวอย่างไฟล์ข้อมูล sample01.csv

ID,SEX,PASS/FAIL,Score,Class

1	M	Pass	45.5	B
2	F	Pass	56.78	B
3	M	Pass	89	A
4	F	Pass	77	A
5	M	Fail	32	C
6	F	Fail	12	D
7	M	Fail	35	C
8	F	Pass	62	B
9	M	Pass	68	B+
10	F	Fail	10	D

3

Weka filter

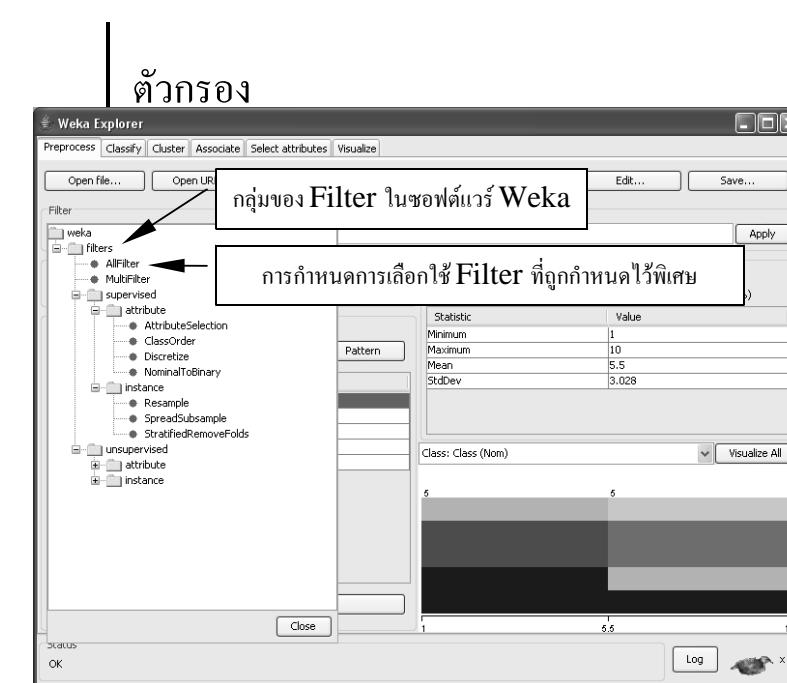


การใช้ตัวกรองในซอฟต์แวร์ Weka

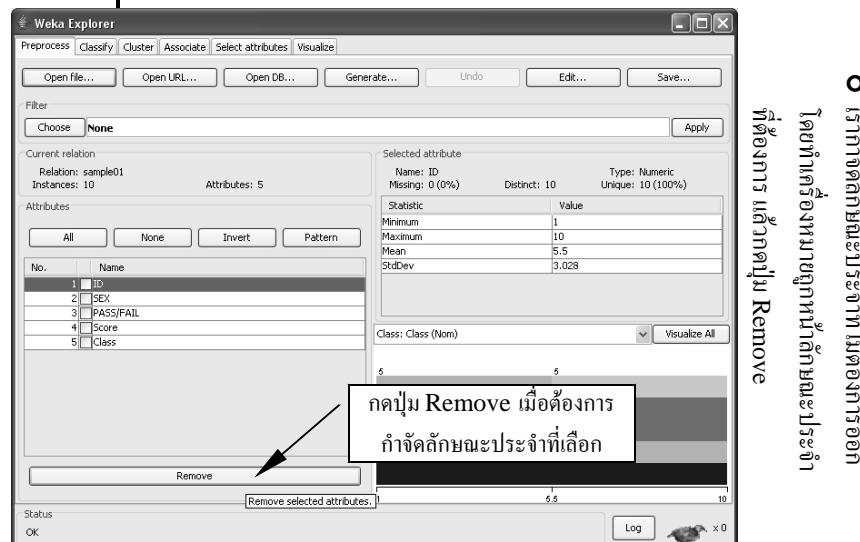
- ตัวกรอง (Filters) รวมรวมโน้มถ่วงในขั้นการเตรียมข้อมูล
- ตัวกรองแบ่งออกเป็นสองลักษณะคือ
 - Supervised รวมโน้มถ่วงที่เปล่งข้อมูลแบบอัตโนมัติที่มีการควบคุมด้วยพารามิเตอร์ที่ผู้ใช้กำหนด แบ่งเป็นสองหมวดใหญ่ คือลักษณะประจำ (attribute) กับข้อมูลแต่ละระเบียน (instance)
 - Unsupervised รวมโน้มถ่วงที่เปล่งข้อมูลที่ผู้ใช้กำหนดเอง แบ่ง เป็นสองหมวดใหญ่คือ ลักษณะประจำ (attribute) กับข้อมูล แต่ละระเบียน (instance)

5

Weka filter



การกำจัดลักษณะประจำ



● เราได้กดปุ่ม 'Remove' ที่มีต้องการลบ
โดยทำเครื่องหมายหน้าปุ่ม 'Remove' ที่ต้องการ เส้นทางคุณ 'Remove'

ตัวกรองแบบอัตโนมัติ Supervised

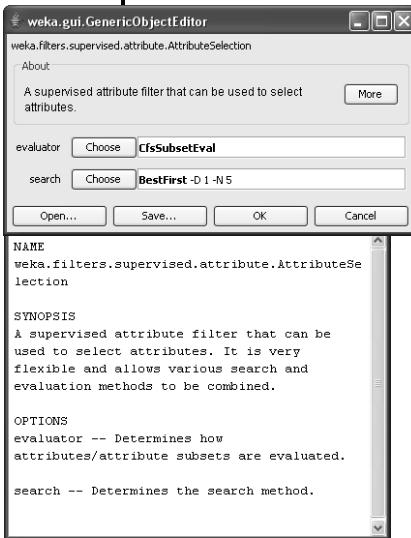
○ ประกอบด้วย

- ลักษณะประจำ: AttributeSelection, ClassOrder, Discretize, NominalToBinary
- ระเบียน: Resample, SpreadSubsample, StratifiedRemoveFolds

8

Weka filter

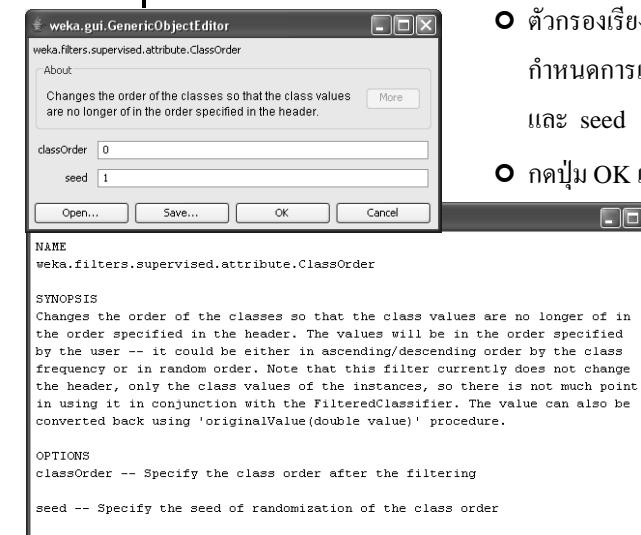
AttributeSelection



- ตัวกรองที่เลือกลักษณะประจำที่นำ
มาวิเคราะห์แบบอัตโนมัติ โดยผู้ใช้
กำหนดตัวประเมินในกล่อง
evaluator และวิธีการค้นในกล่อง
search
- กดปุ่ม OK
- แล้วกดปุ่ม Apply

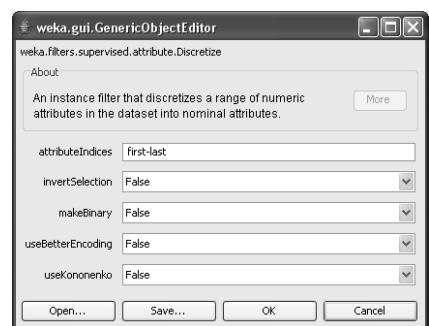
Weka filter

ClassOrder



- ตัวกรองเรียงลำดับคลาส โดยผู้ใช้
กำหนดการเรียงในกล่อง classOrder
และ seed
- กดปุ่ม OK และกดปุ่ม Apply

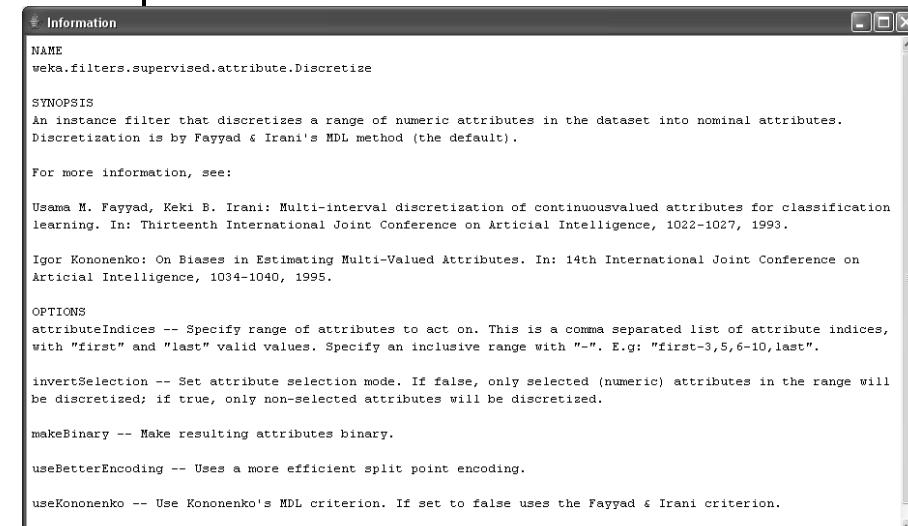
Discretize



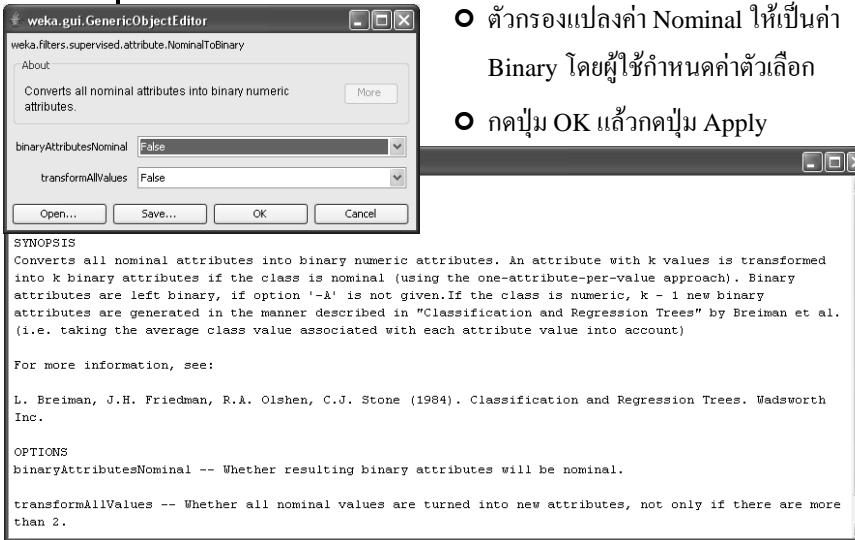
- ตัวกรองแปลงค่าต่อเนื่องให้เป็นค่าไม่
ต่อเนื่อง โดยผู้ใช้เลือกลักษณะประจำที่
ต้องการเปลี่ยนในกล่อง
attributeIndices และผู้ใช้กำหนดตัว
เลือกโดยดู Help ในหน้าตัวไป
- กดปุ่ม OK
- แล้วกดปุ่ม Apply

Weka filter

Discretize Help

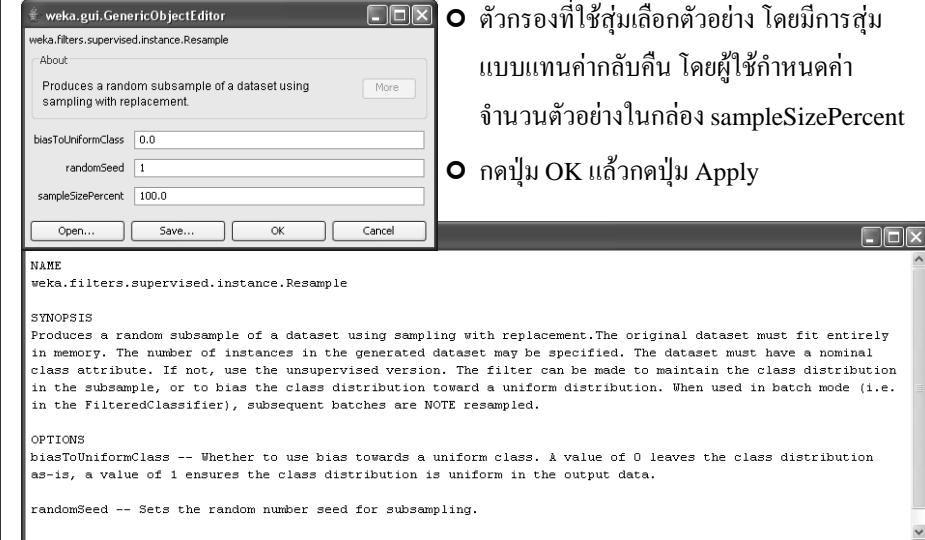


NominalToBinary



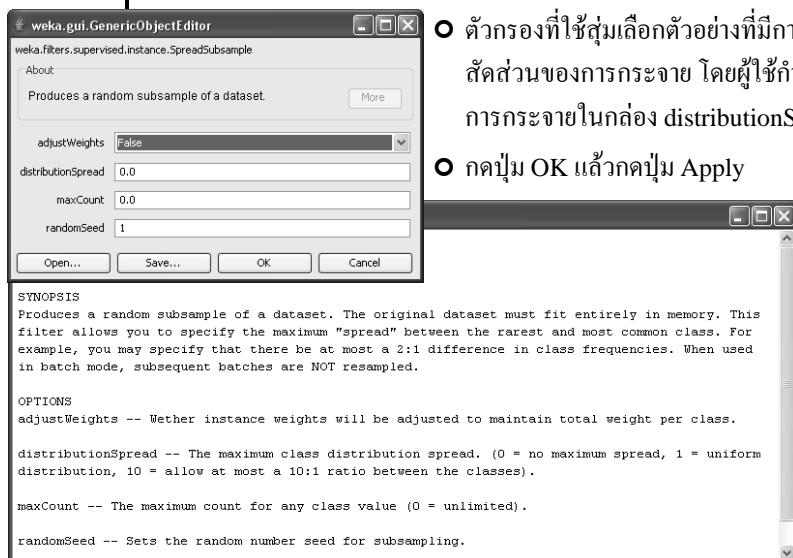
- ตัวกรองแปลงค่า Nominal ให้เป็นค่า Binary โดยผู้ใช้กำหนดค่าตัวเลือก
- กดปุ่ม OK แล้วกดปุ่ม Apply

Resample



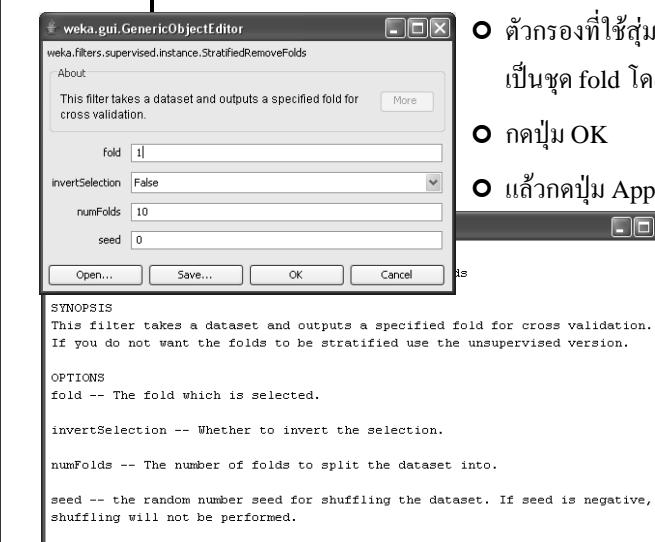
- ตัวกรองที่ใช้สุ่มเลือกตัวอย่าง โดยมีการสุ่มแบบแทนค่ากลับคืน โดยผู้ใช้กำหนดค่าจำนวนตัวอย่างในคล่อง sampleSizePercent
- กดปุ่ม OK แล้วกดปุ่ม Apply

SpreadSubsample



- ตัวกรองที่ใช้สุ่มเลือกตัวอย่างที่มีการกำหนดสัดส่วนของการกระจาย โดยผู้ใช้กำหนดค่าการกระจายในคล่อง distributionSpread
- กดปุ่ม OK แล้วกดปุ่ม Apply

StratifiedRemoveFolds



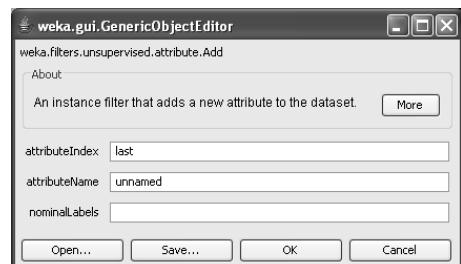
- ตัวกรองที่ใช้สุ่มเลือกกลุ่มตัวอย่างออกเป็นชุด fold โดยผู้ใช้กำหนดค่าตัวเลือก
- กดปุ่ม OK
- แล้วกดปุ่ม Apply

ตัวกรองที่ผู้ใช้กำหนดเอง Unsupervised

- เราจะเลือกอธิบายตัวกรองบางตัวเท่านั้น สำหรับตัวกรองอื่น ผู้ใช้สามารถอ่านได้จาก Help ของซอฟต์แวร์ Weka
- ลักษณะประจำ: Add, AddCluster, AddExpression, AddNoise, ClusterMembership, Copy, Discretize, FirstOrder, MakeIndicator, MergeTwoValues, NominalToBinary, Normalize, NumericToBinary, NumericTransform, Obfuscate, PKIDiscretize, RandomProjection, Remove, RemoveType, RemoveUseless, ReplaceMissingValues, Standardize, StringToNominal, StringToWordVector, SwapValues, TimeSeriesDelta, TimeSeriesTranslate
- ระเบียบ: Normalize, NonSparseToSparse, Randomize, RemoveFolds, RemoveMisclassified, RemovePercentage, RemoveRange, RemoveWithValues, Resample, SparseToNonSparse

17

Weka filter



- ตัวกรองเพิ่มลักษณะประจำ เลือก add โดยเพิ่มลักษณะประจำที่มีค่าตั้งต้นคือ missing value
- กดปุ่ม OK
- แล้วกดปุ่ม Apply

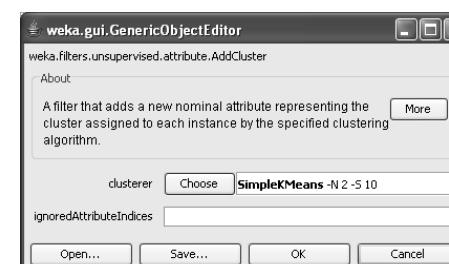
Add filter

ตัวกรองที่ผู้ใช้กำหนดเองกับลักษณะประจำ

- Add filter
- AddCluster filter
- AddExpression filter
- Discretize filter
- NominalToBinary filter
- Normalize filter
- NumericToBinary filter
- NumericTransform filter
- Remove filter
- ReplaceMissingValues filter
- Standardize filter

18

Weka filter



AddCluster filter

- ตัวกรองเพิ่มลักษณะประจำตามการเก็บกลุ่ม เลือก addCluster เลือกวิธีการเก็บกลุ่ม เช่น SimpleKMeans
- กำหนดลักษณะประจำที่ไม่นำมาใช้ในการวิเคราะห์การเก็บกลุ่มใน ignoredAttributeIndices
- กดปุ่ม OK
- แล้วกดปุ่ม Apply

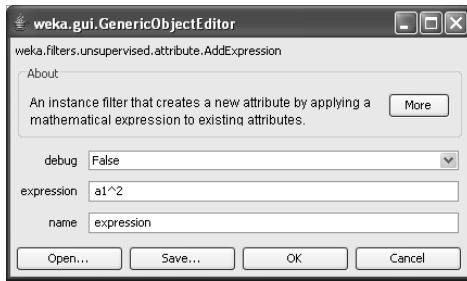
19

Weka filter

20

Weka filter

AddExpression filter

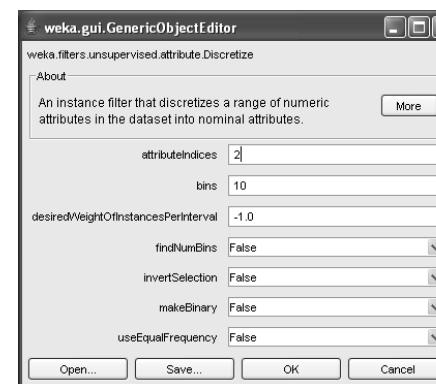


21

Weka filter

- ตัวกรองเพิ่มลักษณะประจำตามนิพจน์ จากลักษณะประจำที่กำหนด เลือก addExpression พิมพ์นิพจน์ที่ต้องการสร้างลักษณะประจำใหม่
- กดปุ่ม OK
- แล้วกดปุ่ม Apply

Discretize filter

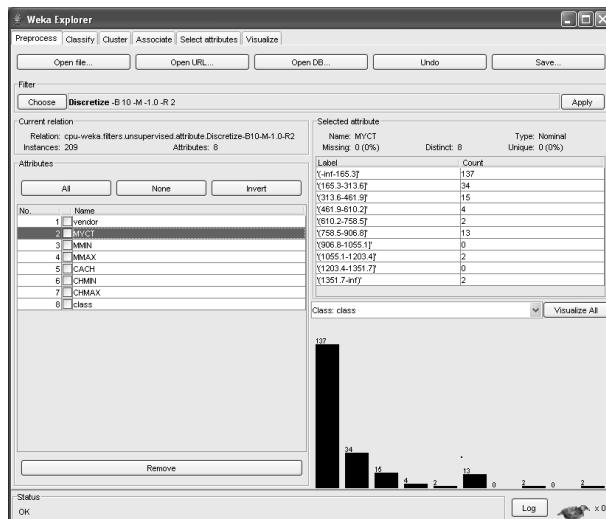


22

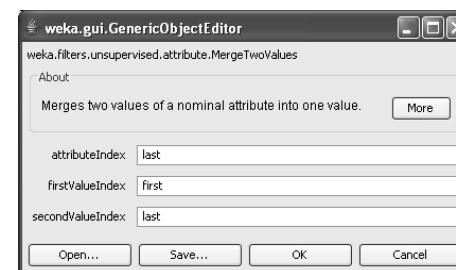
Weka filter

- ตัวกรองแปลงเป็นค่าไม่ต่อเนื่อง ผู้ใช้เลือกลักษณะประจำในช่อง attributeIndices ตามลำดับลักษณะประจำที่กำหนด
- กำหนดจำนวนกล่องที่ต้องการใน bins
- เราสามารถแบ่งแบบ equal width หรือ equal depth โดยปรับเป็น False ที่ useEqualFrequency
- กดปุ่ม OK
- แล้วกดปุ่ม Apply

ผลการใช้ตัวกรอง Discretize



MergeTwoValues filter

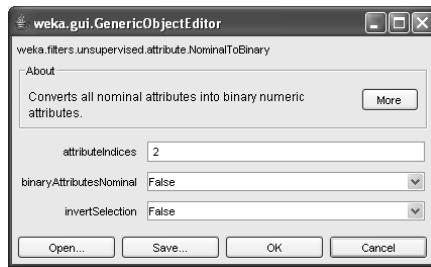


24

Weka filter

- ตัวกรองรวมค่าสองค่าเป็นหนึ่ง เลือก MergeTwoValues
- กำหนดครรชนิของลักษณะประจำใน attributeIndex
- กำหนดค่าใน firstValueIndex และ secondValueIndex
- กดปุ่ม OK
- แล้วกดปุ่ม Apply

NominalToBinary filter

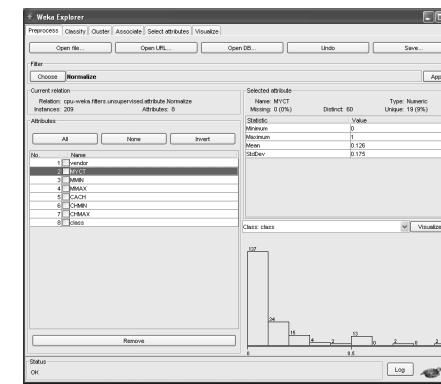


25

- เลือกตัวกรองแปลงค่าไม่ต่อเนื่องเป็นค่า 0 หรือ 1 เลือก NominalToBinary
- กำหนดคุณชนะประจำใน attributeIndices ที่ต้องการ
- กดปุ่ม OK
- แล้วกดปุ่ม Apply

Weka filter

Normalize filter



26

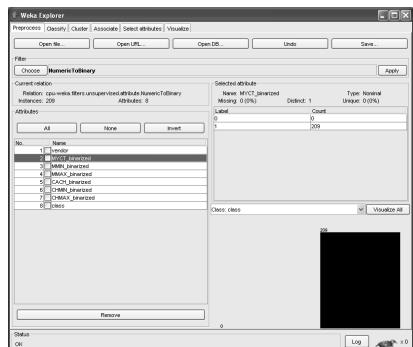
- ตัวกรองเปลี่ยนค่ามาตรฐานเลือก Normalize เพื่อปรับถักยนะประจำทุกคุณชนะประจำจำพวกถักยนะประจำที่เป็นจำนวน จะถูกแปลงให้มีค่าอยู่ในช่วง 0-1 โดยใช้สูตร

$$v'_i = \frac{v_i - \min_A}{\max_A - \min_A}$$

- กดปุ่ม Apply

Weka filter

NumericToBinary filter

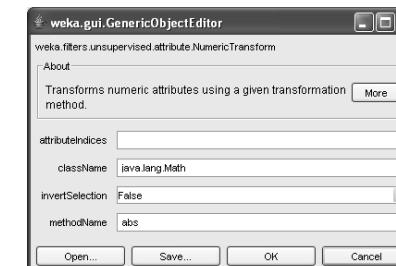


27

- ตัวกรองแปลงข้อมูลจำนวนให้เป็นค่า 0 หรือ 1 เลือก NumericToBinary โดยเปลี่ยนทุกคุณชนะประจำที่เป็นจำนวน ค่าจำนวนที่เป็น 0 จะยังคงค่า 0 แต่ค่าที่ไม่ใช่ 0 จะเปลี่ยนเป็น 1 ทั้งหมด
- กดปุ่ม Apply

Weka filter

NumericTransform filter

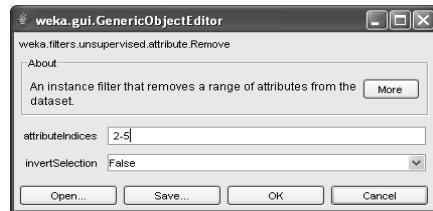


28

- ตัวกรองแปลงโดยใช้ฟังก์ชันจำนวน เลือก NumericTransform จะแปลงค่าในลักษณะประจำตามฟังก์ชันที่กำหนด เช่น abs
- กดปุ่ม OK
- แล้วกด Apply

Weka filter

Remove filter

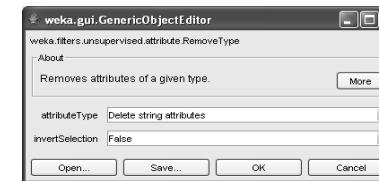


29

Weka filter

- ตัวกรองกำจัดลักษณะประจำ เลือก Remove โดย attributeIndices
- กดปุ่ม OK
- แล้วกดปุ่ม Apply

RemoveType filter

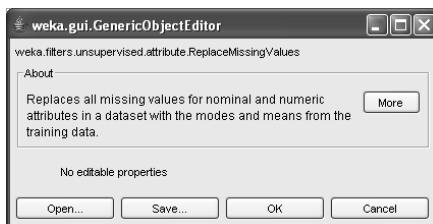


30

Weka filter

- ตัวกรองกำจัดลักษณะประจำตามชนิดของลักษณะประจำ เลือก RemoveType โดยเลือกชนิดที่ต้องการกำจัดใน attributeType
- กดปุ่ม OK
- แล้วกดปุ่ม Apply

ReplaceMissingValue

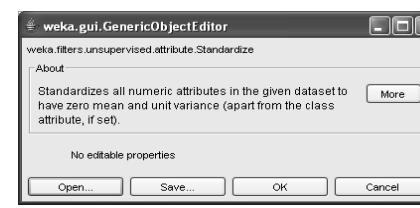


31

Weka filter

- ตัวกรองการแทนค่าที่ขาดหายไปเลือก ReplaceMissingValue
 - แทนด้วยค่าเฉลี่ยสำหรับลักษณะประจำที่เป็นจำนวน
 - แทนด้วยฐานนิยมสำหรับลักษณะประจำที่เป็นค่าไม่ต่อเนื่อง
- กดปุ่ม OK
- แล้วกดปุ่ม Apply

Standardize filter



32

Weka filter

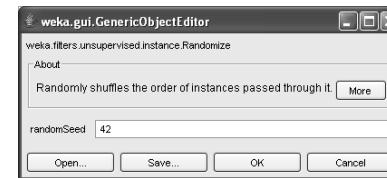
- ตัวกรองเปลี่ยนข้อมูลให้อยู่ในรูปที่มีการแจกแจงมาตรฐาน โดยใช้ z-score โดยเลือก Standardize
$$v'_i = \frac{v_i - \bar{V}}{std_A}, \bar{V} = \sum_{i=1}^n v_i$$
$$std_A = \sqrt{\frac{\sum_{i=1}^n (v_i - \bar{V})^2}{n-1}}$$
- กดปุ่ม OK
- แล้วกดปุ่ม Apply

ตัวกรองที่ตัวกรองที่ผู้ใช้กำหนดเองกับระเบียน

- Randomize
- RemoveFolds
- RemovePercentage
- RemoveRange
- RemoveWithValues
- Resample

33

Weka filter

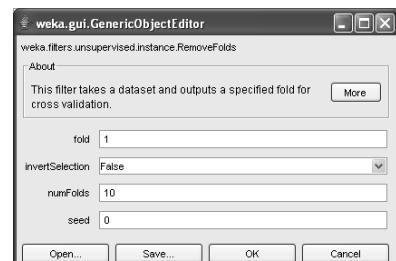


34

Weka filter

- ตัวกรองสลับสุ่ม เลือก Randomize เพื่อให้มีการเรียงระเบียนแบบสุ่ม
- กดปุ่ม OK
- แล้วกดปุ่ม Apply

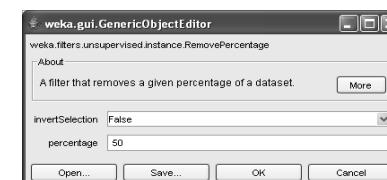
RemoveFold filter



- ตัวกรองกำจัดชุดระเบียน เลือก RemoveFold เพื่อกำจัดชุดข้อมูลตามจำนวนชุด ตามจำนวนชุดทั้งหมดใน numFolds
- กดปุ่ม Save เพื่อบันทึกชุดระเบียน
- กดปุ่ม OK
- แล้วกดปุ่ม Apply

35

Weka filter



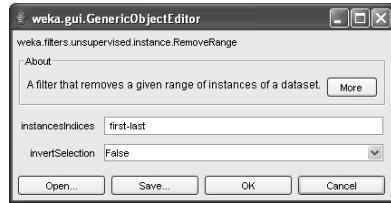
36

Weka filter

RemovePercentage filter

- ตัวกรองกำจัดระเบียนตามเปอร์เซ็นต์ เลือก RemovePercentage เพื่อลดจำนวนข้อมูลโดยเอาออกเท่ากับจำนวนเปอร์เซ็นต์ที่กำหนดใน percentage
- กดปุ่ม OK
- แล้วกดปุ่ม Apply

RemoveRange filter

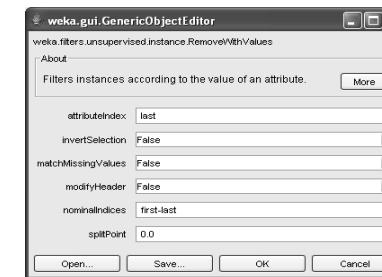


37

- ตัวกรองกำจัดrangeในพิสัยที่กำหนด
เลือก RemoveRange เพื่อลดจำนวน
ข้อมูลที่กำหนดใน instancesindices
- กดปุ่ม OK
- แล้วกดปุ่ม Apply

Weka filter

RemoveWithValues filter

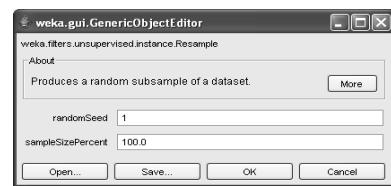


38

- ตัวกรองกำจัดข้อมูลตามค่า เลือก
RemoveWithValues เพื่อลดจำนวน
ข้อมูลออกโดยใช้ attributeIndex
- ค่าที่ตั้งกว่า splitPoint จะถูกกำจัดทิ้ง
- กดปุ่ม OK
- แล้วกดปุ่ม Apply

Weka filter

Resample filter



39

- ตัวกรองสุ่มใหม่ เลือก Resample เพื่อ^{ให้มีการสุ่มข้อมูลใหม่ โดยกำหนดเป็น}
เปอร์เซ็นต์ใน sampleSizePercent
- กดปุ่ม save เพื่อบันทึกข้อมูล
- กดปุ่ม OK
- แล้วกดปุ่ม Apply

Weka filter

สรุป

- ไม่คลุ่นในการเตรียมข้อมูลในซอฟต์แวร์ Weka เรียก ตัวกรอง (Filters) แบ่งออกเป็น
 - Supervised
 - Unsupervised
- นอกจากนี้เราเลือกใช้ตัวกรองกับลักษณะประจำ หรือระเบียน

40

Weka filter