



FAKULTÄT FÜR
INFORMATIK

Feature Selection / Preprocessing

Was ist Feature Selection?

Dataset Details

Add Preprocessing Step

Algorithm: Projections

Dimensions: x₀ x₁ x₂ x₃ x₄ x₅ x₆
 x₇ x₈ x₉ x₁₀ x₁₁ x₁₂ all

Close **+ Add**

Prep

<n

+ Add Preprocessing Step **✕ Clear Preprocessing Pipeline**

Scatter Plot

Sample Size: **Apply**

Dimensions: x₀ x₁ x₂ x₃ x₄ x₅ x₆ x₇ x₈ x₉ x₁₀ x₁₁ x₁₂



Warum Feature Selection?

- Mehr Variablen führen nicht automatisch zu besseren Ergebnissen.
 - Lernen von unwichtigen Daten
 - Mehr Daten notwendig
- Komplexität steigt.
- Datenmessung wird aufwändiger.
- Verständnispotenzial sinkt.

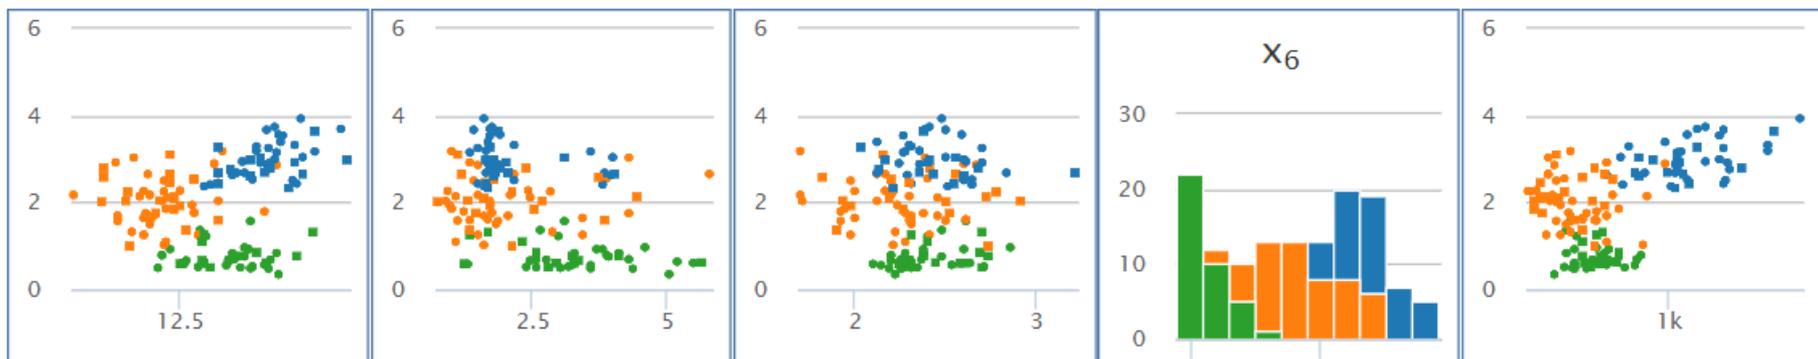
Wrapper-Methoden

- Testen Feature-Set anhand der Qualität einer Klassifikation.
- Klassifikator als Black Box
- Definiere:
 - Wie wird der Untermengen-Raum abgesucht?
 - Wie wird das Ergebnis einer Klassifikation evaluiert?
 - Welcher Klassifikator wird benutzt?
- Ergebnis an Klassifikator angepasst
- Nachteil: (Potenziell) sehr rechenaufwändig
- Beispiel: Beurteile Subset nach Test / Validierung

50530	Wine	kNN	distance: "euclidean" k: 5 weights: "uniform"	0.636	-	edit Clone Job Submit Job
50551	Wine	kNN	distance: "euclidean" k: 5 weights: "distance"	0.955	0.841	edit Clone Job

Filter-Methoden

- Testen Feature-Set anhand statistischer Eigenschaften in den Daten.
- Klassifikator nicht nötig.
- Definiere:
 - Wie wird der Untermengen-Raum abgesucht?
 - Wie wird die Nützlichkeit eines Subsets berechnet?
- Ergebnis für verschiedene Klassifikatoren nutzbar.
- Vorteil: (Potenziell) schnell
- Beispiel: Beurteile Subset nach visueller Begutachtung



Filter-Methoden 2

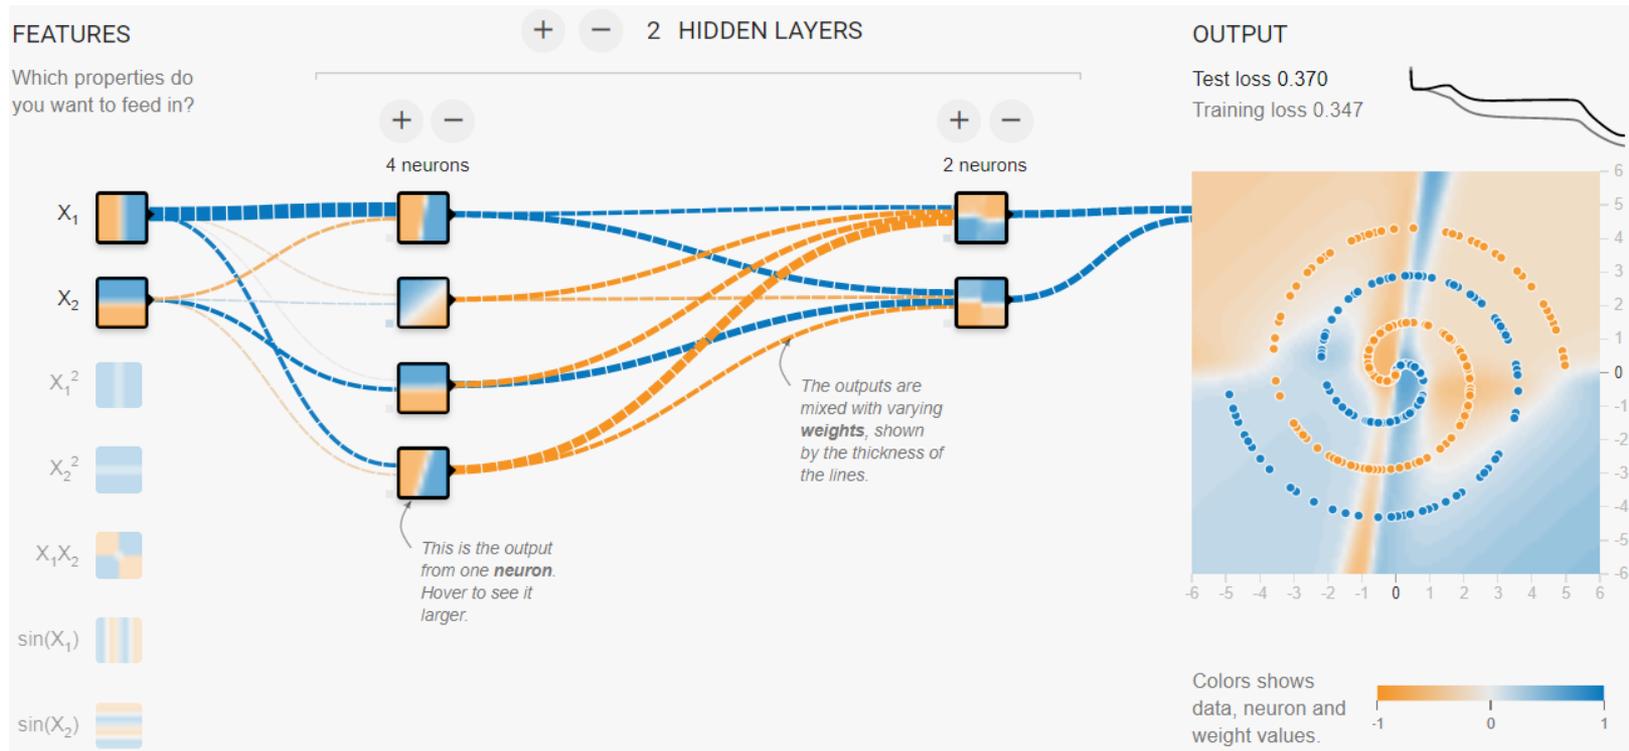
- Transinformation (Mutual Information):

- $$I(X, Y) = \sum_{y \in Y} \sum_{x \in X} p(x, y) \times \log\left(\frac{p(x, y)}{p(x) \times p(y)}\right)$$

- Integral für kontinuierliche Werte
 - 0 für unabhängige Variablen
 - Steigt mit zunehmender Abhängigkeit
 - Vergleiche Transinformation zwischen jeder Variable und der Klassifikation.

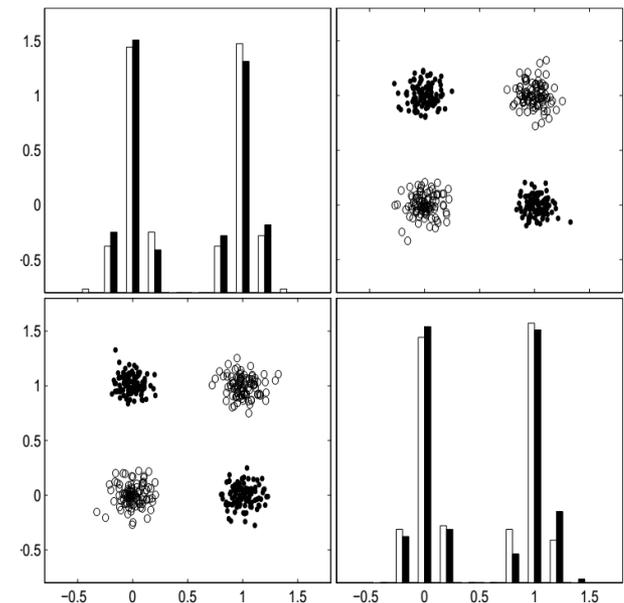
Embedded-Methoden

- Bauen Feature-Sets während des Lernens auf.
- In den Klassifikator integriert.
- Vorteil: (Potenziell) schnell
- Beispiel: Neuronale Netze



Wie wählt man Feature Sets zum Testen aus?

- Klassisch:
 - Forward Selection: Starte bei 0, füge das Element hinzu, das den größten Gewinn an Genauigkeit bringt
 - Backward Elimination: Starte bei allen, entferne das Element, bei dem die Genauigkeit am geringsten abnimmt.
 - Setze einen Grenzwert für Zu-/Abnahme der Genauigkeit, um das Verfahren zu beenden.
- Problem:
 - Variablen von geringem Einzelnutzen können gemeinsam nützlich sein.
 - Redundante Variablen erkennen ist aufwändig.
 - Lösung: Ensemble Methods

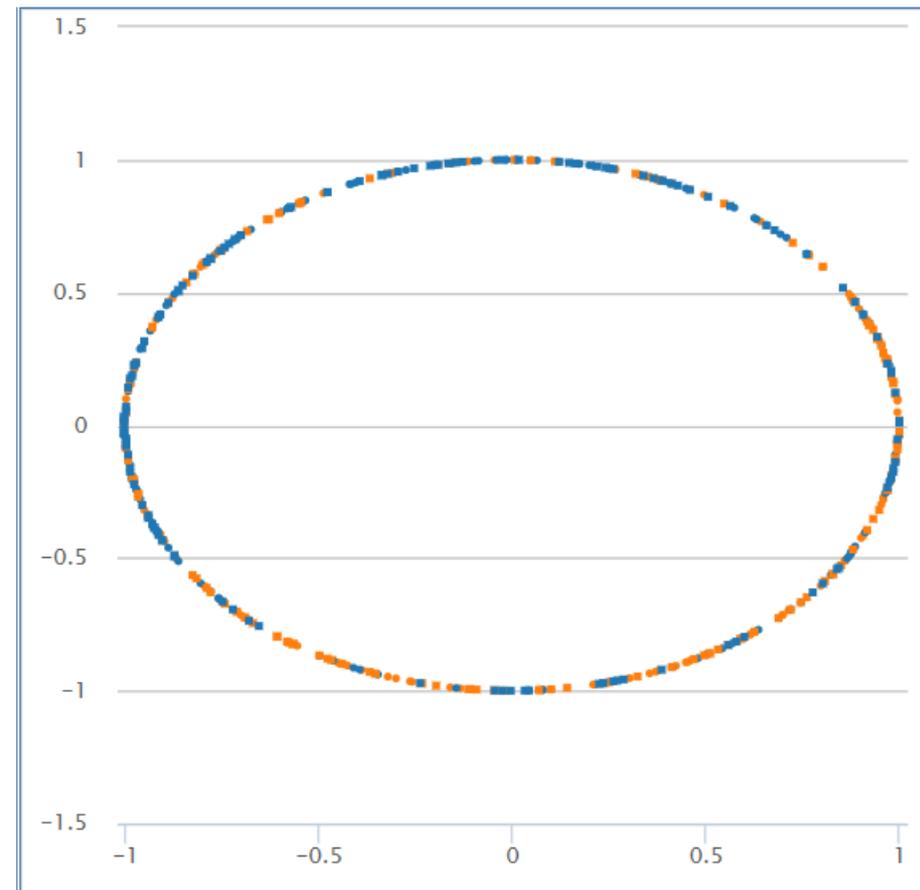
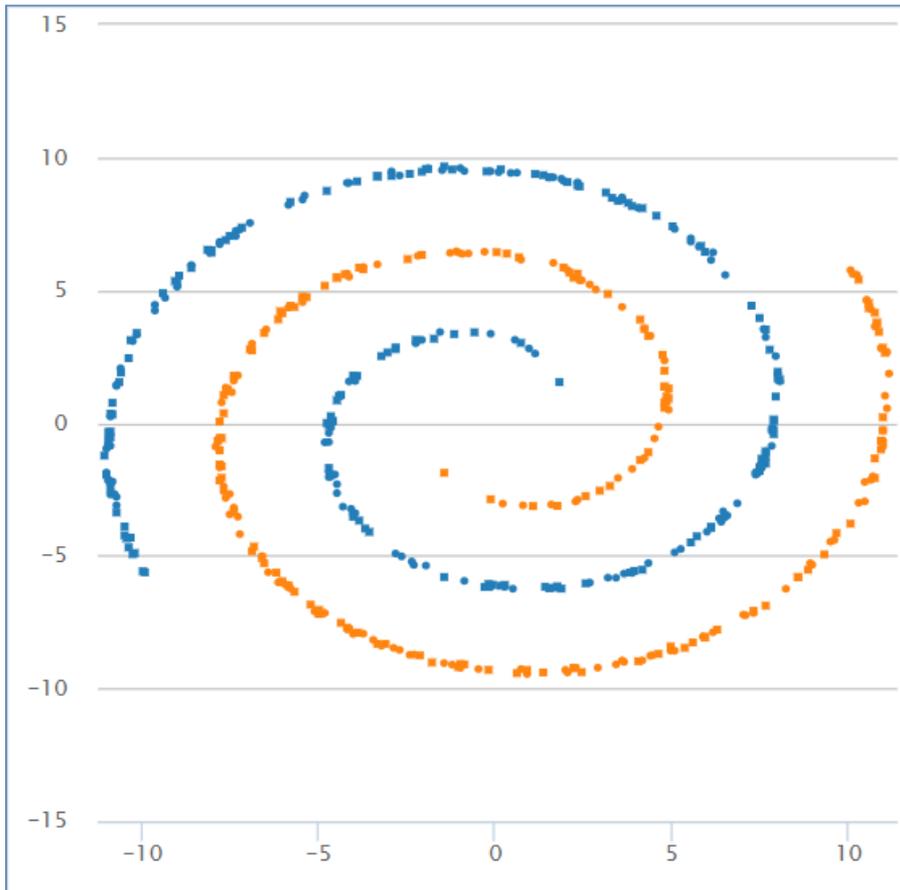


Weitere mögliche Preprocessing-Schritte

- Normalizer
- Standardizer
- Min-Max
- Principle Component Analysis (PCA)

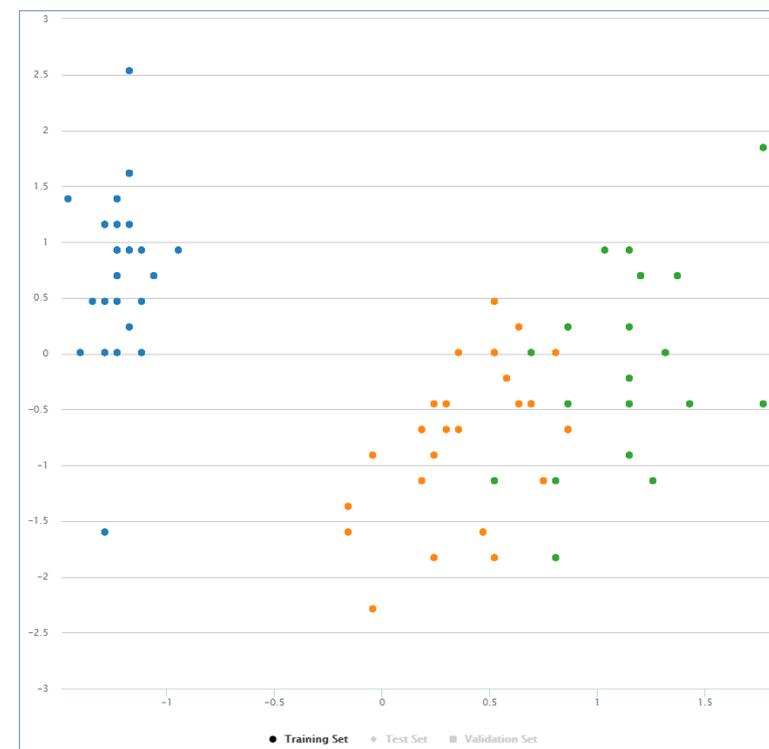
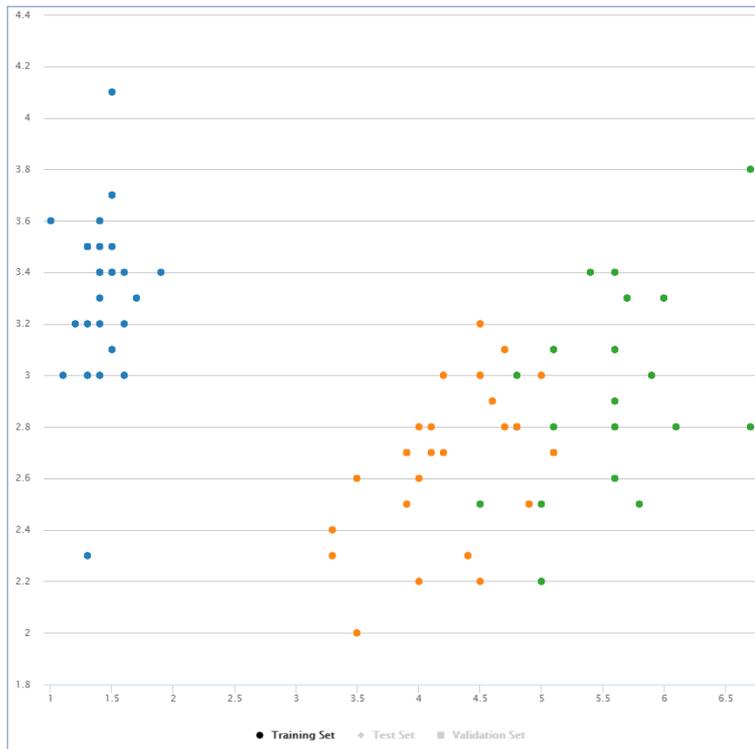
Normalizer

- Bringt die Länge der Vektoren auf 1.
- Gut, wenn sie unwichtig ist, zum Beispiel bei Textklassifikation.



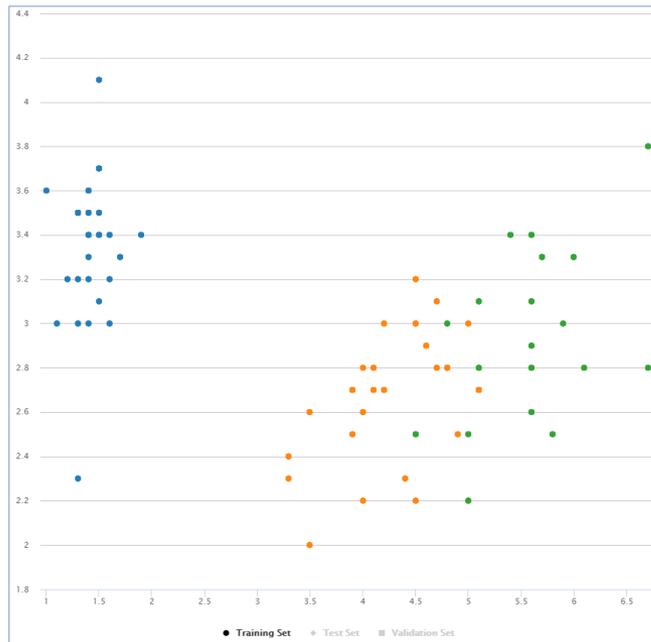
Standardizer

- Bringt den Durchschnitt der Trainingsdaten auf 0, die Varianz auf 1.
- Macht die Dimensionen vergleichbar.
- Vorteil: Ausreißer beeinflussen die Skalierung kaum.
- Nachteil: Die Intervalle müssen nicht gleich sein.

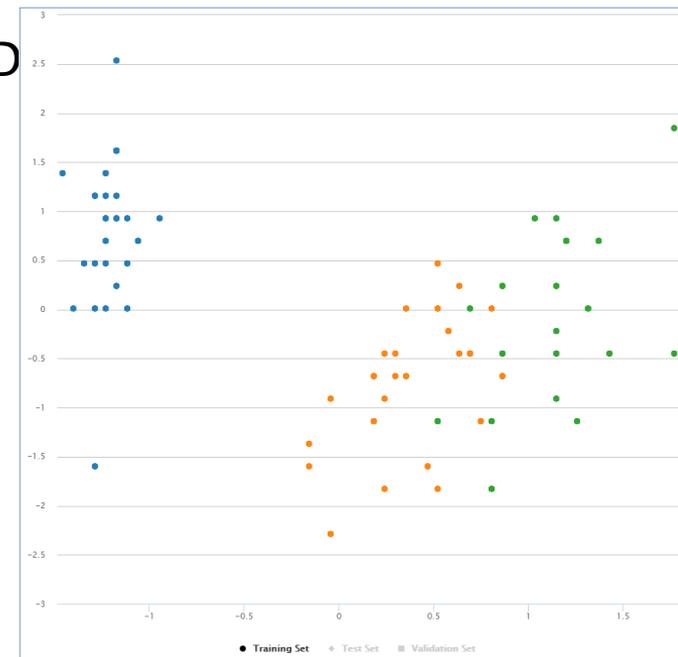


Min-Max Scaling

- Bringt die Trainingsdaten auf ein vorgegebenes Intervall.
- Macht die Dimensionen vergleichbar.
- Nachteil: Ausreißer beeinflussen die Skalierung stark.
- Nachteil: Validierungsdaten können außerhalb des Intervalls liegen.
- Nachteil: Für viele Algorithmen unbrauchbar, z.B. SVM, kNN



en Netzen: Brauchen D



Vielen Dank für Ihre Aufmerksamkeit!

www.ovgu.de