Maschinelles Lernen mit RapidMiner

technische universität dortmund

Fakultät Informatik
Lehrstuhl für Künstliche Intelligenz

Inhalt

- Motivation / Ziel
- Konzept von RapidMiner
- Beispiele
- Details, Implementierung
  - ExampleSet, Attribute
  - Übungen

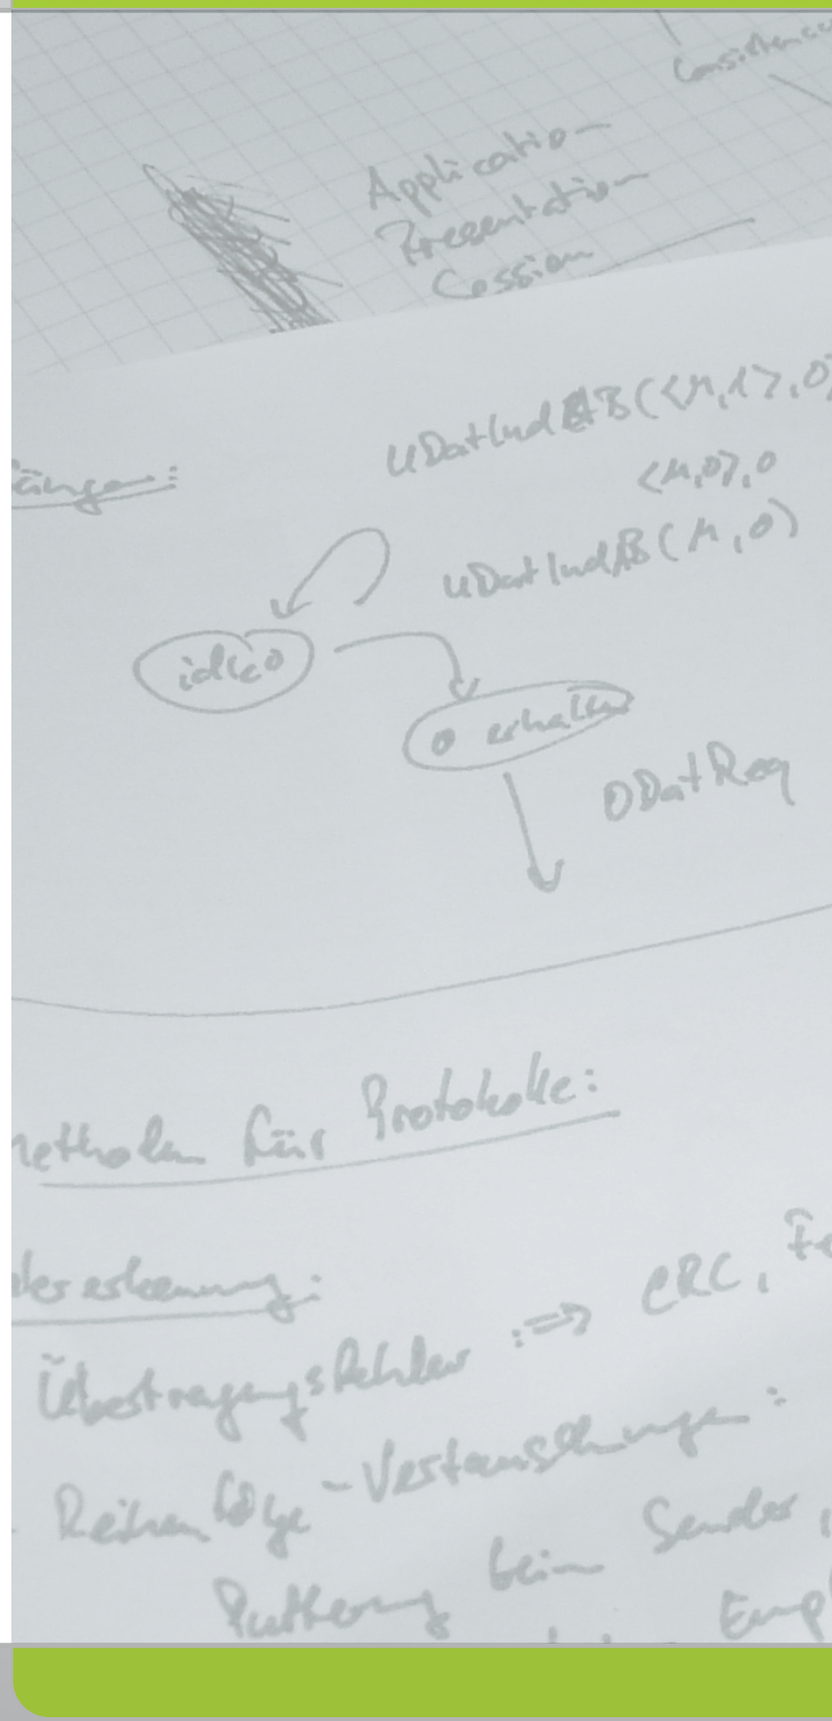

Motivation

- Abstrakte maschinelle Lernaufgaben aus der Vorlesung
  - Clustering
  - Klassifikation/Regression
  - Funktionslernen
- Darüber hinaus
  - Merkmalsextraktion, -generierung, -selektion
  - Zeitreihenanalyse, Text-Mining

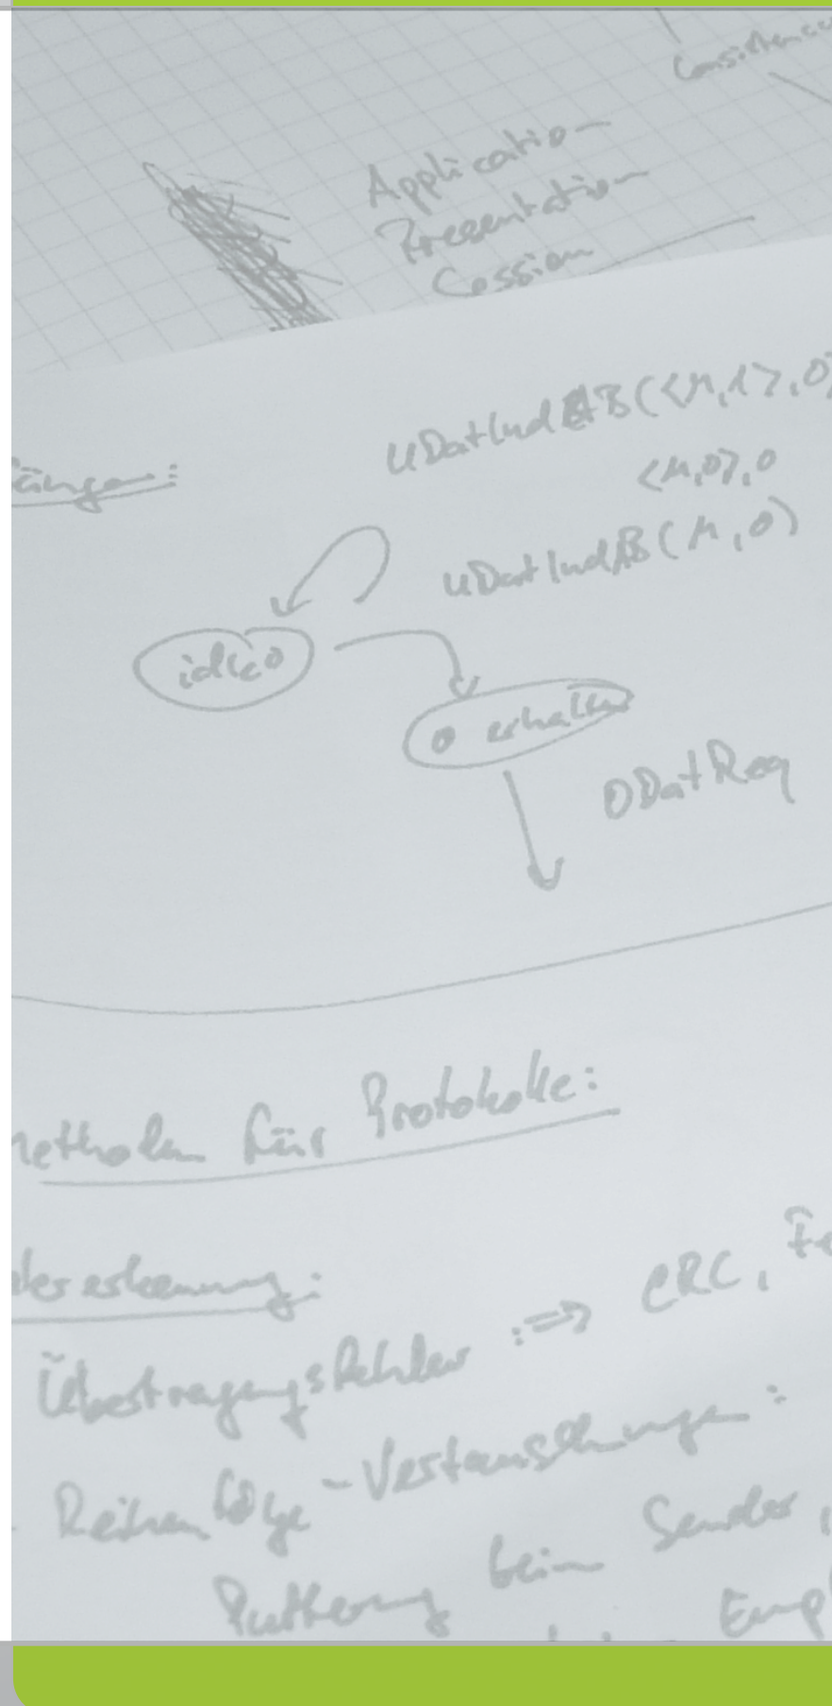

Motivation

- In der Praxis leider häufig:
  - Jeder implementiert „seinen“ Algorithmus für seine Anwendung neu
  - Jede Anwendung setzt auf unterschiedliche Datenformate
  - Modell-/Verfahrensselektion durch Ausprobieren auf den eigenen Daten

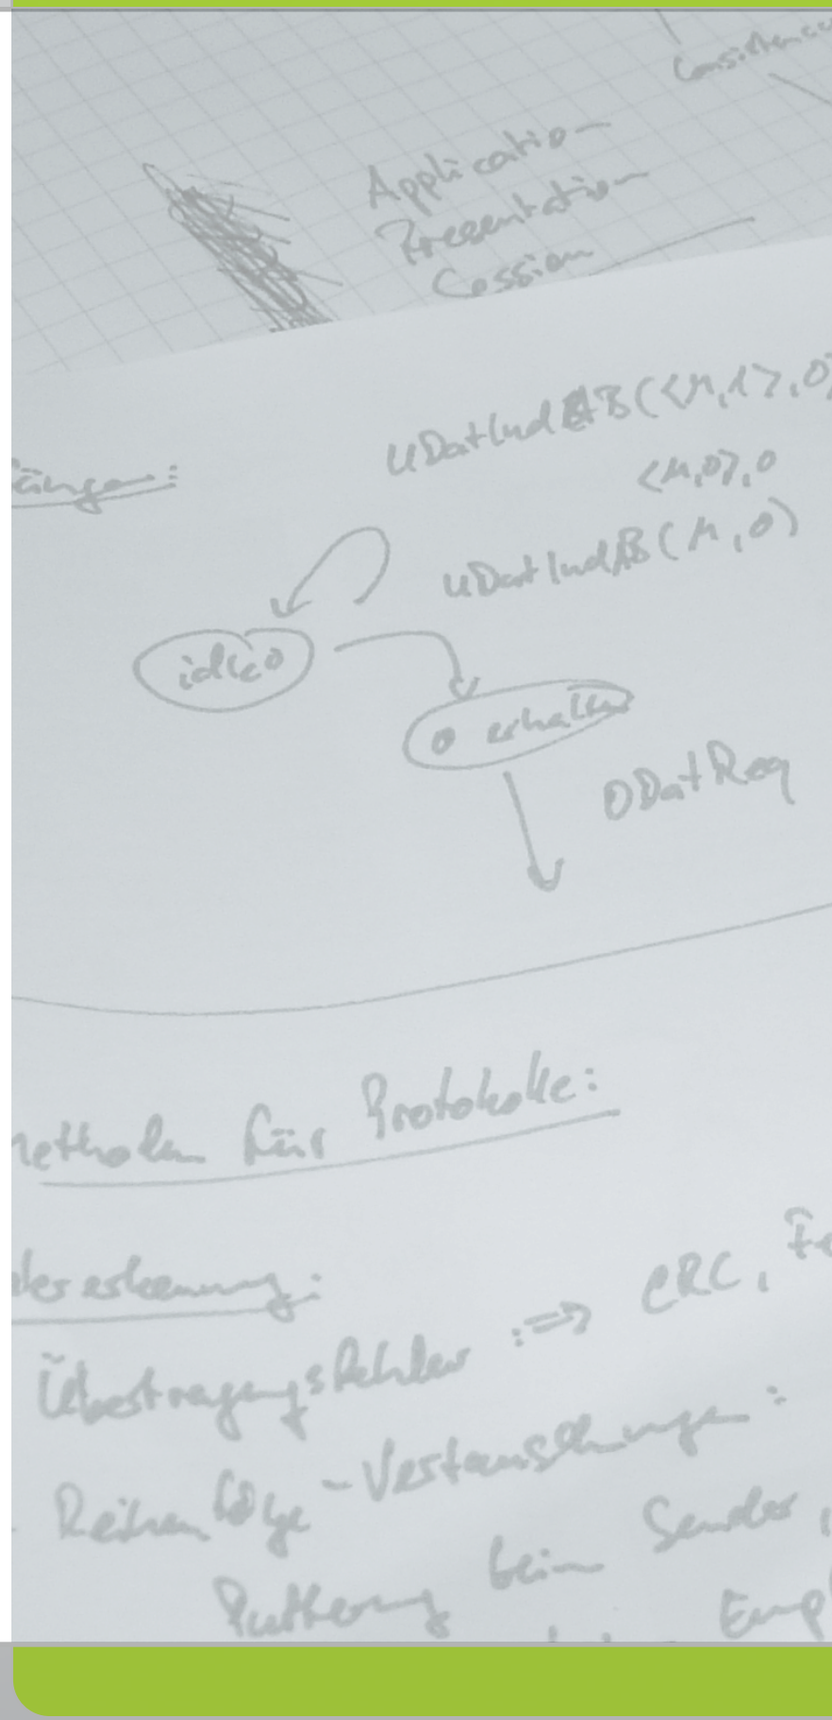

Motivation

- Dabei häufig viele Schritte gleich
  - ML-Experiment besteht aus unterschiedlichen Teilaufgaben
  - Datenvorverarbeitung spielt wichtige Rolle für Lernaufgaben/-algorithmen
- Evaluationen erfordern flexible Experimentierumgebung
- Ggf. periodische Wiederholungen von Analysen notwendig

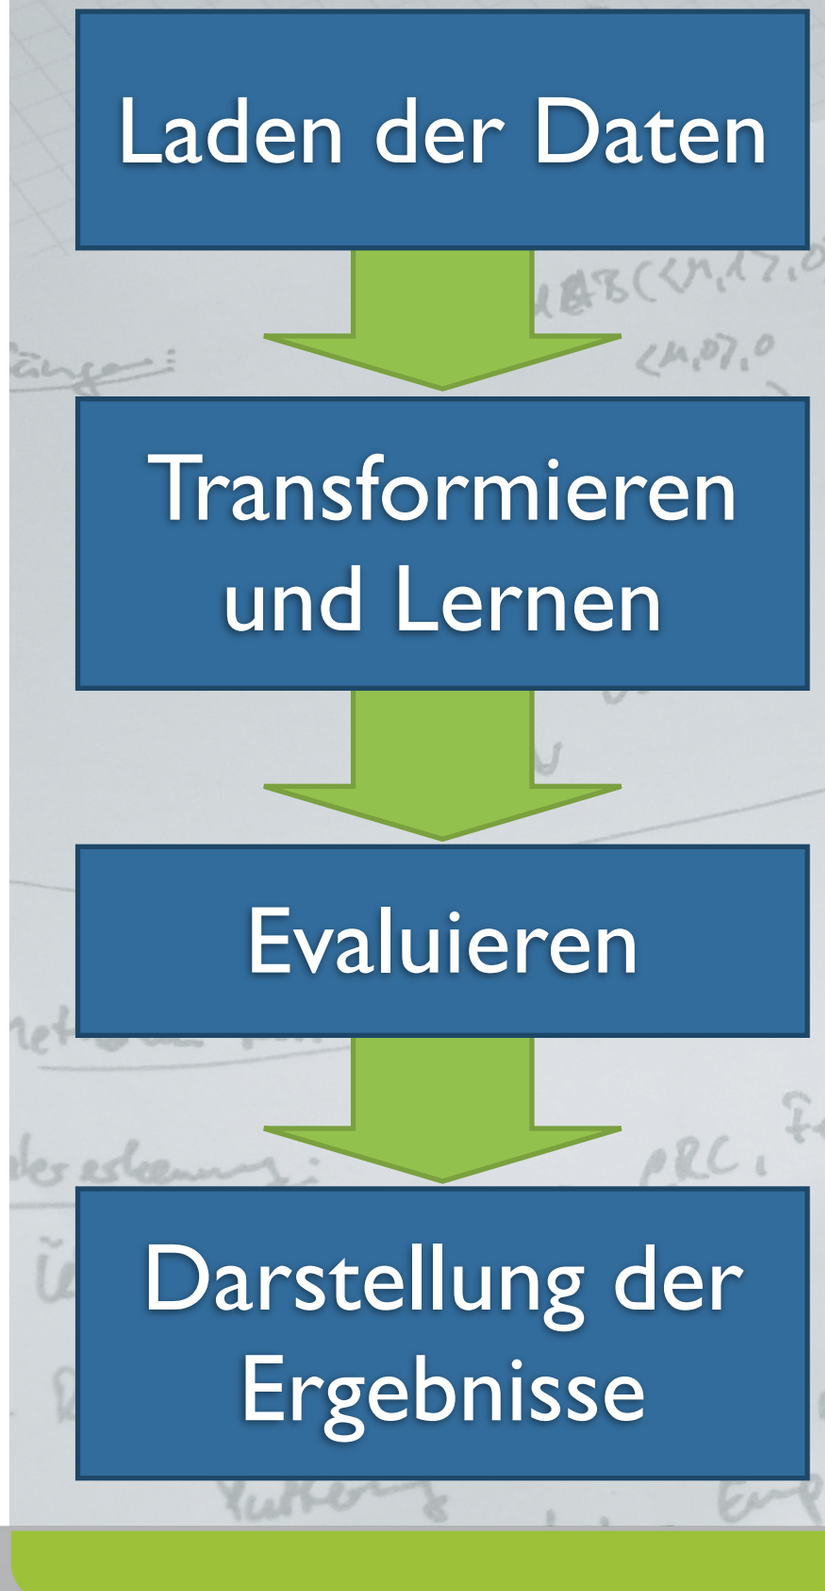

Motivation

- Dabei häufig viele Schritte gleich
  - ML-Experiment besteht aus unterschiedlichen Teilaufgaben
  - Datenvorverarbeitung spielt wichtige Rolle für Lernaufgaben/-algorithmen
- Evaluationen erfordern flexible Experimentierumgebung
- Ggf. periodische Wiederholungen von Analysen notwendig

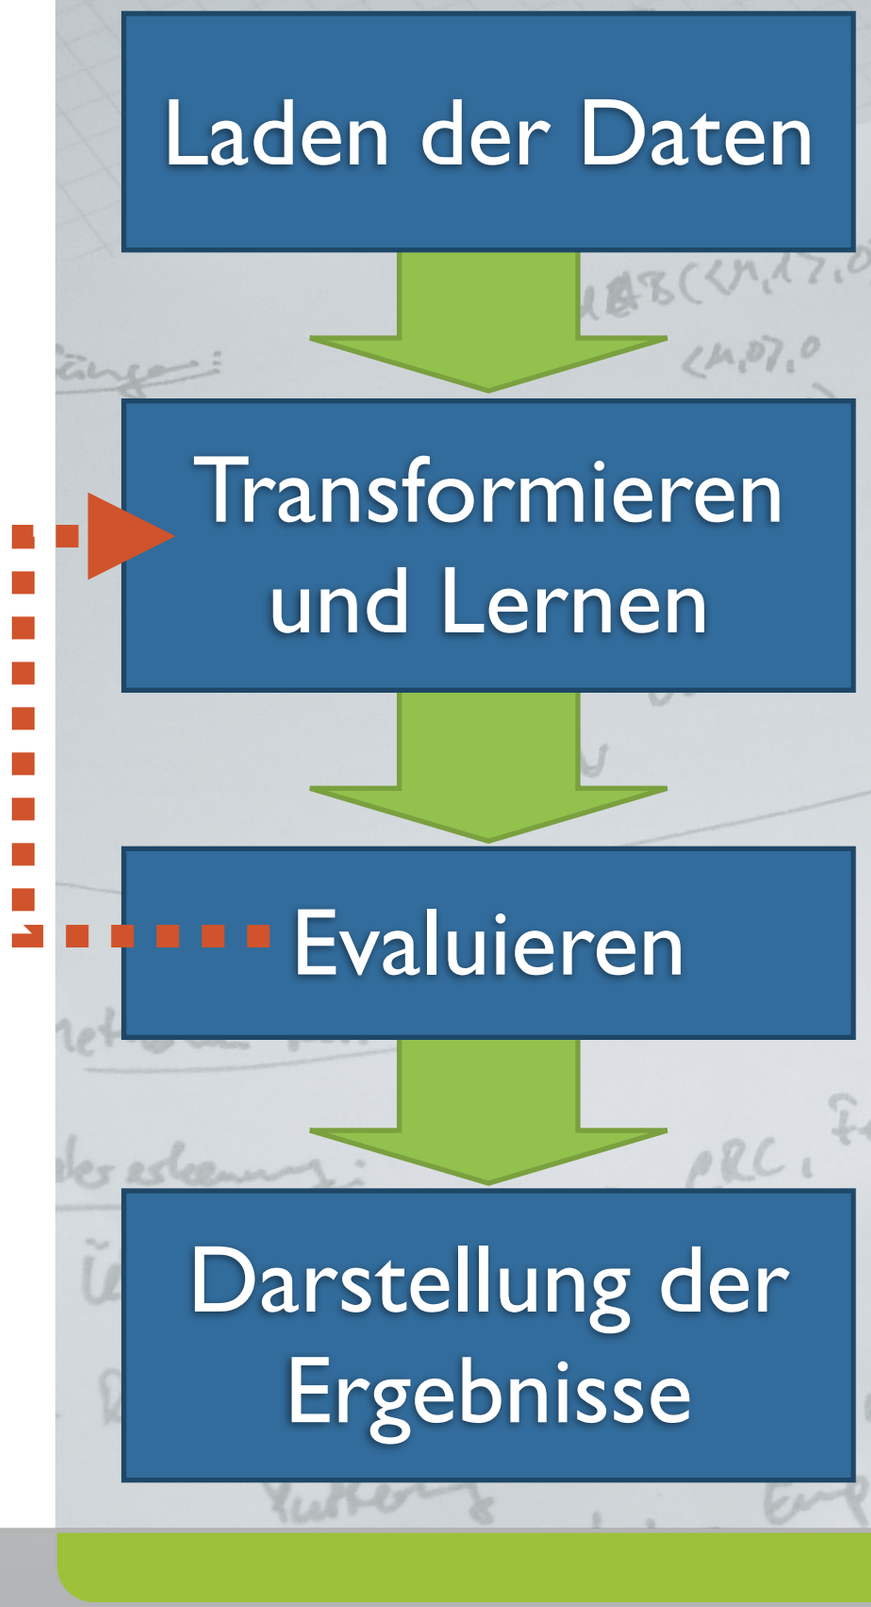

Ziele (RapidMiner)

- Abstraktion der ML-Experimente
  - Einfache, wiederverwendbare Beschreibung von Experimenten
  - Austauschbarkeit von Lern-Verfahren, insbesondere:
    - Durchführen von Vergleichen unterschiedlicher Verfahren
  - Kombination/Verschachtelung von Verfahren

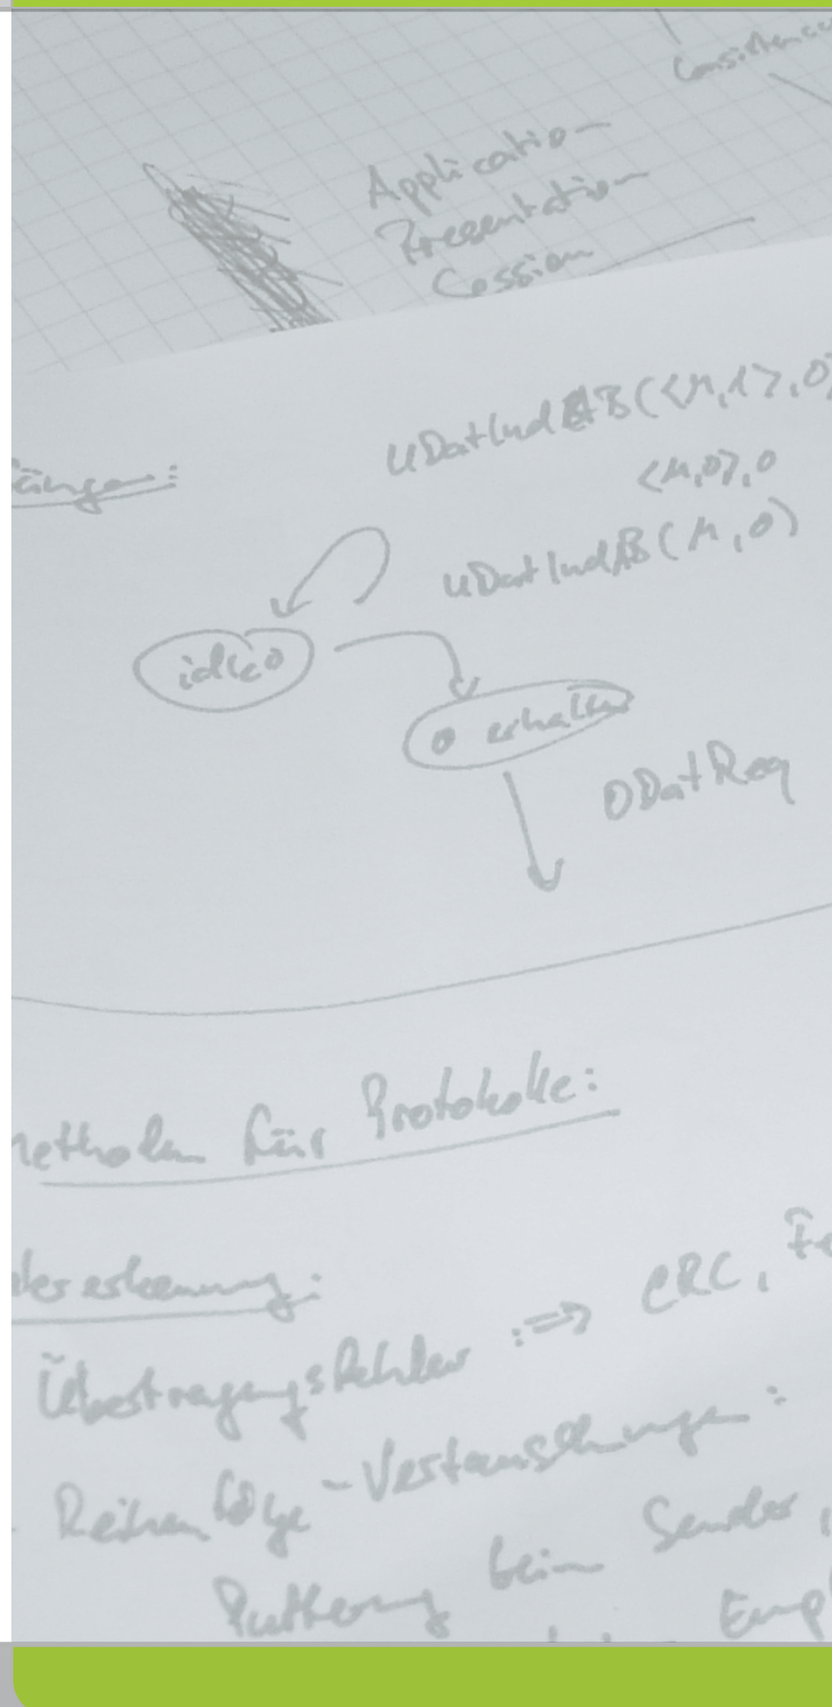

RapidMiner

- Modellierung von ML-Experimenten als Abfolge von Operatoren (Ketten)
- Verschachtelung von Operatoren
- Transparente/effiziente Datenhaltung
- Leichte Erweiterbarkeit durch Plugins
- GUI-Modus/Batch-Modus
- Einbindung externer Programme (z.B. Weka, SVM-Imlementierungen)

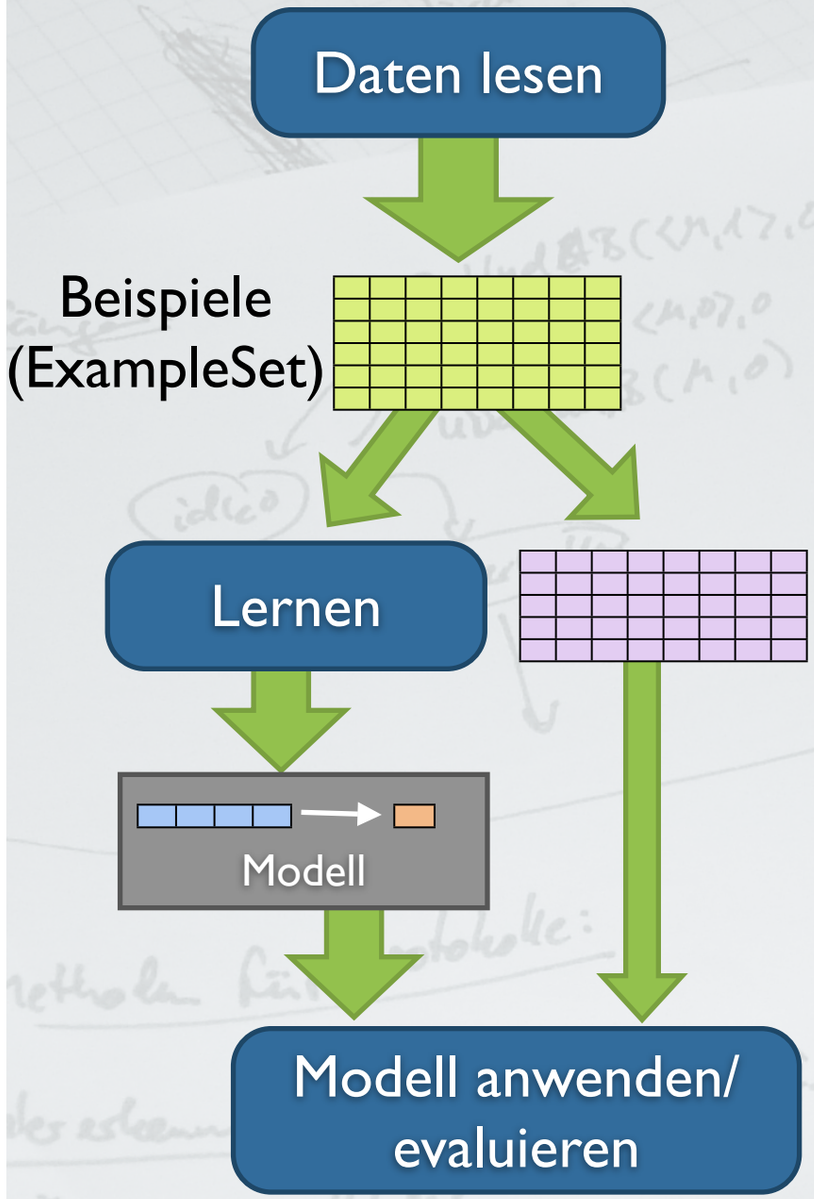

RapidMiner

- Modellierung von ML-Experimenten als Abfolge von Operatoren (Ketten)
- Verschachtelung von Operatoren
- Transparente/effiziente Datenhaltung
- Leichte Erweiterbarkeit durch Plugins
- GUI-Modus/Batch-Modus
- Einbindung externer Programme (z.B. Weka, SVM-Imlementierungen)

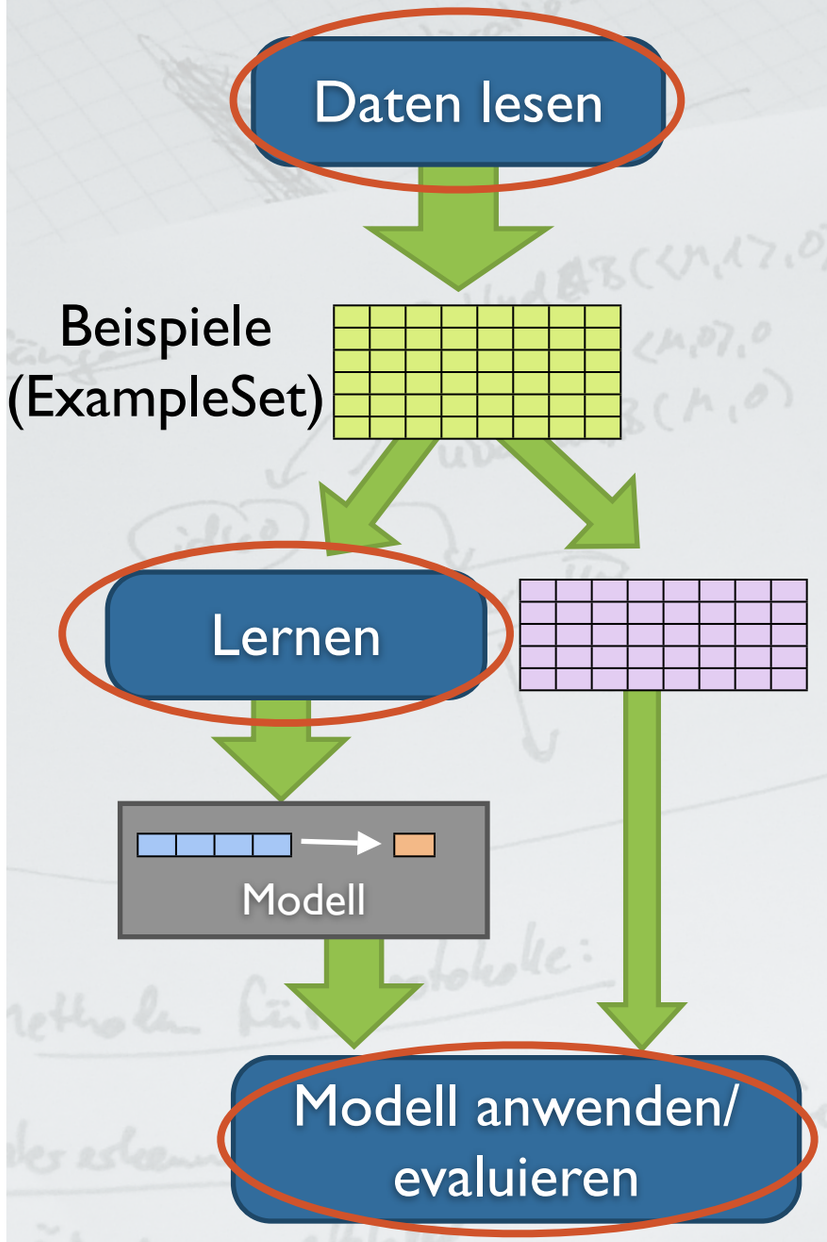

RapidMiner

- Modellierung von ML-Experimenten als Abfolge von Operatoren (Ketten)
- Verschachtelung von Operatoren
- Transparente/effiziente Datenhaltung
- Leichte Erweiterbarkeit durch Plugins
- GUI-Modus/Batch-Modus
- Einbindung externer Programme (z.B. Weka, SVM-Imlementierungen)

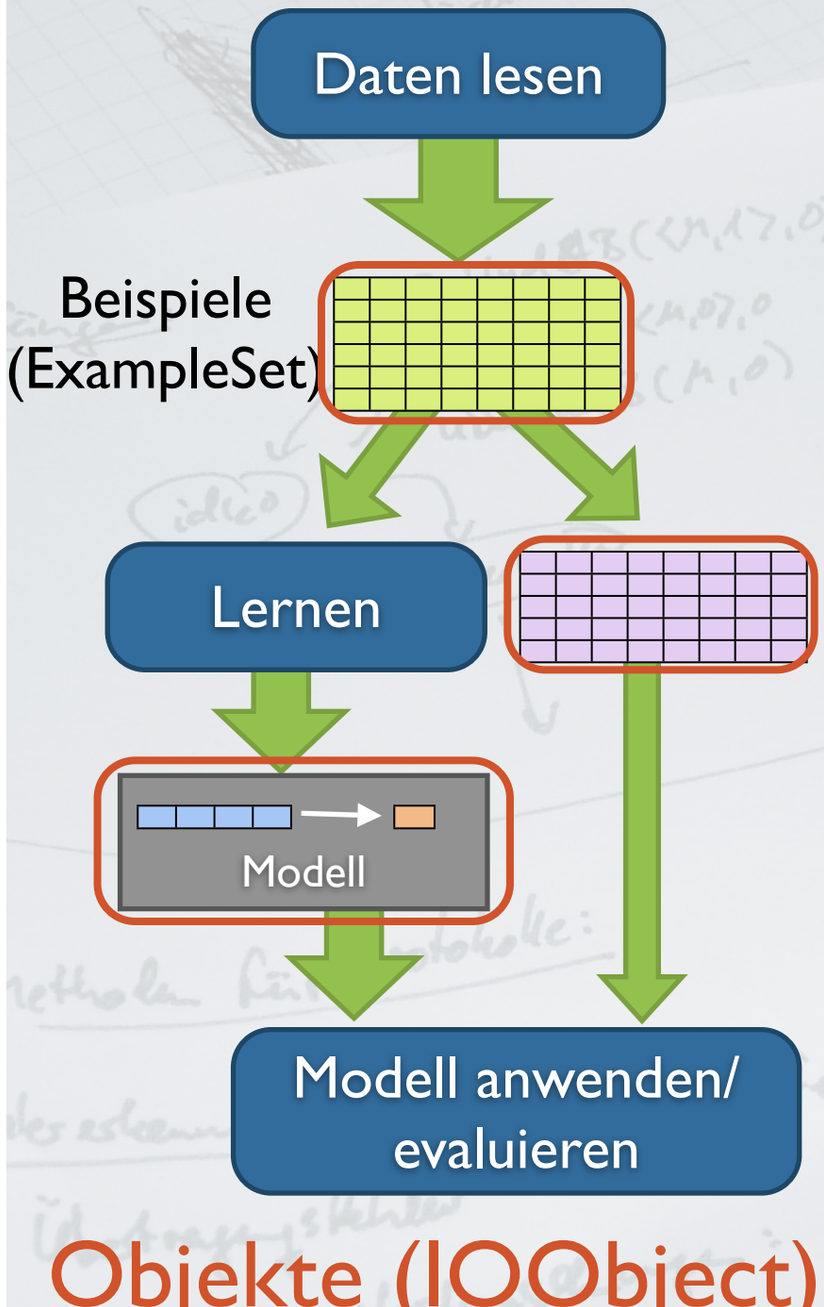

Integrierte Operatoren

- Operatoren zur Ein-/Ausgabe
- Datenvorverarbeitung
- Zahlreiche Lernverfahren (Weka-Lerner, Clustering, ...)
- Performanzbewertung von Lernverfahren
- Verwaltung/Ausgabe von Lernergebnissen

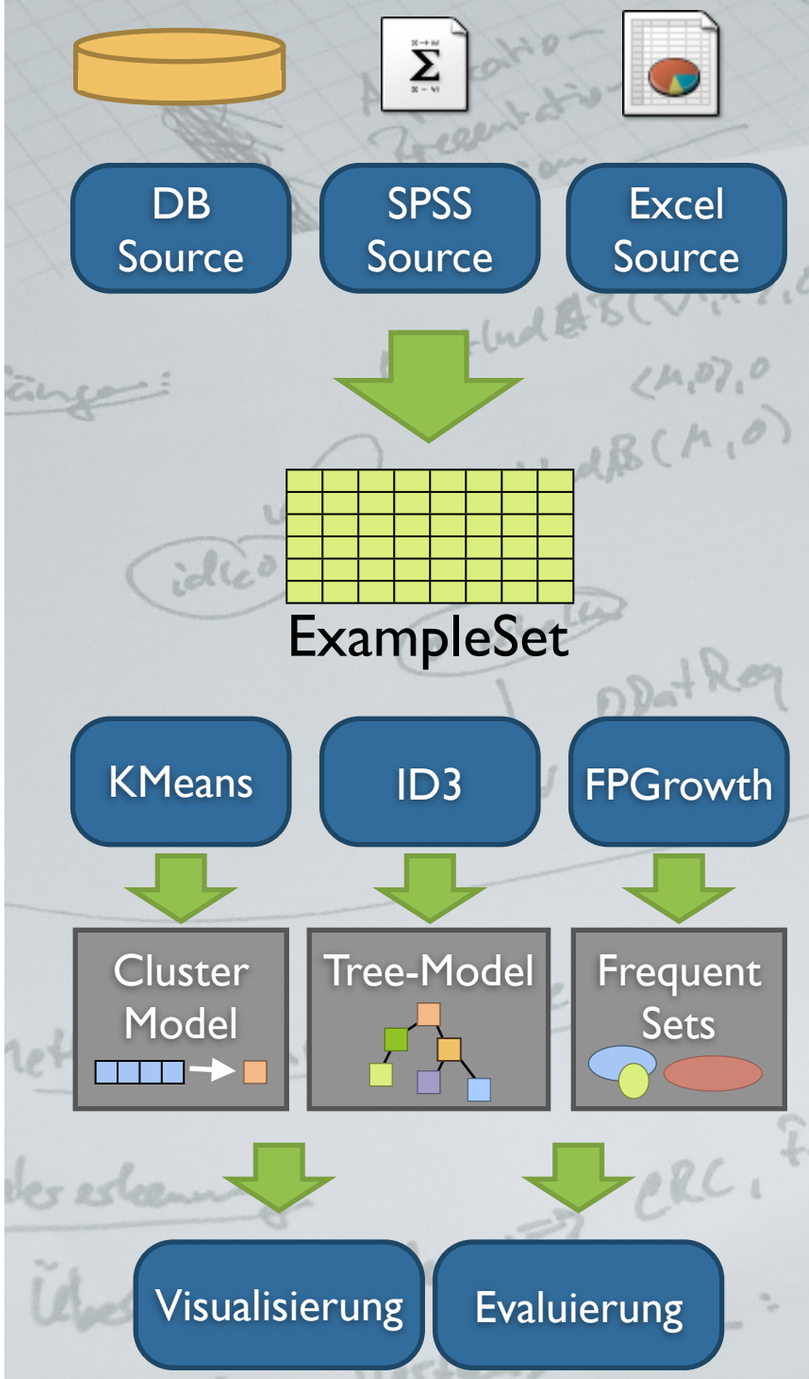

Information

- Open-Source (GPL-Lizenz)
- Erfolgreiche Anwendung auf unterschiedliche Lernaufgaben
- Weltweite Verbreitung (Anwender / Wissenschaftler in über 30 Ländern)
- Dokumentation/Download/uvm. unter **http://rapid-i.com**

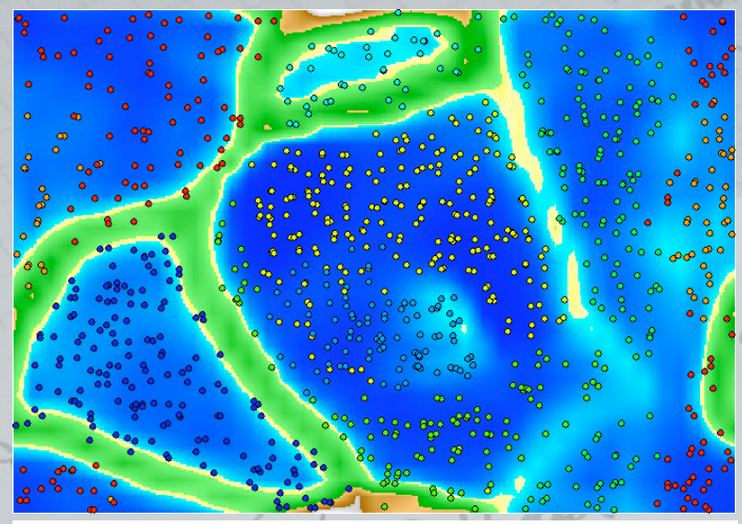

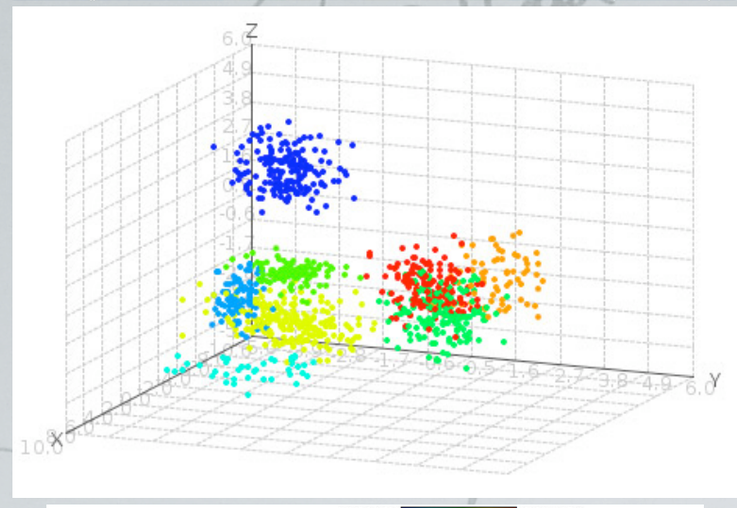

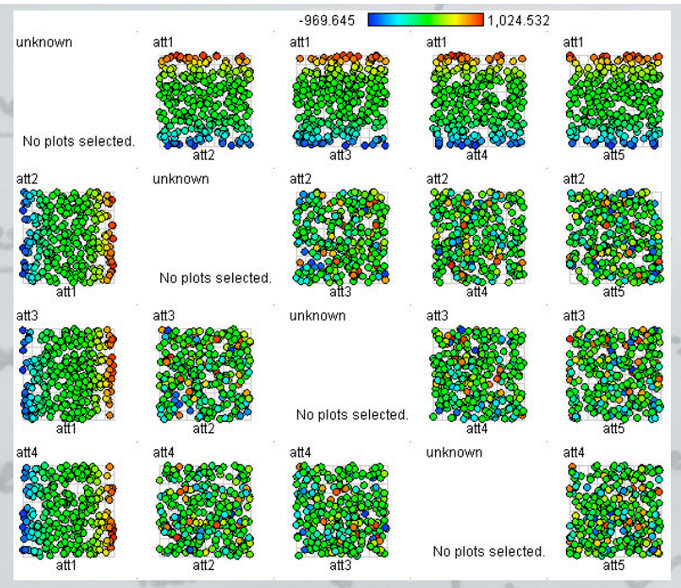

rapid-I
REPORT THE FUTURE

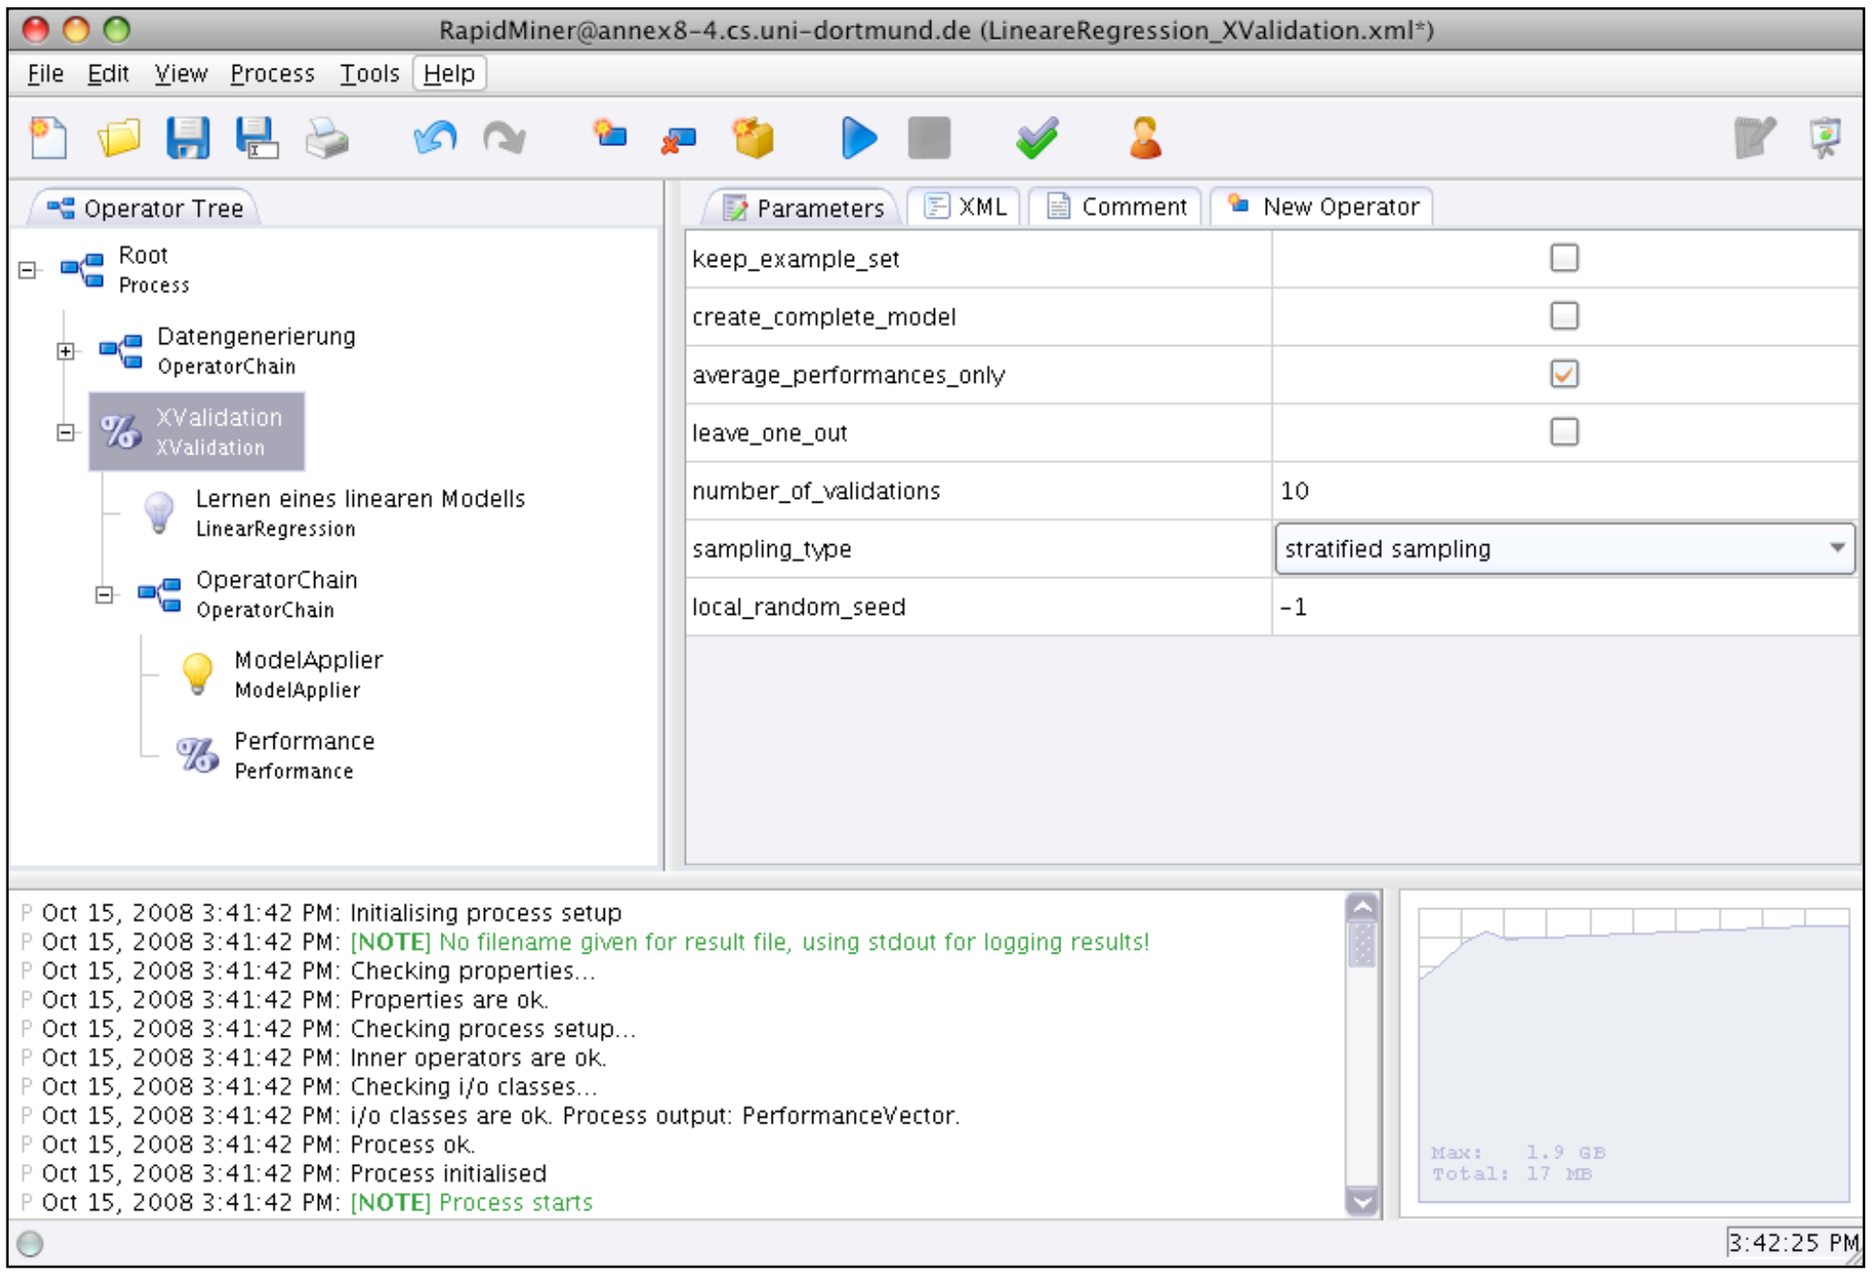
RapidMiner@annex8-4.cs.uni-dortmund.de (LineareRegression_XValidation.xml*)
File Edit View Process Tools Help
Operator Tree
Root
Process
Datengenerierung
OperatorChain
XValidation
XValidation
Lernen eines linearen Modells
LinearRegression
OperatorChain
OperatorChain
ModelApplier
ModelApplier
Performance
Performance
Parameters
XML
Comment
New Operator
keep_example_set
create_complete_model
average_performances_only
leave_one_out
number_of_validations
10
sampling_type
stratified sampling
local_random_seed
-1
Oct 15, 2008 3:41:42 PM: Initialising process setup
Oct 15, 2008 3:41:42 PM: [NOTE] No filename given for result file, using stdout for logging results!
Oct 15, 2008 3:41:42 PM: Checking properties...
Oct 15, 2008 3:41:42 PM: Properties are ok.
Oct 15, 2008 3:41:42 PM: Checking process setup...
Oct 15, 2008 3:41:42 PM: Inner operators are ok.
Oct 15, 2008 3:41:42 PM: Checking i/o classes...
Oct 15, 2008 3:41:42 PM: i/o classes are ok. Process output: PerformanceVector.
Oct 15, 2008 3:41:42 PM: Process ok.
Oct 15, 2008 3:41:42 PM: Process initialised
Oct 15, 2008 3:41:42 PM: [NOTE] Process starts
Max: 1.9 GB
Total: 17 MB
3:42:25 PM

Aufbau/ Ablauf

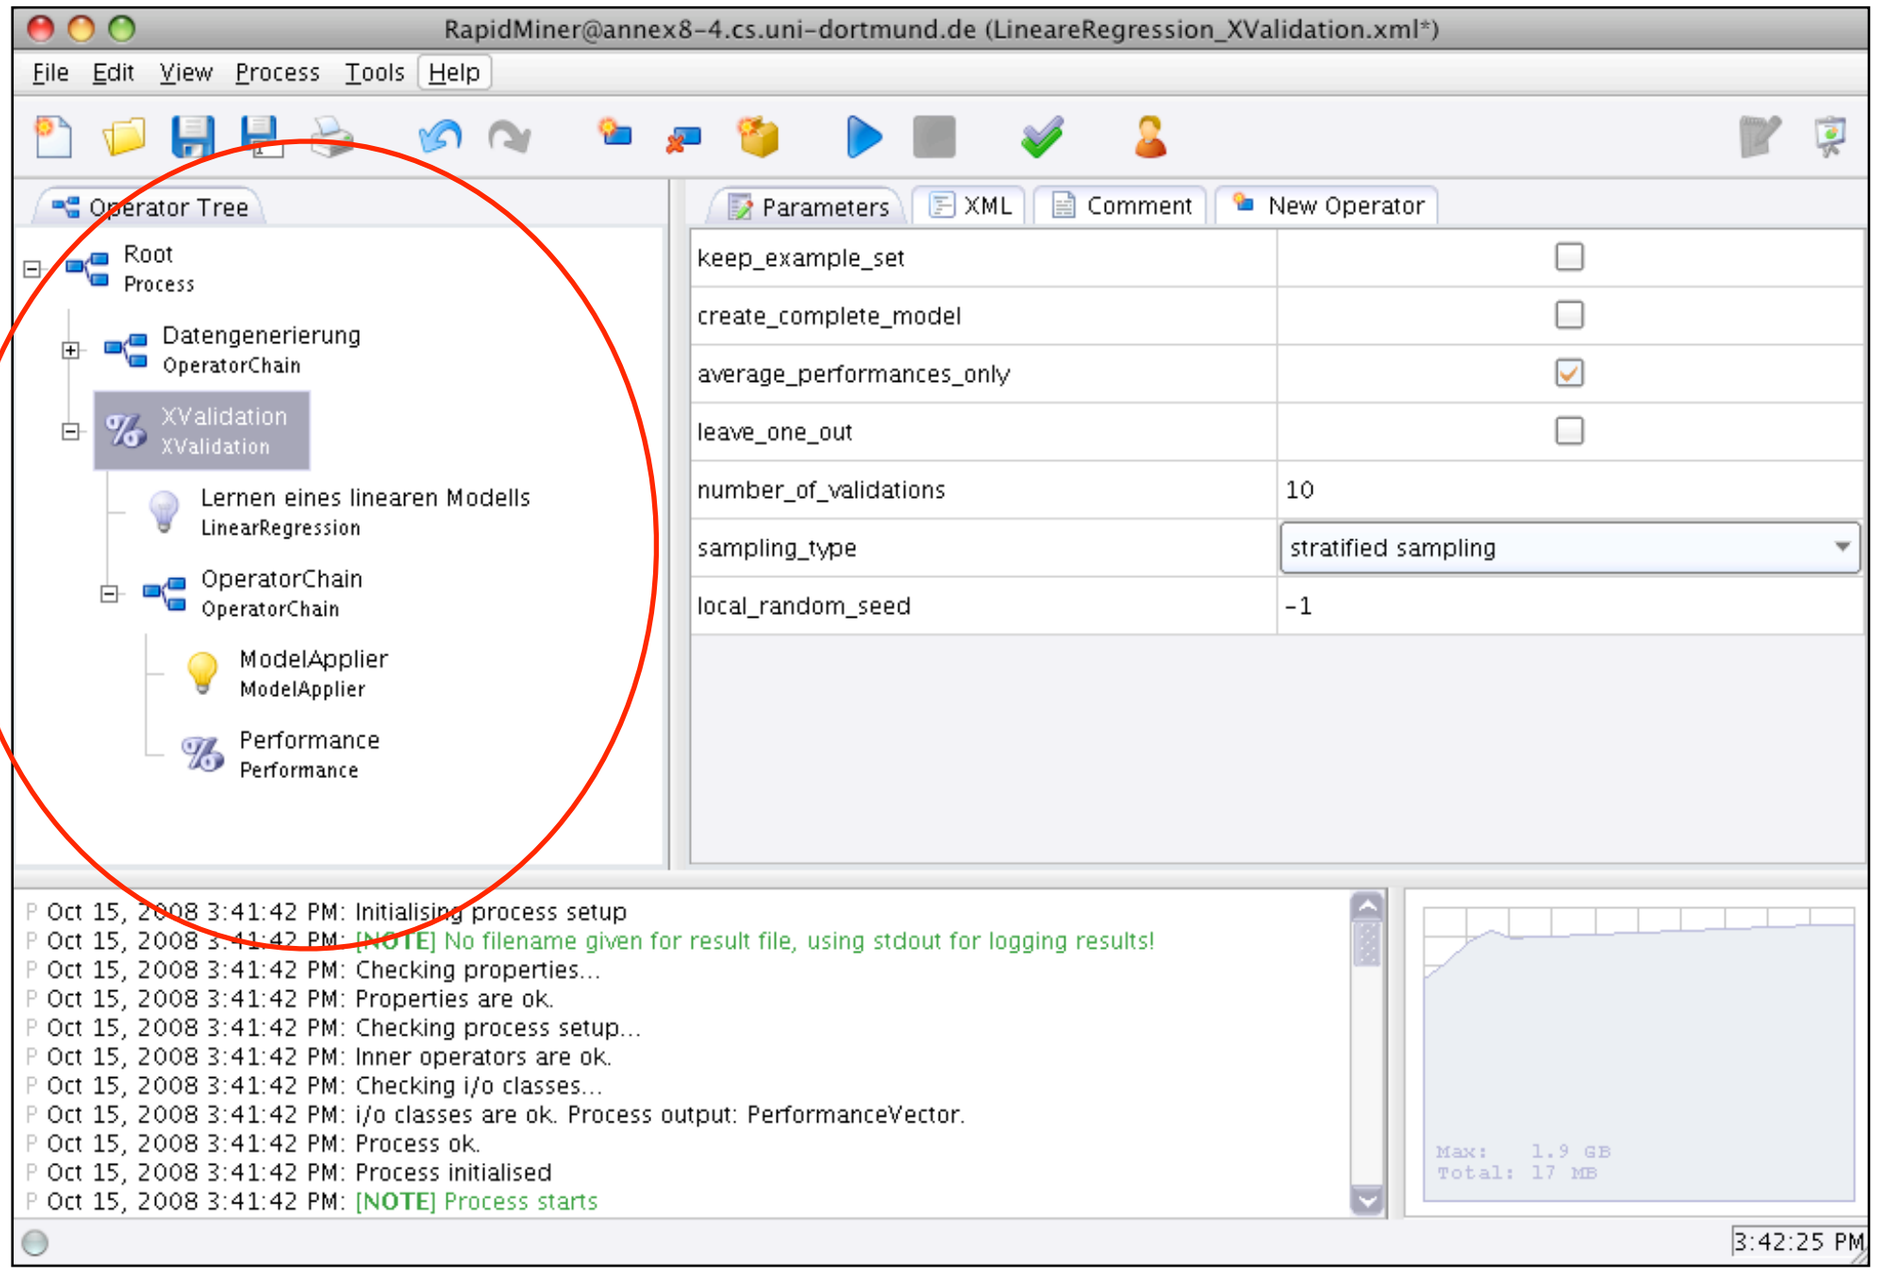

Aufbau/ Ablauf

Parameter

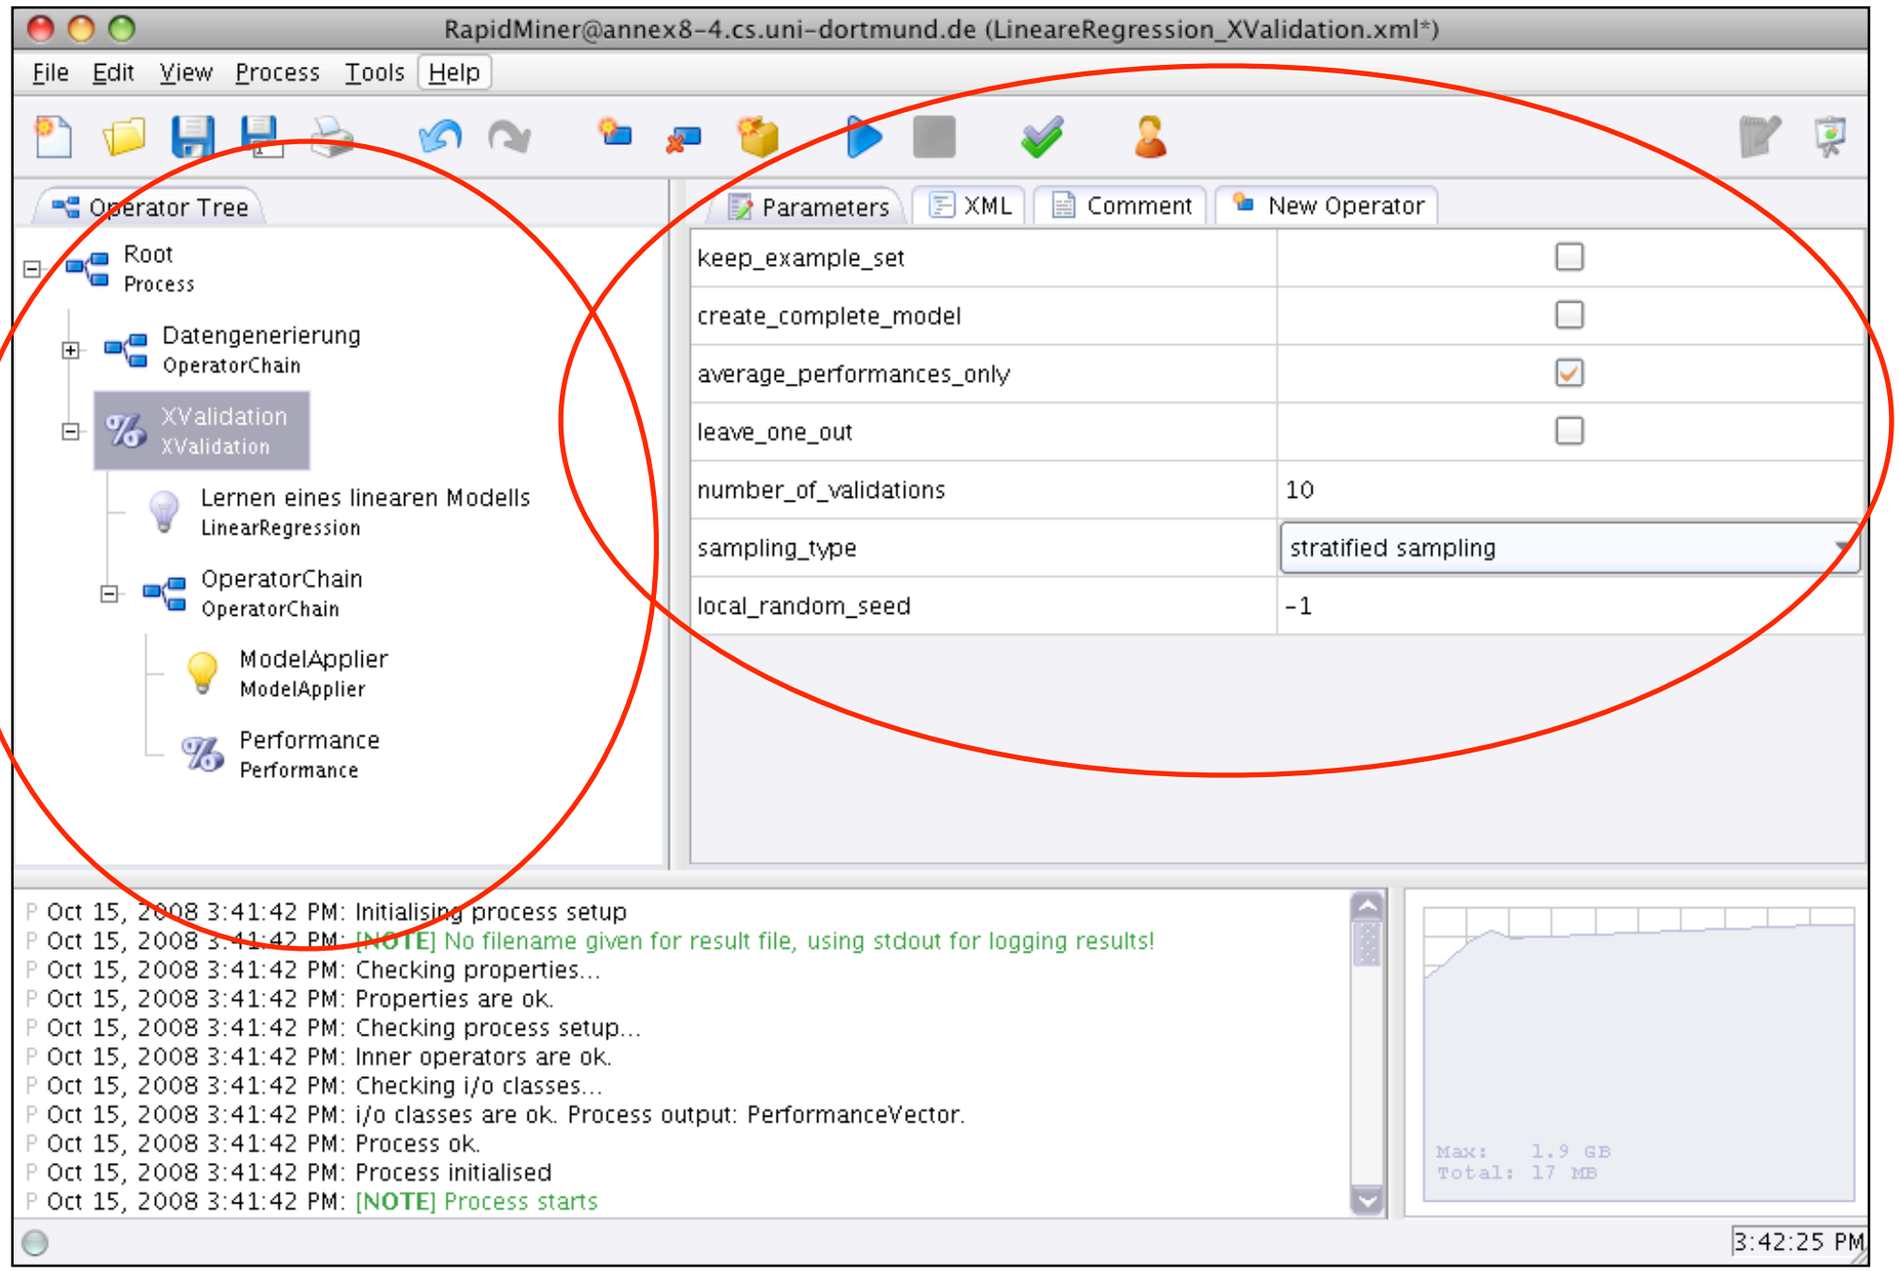

Aufbau/ Ablauf

Parameter

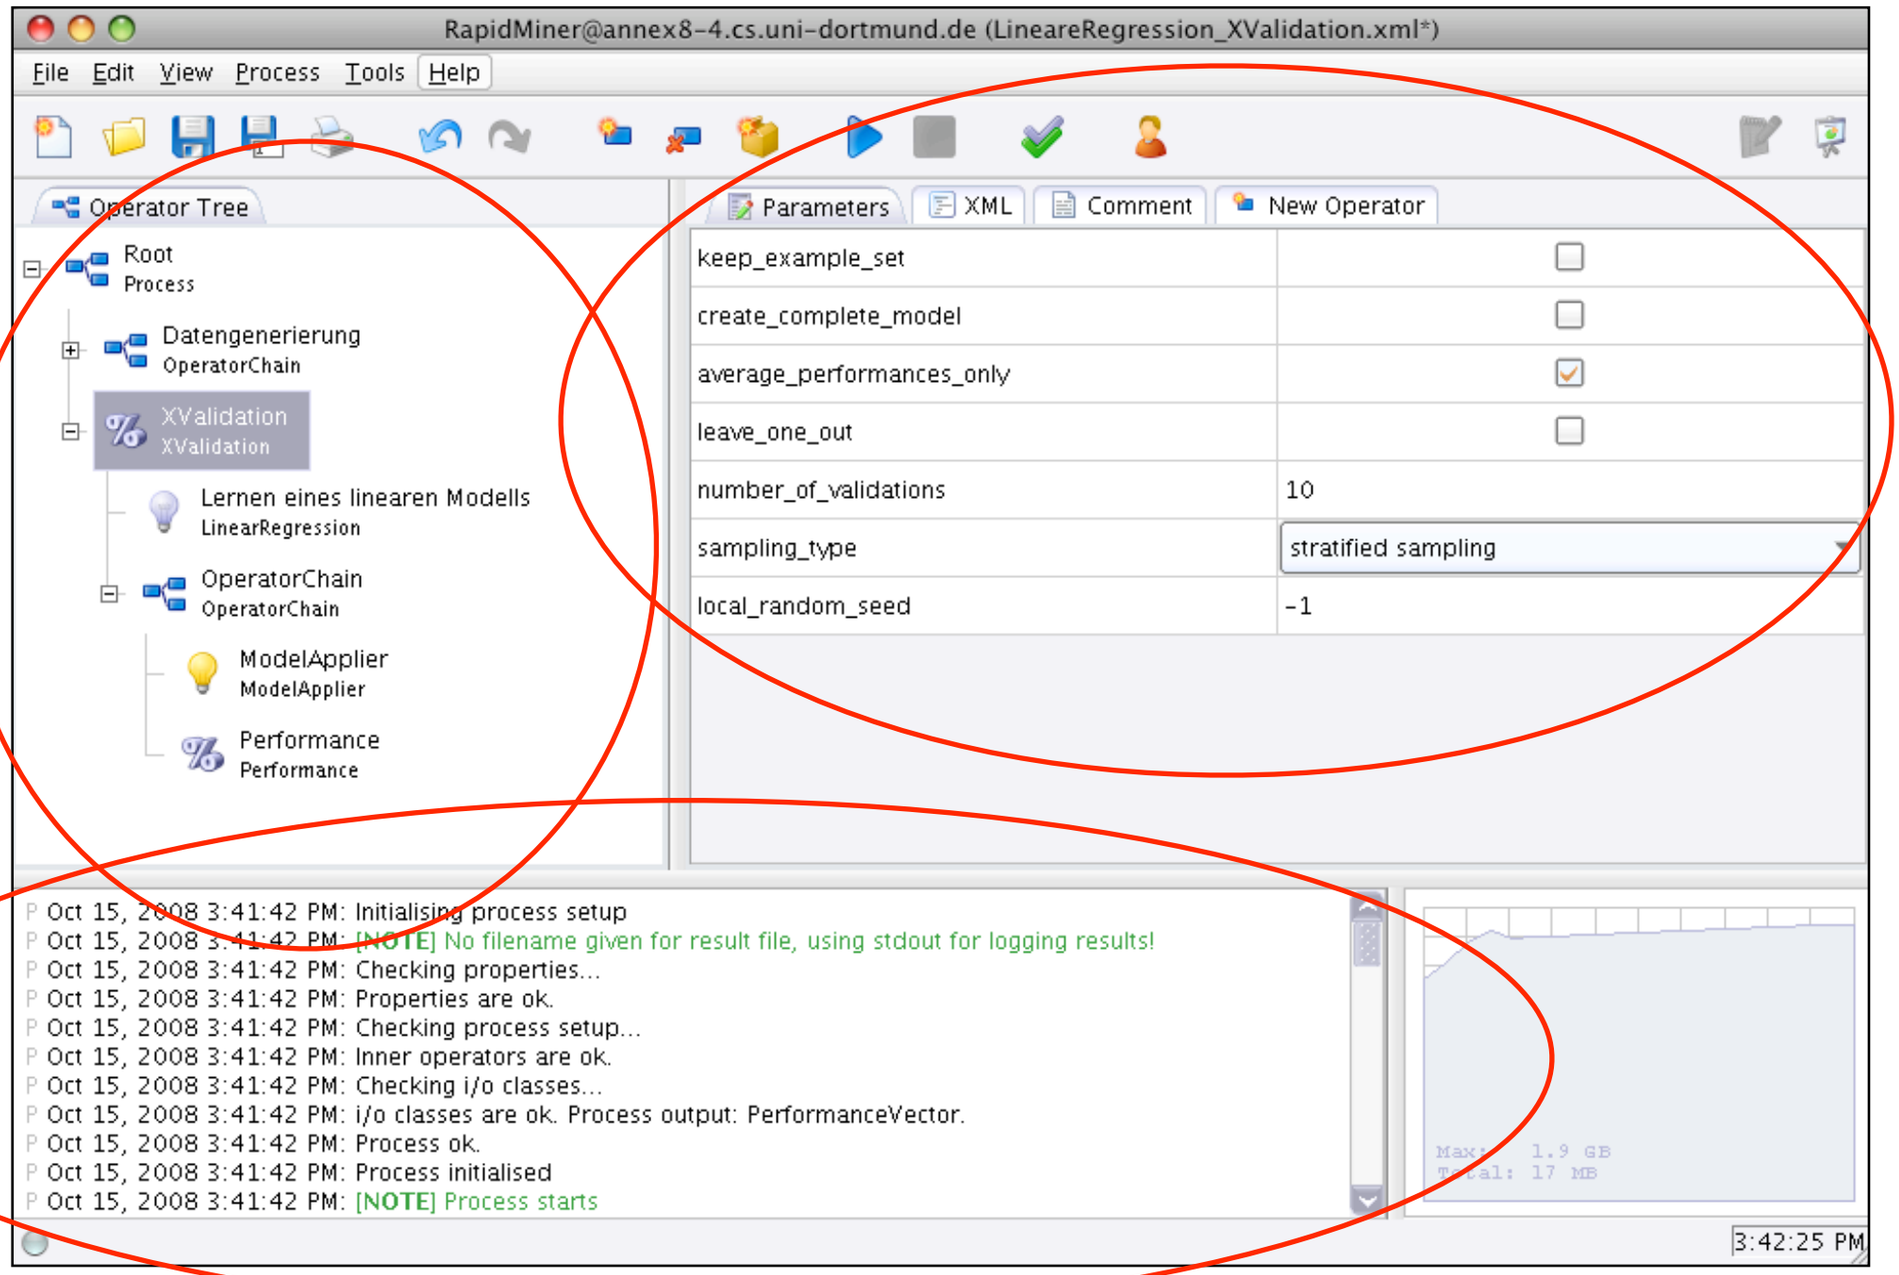

Logfenster

Operatorbaum

- Operatorbaum ist die zentrale Darstellung eines Experimentes
- Operatoren sind in einer Baumstruktur aufgebaut
- Einige Operatoren erlauben innere Operatoren
- Abarbeitung der Operatoren in DFS Reihenfolge

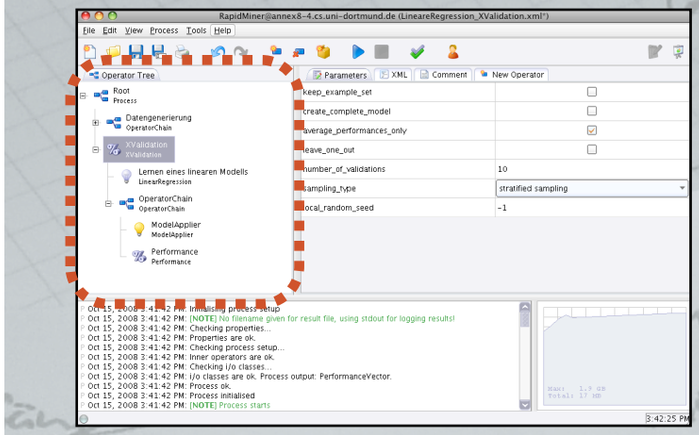

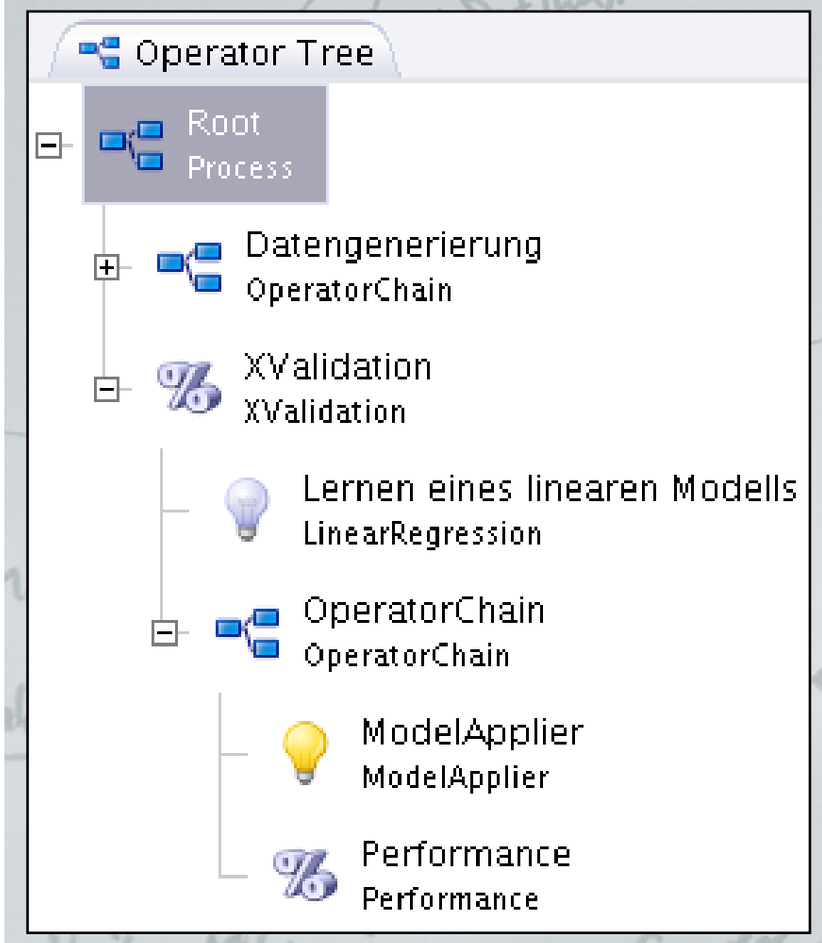

Parameter-Ansicht

- Viele Operatoren benötigen eine Reihe von zusätzlichen Parametern
  - Die Parameter-Ansicht zeigt für den aktuell ausgewählten Operator die verfügbaren Parameter an
- Einige Parameter sind nur im „Experten-Modus“ sichtbar

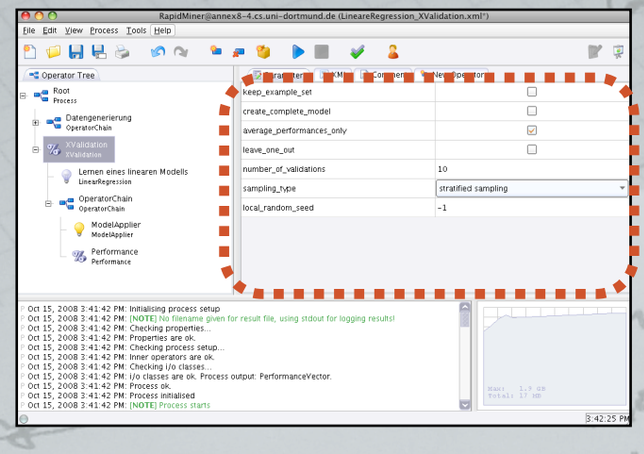

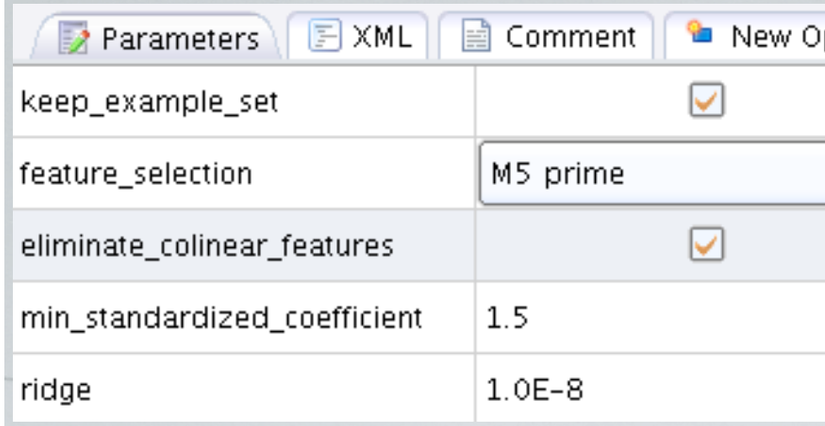

XML-Sicht

- Jedes Experiment ist in XML beschrieben
  - Über den XML-Reiter kann das Experiment in XML angezeigt und verändert werden

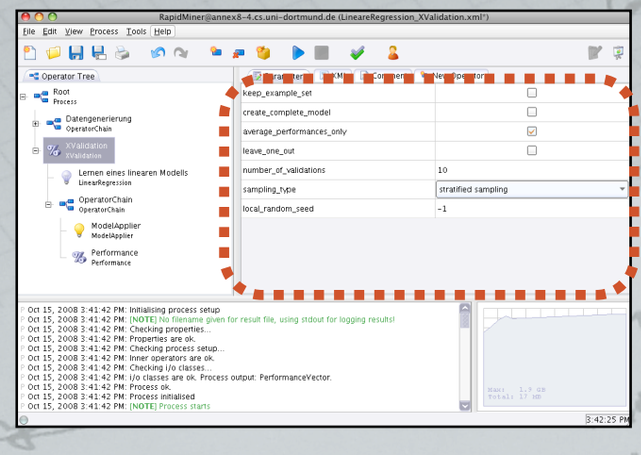

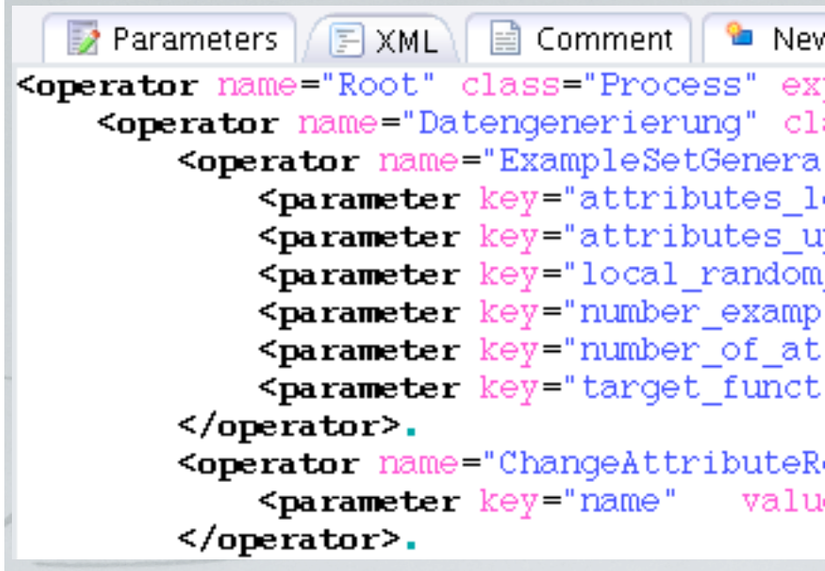

Operator-Menü

- Eine der Stärken von RapidMiner ist die Vielzahl unterschiedlicher Operatoren
  - Der Reiter „New Operator“ erlaubt das Hinzufügen neuer Operatoren zum Experiment per DnD
- **Hinweis:** Über das sehr praktische Suchfeld lassen sich Operatoren schneller finden!

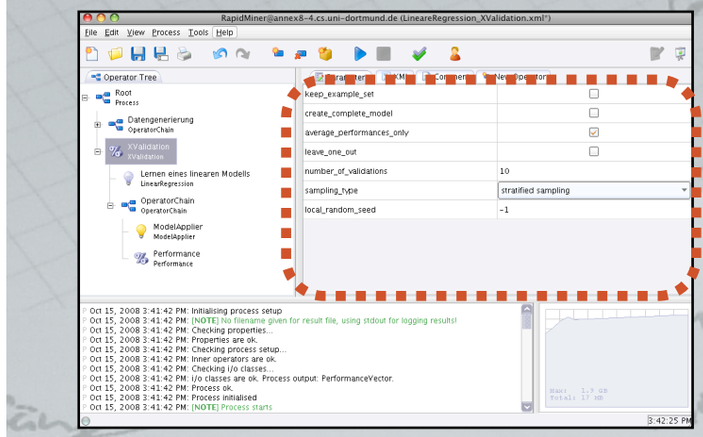

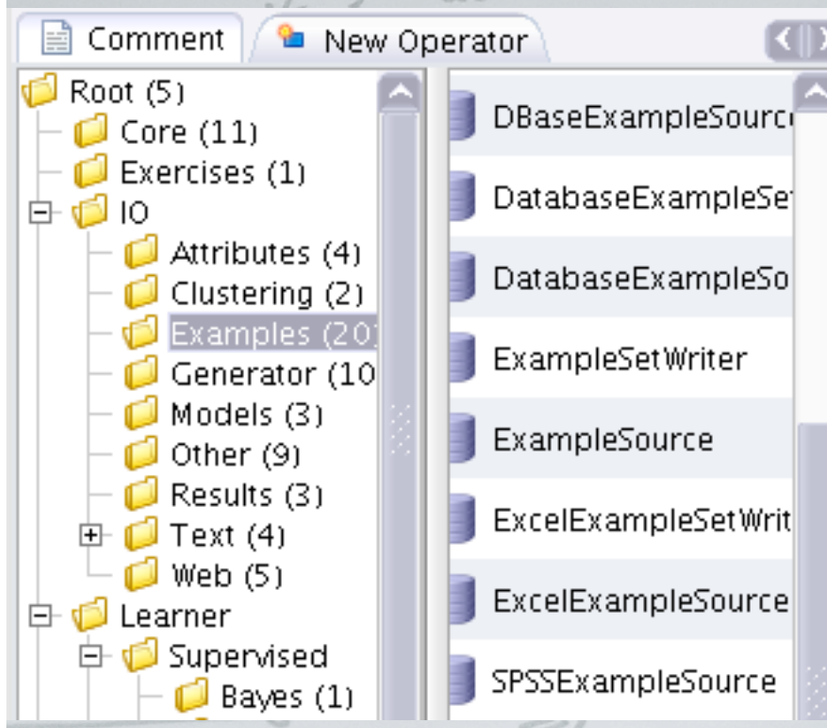

Log-Fenster

- Im Log-Fenster werden allerhand Informationen angezeigt:
  - Über den gerade laufenden Operator
  - Ausgaben durch den Operator

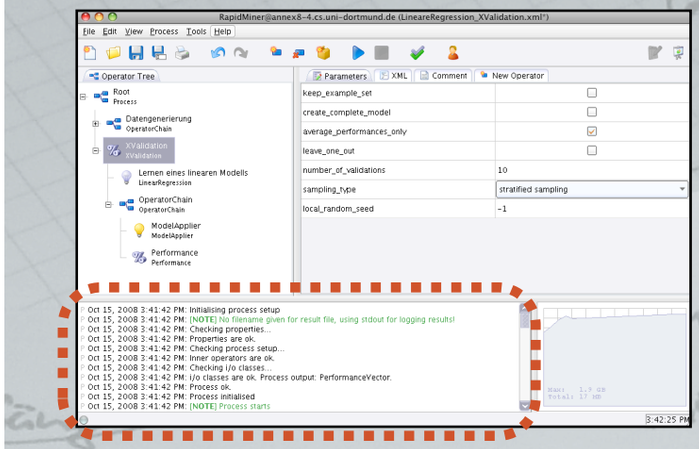

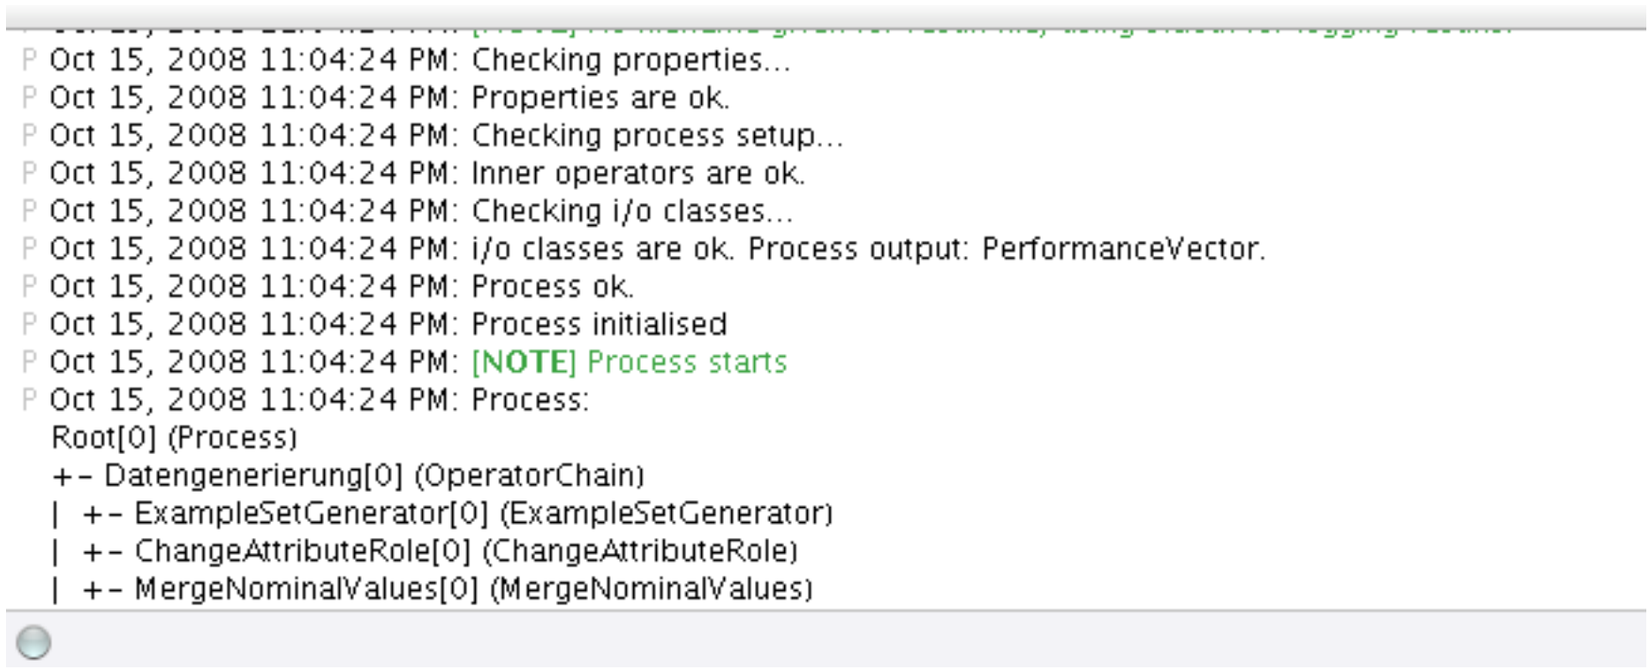

RapidMiner

- Kurze Demo

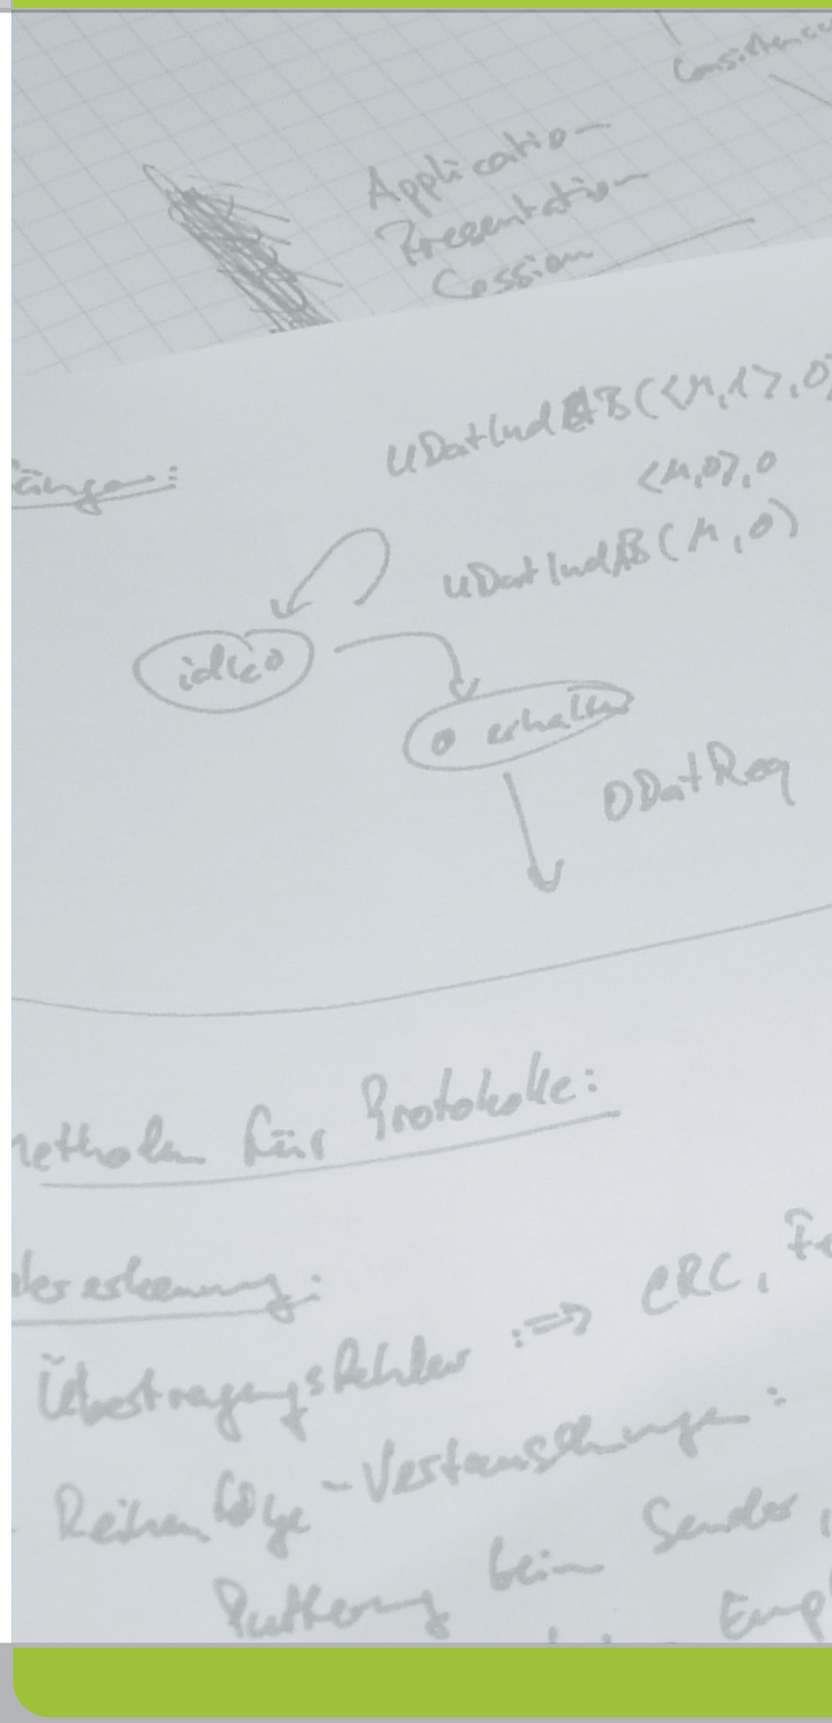

Details

- **Operatoren** erhalten `IOObjects` und liefern ggf. mehrere `IOObjects` zurück
- Operatoren erweitern die Klasse **`Operator`**
- `IOObject` ist eine abstrakte Klasse, von der z.B. **`ExampleSet`**, **`Model`**, usw. erben

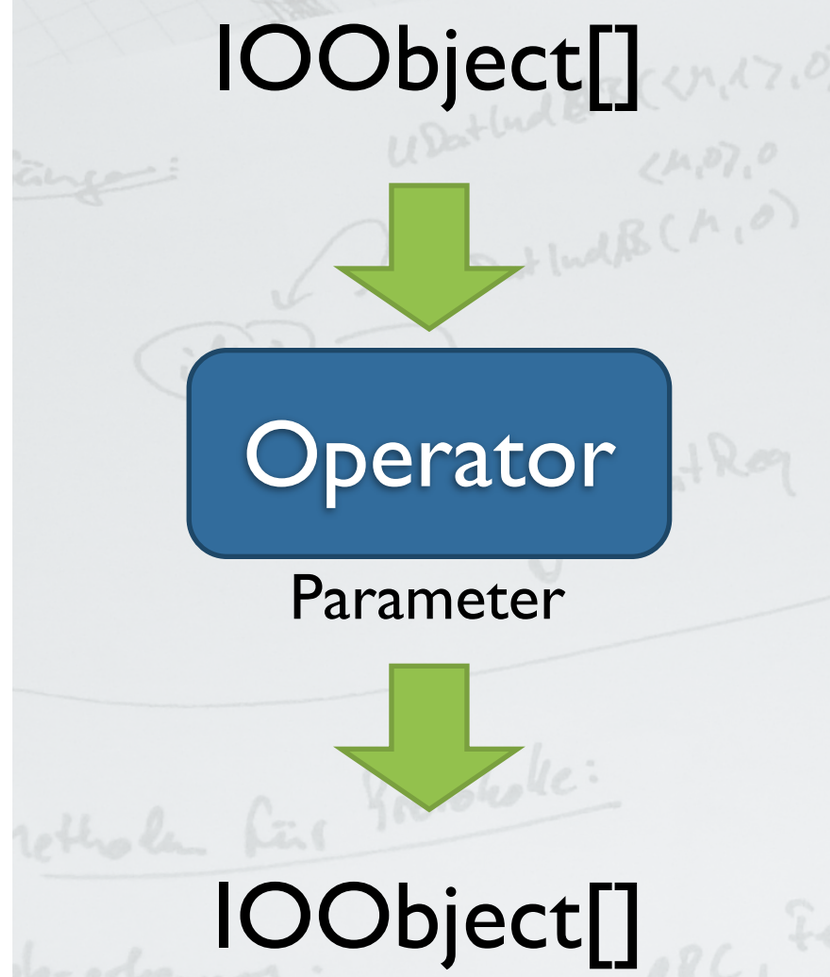

Details

- **Operatoren** erhalten `IOObjects` und liefern ggf. mehrere `IOObjects` zurück
- Operatoren erweitern die Klasse **`Operator`**
- `IOObject` ist eine abstrakte Klasse, von der z.B. **`ExampleSet`**, **`Model`**, usw. erben
- Beispiel für einen Lernalgorithmus:
  - Operator, der ein **ExampleSet** Objekt erhält und ein **Model** Objekt erzeugt

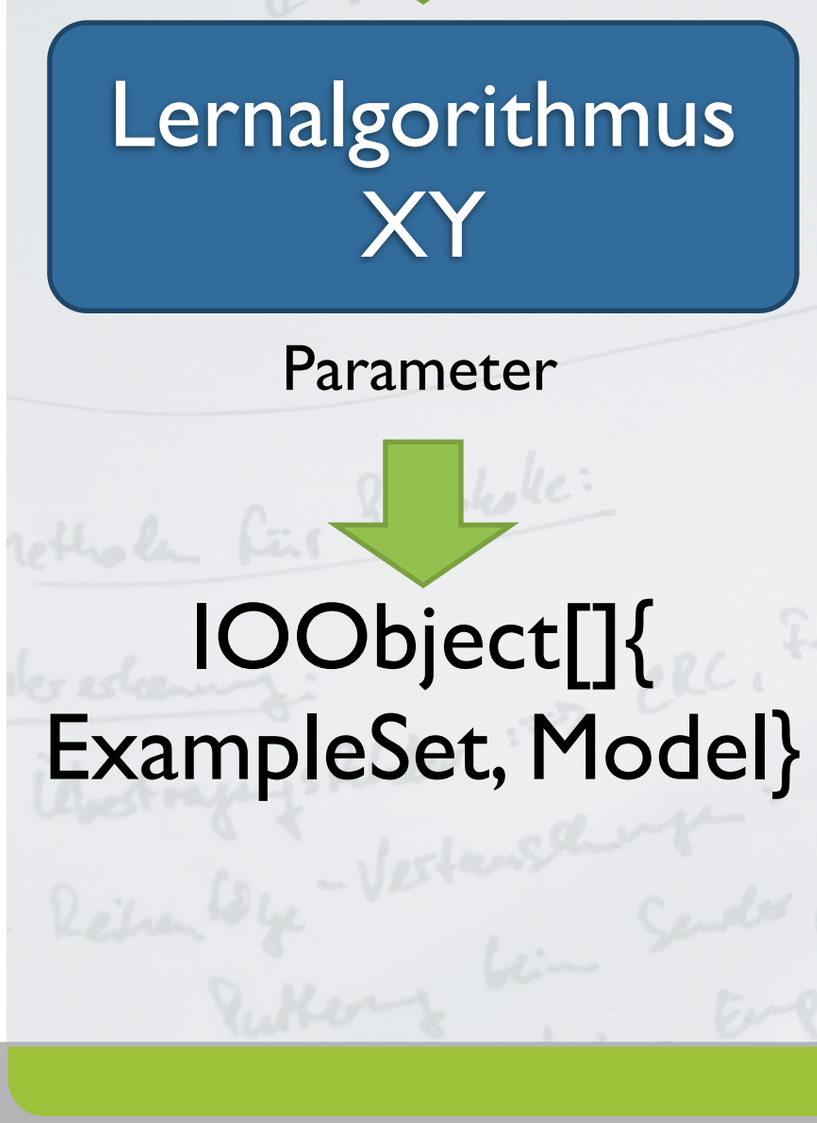

Details

- Objekte, die zwischen Operatoren ausgetauscht werden:
  - **ExampleSet** (eine Menge von Daten)
  - **Model** (gelerntes Model)
  - **PerformanceVector** (Menge von Leistungsmaßen)
  - **Merkmalsgewichte**
  - **...**

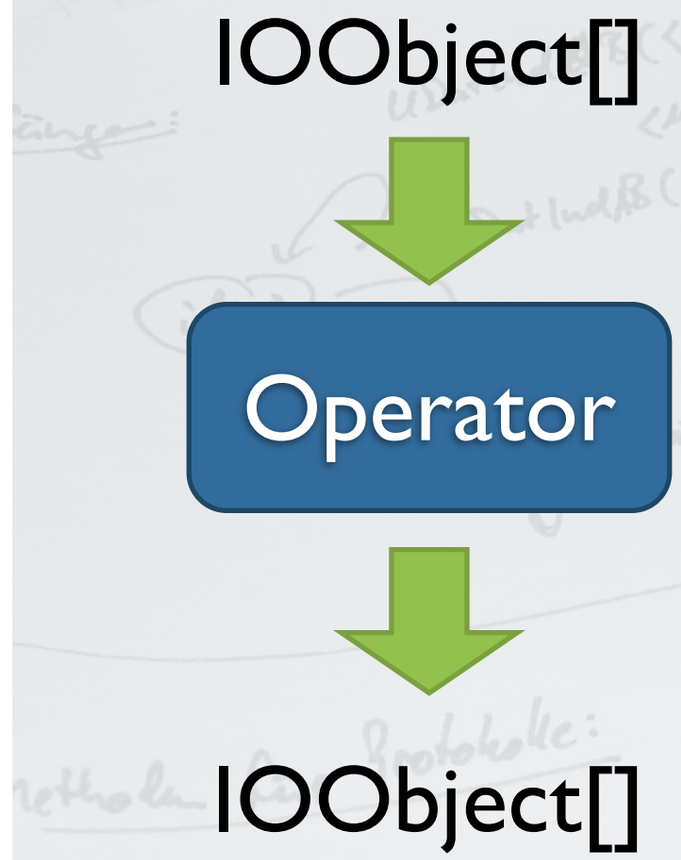

Details

- Die wichtigsten Klassen sind
  - `Example`, `ExampleSet`
  - `Attribute`, `Attributes`
- Jedes **Attribut** referenziert eine „Spalte“ bzw. Eigenschaft der Daten
- Jedes **Example** entspricht einer Zeile, also einem Beispiel unserer Daten
- **ExampleSet** kann man sich vorstellen als (N x p)-Matrix

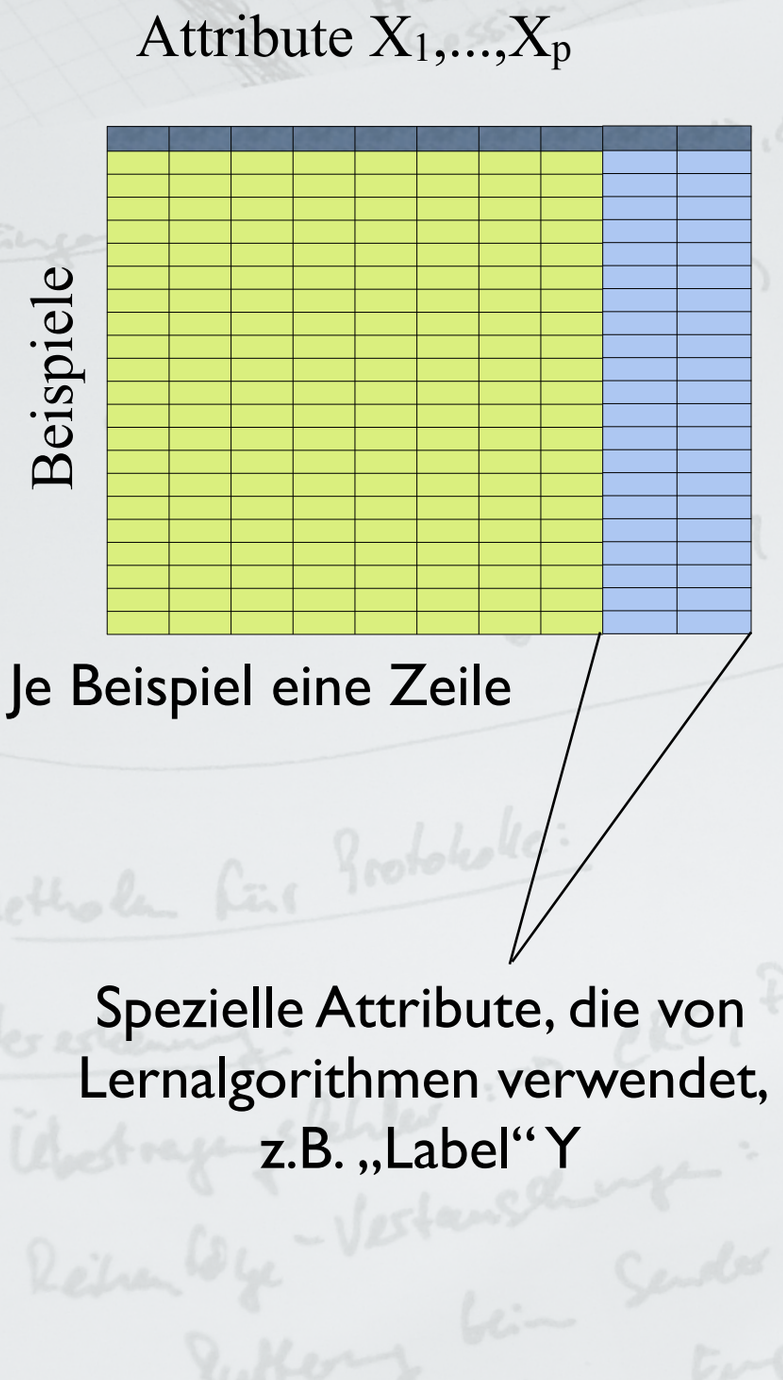

Attribute

- Attribute legen den Wertebereich einer „Spalte“ fest
- Neben einfachen double-Werten sind nominale, Integer oder auch Datums-Attribute möglich
- Die Attribute teilen sich in reguläre und spezielle Attribute auf
  - Regulär: Daten-Werte (in der Vorlesung mit **X** bezeichnet)
  - Speziell: z.B. das „Label“-Attribut

Temp	Outlook	Play (Label)
85	sunny	no
80	sunny	no
83	overcast	yes
70	rain	yes
68	rain	yes

Att1	Att2	Cluster-ID
0,35	4,87	1
0,29	9,27	2
0,47	2,31	0
0,98	7,53	2
0,56	6,82	1

ExampleSet

- ExampleSet stellt eine Menge von Beispielen über diesen Attributen dar
- Implementiert u.a. **`Iterable<Example>`** :

```
ExampleSet examples = ...

for( Example ex : examples ){
    ...
}
```

ExampleSet

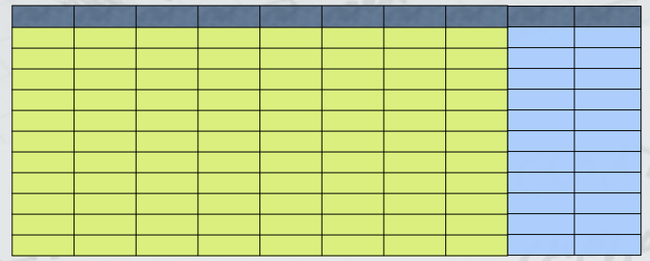

RapidMiner bietet Darstellung von ExampleSets als Tabelle

Data Table

Meta Data View | Data View | Plot View

ExampleSet (2000 examples, 1 special attribute, 2

row no.	label	att1	att2
1	class0	0.185	-0.866
2	class1	-0.629	-0.640
3	class1	-0.605	-0.430
4	class0	-0.872	-0.598
5	class0	-0.376	-0.500
6	class0	-0.246	-0.804
7	class1	-1.451	0.064

Example

- Example entspricht einem Beispiel, d.h. einer Menge von Werten für Attribute
- Beispiele werden intern durch eine Menge von double Werten repräsentiert

```
Example ex = ...

for(Attribute a : ex.getAttributes()){

    double value = ex.getValue( a );

}
```

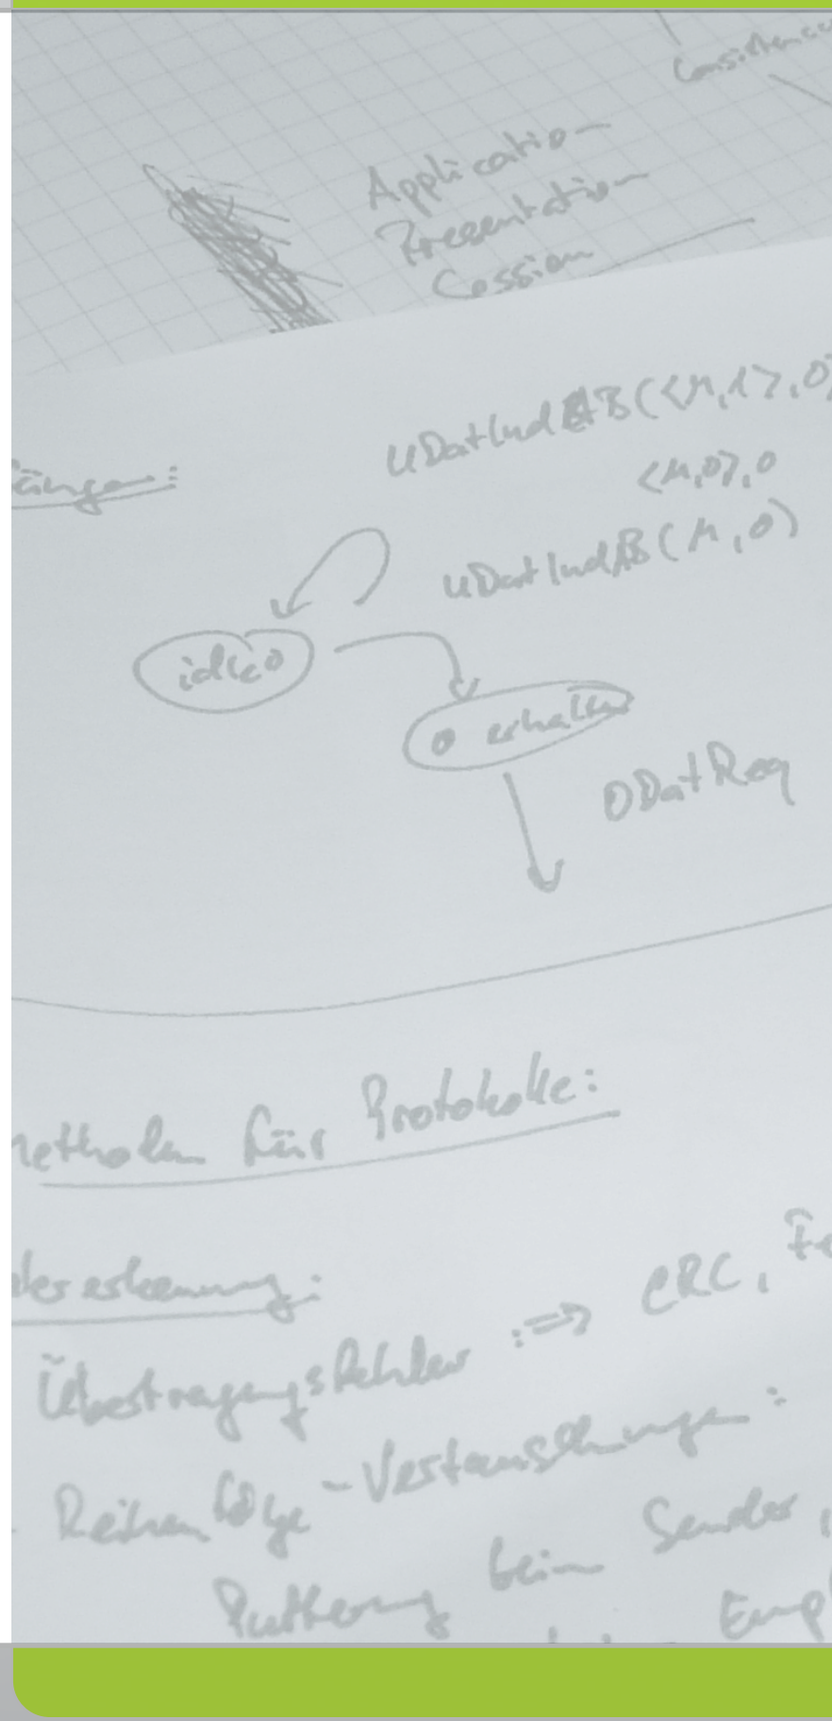

Example

- Example entspricht einem Beispiel, d.h. einer Menge von Werten für Attribute
- Beispiele werden intern durch eine Menge von double Werten repräsentiert

```
Example ex = ...

for(Attribute a : ex.getAttributes()){

    double value = ex.getValue( a );

}
```

Iteration über die **regulären** Attribute!

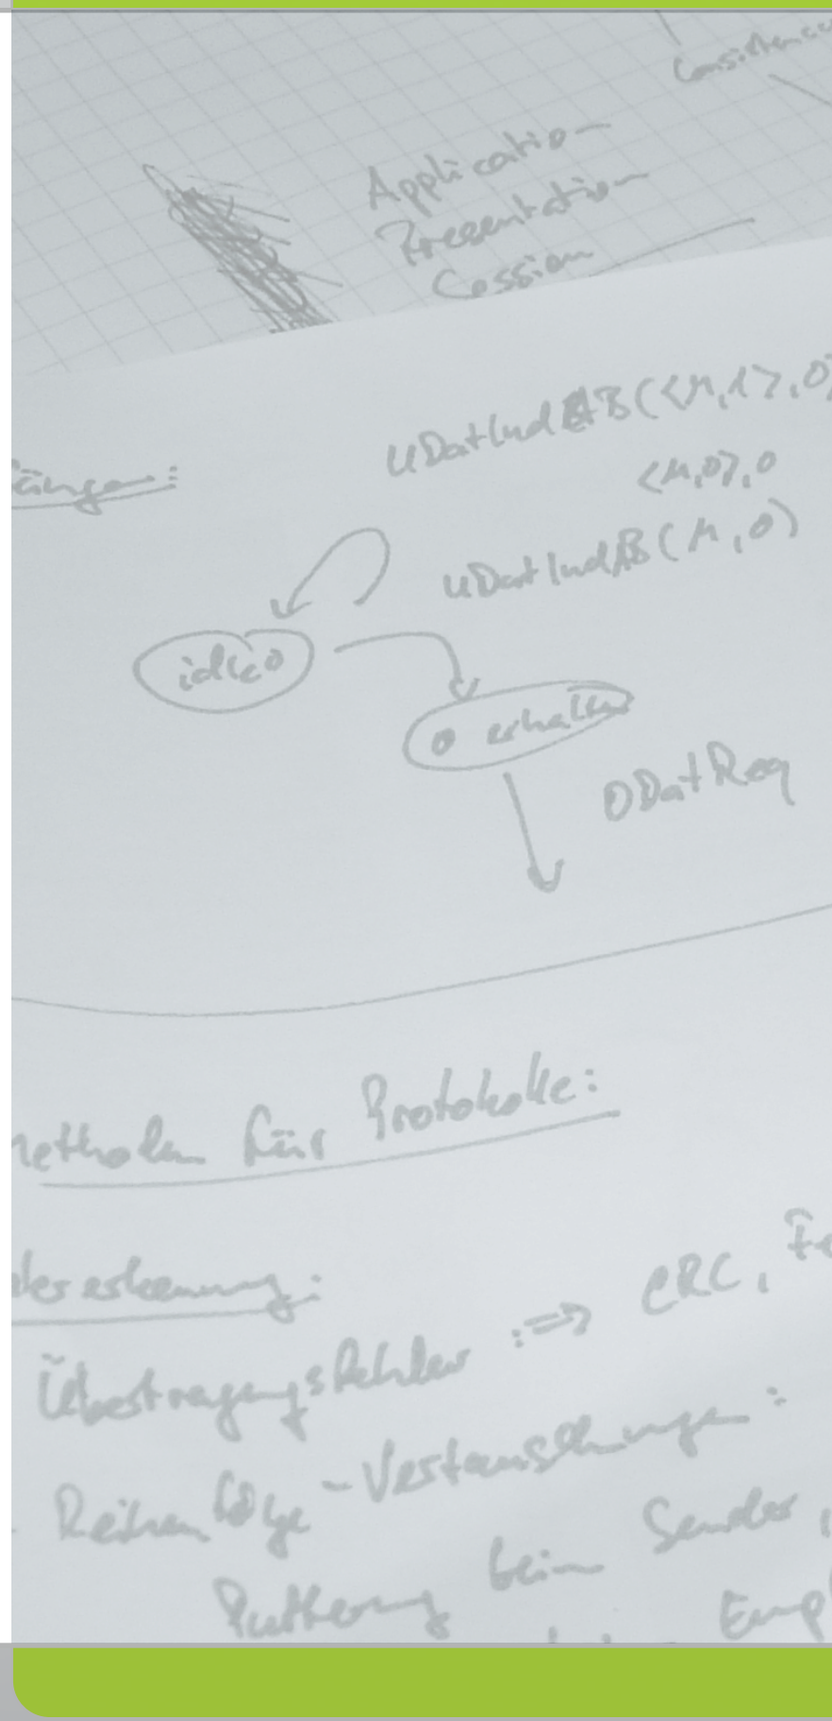

Attribute

- Nominale Attribute enthalten implizit ein Mapping

  double -> nominaler Wert

```
Example ex = ...
Attribute a = ...

double value = ex.getValue( a );

if( a.isNominal() ){

  String s = ex.getNominalValue( value );

}
```

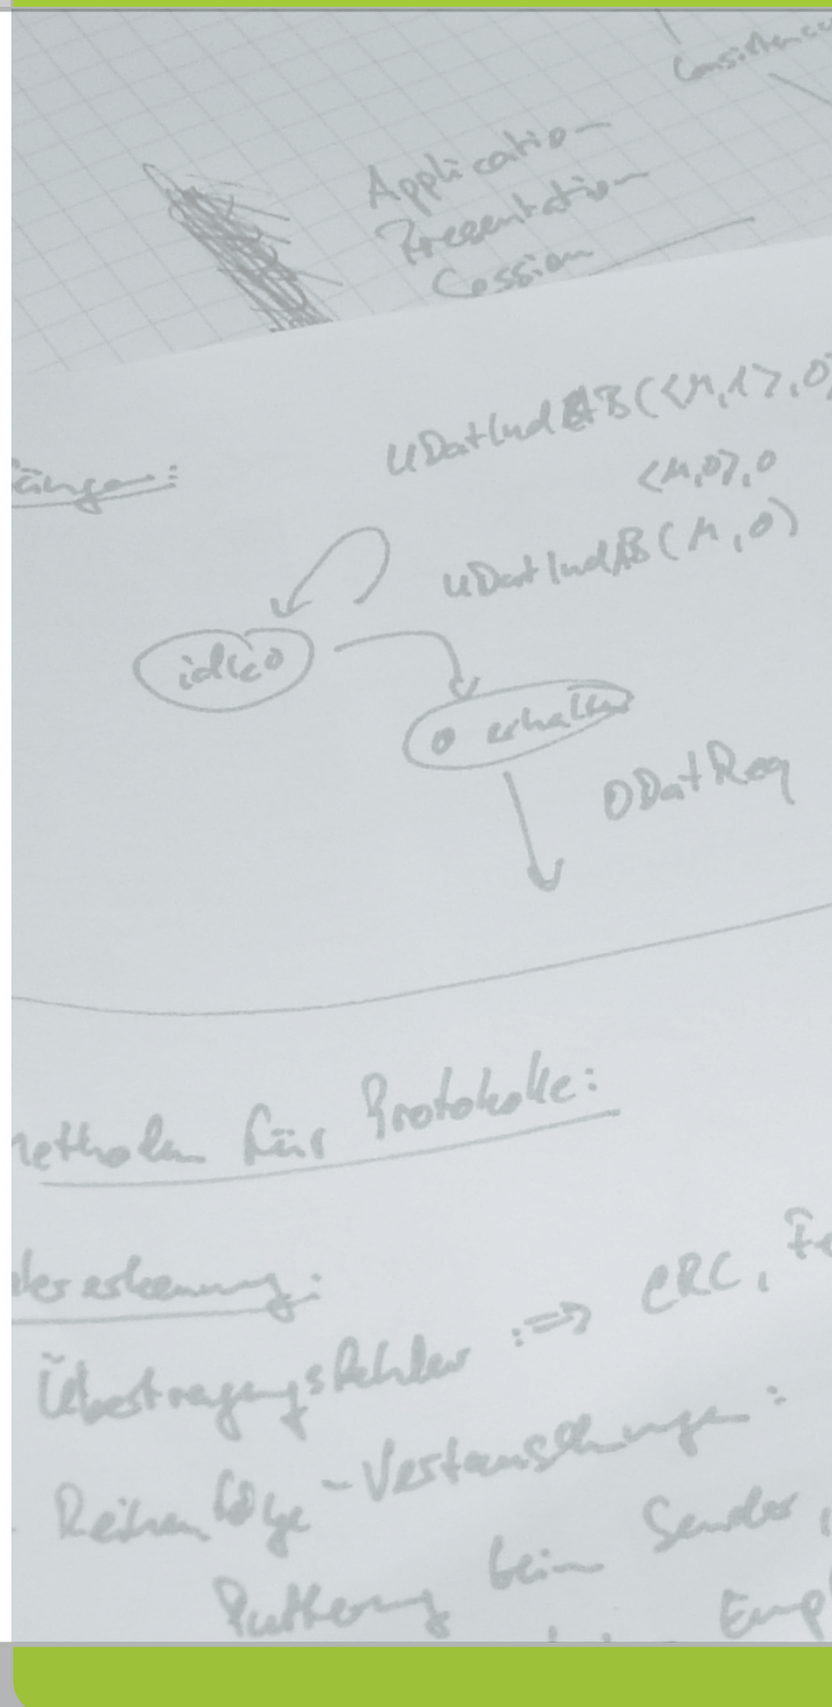

Übungen

- Über *subversion* ist der Lesezugriff auf ein Plugin-Projekt möglich
- **mlv-uebung** ist ein Java-Eclipse Projekt, welches ein eigenständiges RapidMiner-Plugin darstellt
- Das Plugin wird z.B. mit dem Ant-Tool erstellt:

  ant plugin

https://kissen.cs.uni-dortmund.de/svn/mlv-uebung/

Software

http://rapid-i.com
http://www.eclipse.org
http://subclipse.tigris.org
http://ant.apache.org

Übungen

- Das Projekt mlv-uebung enthält einige Basis-Klassen (com.rapidminer.plugin)
- Die zu implementierenden Übungen sind im Paket
  com.rapidminer.exercises
- Die Lösungen können im Ordner „solutions“ innerhalb des Projektes erstellt werden
- Mit „ant plugin“ läßt sich das Plugin erstellen

https://kissen.cs.uni-dortmund.de/svn/mlv-uebung/

Software
http://rapid-i.com
http://www.eclipse.org
http://subclipse.tigris.org
http://ant.apache.org

Übungen

- Mit Hilfe von **Ant** läßt sich das Plugin erstellen
  - Dazu im Verzeichnis **mlv-uebung** den Befehl „ant plugin“ aufrufen
  - Das entstehende Jar-Archiv ist das Plugin mit Eurer Lösung
  - Nach Kopie in ${RM}/lib/plugins/ sind die Operatoren aus dem Plugin beim nächsten Start verfügbar

https://kissen.cs.uni-dortmund.de/svn/mlv-uebung/

Software
http://rapid-i.com
http://www.eclipse.org
http://subclipse.tigris.org
http://ant.apache.org

Übungen

- Ausgabe der Übungsblätter in der Vorlesung
- Abgabe per Mail bis Dienstag danach
- Implementationsaufgaben:
  - Nach Möglichkeit in **einer** Datei (PDF) + Quellen (.java-Dateien)
  - Ansonsten: RM-Experiment (XML) + Ausgabe
- Gruppenabgaben (bis 4 Studierende) **erwünscht**

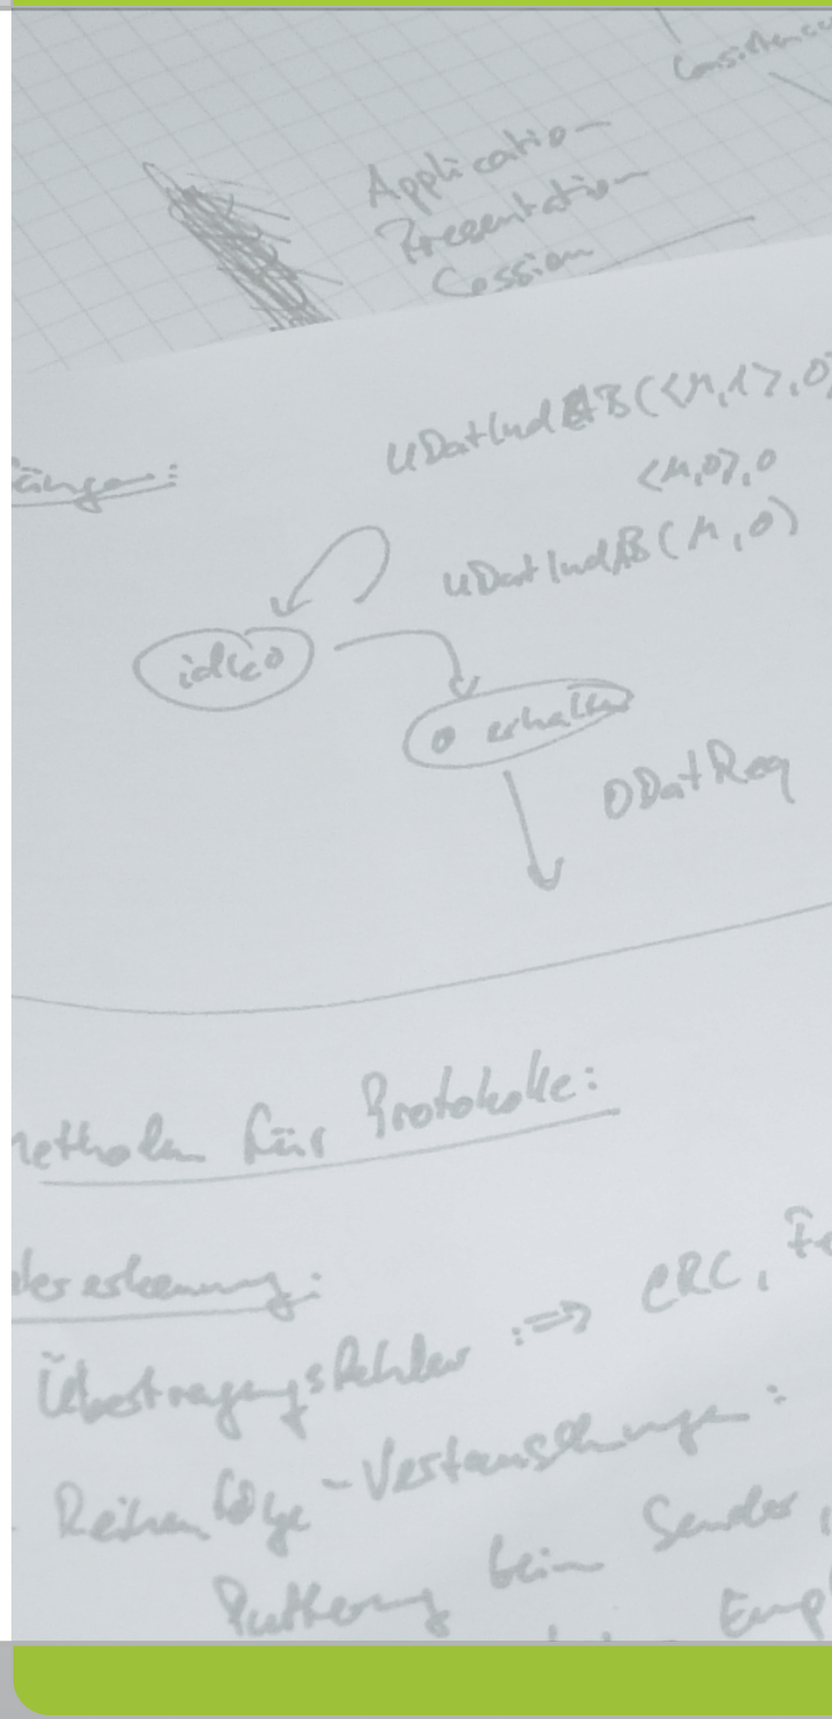

Übungen

- Fragen zu den Übungen, Eclipse/ Subversion oder ähnliches?
  - Sprechstunde:
    Montags 14 Uhr in GB IV, Raum 119
  - Per Telefon: 755-6487
  - Per Mail:
    christian.bockermann@cs.uni-dortmund.de