LEHRSTUHL 14
SOFTWARE ENGINEERING

Vorlesung

Methodische Grundlagen des Software-Engineering

im Sommersemester 2013

Prof. Dr. Jan Jürjens

TU Dortmund, Fakultät Informatik, Lehrstuhl XIV

Teil 2.4: Datenbeschaffung

v. 13.05.2013

2.4 Datenbeschaffung

[mit freundlicher Genehmigung basierend auf einem englischen Foliensatz von Prof. Dr. Wil van der Aalst (TU Eindhoven)]

Literatur:

[vdA11] Wil van der Aalst: **Process Mining: Discovery, Conformance and Enhancement of Business Processes**, Springer-Verlag. 2011.
Unibibliothek (6 Exemplare): http://www.ub.tu-dortmund.de/katalog/titel/1332248
(Bei Engpässen kann eine **Kopiervorlage** der relevanten Ausschnitte zur Verfügung gestellt werden.)

- **Kapitel 4**

Einordnung
2.4 Datenbeschaffung

- Geschäftsprozessmodellierung
- Business Process Mining
  - Einführung: Process Mining
  - Petrinetze
  - Prozessmodellierung und Analyse
  - Data-Mining
  - Datenbeschaffung
  - Prozessextraktion
  - Fortgeschrittene Prozessextraktion
- Modellbasierte Softwareentwicklung
- Modellbasierte Entwicklung sicherer Software

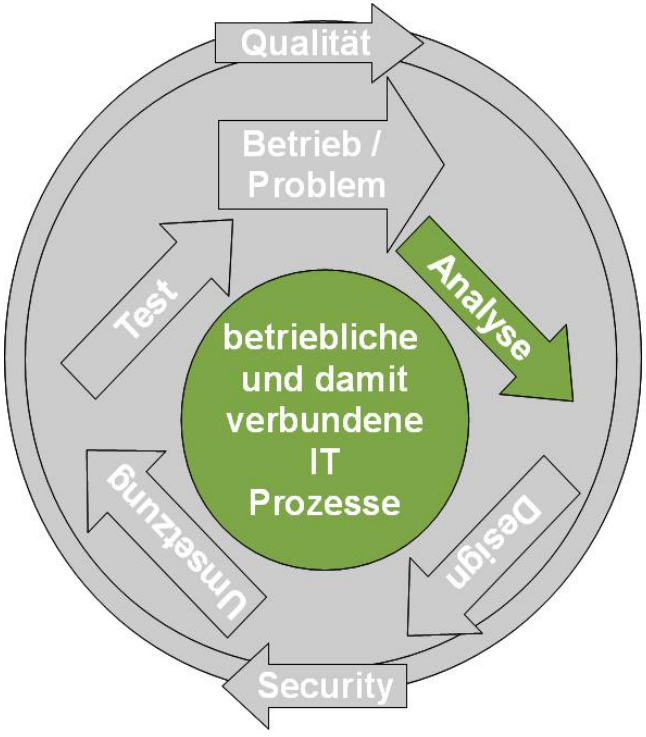

Ziel des Process-Minings

- Was geschah in der Vergangenheit ?
- Warum ist es passiert ?
- Was wird vermutlich in der Zukunft geschehen ?
- Wann und warum weichen Unternehmen und Leute voneinander ab ?
- Wie kann ein Prozess besser kontrolliert werden ?
- Wie kann ein Prozess neu entworfen werden, sodass die Performanz gesteigert wird ?

Datenbeschaffung

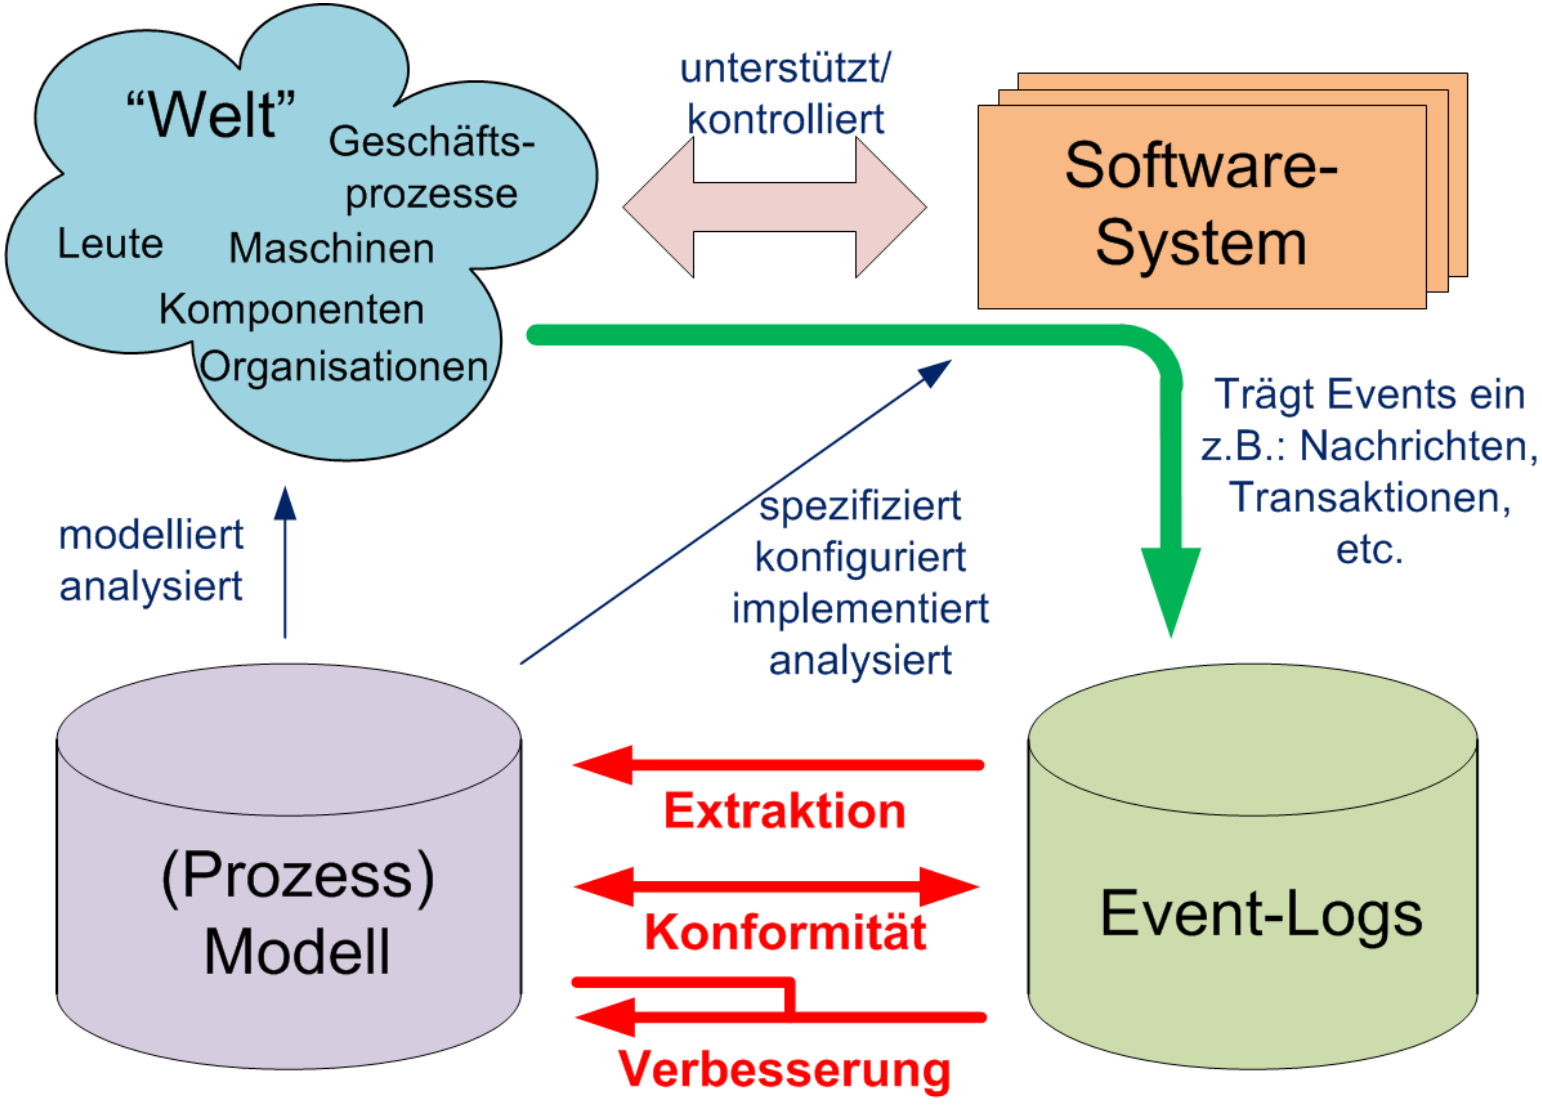

Von heterogenen Datenquellen zu Ergebnissen des Process-Minings

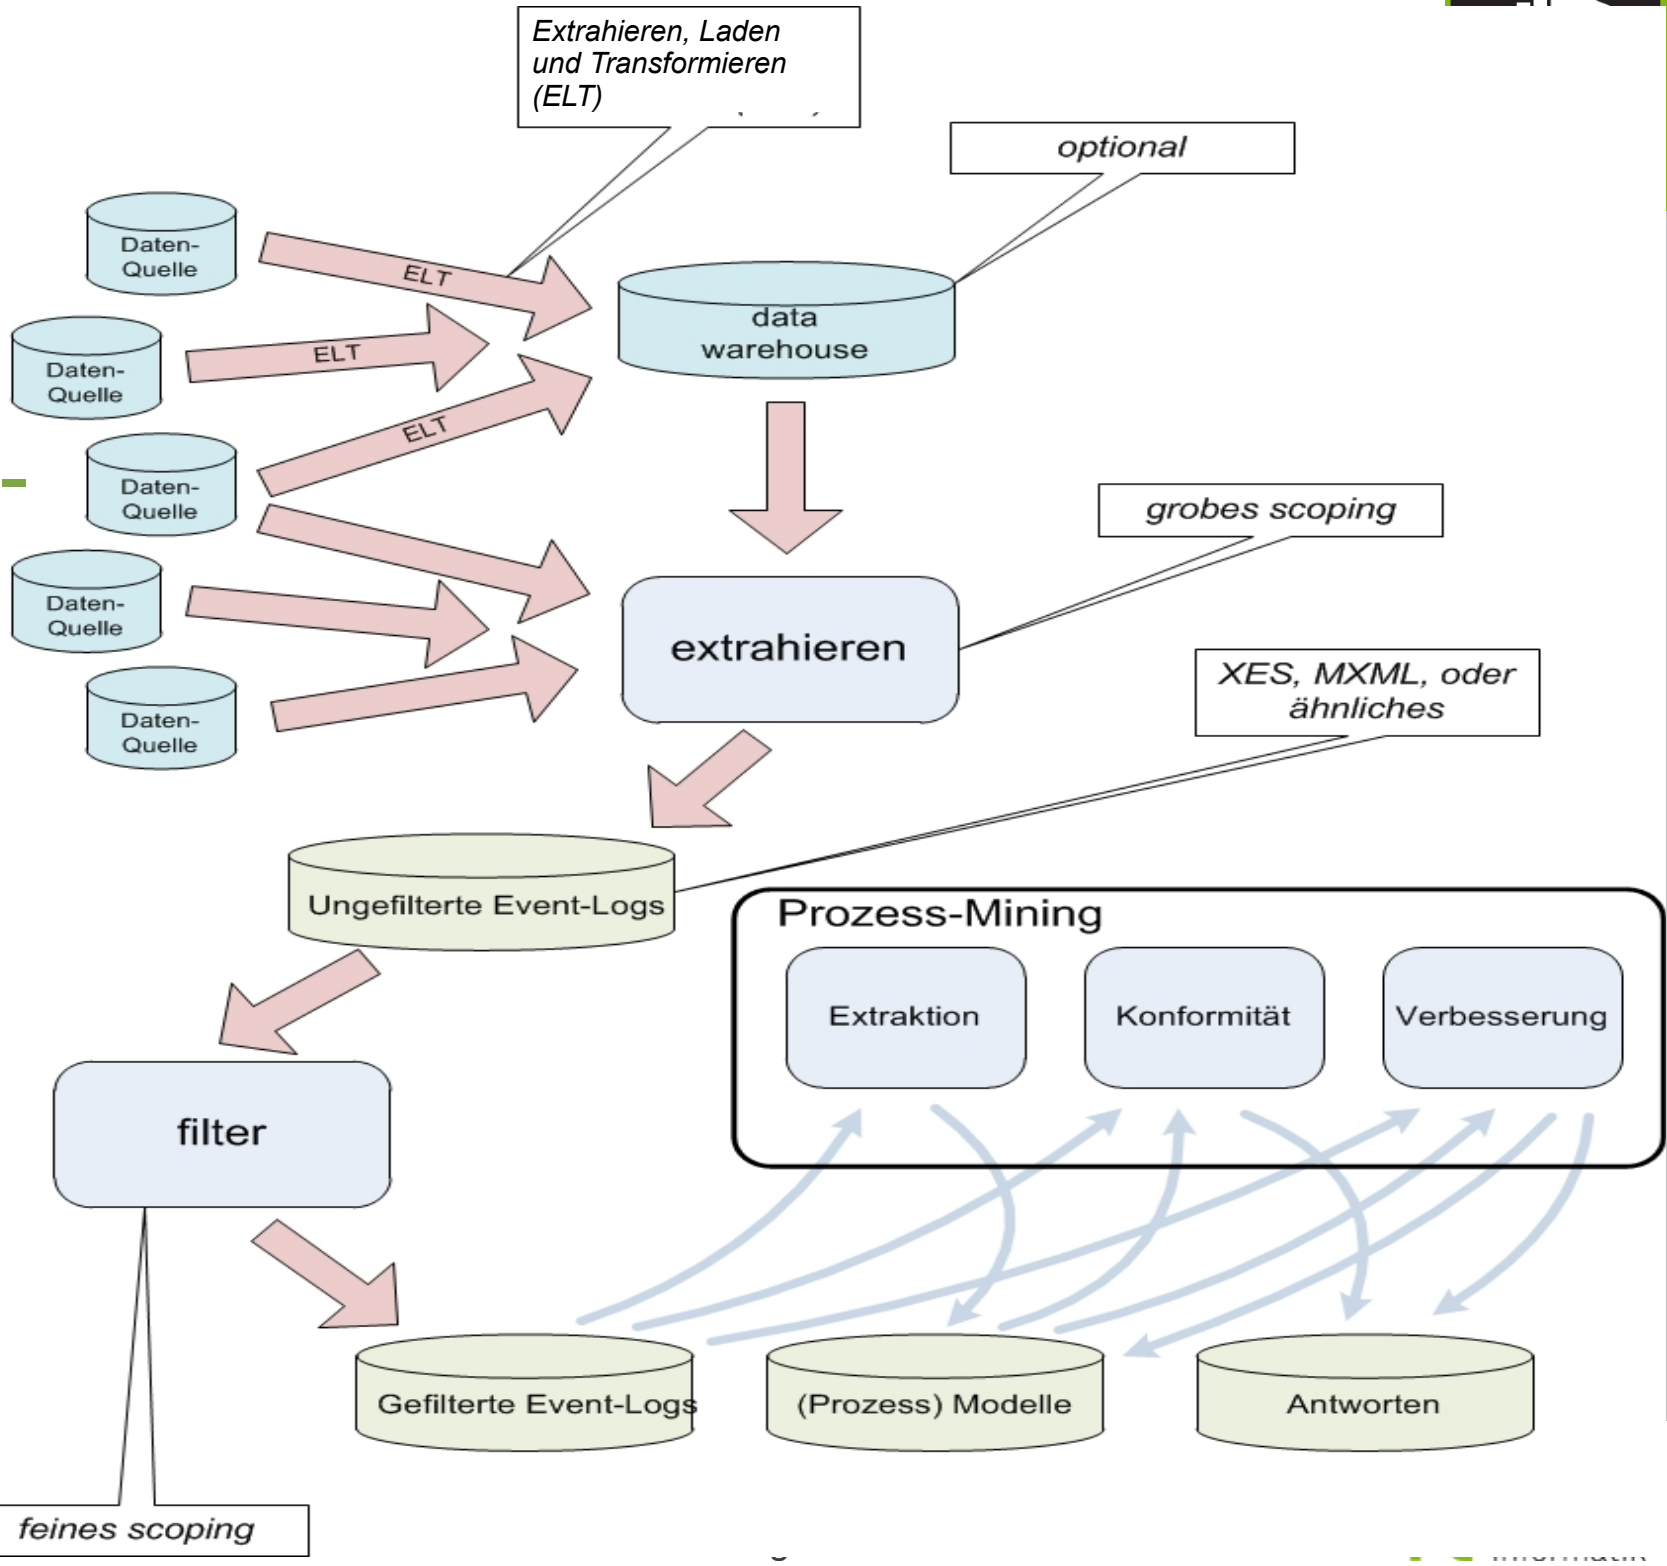

Beispiel Log

- Ein Prozess enthält Fälle (cases).
- Ein Fall besteht aus Events, jeder Event kann genau einem Fall zugeordnet werden.
- Events innerhalb eines Falles sind geordnet.
- Events können Attribute haben.
- Beispiele typischer Attributnamen sind: activity, time, costs und resource.

case id	event id	properties				
		timestamp	activity	resource	cost	...
1	35654423	30-12-2010:11.02	register request	Pete	50	...
	35654424	31-12-2010:10.06	examine thoroughly	Sue	400	...
	35654425	05-01-2011:15.12	check ticket	Mike	100	...
	35654426	06-01-2011:11.18	decide	Sara	200	...
	35654427	07-01-2011:14.24	reject request	Pete	200	...
2	35654483	30-12-2010:11.32	register request	Mike	50	...
	35654485	30-12-2010:12.12	check ticket	Mike	100	...
	35654487	30-12-2010:14.16	examine casually	Pete	400	...
	35654488	05-01-2011:11.22	decide	Sara	200	...
	35654489	08-01-2011:12.05	pay compensation	Ellen	200	...
3	35654521	30-12-2010:14.32	register request	Pete	50	...
	35654522	30-12-2010:15.06	examine casually	Mike	400	...
	35654524	30-12-2010:16.34	check ticket	Ellen	100	...
	35654525	06-01-2011:09.18	decide	Sara	200	...
	35654526	06-01-2011:12.18	reinitiate request	Sara	200	...
	35654527	06-01-2011:13.06	examine thoroughly	Sean	400	...
	35654530	08-01-2011:11.43	check ticket	Pete	100	...
	35654531	09-01-2011:09.55	decide	Sara	200	...
	35654533	15-01-2011:10.45	pay compensation	Ellen	200	...
4	35654641	06-01-2011:15.02	register request	Pete	50	...
	35654643	07-01-2011:12.06	check ticket	Mike	100	...
	35654644	08-01-2011:14.43	examine thoroughly	Sean	400	...
	35654645	09-01-2011:12.02	decide	Sara	200	...
	35654647	12-01-2011:15.44	reject request	Ellen	200	...
...	...	...	...	...	...	...

Alternative Ansicht

case id	event id	properties				
		timestamp	activity	resource	cost	…
1	35654423	30-12-2010:11.02	Registrierung anfragen	Pete	50	…
	35654424	31-12-2010:10.06	gründlich überprüfen	Sue	400	…
	35654425	05-01-2011:15.12	Ticket überprüfen	Mike	100	…
	35654426	06-01-2011:11.18	entscheiden	Sara	200	…
	35654427	07-01-2011:14.24	Anfrage ablehnen	Pete	200	…
2	35654483	30-12-2010:11.32	Registrierung anfragen	Mike	50	…
	35654485	30-12-2010:12.12	Ticket überprüfen	Mike	100	…
	35654487	30-12-2010:14.16	normal überprüfen	Pete	400	…
	35654488	05-01-2011:11.22	entscheiden	Sara	200	…
	35654489	08-01-2011:12.05	Entschädigung bezahlen	Ellen	200	…
3	35654521	30-12-2010:14.32	Registrierung anfragen	Pete	50	…
	35654522	30-12-2010:15.06	normal überprüfen	Mike	400	…
	35654524	30-12-2010:16.34	Ticket überprüfen	Ellen	100	…
	35654525	06-01-2011:09.18	entscheiden	Sara	200	…
	35654526	06-01-2011:12.18	Anfrage neu einleiten	Sara	200	…
	35654527	06-01-2011:13.06	gründlich überprüfen	Sean	400	…
	35654530	08-01-2011:11.43	Ticket überprüfen	Pete	100	…
	35654531	09-01-2011:09.55	entscheiden	Sara	200	…
	35654533	15-01-2011:10.45	Entschädigung bezahlen	Ellen	200	…
4	35654641	06-01-2011:15.02	Registrierung anfragen	Pete	50	…
	35654643	07-01-2011:12.06	Ticket überprüfen	Mike	100	…
	35654644	08-01-2011:14.43	gründlich überprüfen	Sean	400	…
	35654645	09-01-2011:12.02	entscheiden	Sara	200	…
	35654647	12-01-2011:15.44	Anfrage ablehnen	Ellen	200	…
…	…	…	…	…	…	…

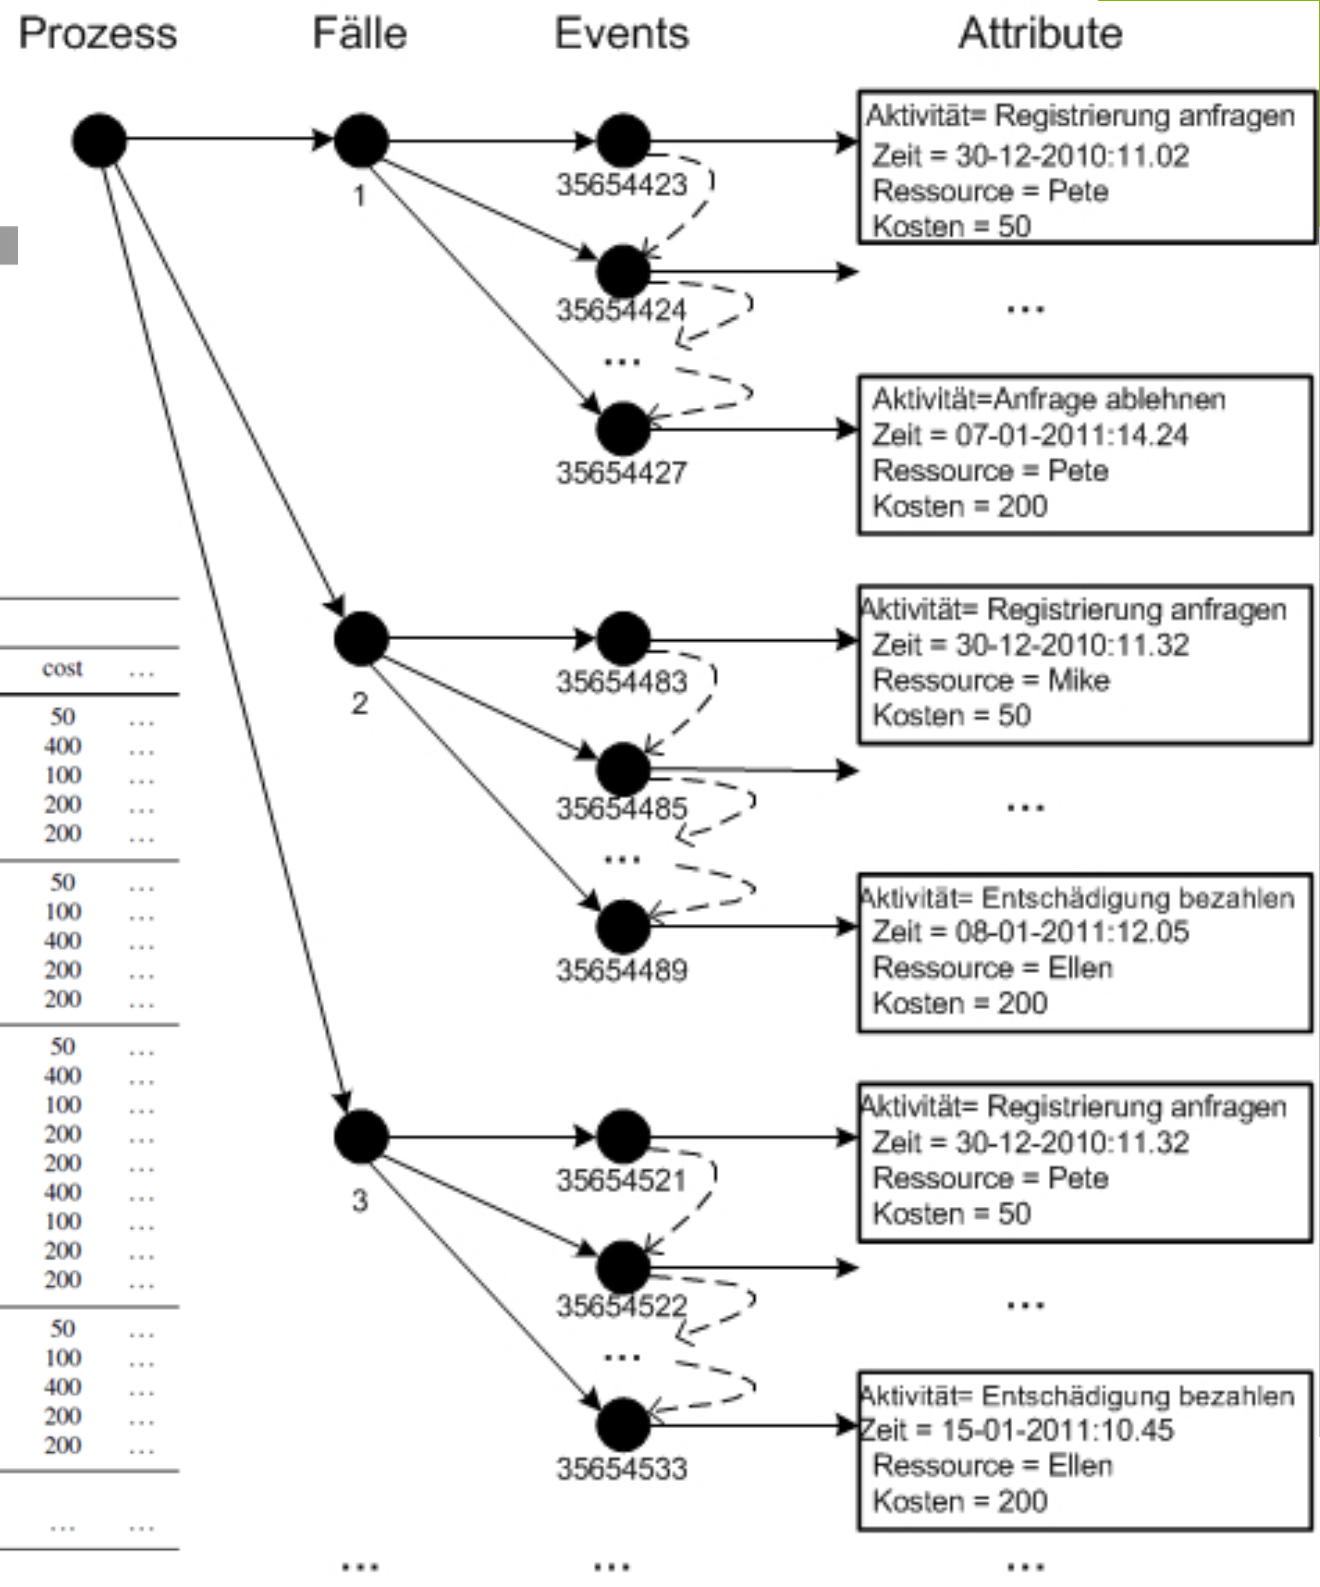

Standard-Lebenszyklus-Modell einer Transaktion

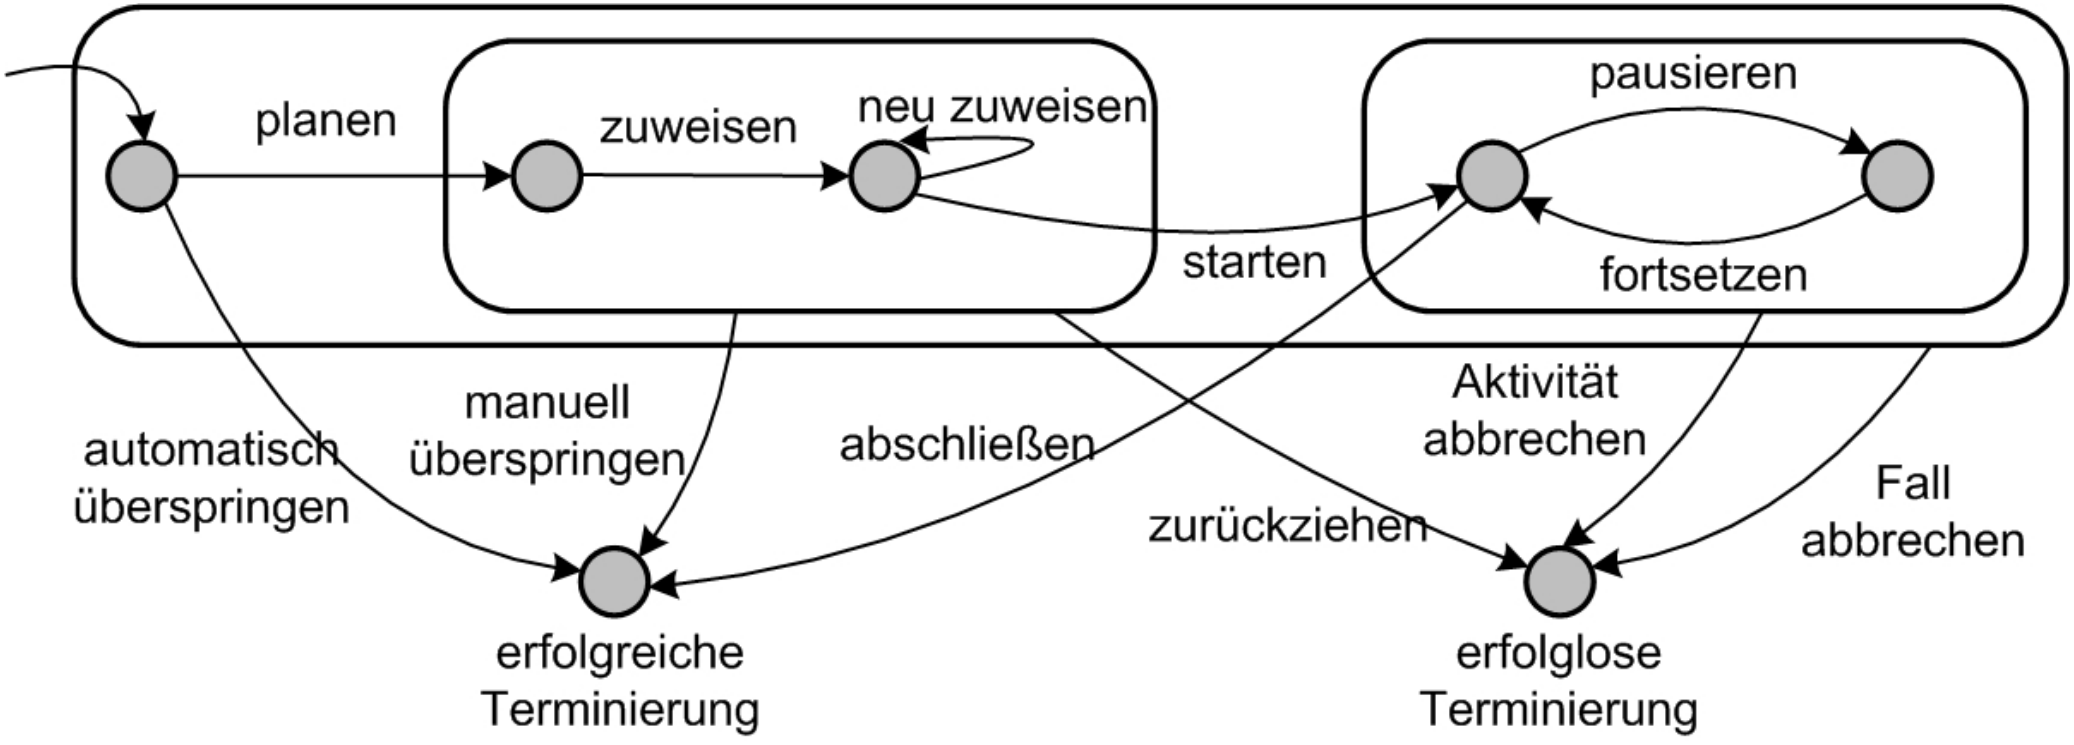

Fünf Aktivitätsinstanzen

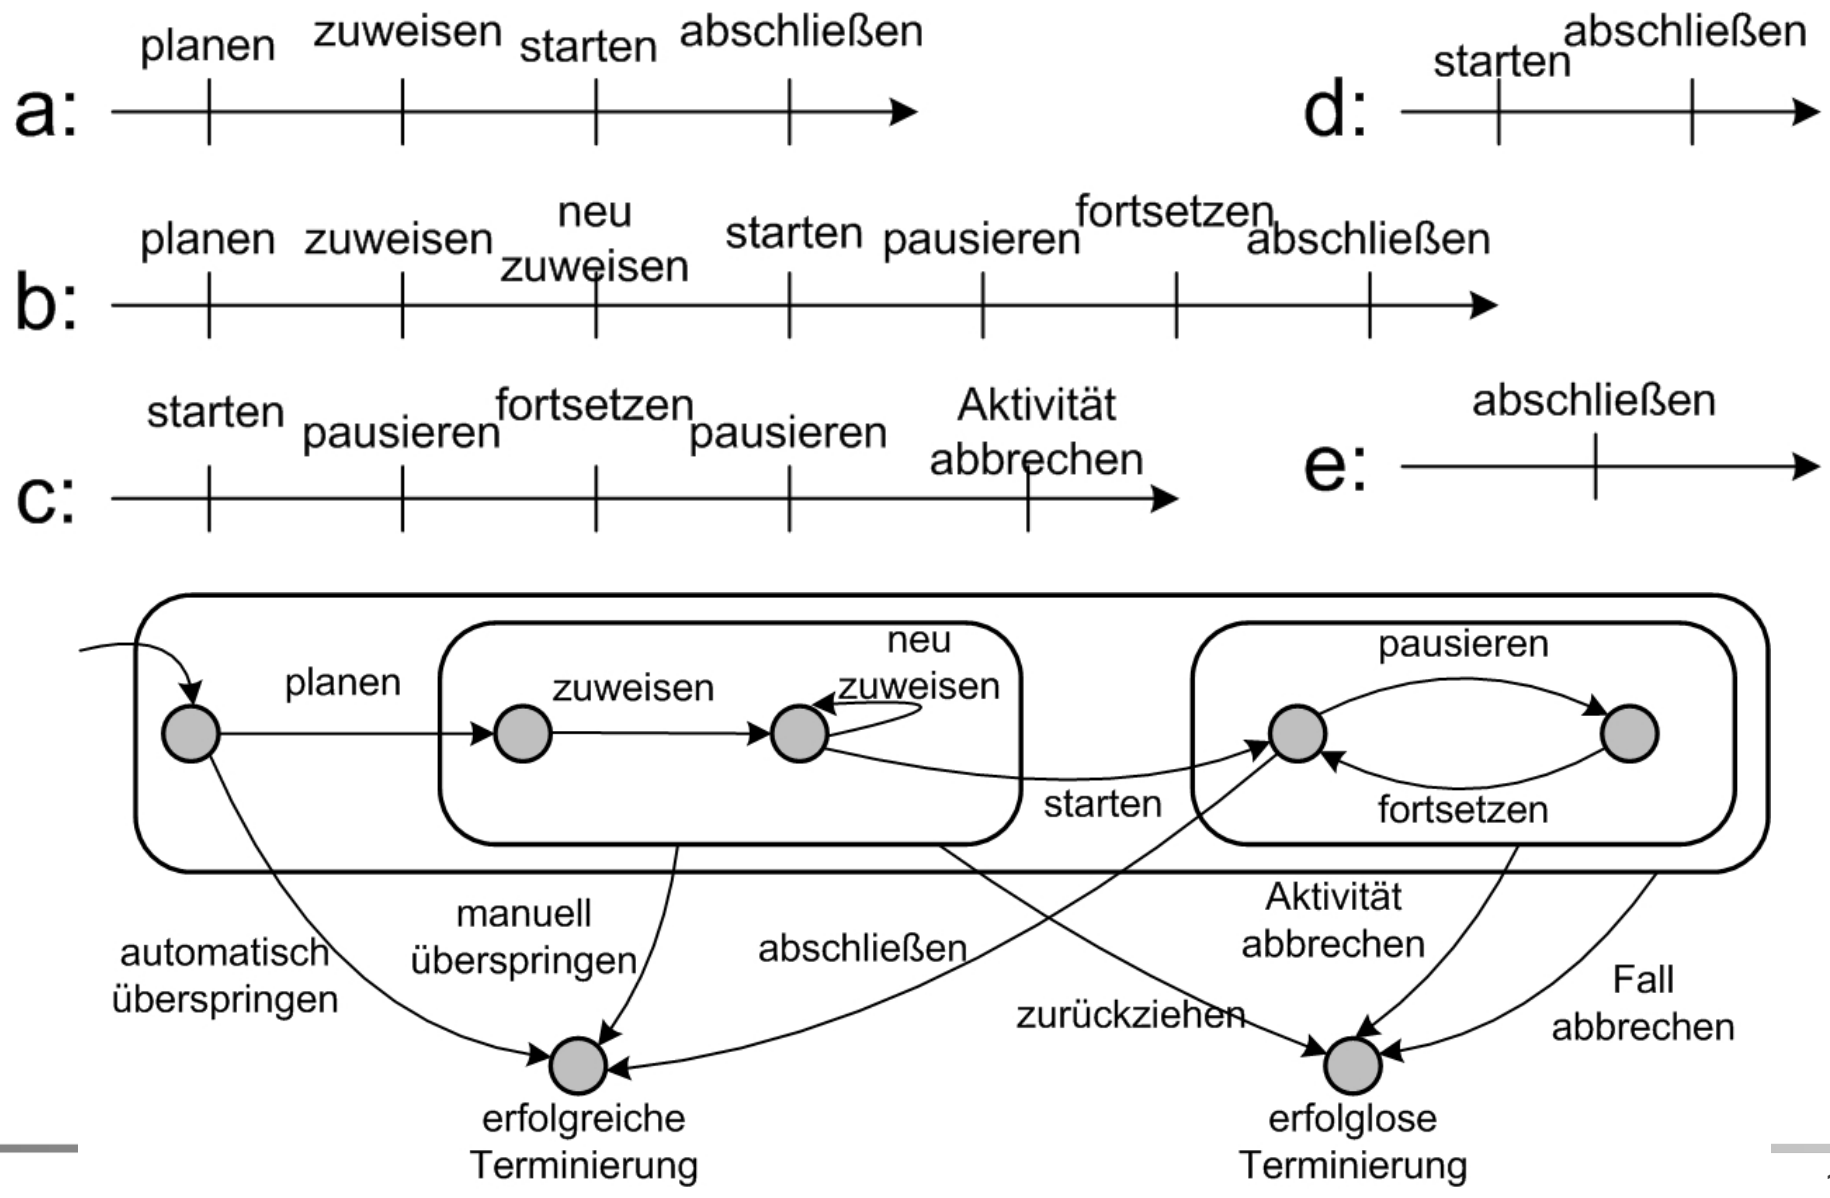

Überlappende Aktivitätsinstanzen

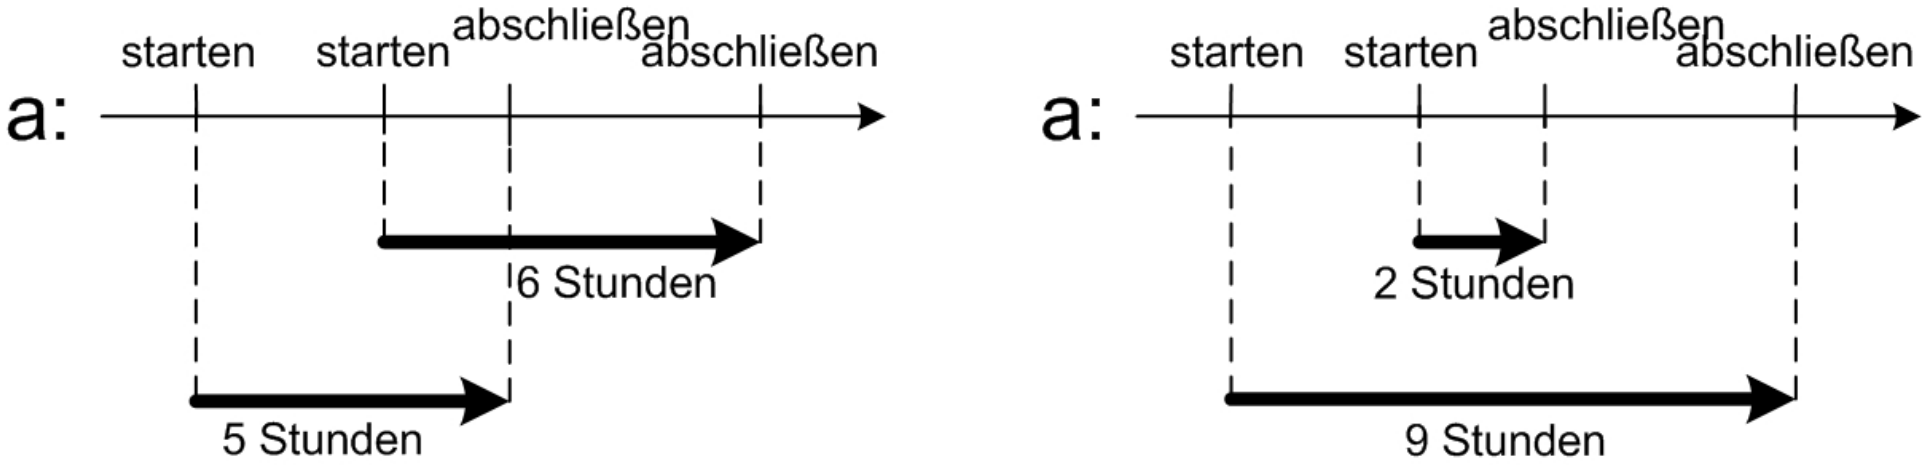

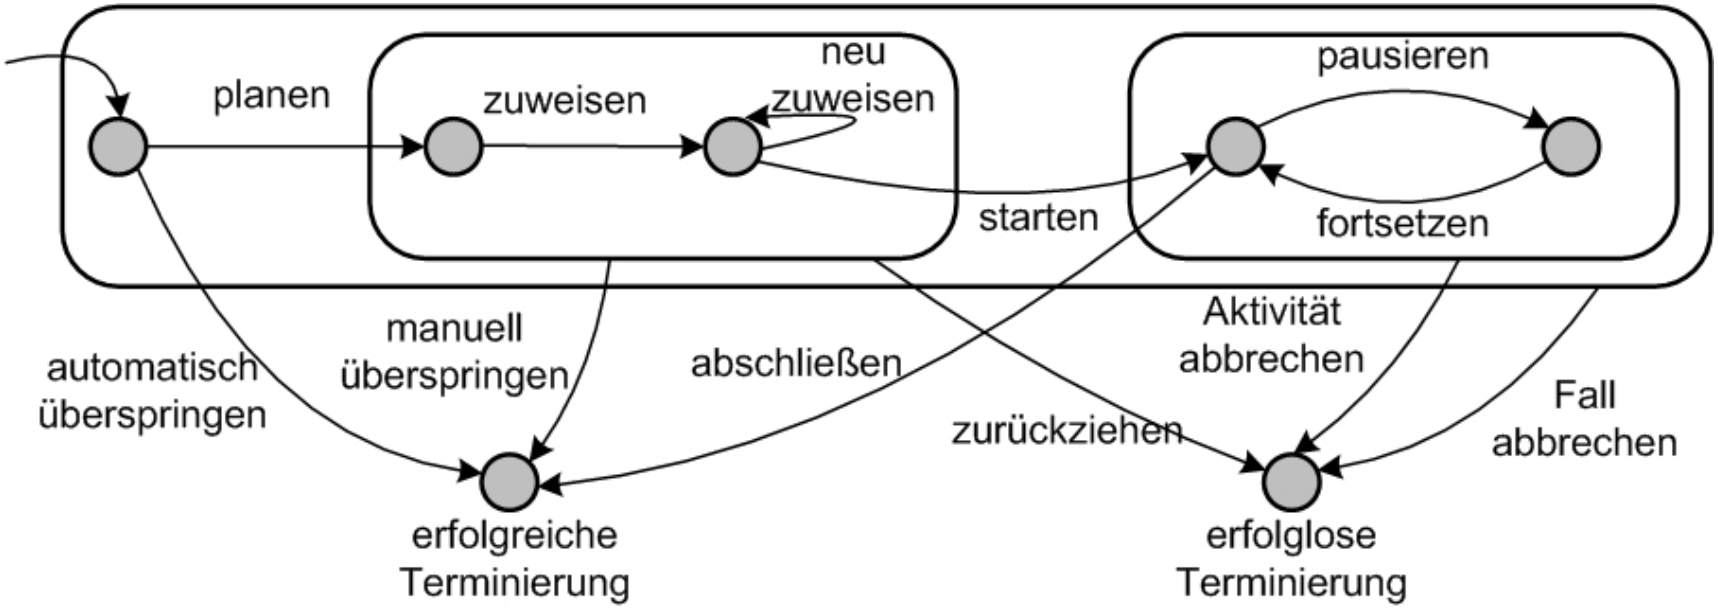

Attribute im Einsatz

Soziales Netzwerk, welches darstellt, wie Arbeit von einer Person zu einer anderen Verteilt wird.

Performanz-Indikatoren pro Aktivität

Aktivität b
Häufigkeit: 456
Wartezeit: 15.6 +/- 2.5 hours
Bearbeitungszeit: 1.2 +/- 0.5 hours
Kosten: 412 +/- 55 euros

Aktivität g
Häufigkeit: 311
Wartezeit: 12.4 +/- 2.1 hours
Bearbeitungszeit: 0.5 +/- 0.2 hours
Kosten: 198 +/- 35 euros

Aktivität h
Häufigkeit: 407
Wartezeit: 7.4 +/- 1.8 hours
Bearbeitungszeit: 1.1 +/- 0.3 hours
Kosten: 209 +/- 38 euros

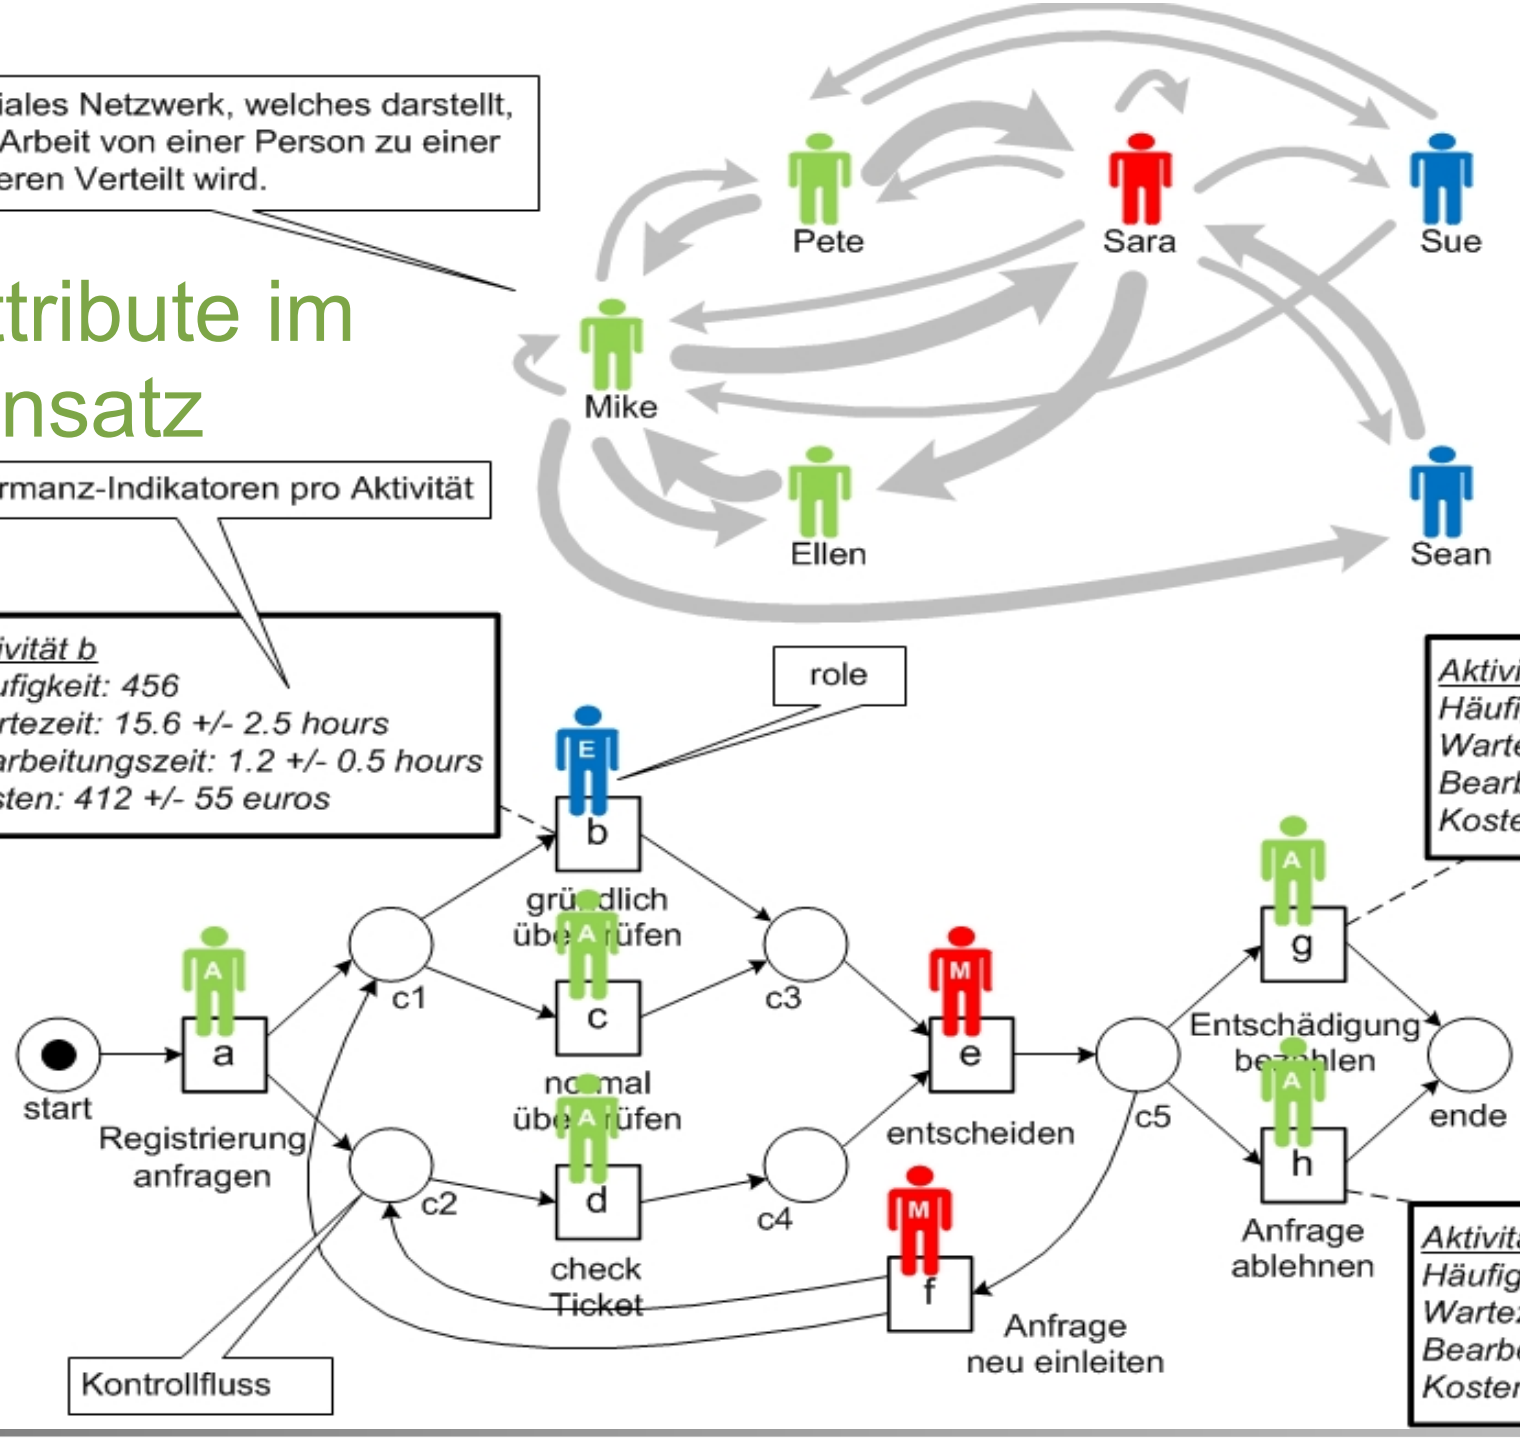

XES (eXtensible Event Stream)

- **Standard-Datenspeicherformat für Event-Logs**
- Siehe www.xes-standard.org.
- Von der IEEE Arbeitsgruppe für Process-Mining übernommen.
- Vorgänger: MXML und SA-MXML.
- Wird von Tools wie ProM (ab Version 6), Nitro, XESame und OpenXES unterstützt.
- ProMimport unterstützt MXML.

XES Schema

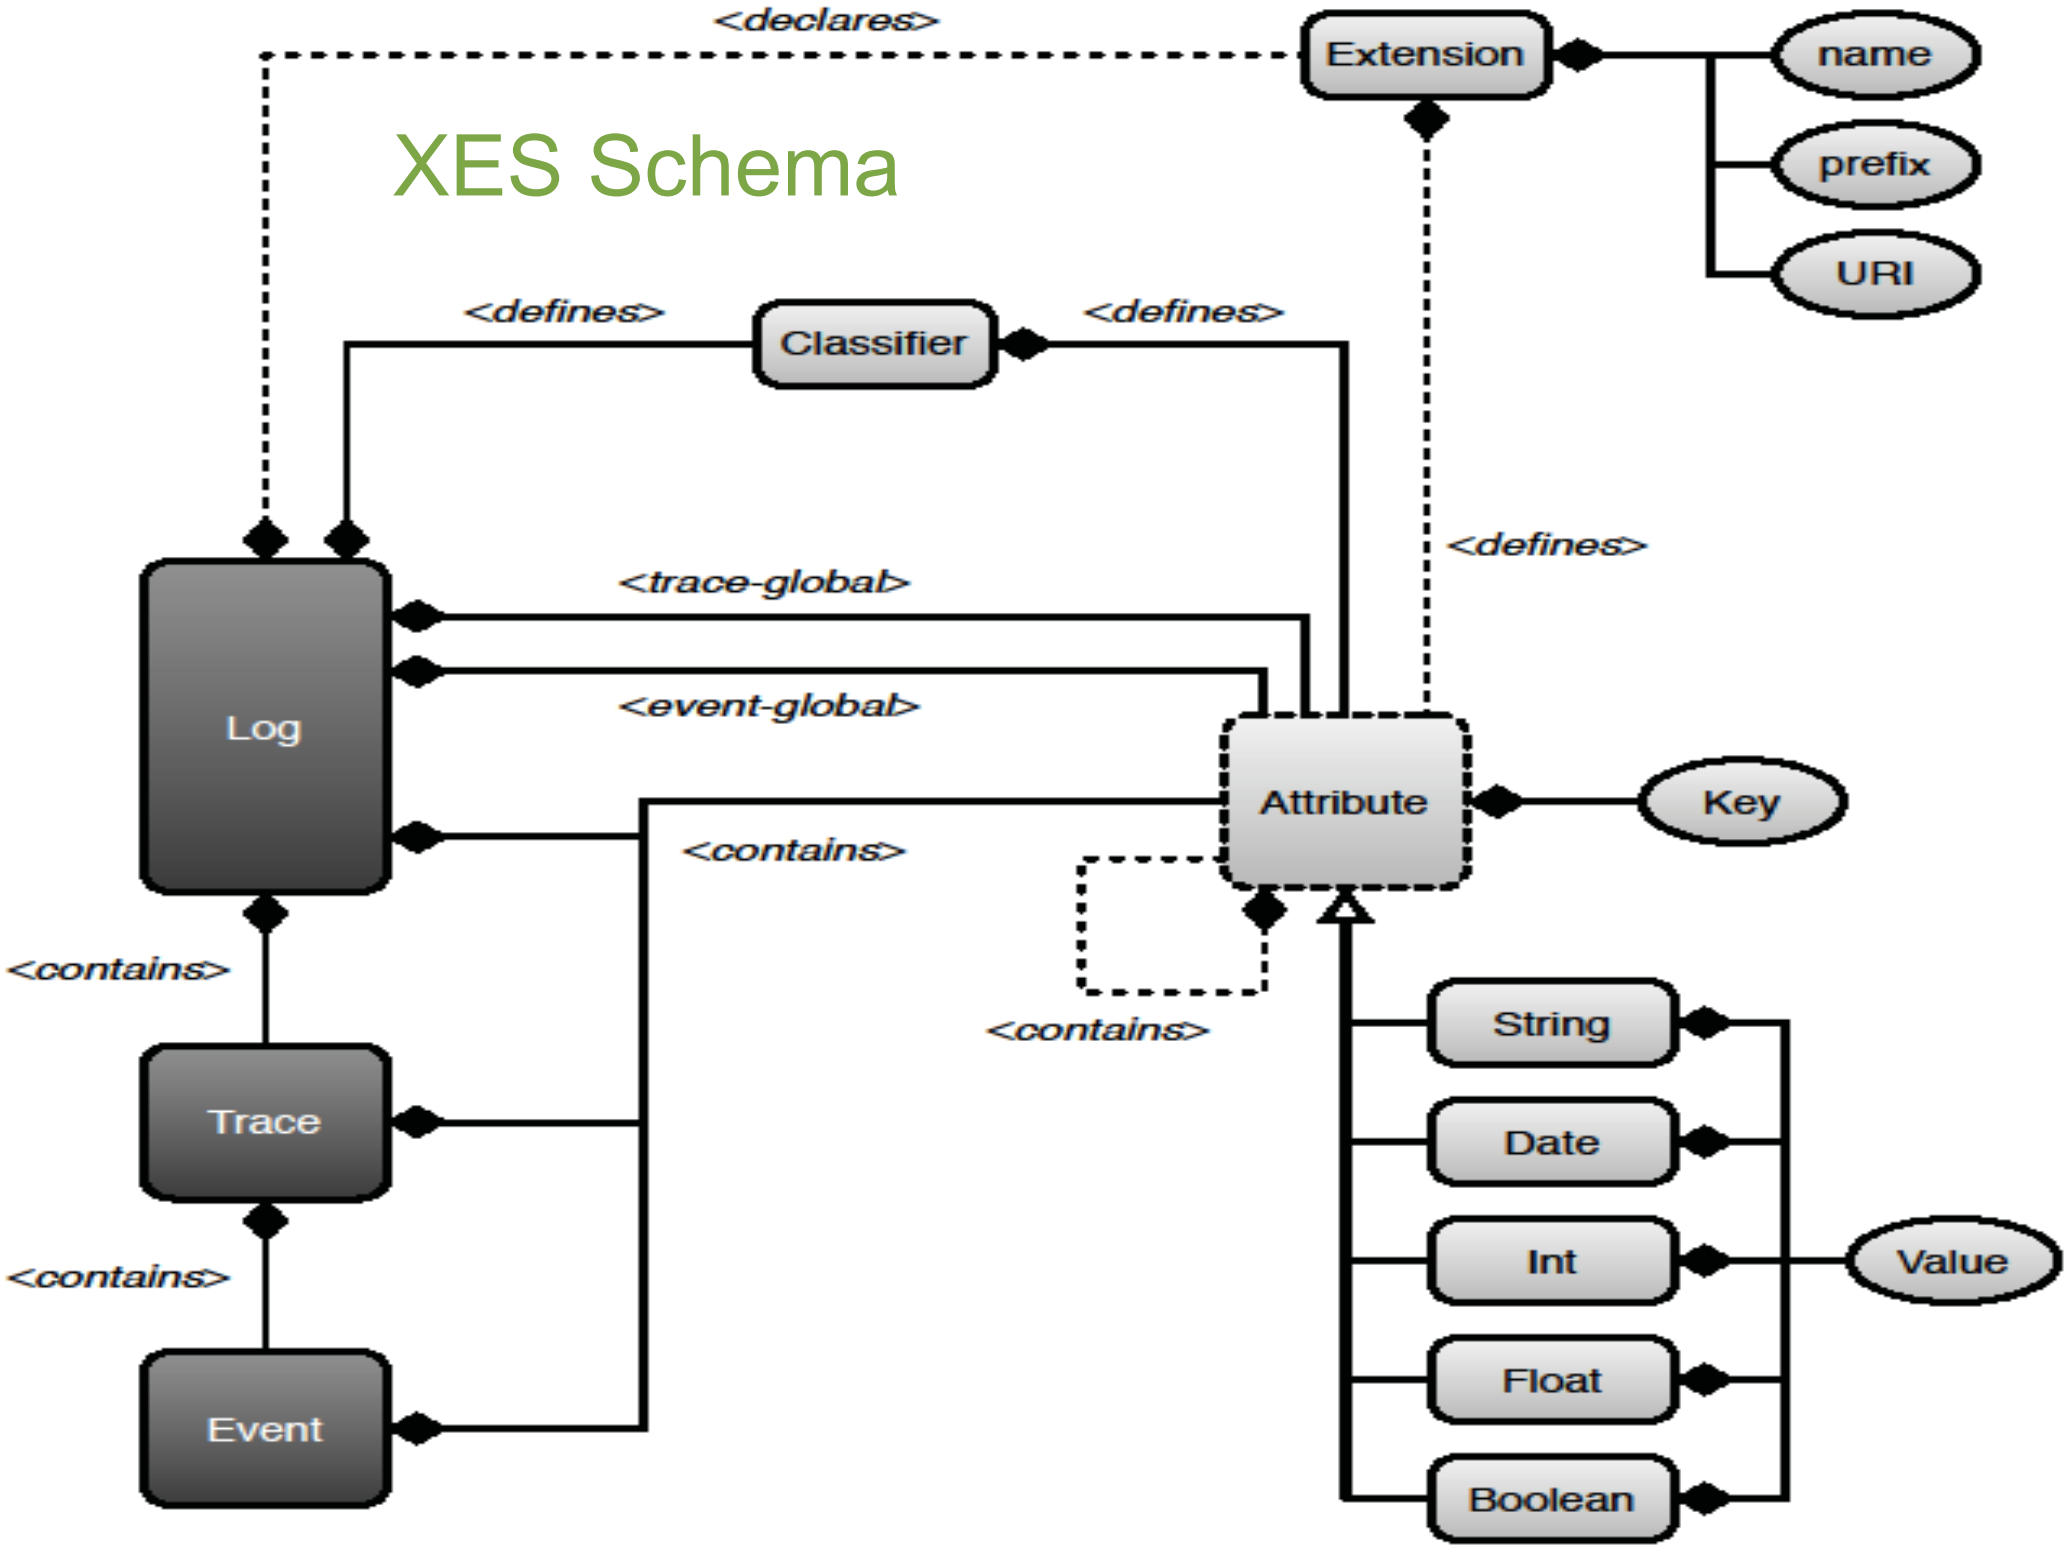
<declares>
Extension
name
prefix
URI
<defines>
Classifier
<defines>
<defines>
Log
<trace-global>
<event-global>
Attribute
Key
<contains>
<contains>
<contains>
Trace
<contains>
Event
String
Date
Int
Float
Boolean
Value

XES

Event-Log besteht aus:

- **Traces** (Prozessinstanzen)
  - **Events**

Standarderweiterungen:

- concept (zur Namensgebung)
- lifecycle (für Transaktionseigenschaften)
- org (unternehmerische Perspektive)
- time (Zeitstempel)
- semantic (Referenzen zu Ontologie)

```
<log xes.version="1.0" xes.features="nested-attributes" openxes.version="1.0RC7">
  <extension name="Concept" prefix="concept" uri="http://code.deckfour.org/xes/concept.xesext"/>
  <extension name="Semantic" prefix="semantic" uri="http://code.deckfour.org/xes/semantic.xesext"/>
  <extension name="Time" prefix="time" uri="http://code.deckfour.org/xes/time.xesext"/>
  <extension name="Organizational" prefix="org" uri="http://code.deckfour.org/xes/org.xesext"/>
  <extension name="Lifecycle" prefix="lifecycle" uri="http://code.deckfour.org/xes/lifecycle.xesext"/>
- <global scope="trace">
    <string key="concept:name" value="__INVALID__"/>
  </global>
- <global scope="event">
    <string key="concept:name" value="__INVALID__"/>
    <string key="lifecycle:transition" value="complete"/>
  </global>
  <classifier name="MXML Legacy Classifier" keys="concept:name lifecycle:transition"/>
  <classifier name="Event Name" keys="concept:name"/>
  <classifier name="Resou
  <string key="source" val
  <string key="concept:nar                                    d_more_data.zip"/>
  <string key="lifecycle:mod                value="standard"/>
  <string key="description" value="Simulated process"/>
- <trace>
    <string key="concept:name" value="1"/>
    <string key="description" value="Simulated process instance"/>
  - <event>
      <string key="org:resource" value="Mike"/>
      <date key="time:timestamp" value="2006-01-01T00:00:00.000+01:00"/>
      <string key="concept:name" value="invite reviewers"/>
      <string key="lifecycle:transition" value="start"/>
    </event>
  - <event>
      <string key="org:reso
      <date key="time:time                    01-06T00:00:00.000+01:00"/>
      <string key="concept:name" value="invite reviewers"/>
      <string key="lifecycle:transition" value="complete"/>
    </event>
  - <event>
```

Erweiterungen laden

jeder Trace hat einen Namen

jedes Event hat einen Namen und eine Transition

classifier = Name + Transition

Beginn vom Trace (Prozessinstanz)

Name des Trace

Ressource

Zeitstempel

Name des Events (Aktivitätsname)

Transition

```
- <event>
    <string key="org:resource" value="Anne"/>
    <date key="time:timestamp" value="2009-06-23T01:00:00.000+02:00"/>
    <string key="concept:name" value="accept"/>
    <string key="lifecycle:transition" value="start"/>
  </event>
- <event>
    <string key="org:resource" value="Anne"/>
    <date key="time:timestamp" value="2009-06-28T01:00:00.000
    <string key="concept:name" value="accept"
    <string key="lifecycle:transition" value="complete"/>
  </event>
</trace>
- <trace>
  <string key="concept:name" value="68"/>
  <string key="description" value="Simulated process instance"/>
- <event>
    <string key="org:resource" value="Mike"/>
    <date key="time:timestamp" value="2006-10-14T01:00:00.000+02:00"/>
    <string key="concept:name" value="invite reviewers"/>
    <string key="lifecycle:transition" value="start"/>
  </event>
- <event>
    <string key="org:resource" value="Mike"/>
    <date key="time:timestamp" value="2006-10-14T01:00:00.000+02:00"/>
    <string key="concept:name" value="invite reviewers"/>
    <string key="lifecycle:transition" value="complete"/>
  </event>
- <event>
    <string key="org:resource" value="Pam"/>
    <date key="time:timestamp" value="2006-10-14T01:00:00.000+02:00"/>
    <string key="lifecycle:transition" value="complete"/>
    <string key="Result by Reviewer A" value="reject"/>
    <string key="concept:name" value="get review 1"/>
  </event>
- <event>
```

Abschluss vom Trace (Prozessinstanz)

Beginn vom Trace

Name des Trace

Ressource

Zeitstempel

Name des Event (Name der Aktivität)

zum Event zugeordnete Daten

Herausforderungen beim Extrahieren des Event-Logs

- Korrelation: Events in Event-Log: nach Fällen gruppiert.
  Nicht trivial: setzt **Korrelation** der **Events untereinander** voraus.
- Zeitstempel: Muss **Events** pro Fall **ordnen**.
  Typische Probleme: **nur Datum**, **unterschiedliche Uhren**, **verzögertes Loggen**.
- Snapshots: Fälle ggf. **über** Dauer der **Aufnahme hinweg** aktiv.
  Z.B.: Fall vor Beginn des Event-Logs gestartet.
- Scoping: Welche Tabellen berücksichtigen ?
- Granularität: Events in Event-Log: andere Granularität als für Endnutzer relevante Aktivitäten.

Event-Logs vs. Tabellen

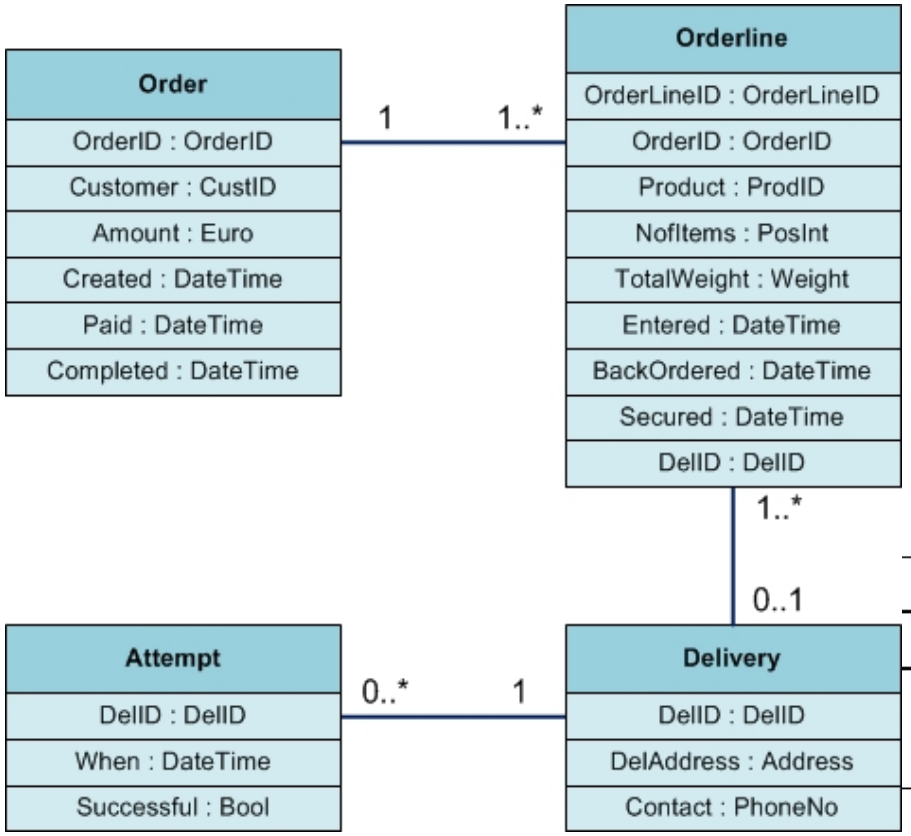

Order

OrderID	Customer	Amount	Created	Paid	Completed
91245	John	100	28-11-2011:08.12	02-12-2011:13.45	05-12-2011:11.33
91561	Mike	530	28-11-2011:12.22	03-12-2011:14.34	05-12-2011:09.32
91812	Mary	234	29-11-2011:09.45	02-12-2011:09.44	04-12-2011:13.33
92233	Sue	110	29-11-2011:10.12	null	null
92345	Kirsten	195	29-11-2011:14.45	02-12-2011:13.45	null
92355	Pete	320	29-11-2011:16.32	null	null
...	...	...	...	...	...

Delivery

DelID	DelAddress	Contact
882345	5513VJ-22a	0497-255366
882346	5513XG-45	040-229876
...	...	...

Attempt

DelID	When	Successful
882345	05-12-2011:08.55	false
882345	06-12-2011:09.12	false
882345	07-12-2011:08.56	true
882346	05-12-2011:08.43	true
...	...	...

Orderline

OrderLineID	OrderID	Product	NofItems	TotalWeight	Entered	BackOrdered	Secured	DelID
112345	91245	iPhone 4G	1	0.250	28-11-2011:08.13	null	28-11-2011:08.55	882345
112346	91245	iPod nano	2	0.300	28-11-2011:08.14	28-11-2011:08.55	30-11-2011:09.06	882346
112347	91245	iPod classic	1	0.200	28-11-2011:08.15	null	29-11-2011:10.06	882345
112448	91561	iPhone 4G	1	0.250	28-11-2011:12.23	null	28-11-2011:12.59	882345
112449	91561	iPod classic	1	0.200	28-11-2011:12.24	28-11-2011:16.22	null	null
112452	91812	iPhone 4G	5	1.250	29-11-2011:09.46	null	29-11-2011:10.58	882346
...	...	...	...	...	...	...	...	...

Instanz: Bestellung

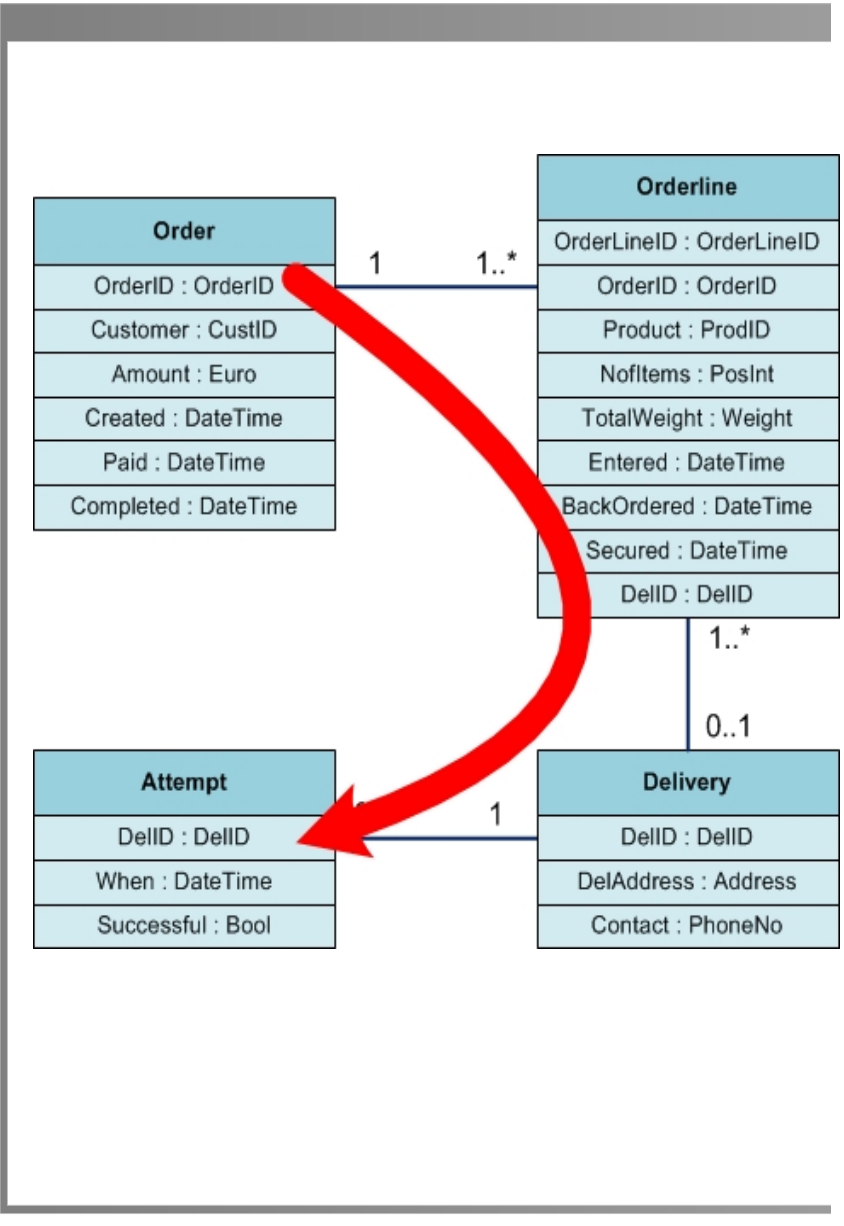

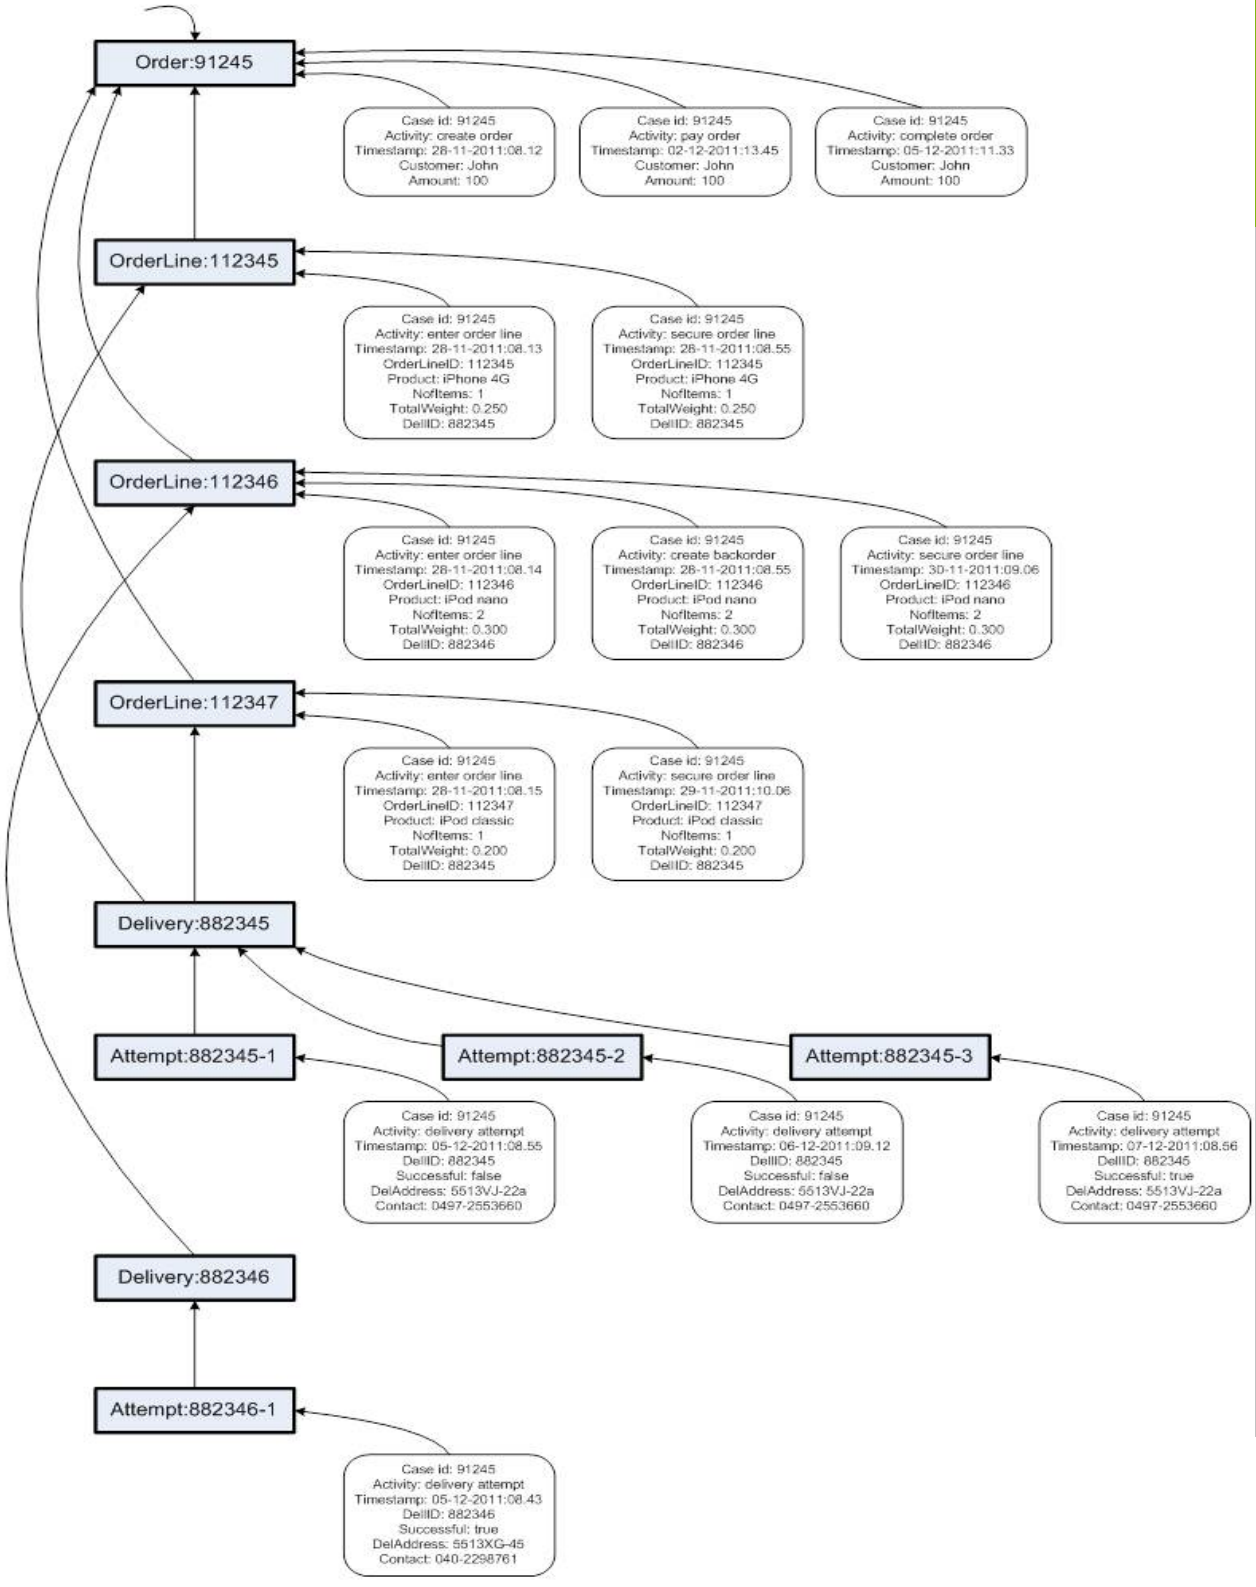

case id	activity	timestamp	other attributes
91245	create order	28-11-2011:08.12	Customer: John, Amount: 100
91245	enter order line	28-11-2011:08.13	OrderLineID: 112345, Produ 4G, NofItems: 1, TotalWeight: (lID: 882345
91245	enter order line	28-11-2011:08.14	OrderLineID: 112346, Prod nano, NofItems: 2, TotalWeig DellID: 882346
91245	enter order line	28-11-2011:08.15	OrderLineID: 112347, Product: sic, NofItems: 1, TotalWeight: (lID: 882345
91245	secure order line	28-11-2011:08.55	OrderLineID: 112345, Produ 4G, NofItems: 1, TotalWeight: (lID: 882345
91245	create backorder	28-11-2011:08.55	OrderLineID: 112346, Prod nano, NofItems: 2, TotalWeig DellID: 882346
91245	secure order line	29-11-2011:10.06	OrderLineID: 112347, Product: sic, NofItems: 1, TotalWeight: (lID: 882345
91245	secure order line	30-11-2011:09.06	OrderLineID: 112346, Prod nano, NofItems: 2, TotalWeig DellID: 882346
91245	pay order	02-12-2011:13.45	Customer: John, Amount: 100
91245	delivery attempt	05-12-2011:08.43	DellID: 882346, Successful: tru dress: 5513XG-45, Contact: 04
91245	delivery attempt	05-12-2011:08.55	DellID: 882345, Successful: lAddress: 5513VJ-22a, Conta 2553660
91245	complete order	05-12-2011:11.33	Customer: John, Amount: 100
91245	delivery attempt	06-12-2011:09.12	DellID: 882345, Successful: lAddress: 5513VJ-22a, Conta 2553660
91245	delivery attempt	07-12-2011:08.56	DellID: 882345, Successful: lAddress: 5513VJ-22a, Conta 2553660
91561	create order	28-11-2011:12.22	Customer: Mike, Amount: 530
91561	enter order line	28-11-2011:12.23	OrderLineID: 112448, Produ 4G, NofItems: 1, TotalWeight: (lID: 882345
...	...	...	...
...	...	...	...

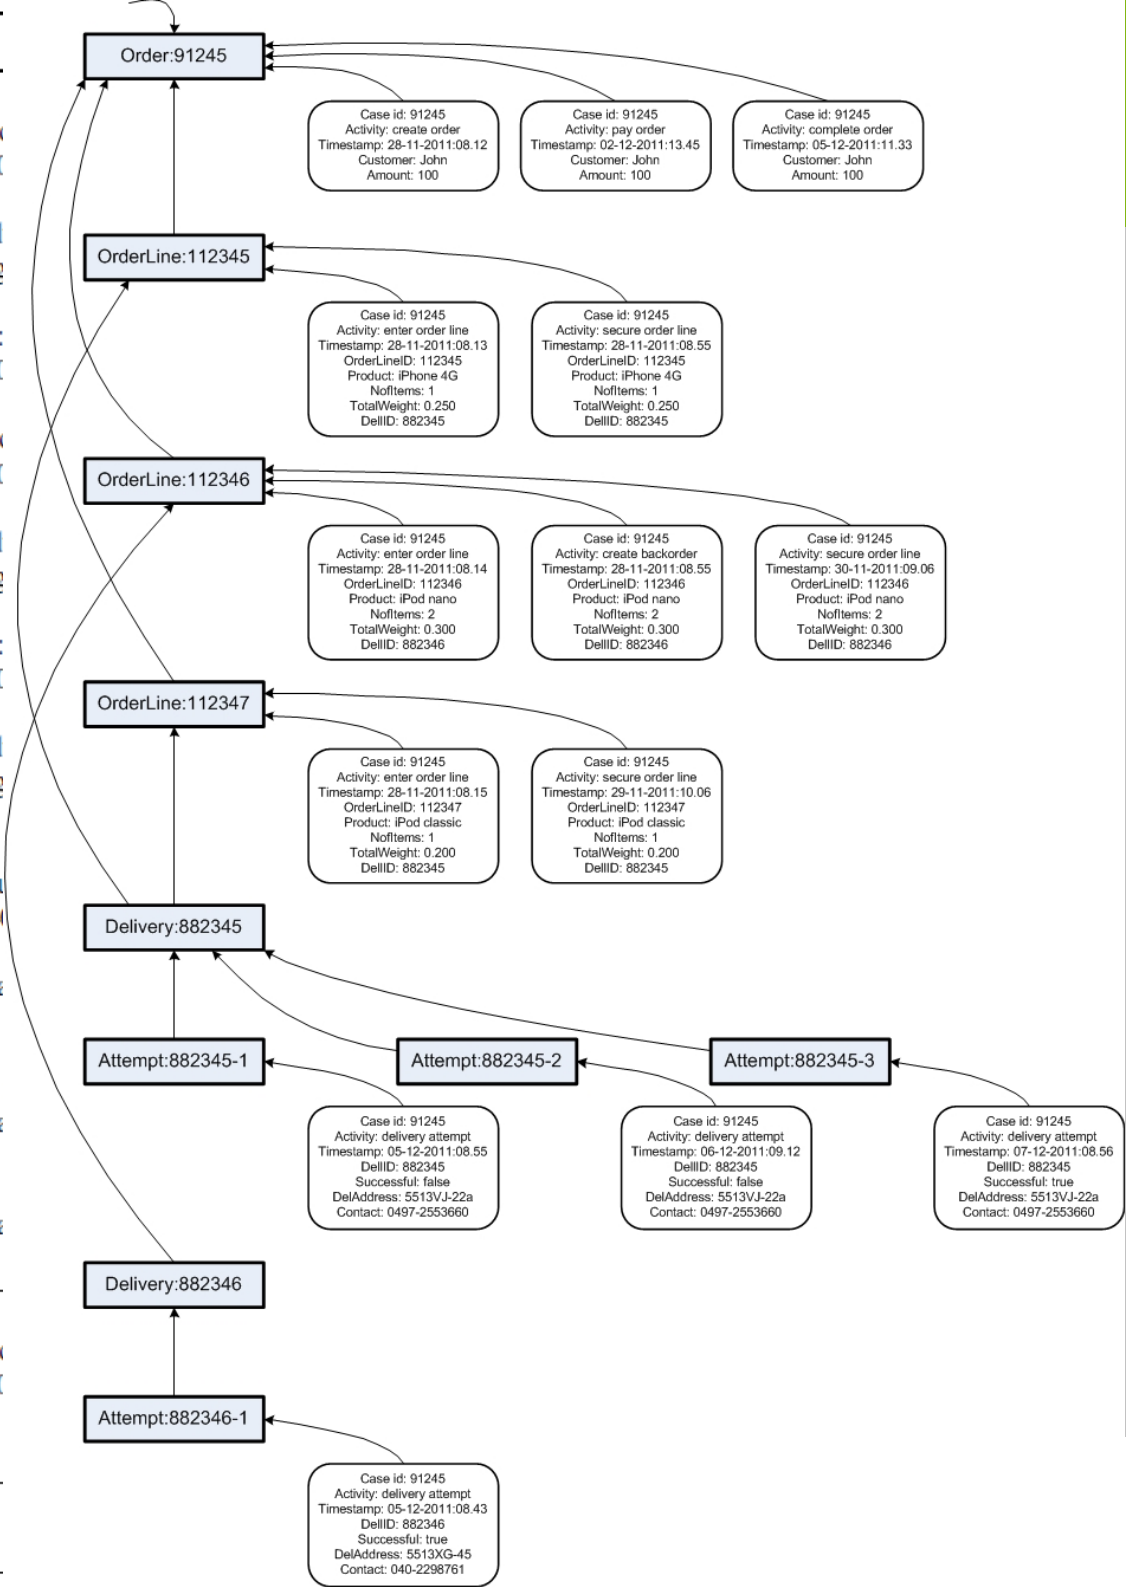

Instanz: Orderline

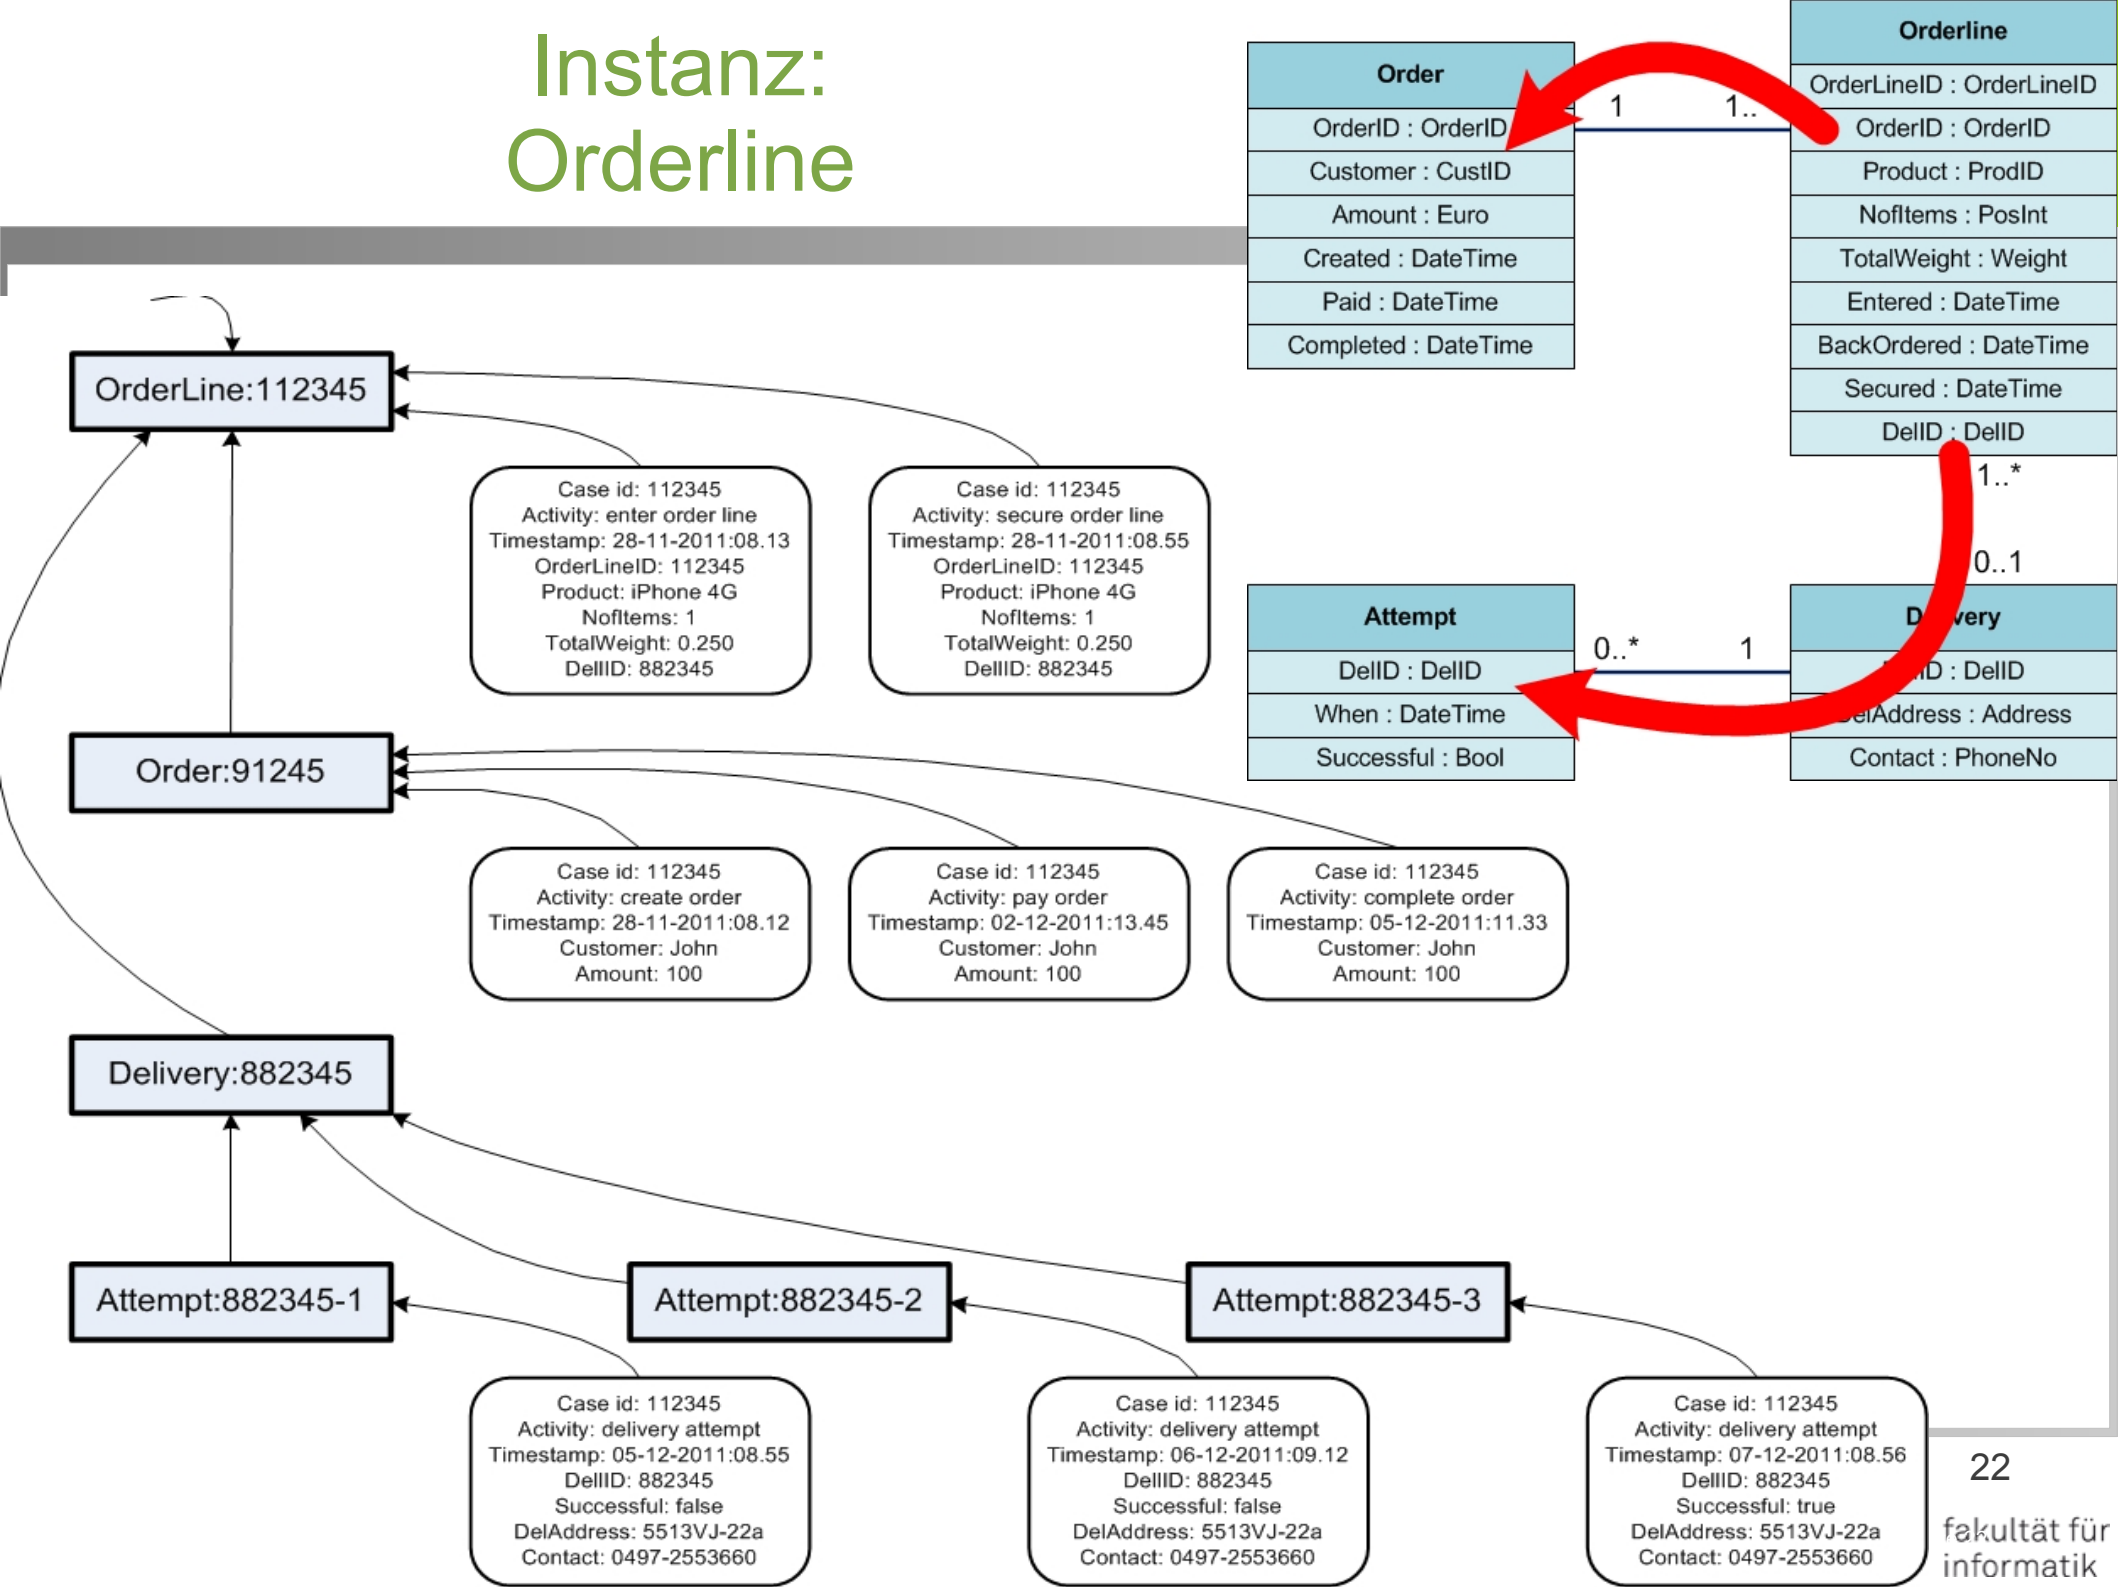

Weitere Beispiele

- Lebenszyklus von Rezensenten, Autoren, wissenschaftlichen Publikationen, Korrekturen, Programmkommittee-Vorsitzenden, etc.
- Lebenszyklus von Bewerbungen und Stellenangeboten.
- Röntgengerät-Logs: Gerät, Patient, Behandlung, Prozedur, etc.

- Auswahl und Scoping der Instanzen notwendig.

Event-Logs extrahieren

- Nicht nur syntaktisches Problem.
- Verschiedene Blickwinkel möglich.
- Wichtig:
  - Richtigen Instanzbegriff auswählen.
  - Events ordnen.
  - Events auswählen.

Zusammenfassung: 2.4 Datenbeschaffung

- Von hetereogenen Datenquellen zu Process-Mining
- Event Logs, verschiedene Ansichten
- Überlappende Instanzen
- Attribute
- Datenspeicherformat XES
- Herausforderungen beim Extrahieren
- Event-Logs vs. Tabellen und Instanzen