

Vorlesung
***Methodische Grundlagen des
Software-Engineering***
im Sommersemester 2014

Prof. Dr. Jan Jürjens

TU Dortmund, Fakultät Informatik, Lehrstuhl XIV

Teil 2.0: Einführung: Process-Mining

v. 06.05.2014

2.0 Einführung: Process-Mining

[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 1**

Einordnung

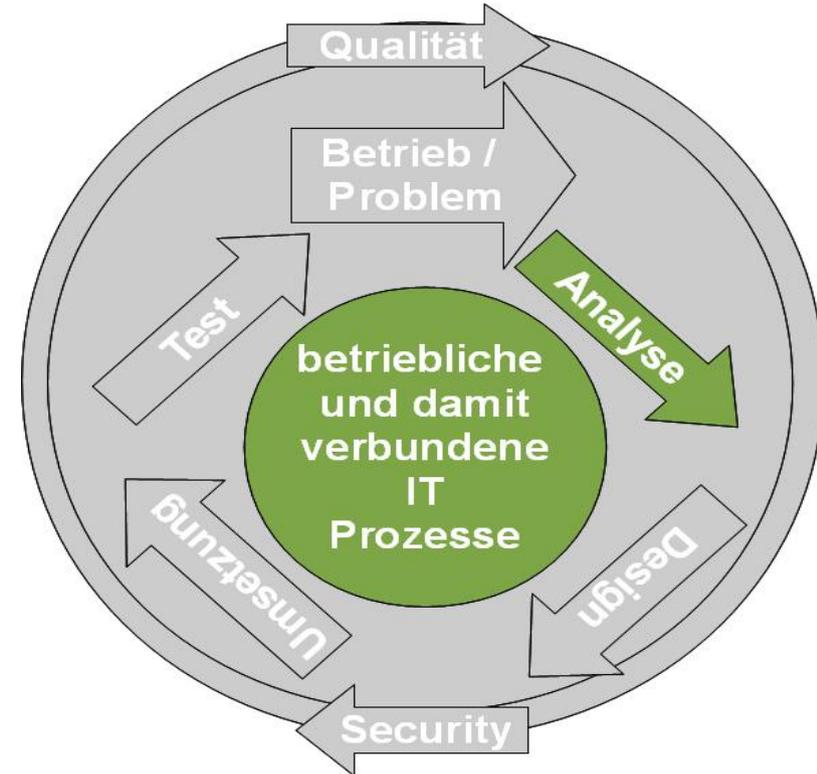
2.0: Einführung: Process-Mining

- Geschäftsprozessmodellierung

- **Process-Mining**

- Einführung: Process-Mining
- Petrinetze
- Data-Mining
- Datenbeschaffung
- Prozessextraktion
- Konformanzanalyse
- Mining: Zusätzliche Perspektiven
- Betriebsunterstützung
- Werkzeugunterstützung
- Analysiere „Lasagne Prozesse“
- Analysiere „Spaghetti Prozesse“
- Kartographie und Navigation
- Epilog

- Modellbasierte Entwicklung sicherer Software



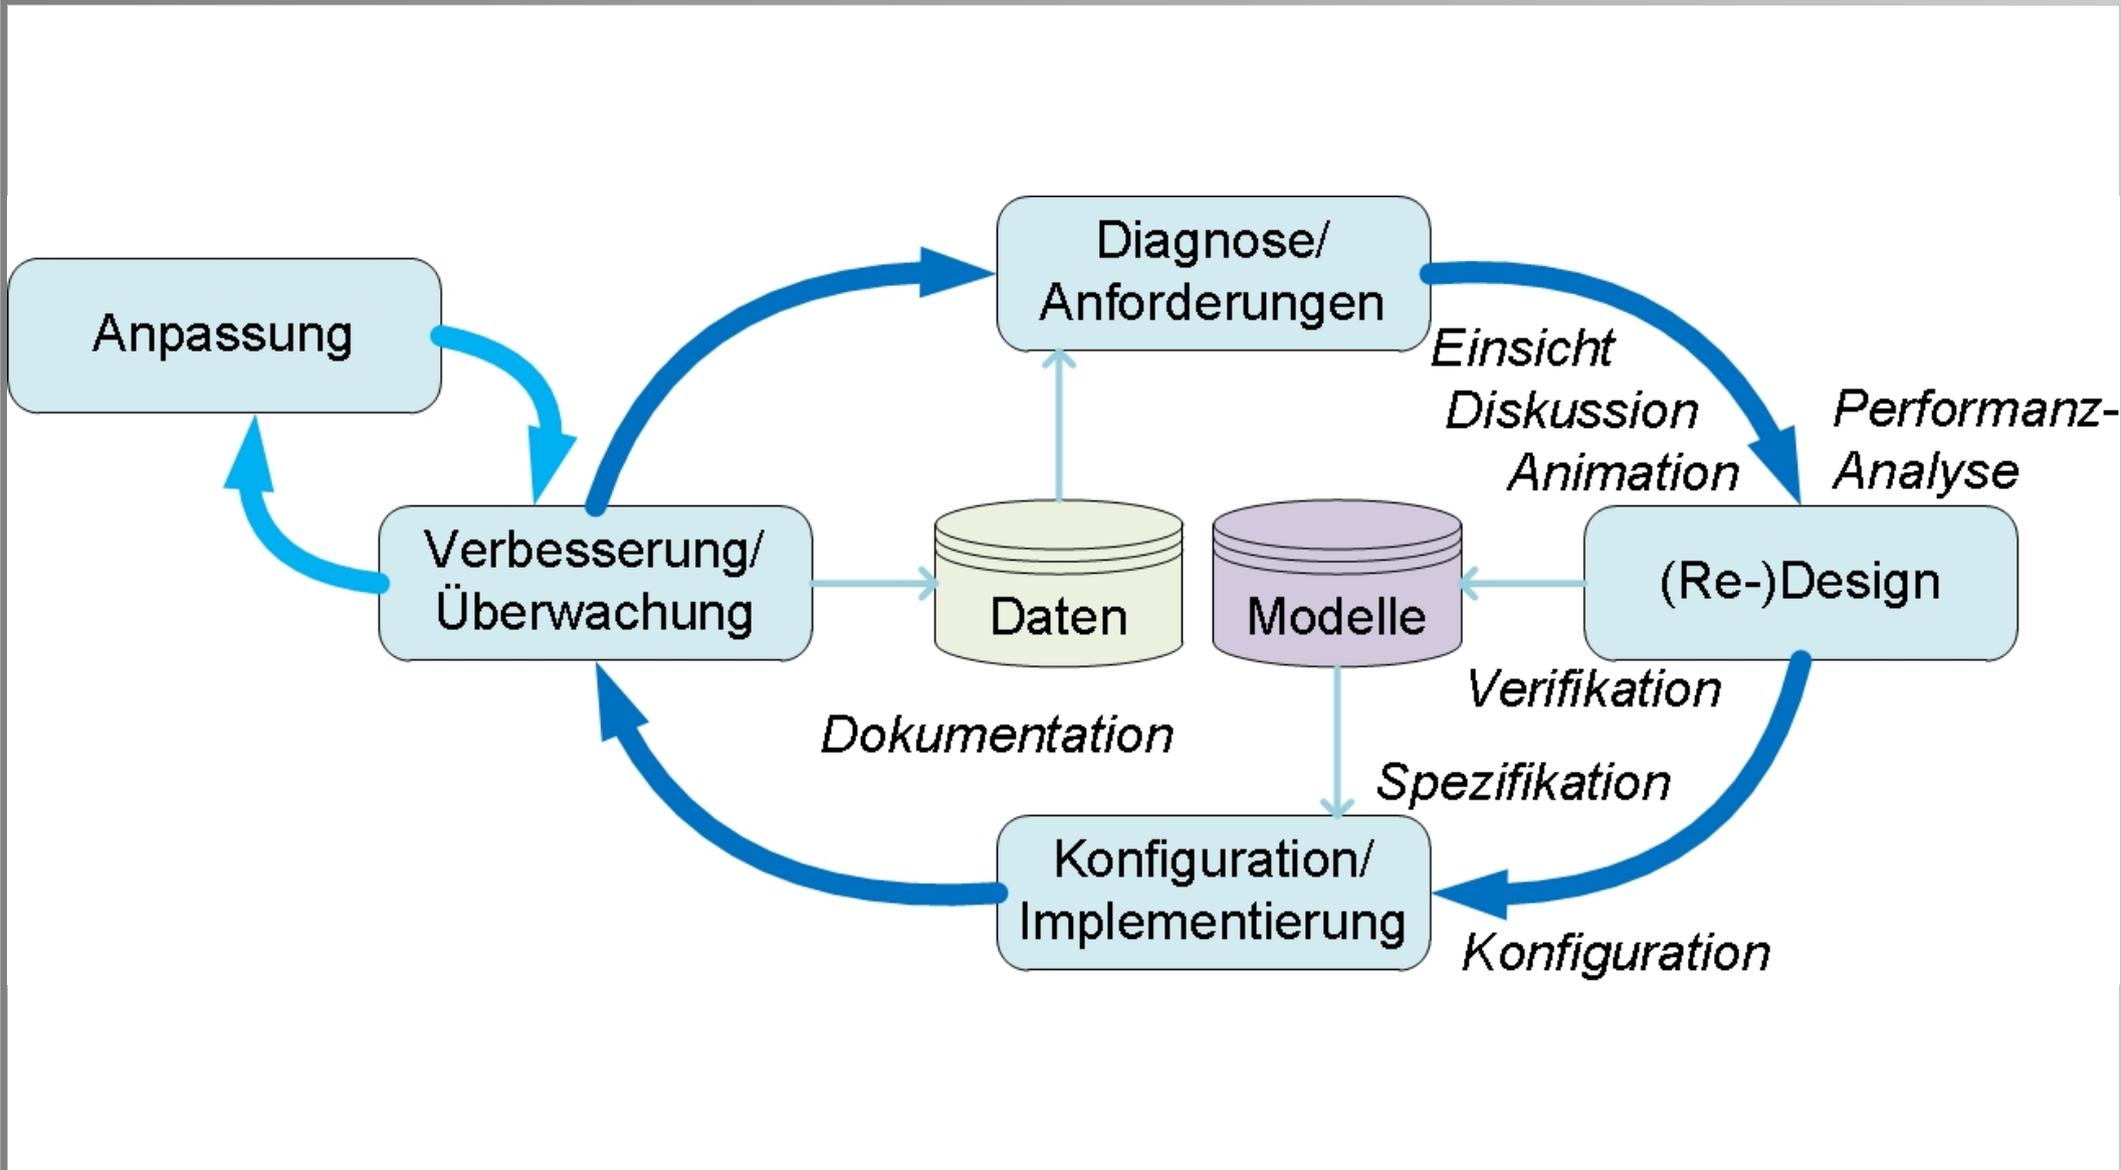
Einleitung: Einführung: Process-Mining

- Letzter Abschnitt 1.4: Von **Modellen** zur **Ausführung** durch **Workflowautomatisierung**.
- Dieses Kapitel 2: Von **Ausführungsdaten** zu **Modellen** (manuelle Erstellung vermeiden; Konformanz überprüfen).
 - Dieser Abschnitt 2.0: Kurze **Einführung** und **Motivation** für die Inhalte von Kapitel 2: **Business Process Mining**.

- **Motivation für Business Process Mining**
- **Business Process Mining:**
Konformanz, Extraktion, Verbesserung

- **Einsicht:** Prozess von verschiedenen Seiten betrachten.
- **Diskussion:** Stakeholder können Entscheidungen strukturieren.
- **Dokumentation:** Personen anleiten, Zertifizierungen erhalten (z.B. ISO 9000 Qualitätsmanagement).
- **Verifikation:** Prozessmodelle analysieren: Fehler in System oder Prozeduren finden (z.B. Deadlocks).
- **Performance-Analyse:** Simulation => z.B. beeinflussende Faktoren für Antwortzeiten, Service Level etc. verstehen.
- **Animation:** End-Nutzer können Szenarios “durchspielen”; Feedback an Designer geben.
- **Spezifikation:** Process-aware Information System (PAIS) vor Implementierung modellieren (“Vertrag zwischen Entwicklern und End-Nutzer / Management“).
- **Konfiguration:** Modelle als Konfiguration von Systemen.

BPM-Lebenszyklus: klassischer Gebrauch von Prozessmodellen

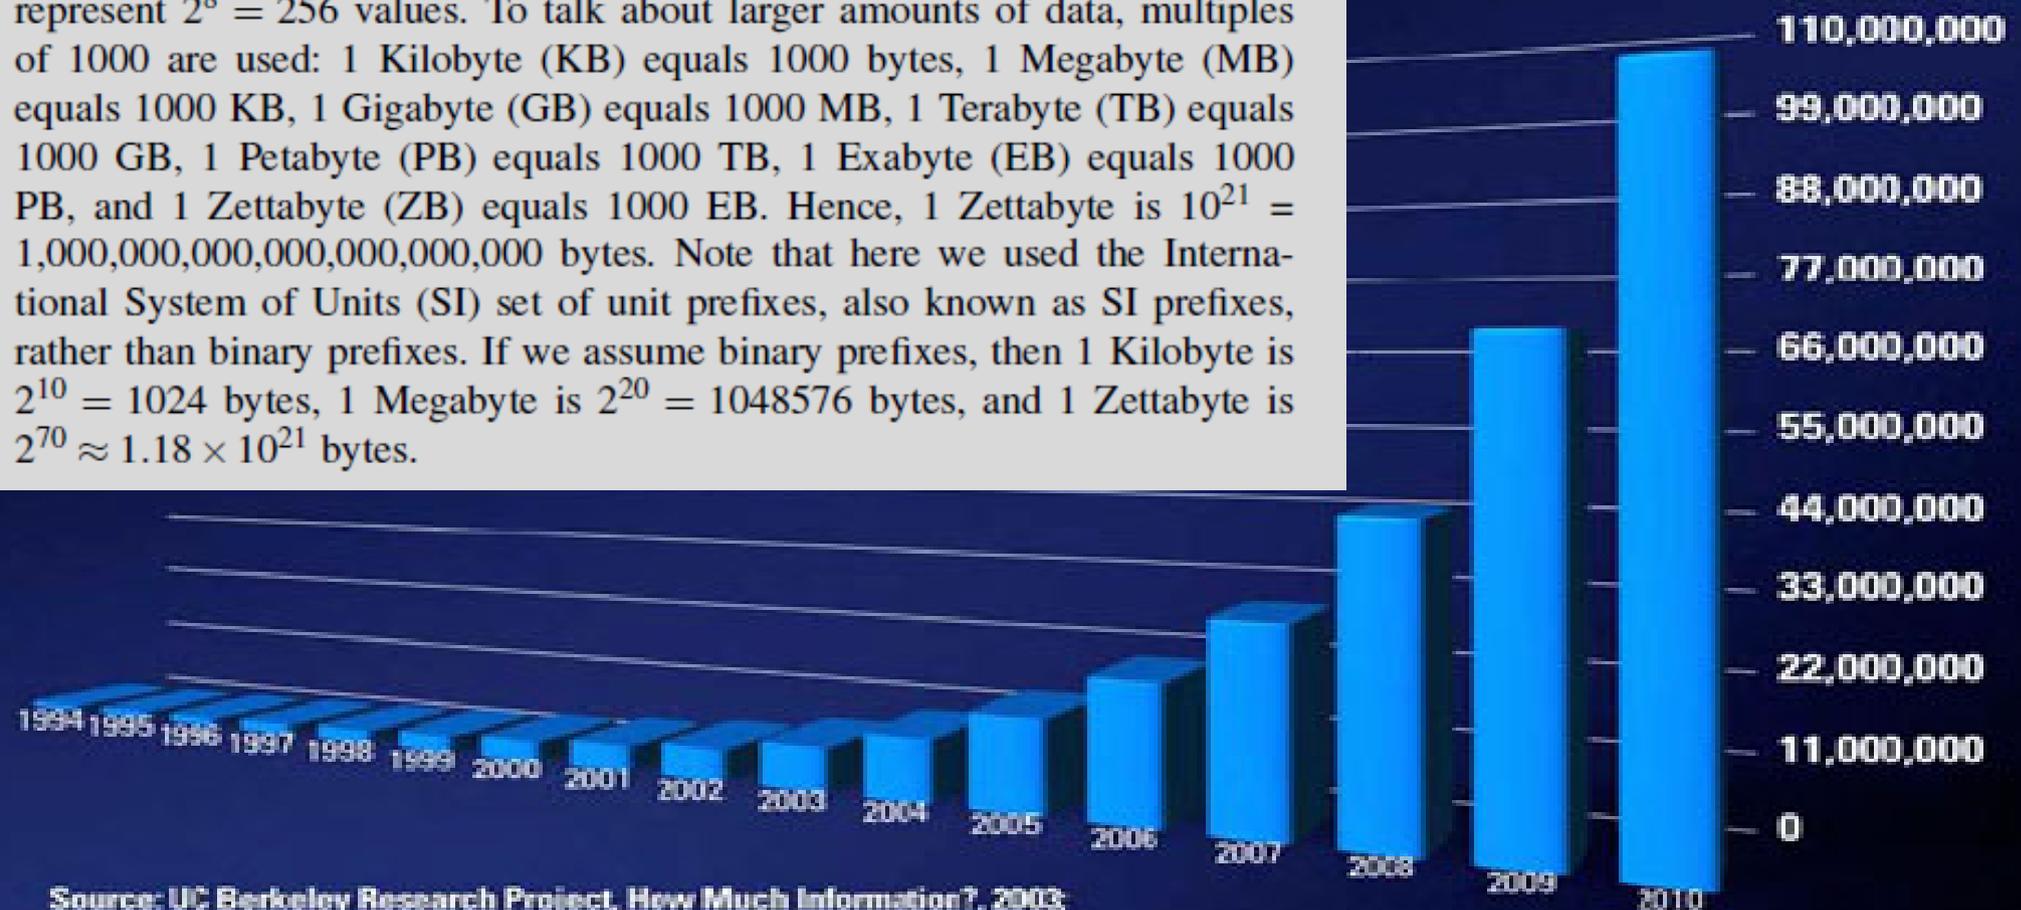




From Bits to Zettabytes

A “bit” is the smallest unit of information possible. One bit has two possible values: 1 (on) and 0 (off). A “byte” is composed of 8 bits and can represent $2^8 = 256$ values. To talk about larger amounts of data, multiples of 1000 are used: 1 Kilobyte (KB) equals 1000 bytes, 1 Megabyte (MB) equals 1000 KB, 1 Gigabyte (GB) equals 1000 MB, 1 Terabyte (TB) equals 1000 GB, 1 Petabyte (PB) equals 1000 TB, 1 Exabyte (EB) equals 1000 PB, and 1 Zettabyte (ZB) equals 1000 EB. Hence, 1 Zettabyte is $10^{21} = 1,000,000,000,000,000,000,000$ bytes. Note that here we used the International System of Units (SI) set of unit prefixes, also known as SI prefixes, rather than binary prefixes. If we assume binary prefixes, then 1 Kilobyte is $2^{10} = 1024$ bytes, 1 Megabyte is $2^{20} = 1,048,576$ bytes, and 1 Zettabyte is $2^{70} \approx 1.18 \times 10^{21}$ bytes.

Terabytes



Source: UC Berkeley Research Project, How Much Information?, 2003;
IDC, Disk Storage System Quarterly Tracker (as of 2006)

Datenflut bewältigen mittels GP-Modellierung: **GP-Modellierung** bei **Prozessausführung** optimal nutzen (z.B. **Prozessoptimierung**).

Relevante Ansätze:

- Business Process Management (BPM)
- Business Intelligence (BI)
- Online Analytical Processing (OLAP)
- Business Activity Monitoring (BAM)
- Complex Event Processing (CEP)
- Corporate Performance Management (CPM)
- Visual Analytics (VA)
- Predictive Analytics (PA)
- Continuous Process Improvement (CPI)
- Total Quality Management (TQM)
- Six Sigma

Motorola, frühe 1980er. „DMAIC“-Ansatz:

- **Definiere** (**D**efine) Problem und Ziel,
- **Messe** (**M**easure) Hauptindikatoren für Leistung; sammele Daten,
- **Analysiere** (**A**nalyze) Daten: Zusammenhang zwischen Ursache und Wirkung ermitteln und verifizieren,
- **Verbessere** (**I**mprove) aktuellen Prozess basierend auf Analyse
- **Kontrolliere** (**C**ontrol) Prozess: Zielabweichung minimieren.

Aktuelle Herausforderung: GP-Modellierung für Compliance

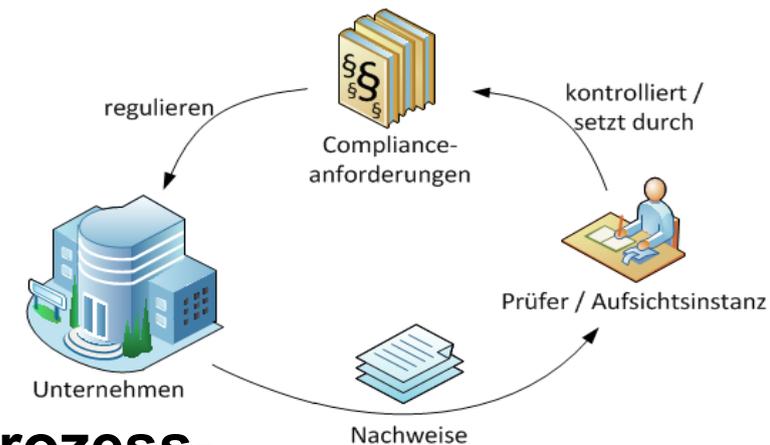
Steigende Anzahl von Regulierungen

- z.B. **Finanzen**: Solvency II, Basel III; **Gesundheit**: Medizinproduktegesetz (MPG); **Pharma**: Arzneimittelmarktneuordnungsgesetz (AMNOG)

Steigende Komplexität des Compliance-Nachweises:

- **Viele Facetten**: Anforderungen an Geschäftsprozesse (Design + Ausführung), IT-Infrastruktur (+ deren Prozesse), deren Abhängigkeiten...
- **Wechselseitige Abhängigkeiten** von Vorgaben
- **Aggregation** von Vorgaben bei komplexen IT-Systemen
- **Cloud-Computing** → besondere Anforderungen

=> **Nachweis der Compliance mit Geschäftsprozessmodellierung und -überwachung** erleichtern.



Nachteile manueller Prozessmodellierung

Was sind Nachteile von manueller Prozessmodellierung ?

Was sind Nachteile von manueller Prozessmodellierung ?

- (1) **“Handgemachte” Modelle unterscheiden** sich oft von Realität: idealisierte Sicht auf Prozess (“Papier-Tiger”).
 - (Nur) **ausführbare** Modelle können bestimmte Arbeitsweise tatsächlich **erzwingen** (vgl. Compliance-Nachweis).
- (2) **Manuelle** Erstellung der Modelle oft **aufwendig**.
=> **Prozessänderungen** im Modell oft **nicht nachgezogen**.

Wie kann ich diese Nachteile überwinden ?

Was sind Nachteile von manueller Prozessmodellierung ?

(1) **“Handgemachte”** Modelle **unterscheiden** sich oft von Realität:
idealisierte Sicht auf Prozess (“Papier-Tiger”).

- (Nur) **ausführbare** Modelle können bestimmte Arbeitsweise tatsächlich **erzwingen** (vgl. Compliance-Nachweis).

(2) **Manuelle** Erstellung der Modelle oft **aufwendig**.

=> **Prozessänderungen** im Modell oft **nicht nachgezogen**.

Wie kann ich diese Nachteile überwinden (unter Verwendung des Laufzeitverhaltens in Form von generierten Logdaten) ?

(1) => **Konformanz** Laufzeitverhalten <-> Prozessmodell **überprüfen** !

(1) & (2) => **Prozessmodell** aus Laufzeitverhalten **extrahieren** !?

- Erleichtert durch heutige große Menge an Event-Daten.

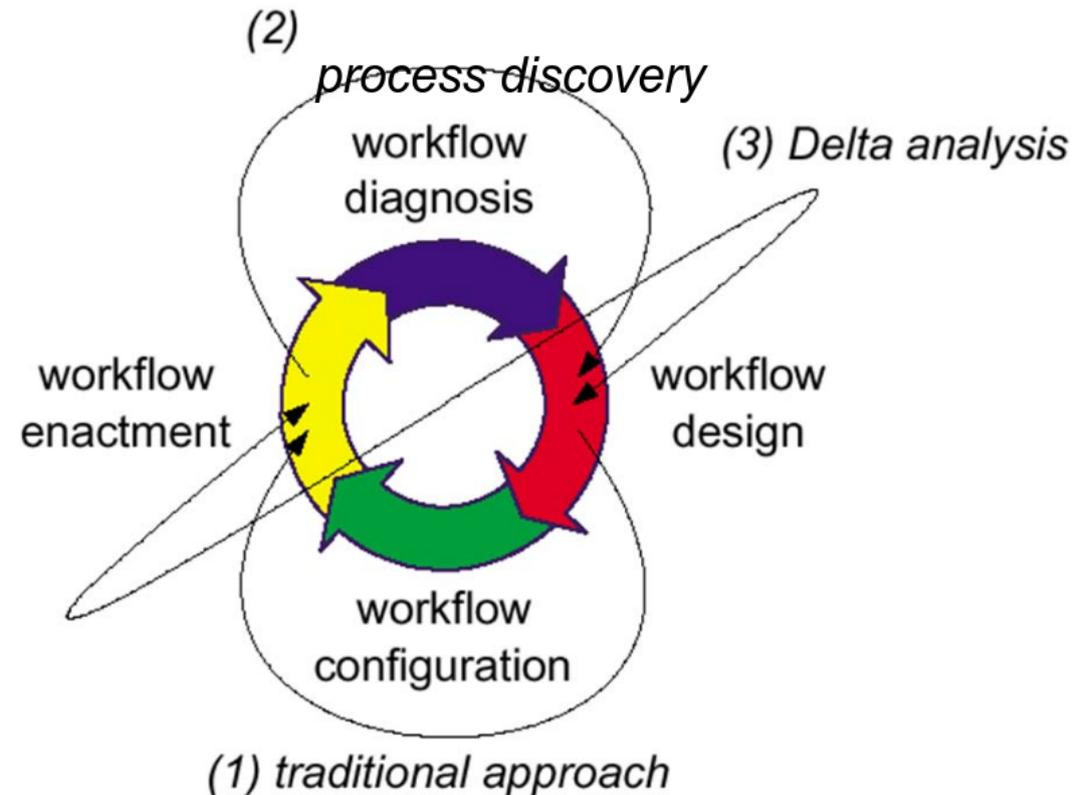
→ **Process-Mining** !

- (Teil-)automatisierte **Extraktion** von **GP-Modellen** aus **Laufzeitdaten** (z.B. Log-Daten).
- **Extraktion** von Modellen basierend auf Fakten.
- Ziel **nicht** Erzeugung eines einzelnen Modells des Prozesses.
- **Sondern**: verschiedene **Sichten** auf gleiche Realität auf verschiedenen **Abstraktionsebenen**. Beispiel: nur **häufigstes** Verhalten betrachten, für einfaches Modell (**“80%-Modell”**).
- Auch **gesamtes** Verhalten betrachtbar (**“100%-Modell”**, deckt alle beobachteten Fälle ab).

Klassischer „**Lebenszyklus**“ von Workflows:

- Workflow **design**: Entwurf des Workflows
- Workflow **configuration**: Konfiguration des Workflows
- Workflow **enactment**:
Ausführung des Workflows
- Workflow **diagnosis**:
Diagnose des
ausgeführten Workflows

Klassisches Vorgehen (1):
Workflow-**Ausführung** auf
Basis des Workflow-**Designs**.



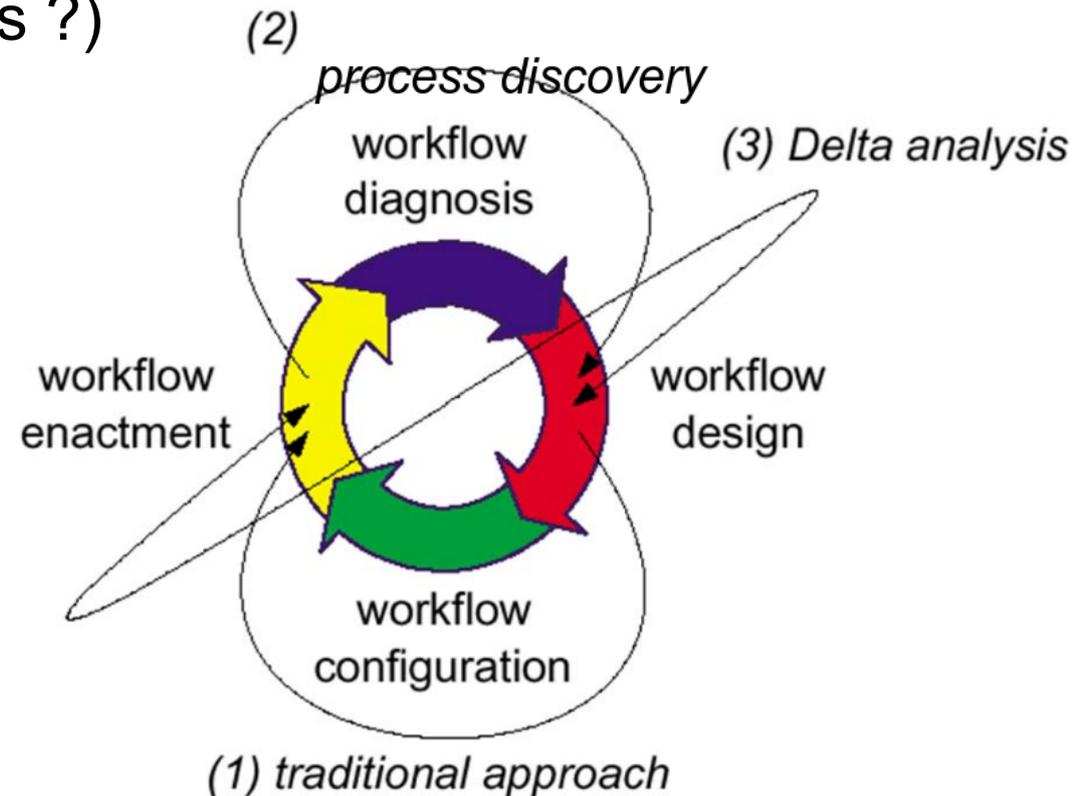
Ansätze auf Basis von **Process-Mining**:

- **Process Discovery (2): Extraktion des Workflow-Designs für ausgeführten Workflow.**

(Wie sieht Prozess (wirklich) aus ?)

- **Delta Analysis (3): Vergleich Workflow-Design mit ausgeführtem Workflow.**

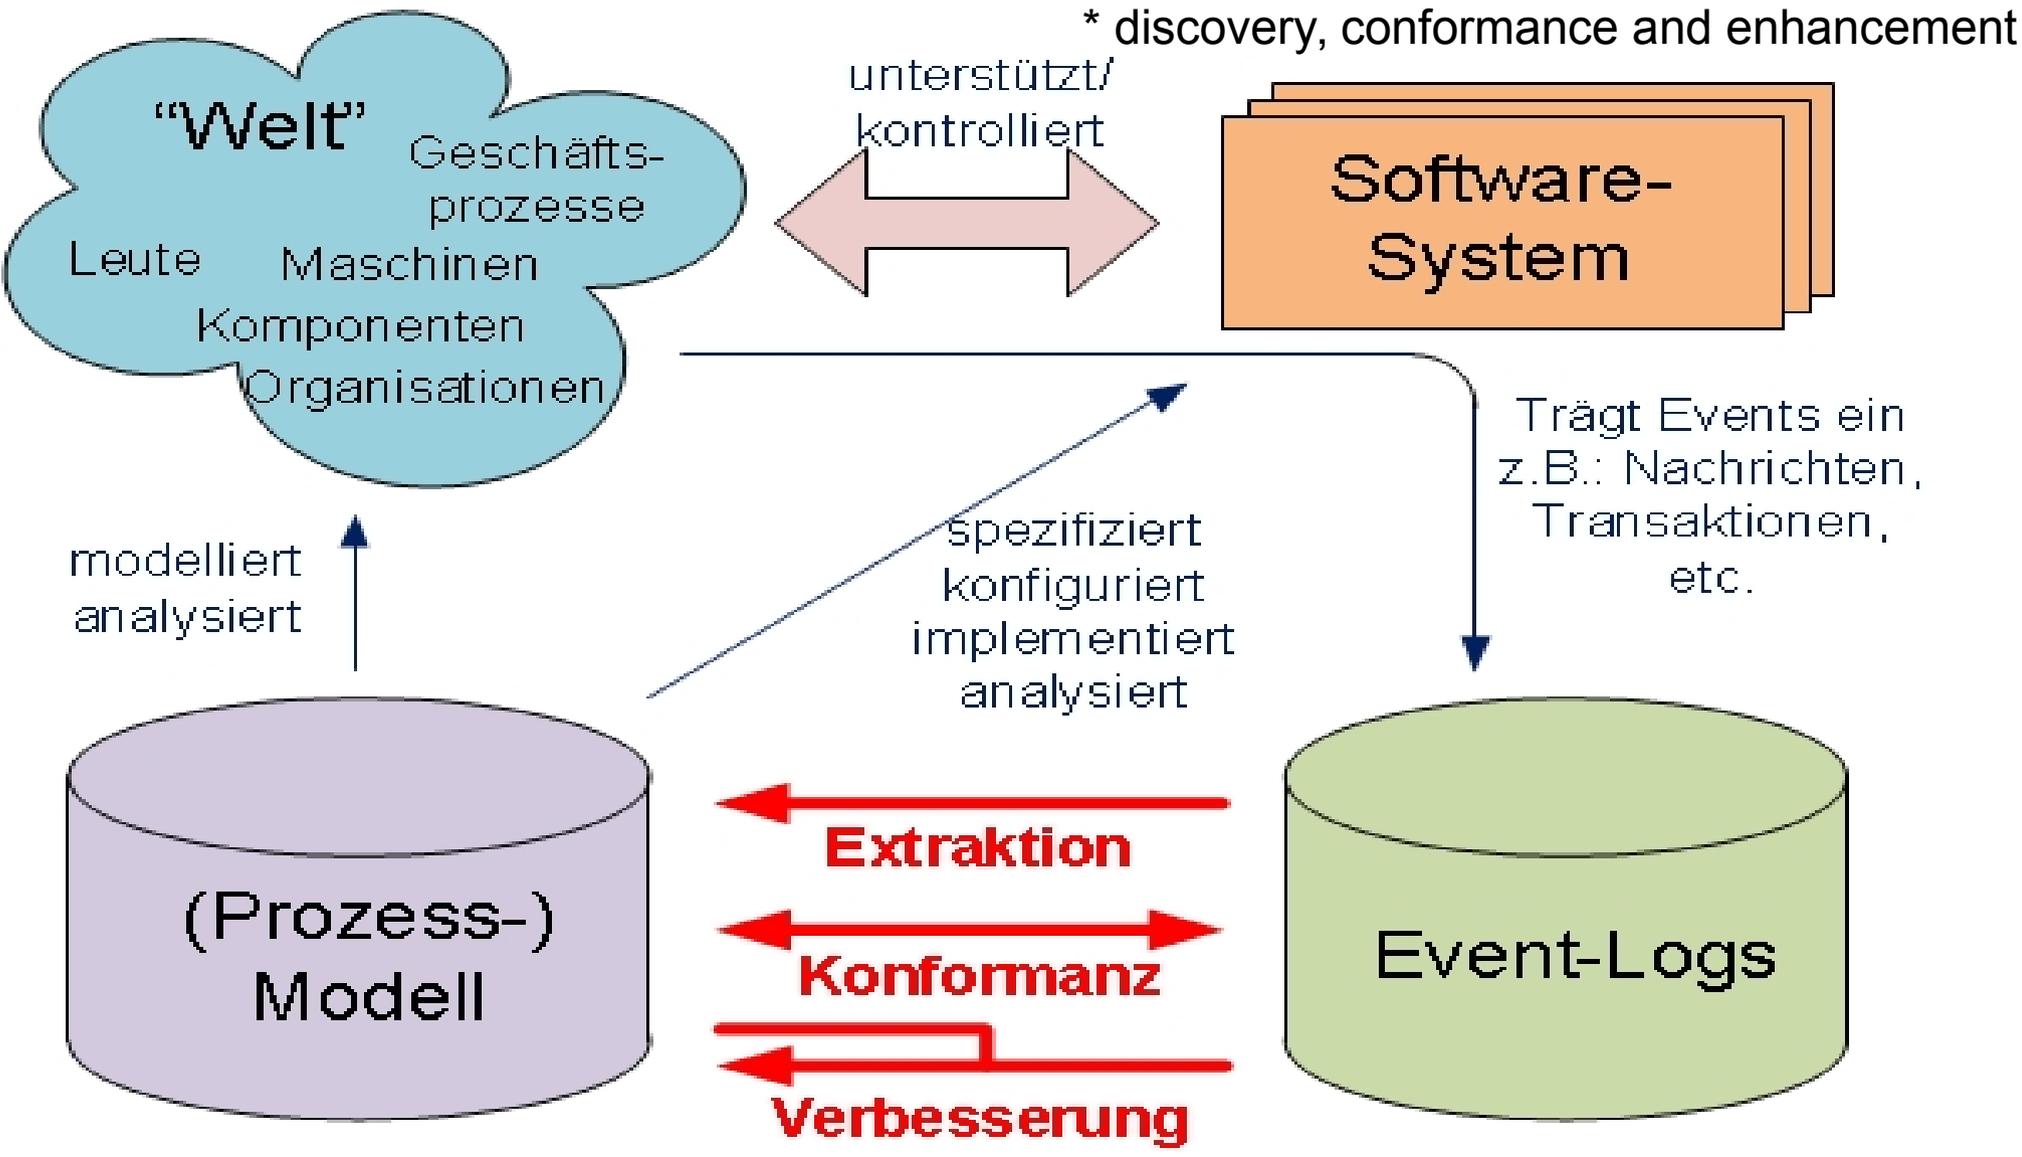
(Passiert das, was spezifiziert wurde ?)



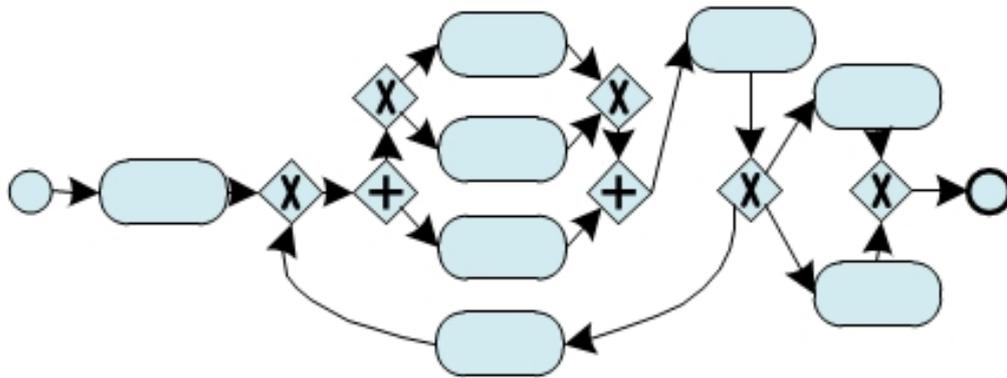


- Motivation für Business Process Mining
- **Business Process Mining:**
Konformanz, Extraktion, Verbesserung

Prozess-Modell vs. Event-Logs: Konformanz, Extraktion, Verbesserung*

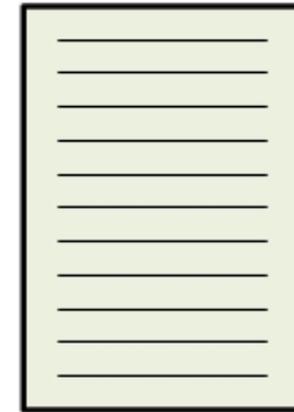


Konformanz zwischen Prozessmodell und Event-Log ?

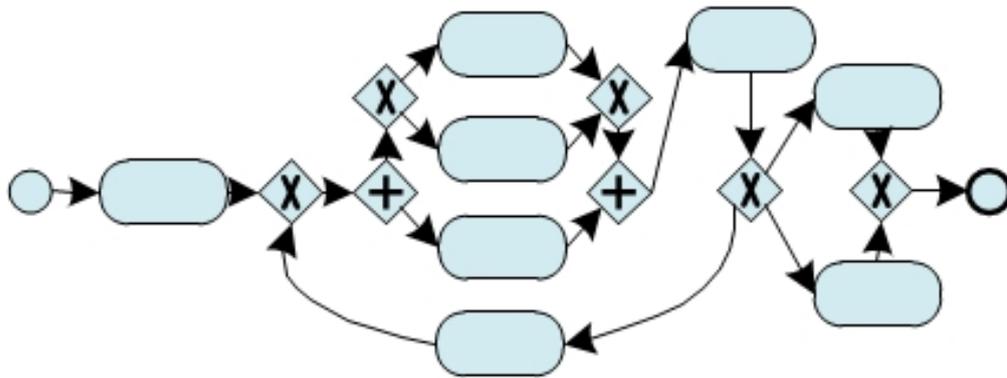


Prozessmodell

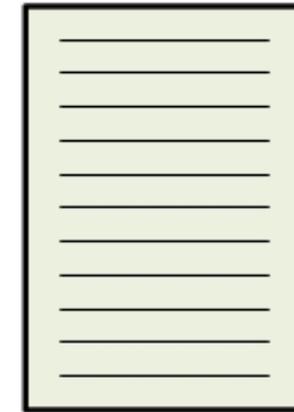
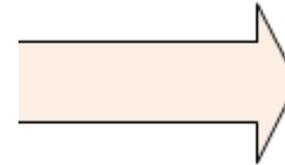
?



Event-Log



Prozessmodell

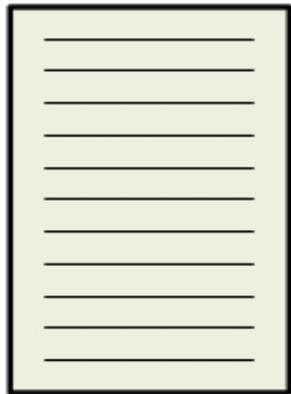


Event-Log

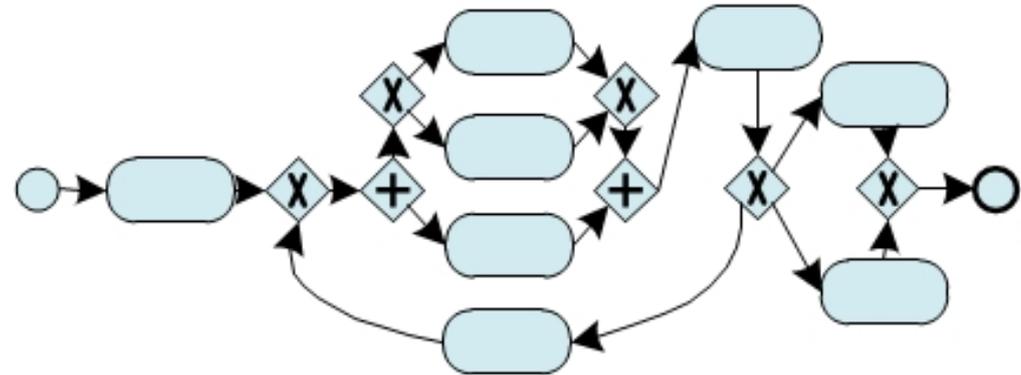
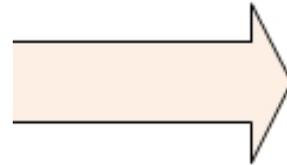
Aus Prozessmodell Menge der möglichen Event-Logs generieren.
Beobachtetes Event-Log ist konformant zu Prozessmodell, wenn es in dieser Menge enthalten ist.

(Geht nur, wenn Menge der möglichen Event-Logs endlich. Ansonsten Konformanz „online“ überprüfen, d.h. iterativ jeweils die Menge der möglichen nächsten Prozessschritte generieren und mit dem nächsten Log-Datum vergleichen.)

Extraktion durch "Play-In"



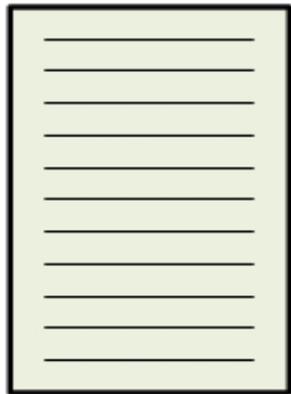
Event-Log



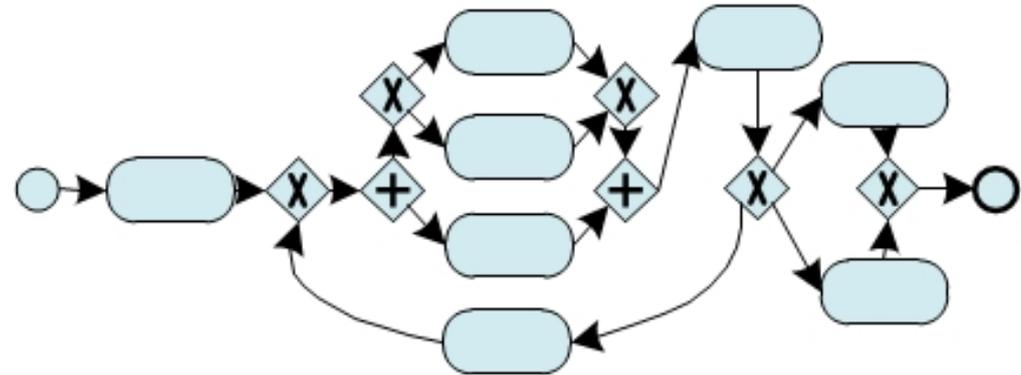
Prozessmodell

Aus gegebener Menge Event-Logs automatisch zugehöriges Prozessmodell generieren.

Was genau heisst „zugehöriges“ ?



Event-Log



Prozessmodell

Aus gegebener Menge Event-Logs automatisch zugehöriges Prozessmodell generieren.

Was genau heisst „zugehöriges“ ?

- Ursprüngliche Event-Logs **konform** zu generiertem Prozessmodell: Häufig gefordert (aber nicht immer: „80%-Modell“ - nur häufigstes Verhalten in Modell abbilden, z.B. zur Modellvereinfachung).
- Gibt mehr als ein solches Prozessmodell: Kann z.B. zusätzliche Verzweigungen hinzufügen. Wäre aber nicht sinnvoll, also oft möglichst „**präzises**“ oder „**einfaches**“ Modell gesucht. Nicht-trivial zu definieren; ggf. **trade-offs**.

Prozessextraktion Beispiel: Startpunkt: Event-Log

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

Fall ID	Event ID	Eigenschaften				
		Zeitstempel	Aktivität	Ressource	Kosten	...
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	...

Speicherformate: XES, MXML, SA-MXML, CSV, etc.

Vereinfachter Event-Log



Fall ID	Event ID	Eigenschaften			
		Zeitstempel	Aktivität	Ressource	Kosten
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

case id	trace
1	$\langle a, b, d, e, h \rangle$
2	$\langle a, d, c, e, g \rangle$
3	$\langle a, c, d, e, f, b, d, e, g \rangle$
4	$\langle a, d, b, e, h \rangle$
5	$\langle a, c, d, e, f, d, c, e, f, c, d, e, h \rangle$
6	$\langle a, c, d, e, g \rangle$

- a = Registrierung anfragen (register request),
- b = gründlich überprüfen (examine thoroughly),
- c = normal überprüfen (examine casually),
- d = Ticket überprüfen (check ticket),
- e = entscheiden (decide),
- f = Anfrage neu einleiten (reinitiate request),
- g = Entschädigung bezahlen (pay compensation),
- h = Anfrage ablehnen (reject request)

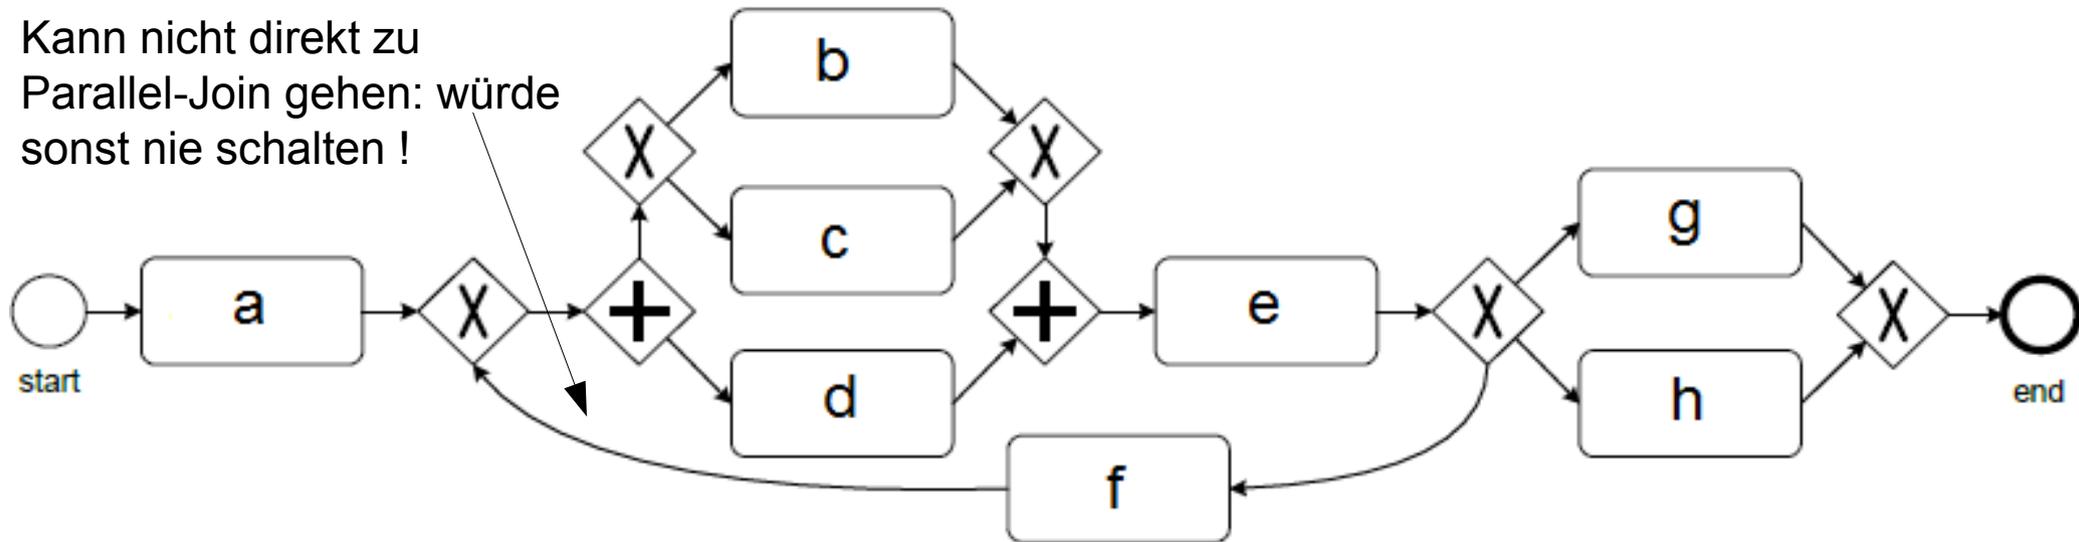
Prozess-Discovery: BPMN-Modell

case id	trace
1	$\langle a, b, d, e, h \rangle$
2	$\langle a, d, c, e, g \rangle$
3	$\langle a, c, d, e, f, b, d, e, g \rangle$
4	$\langle a, d, b, e, h \rangle$
5	$\langle a, c, d, e, f, d, c, e, f, c, d, e, h \rangle$
6	$\langle a, c, d, e, g \rangle$
...	...

Prozess-Discovery: BPMN-Modell

case id	trace
1	$\langle a, b, d, e, h \rangle$
2	$\langle a, d, c, e, g \rangle$
3	$\langle a, c, d, e, f, b, d, e, g \rangle$
4	$\langle a, d, b, e, h \rangle$
5	$\langle a, c, d, e, f, d, c, e, f, c, d, e, h \rangle$
6	$\langle a, c, d, e, g \rangle$
...	...

Kann nicht direkt zu
Parallel-Join gehen: würde
sonst nie schalten !



Mit Process-Mining extrahierte Perspektiven

In klassischen Prozessmodellen enthalten (hier aus Logdaten extrahiert):

- **Kontrollfluss-Perspektive:** Reihenfolge der **Aktivitäten**.
- **Betriebliche Perspektive:** Informationen über **Ressourcen**: Welche Akteure (z.B.: Systeme) involviert, in welcher Beziehung.

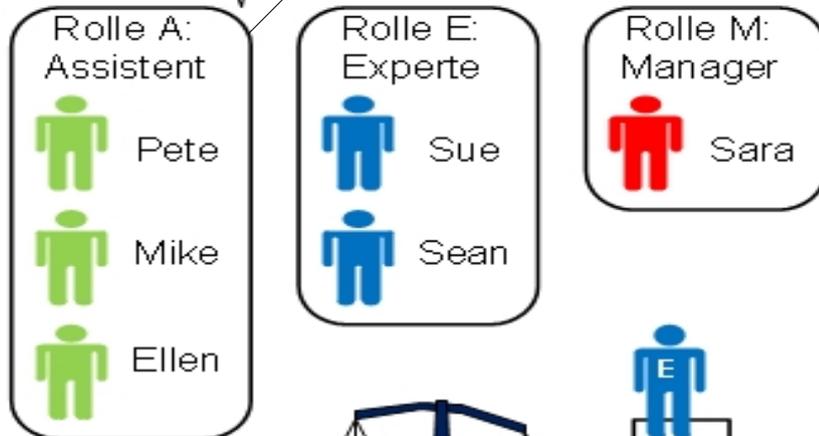
Weitere Informationen über klassische Prozessmodelle hinaus:

- **Fall-Perspektive:** Eigenschaften von **Fällen**. Z.B. über Werte der zugehörigen Daten-Elemente charakterisierbar.
- **Zeitliche Perspektive:** Timing und Frequenz von **Ereignissen**.

Process-Mining: Perspektiven

Mit dem Event-Log können Rollen in der Organisation entdeckt werden (z.B.: Gruppen von Leuten die ähnliche Arbeitsmuster haben). Diese Rollen können genutzt werden, um Individuen Aktivitäten zu zuordnen.

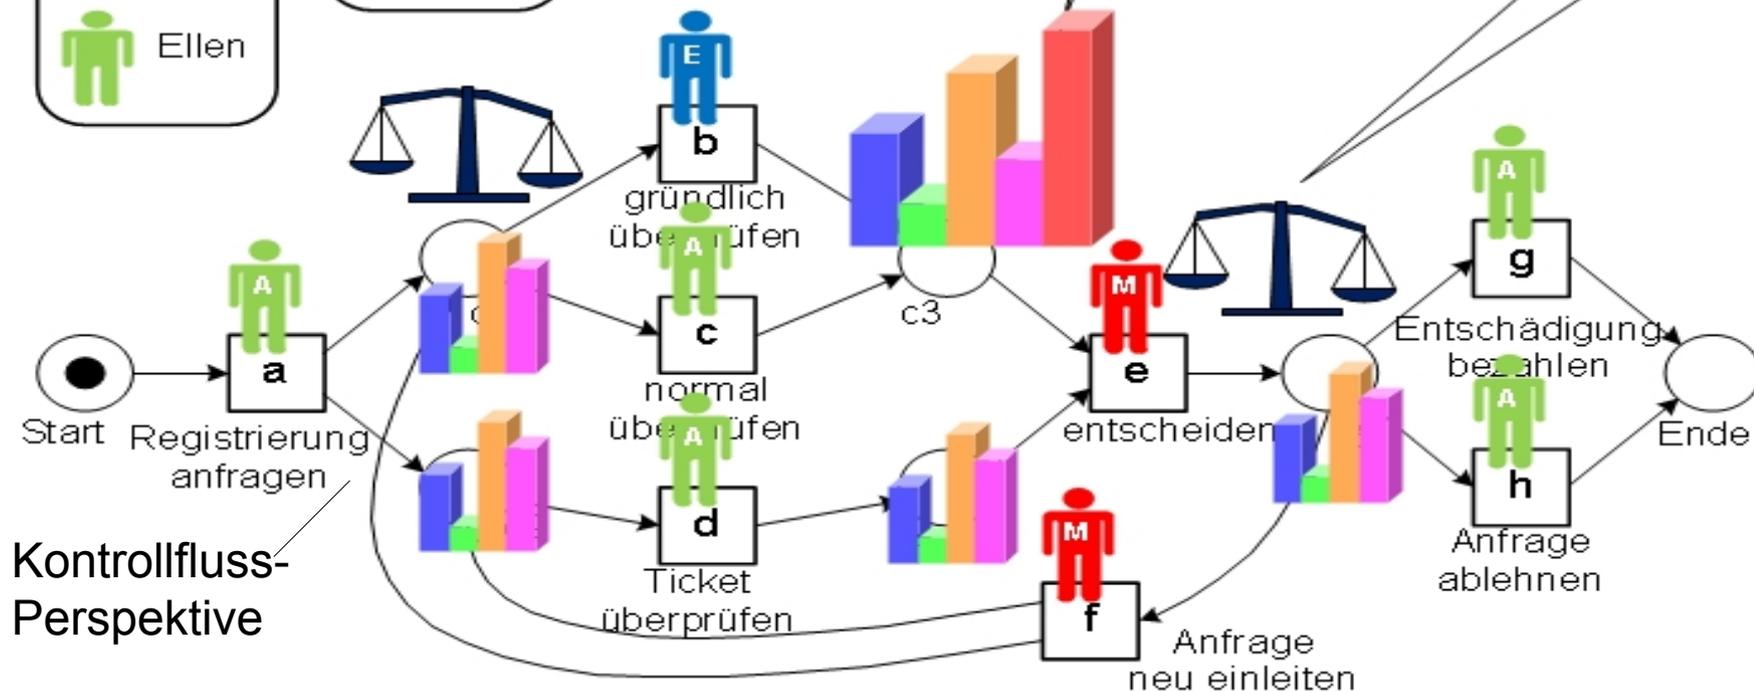
Betriebliche Perspektive



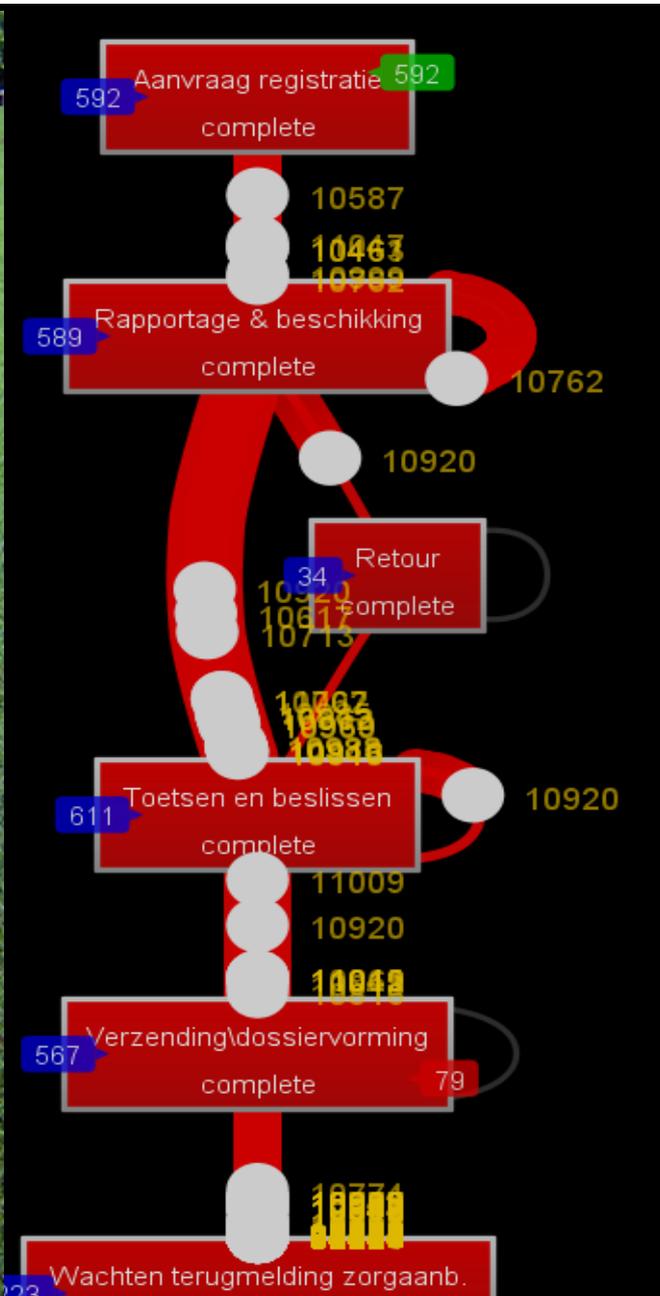
Performanz-Informationen (z.B.: durchschnittliche Zeit zwischen zwei aufeinanderfolgenden Aktivitäten) können vom Event-Log extrahiert werden und visualisiert werden.

Zeitliche Perspektive

Entscheidungsregeln können vom Event-Log erlernt werden. (z.B.: Ein Entscheidungsbaum basierend auf Daten, die zum Zeitpunkt einer bestimmten Entscheidung bekannt waren)



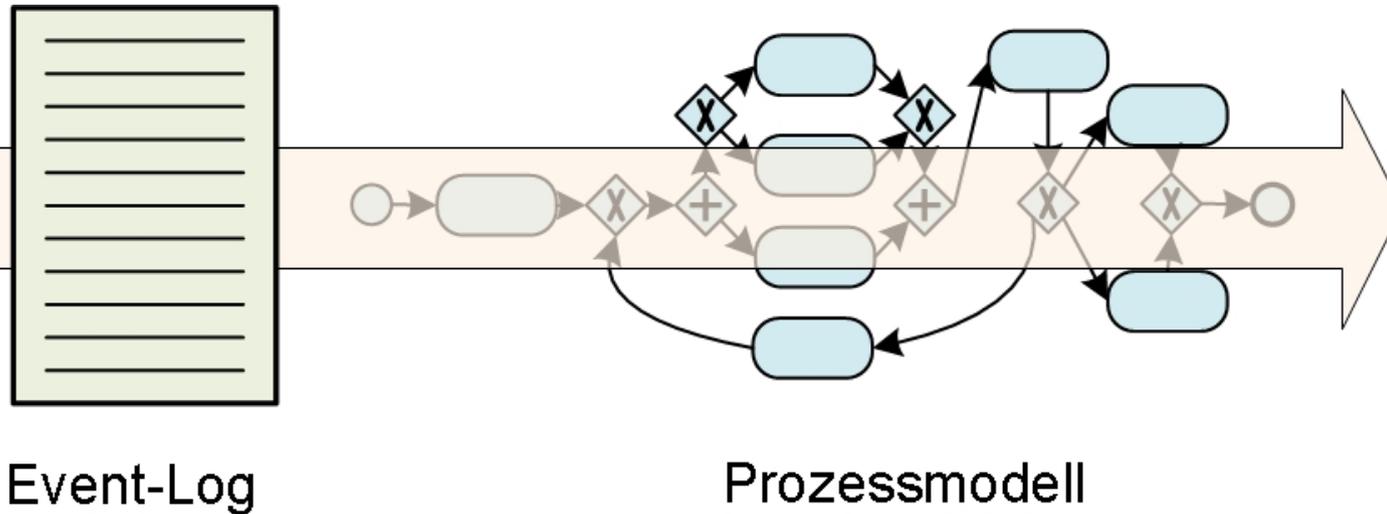
Frequenz von Ereignissen: Wunschpfade in Prozess-Modellen



Spezialfall:
Non-
konformanz
aufdecken



Process-Mining



- Erweitertes Modell zeigt: Zeiten, Frequenzen, etc.
- Diagnosen
- Vorhersagen
- Empfehlungen

Replay: Ausführungsfolgen aus extrahiertem Modell generieren und mit ursprünglichem Event-Log vergleichen.

- Grad der **Konformanz** überprüfen (bis 80%-Modellen).
- Modelle daraufhin entsprechend **nachjustieren**.
- **Voraussagende** Modelle konstruieren.
- **Betriebsunterstützung** (Vorhersagen, Vorschläge, etc.).

Dieser Abschnitt: Kurze Einführung und Motivation für die Inhalte von Kapitel 2: Business Process Mining.

- **Motivation:** Traditionelle Verwendung von Prozessmodellierung vs. aktuelle Herausforderungen (Datenexplosion, Compliance).
- **Einführung:** Business Process Mining: Von Ausführungsdaten zu Modellen (manuelle Erstellung vermeiden; Konformanz überprüfen).
 - Konformanz mittels Play-Out
 - Extraktion mittels Play-In
 - Verbesserung mittels Re-Play

Anschauen:

- Informelle Einführung in Process Mining + Verweis auf weitere Informationen (7 min)

<http://www.promtools.org/pmtv/movies/pmtv01.mov>

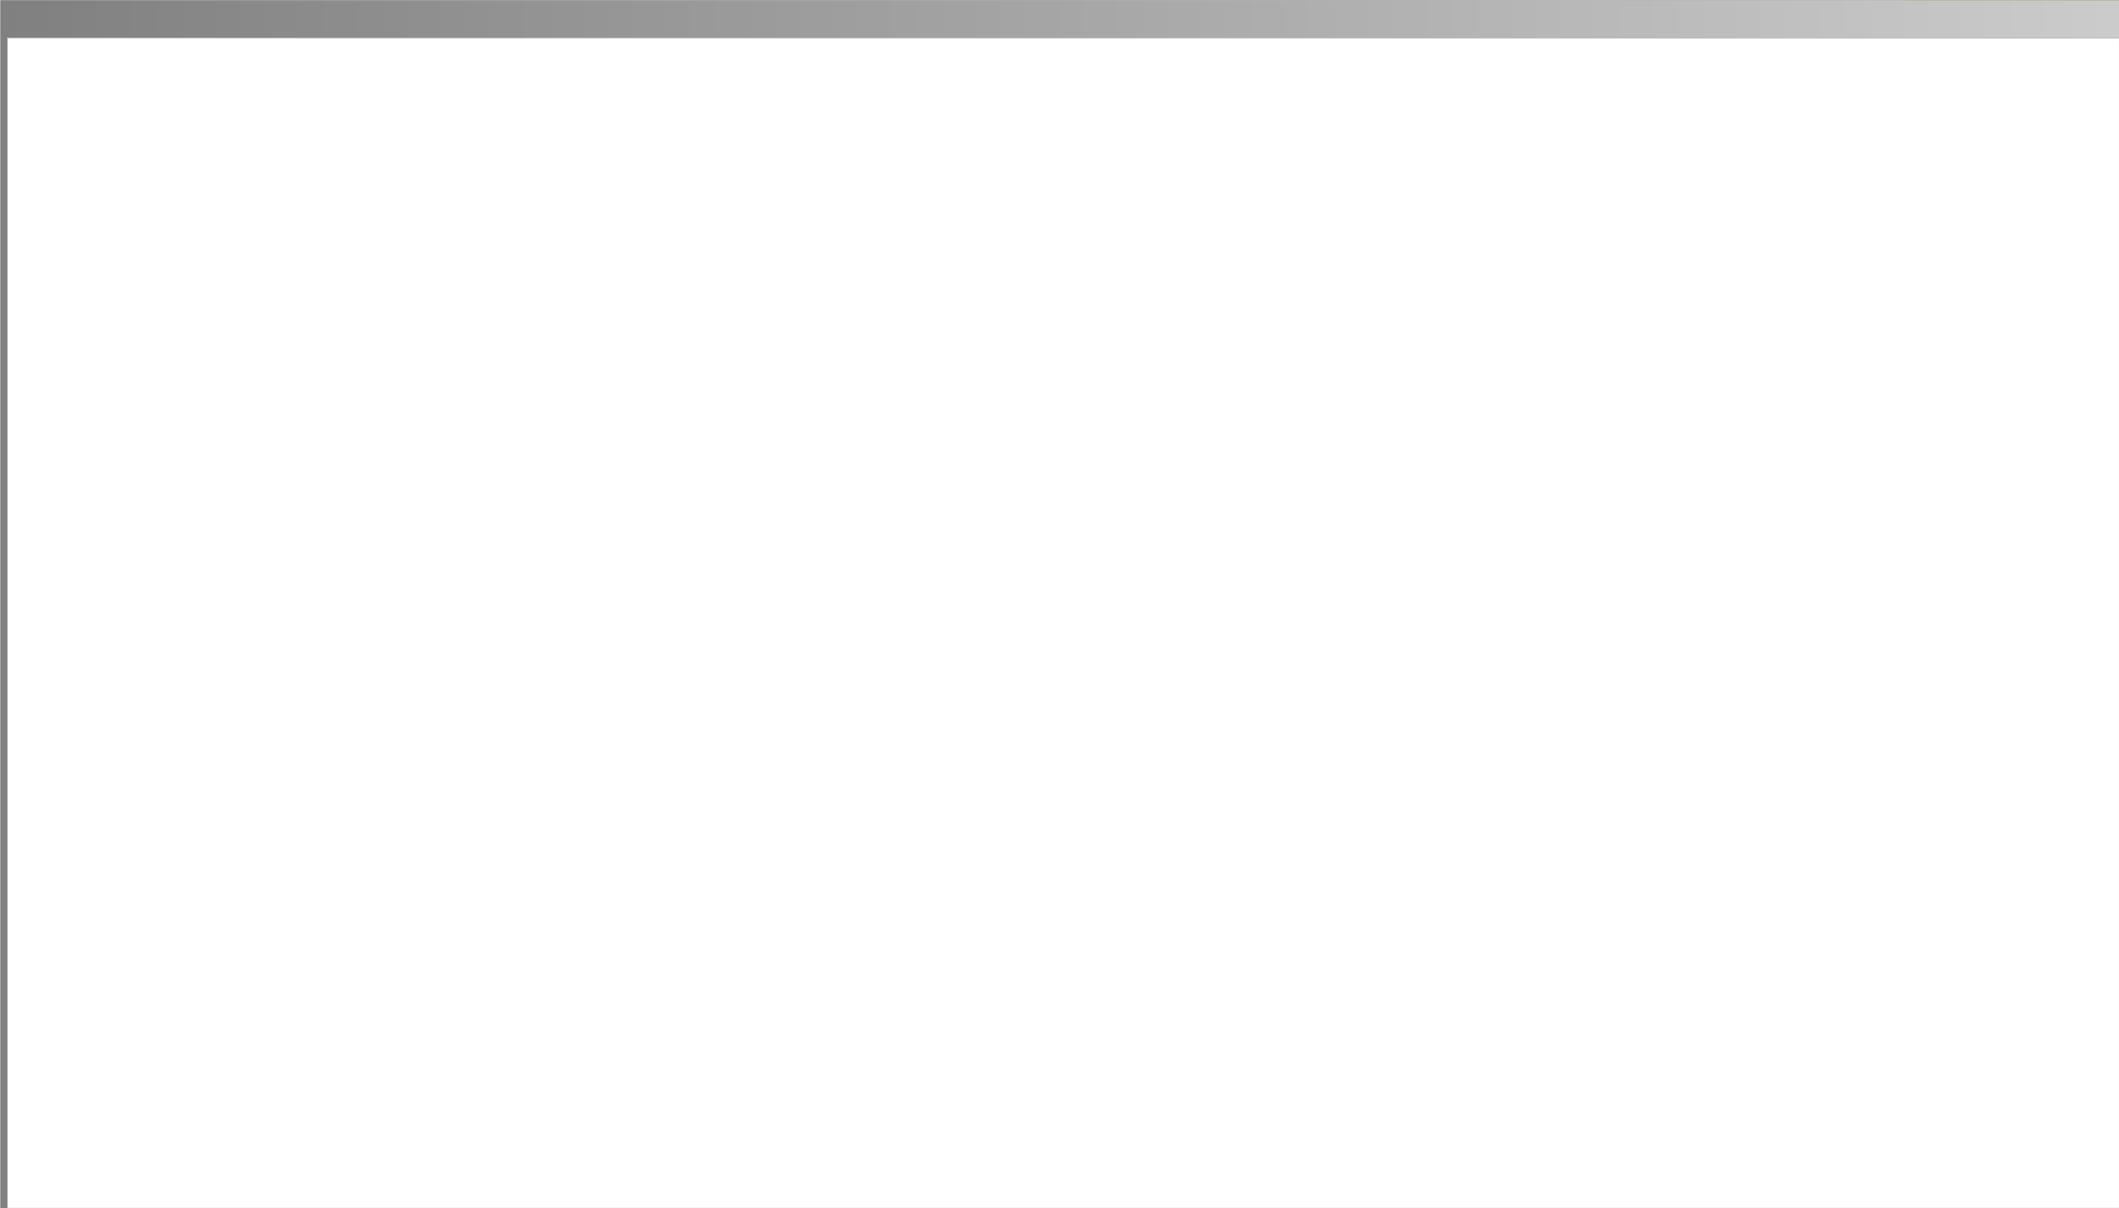
(verlinkt von Vorlesungsseite, Abschnitt Vorlesungsfolien)

- Einführung: Process-Mining
- Petrinetze
- Data-Mining
- Datenbeschaffung
- Prozessextraktion
- Konformanzanalyse
- Mining: Zusätzliche Perspektiven
- Betriebsunterstützung
- Werkzeugunterstützung
- Analysiere „Lasagne Prozesse“
- Analysiere „Spaghetti Prozesse“
- Kartographie und Navigation
- Epilog

Nächster Abschnitt: Einführung bzw. Wiederholung **Petrinetze**
(Grundlage für Process Mining Ansatz).

Anhang (weitere Informationen und Beispiele)

Methodische Grundlagen
des Software-Engineering
SS 2014

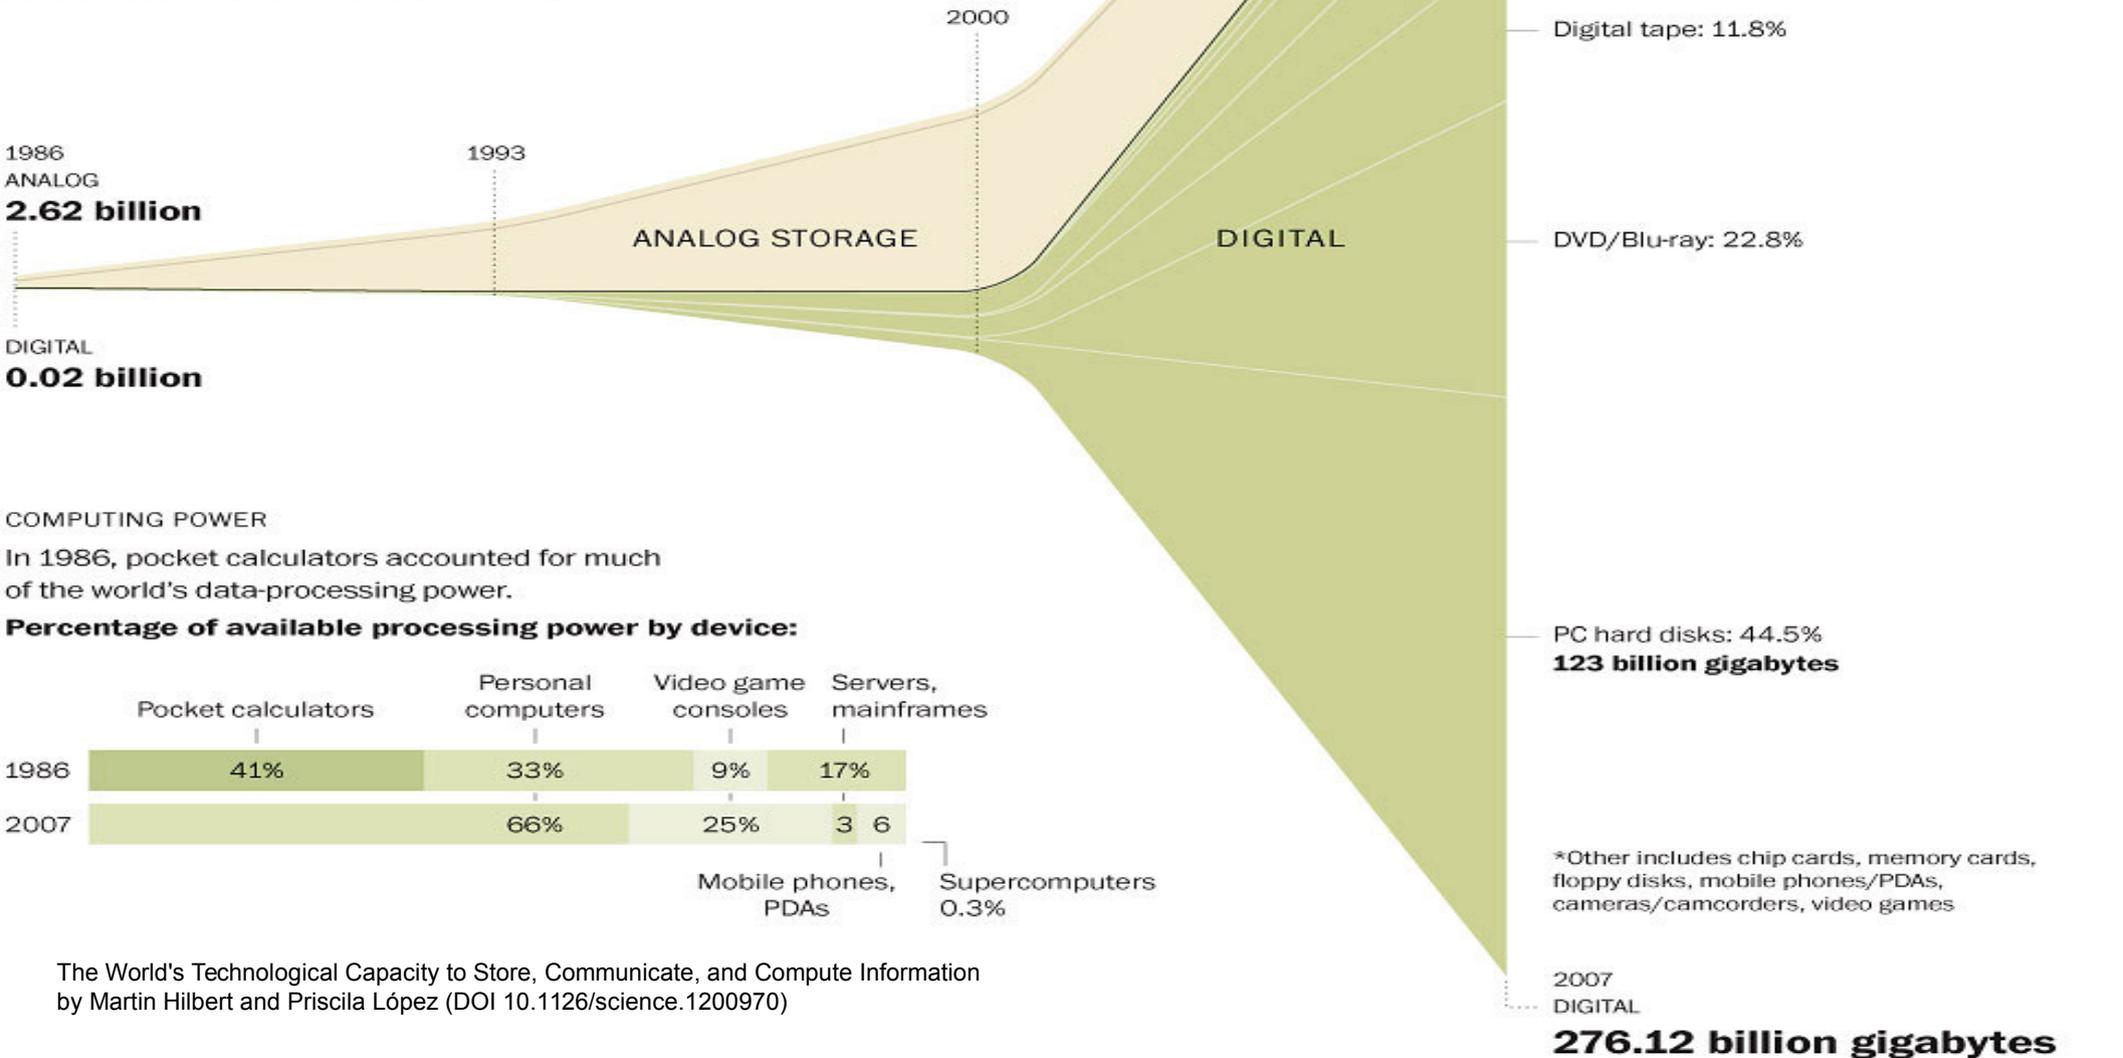


Datenexplosion II

THE WORLD'S CAPACITY TO STORE INFORMATION

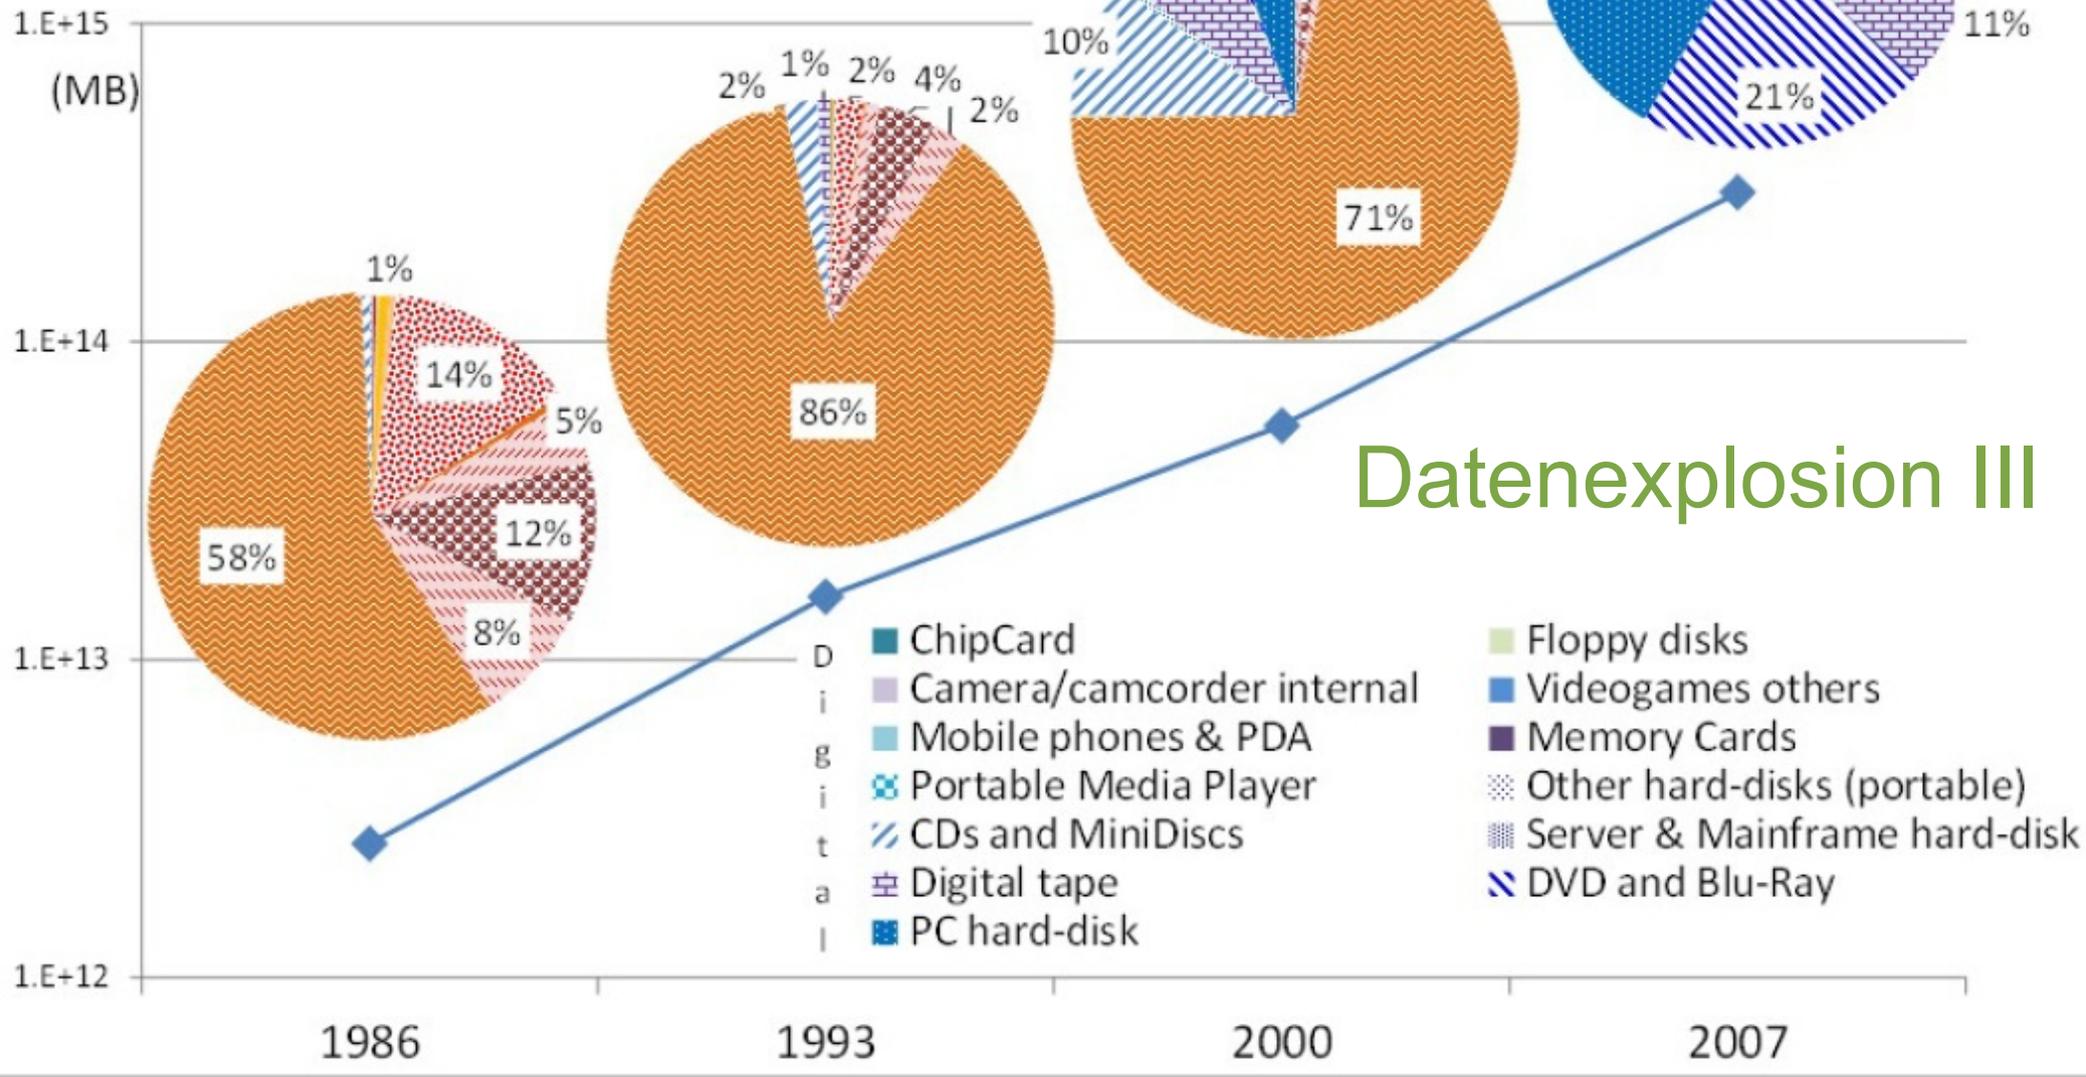
This chart shows the world's growth in storage capacity for both analog data (books, newspapers, videotapes, etc.) and digital (CDs, DVDs, computer hard drives, smartphone drives, etc.)

In gigabytes or estimated equivalent



- Books
- Newsprint
- X-Rays
- Vinyl LP
- Photo negative
- Photo print

- Other paper and print
- TV movie film
- TV episodes film
- Cine movie film
- Audio cassette
- Video analog



Datenexplosion III

- ChipCard
- Camera/camcorder internal
- Mobile phones & PDA
- Portable Media Player
- CDs and MiniDiscs
- Digital tape
- PC hard-disk
- Floppy disks
- Videogames others
- Memory Cards
- Other hard-disks (portable)
- Server & Mainframe hard-disk
- DVD and Blu-Ray



- Mit **Modellen**: **Prozesse erörtern (Re-Design)** und **Entscheidungen** in Prozessen treffen (**Planung** und **Kontrolle**).
- Prozessmodell für Diskussion über:
 - **Verantwortlichkeiten**,
 - **Compliance-Analyse**,
 - **Leistungsvorhersage** durch Simulationen und
 - **Konfiguration** von Workflowmanagement-Systemen.

Modell:

- **Idealisierte** Version der Realität.
- **Menschliches Verhalten** nicht adäquat darstellbar.
- Oft falsche **Abstraktionsebene**.
- **Verifikation** und **Performanzanalyse** braucht **hochqualitative** Modelle.
- Bei zu großem Unterschied **Modell – Wirklichkeit**: modellbasierte Analyse sinnlos.
- Oft fehlt **Abgleich**: handgemachte Modelle – Wirklichkeit.
 - Geschäftsprozessmodellierung nicht vorhanden / nicht vollständig bzw. aktuell.
 - Wird GP-Dokumentation in der Praxis befolgt ?



Process-Mining adressiert die o.g. Probleme:

- **Direkte Verbindung** zwischen **Modell** und **Daten** eines **aktuellen Prozess-Ereignisses**.
- **Prozessextraktions-Techniken**: Sicht aus **verschiedenen Perspektiven / Abstraktionsebenen**.