Vorlesung Wintersemester 2010/11

Workflow-Management-Systeme

Kapitel 13:
Workflow-Mining

Lehrstuhl für Systeme der Informationsverwaltung, Prof. Böhm
Institut für Programmstrukturen und Datenorganisation (IPD)

* Foliensatz basiert auf einer früheren Version von Frank Eichinger/IPD Böhm

Workflow Mining

- Analyse-Techniken für bestehende Systeme.
- Ziel: Verbesserungs-Potentiale aufdecken.

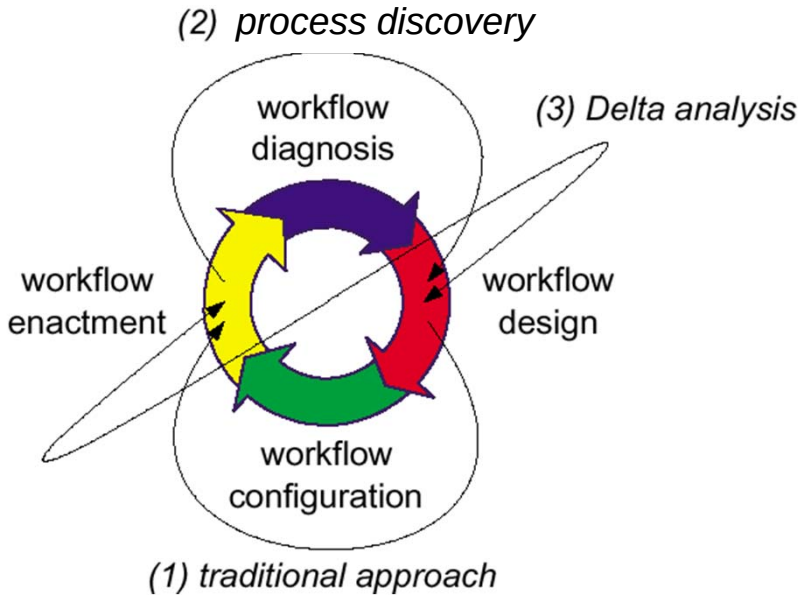

- Kann als Input für BPR (Business Process Reengineering) und CPI (Continuous Process Improvement) genutzt werden.

- Verschiedene Aspekte:
  - Process Discovery (2) – Wie sieht der Prozess (wirklich) aus?
  - Delta Analysis (3) – Passiert das, was spezifiziert wurde?
  - Performance Analysis – Wie können wir den Workflow verbessern?

Process Discovery

- Idee: Umdrehen des traditionellen Ansatzes

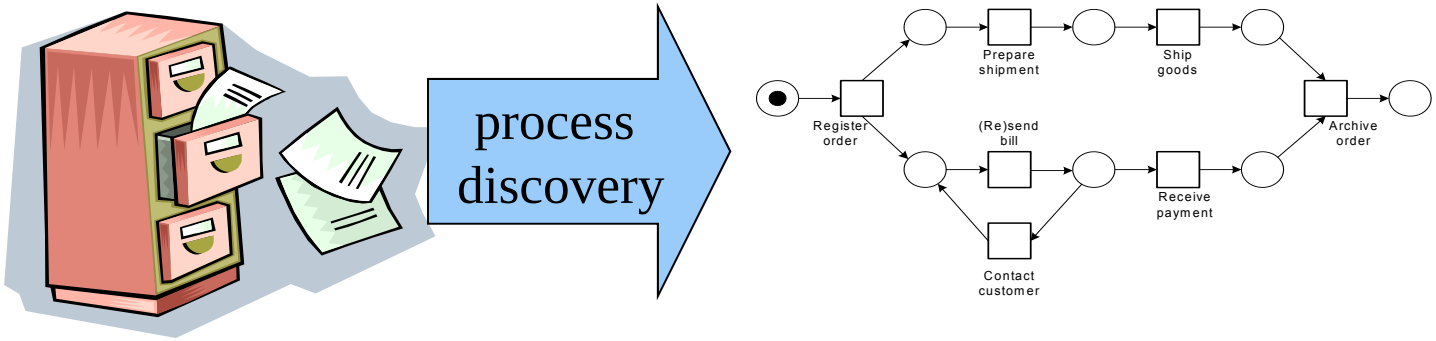

- Ausgangspunkt: Logfile
  - Minimal: Fall-Nummer, Task, zeitliche Ordnung
  - Optional: Genaue Zeit, User, assoziierte Daten etc.
  - „Rauschfrei“
  - „Vollständig“
- Ergebnis: Workflow-Schema als Petri-Netz

Beispiel-Logfile

- Das Beispiel enthält die folgenden Sequenzen:
  - ABCD (case 1, case 3)
  - ACBD (case 2, case 4)
  - AED (case 5)
- Vereinfachte Darstellung:
  - {ABCD, ACBD, AED}
- Vorab: das Petri-Netz dazu:

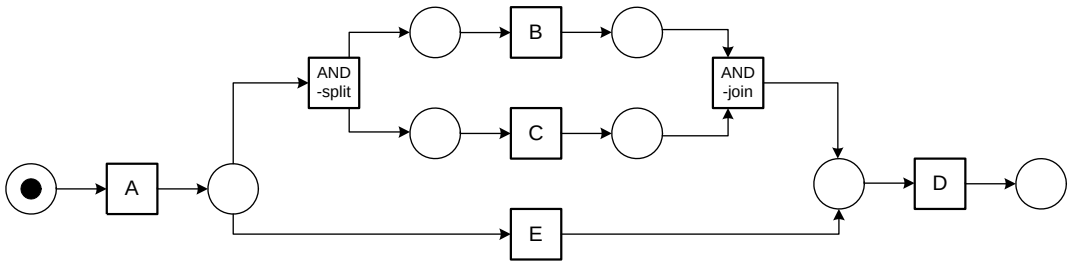


```
case 1, task A
case 2, task A
case 3, task A
case 3, task B
case 1, task B
case 1, task C
case 2, task C
case 4, task A
case 2, task B
case 2, task D
case 5, task A
case 4, task C
case 1, task D
case 3, task C
case 3, task D
case 4, task B
case 5, task E
case 5, task D
case 4, task D
```

Ordnungs-Relationen

- Direkte Nachfolge: **x>y**
  - Gdw. y folgt direkt auf x
- Kausalität: **x→y**
  - Gdw. x>y und nicht y>x
- Parallelität: **x||y**
  - Gdw. x>y und y>x
- Unabhängigkeit: **x#y**
  - Gdw. nicht x>y und nicht y>x und x≠y

- Im Beispiel {ABCD, ACBD, AED}:
- A>B, B>C, C>D, A>C, C>B, B>D, A>E, E>D
- A→B, A→C, A→E, B→D, C→D, E→D
- B||C, C||B
- A#D, B#E, C#E

Idee: Erzeugung eines Petri-Netzes (1)

- Wie kann aus den Relationen ein Workflow-Schema abgeleitet werden?
  - Einfachster Fall: Kausalität

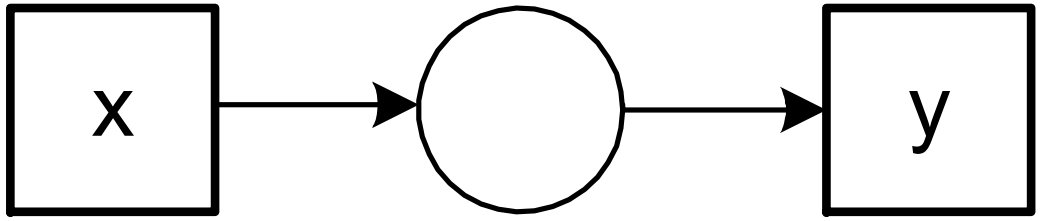

$x \rightarrow y$

Idee: Erzeugung eines Petri-Netzes (2)

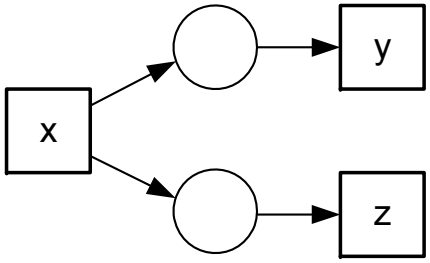

$x \rightarrow y,\ x \rightarrow z,\ y \| z$

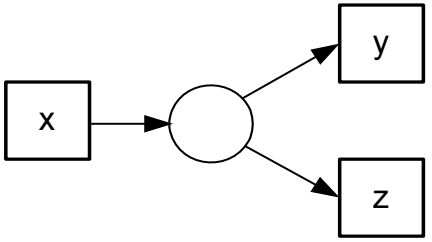

$x \rightarrow y,\ x \rightarrow z,\ y \# z$

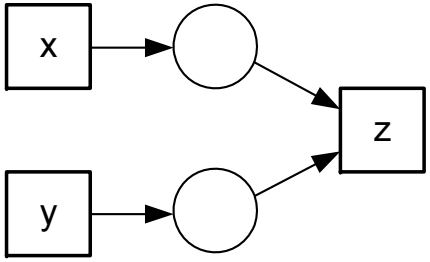

$x \rightarrow z,\ y \rightarrow z,\ x \| y$

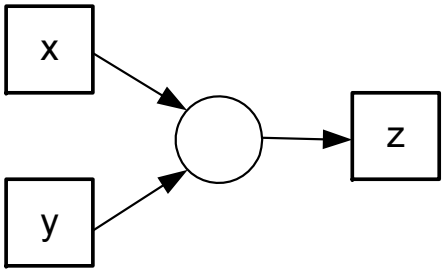

$x \rightarrow z,\ y \rightarrow z,\ x \# y$

Formalisierung: Der α-Algorithmus

Gegeben: Workflow-Log W mit σ = workflow trace (z.B. ABCD)

Anmerkung: für theorische Ergebnise ist die Zugehörigkeit zu einem Case nicht relevant, daher wird im Folgenden davon abstrahiert; für das Mining selbst ist das durchaus wichtig!

Gesucht: Workflow-Schema als Petri-Netz

$\alpha(W)$ = (Stellen P_W, Transitionen T_W, Verbindungen F_W)

1. $T_W = \{t \in T \mid \exists_{\sigma \in W} t \in \sigma\}$, Transitionen
2. $T_I = \{t \in T \mid \exists_{\sigma \in W} t = first(\sigma)\}$, Start-Transition
3. $T_O = \{t \in T \mid \exists_{\sigma \in W} t = last(\sigma)\}$, End-Transition
4. $X_W = \{(A, B) \mid A \subseteq T_W \ \wedge \ B \subseteq T_W \ \wedge \ \forall_{a \in A} \forall_{b \in B} a \rightarrow_W b \ \wedge \ \forall_{a_1, a_2 \in A} a_1 \#_W a_2 \ \wedge \ \forall_{b_1, b_2 \in B} b_1 \#_W b_2\}$, „Kausalitätsrelationen“
5. $Y_W = \{(A, B) \in X_W \mid \forall_{(A', B') \in X_W} A \subseteq A' \wedge B \subseteq B' \Longrightarrow (A, B) = (A', B')\}$, „Maximale Kausalitätsrelationen“
6. $P_W = \{p_{(A,B)} \mid (A, B) \in Y_W\} \cup \{i_W, o_W\}$, Stellen
7. $F_W = \{(a, p_{(A,B)}) \mid (A, B) \in Y_W \wedge a \in A\} \cup \{(p_{(A,B)}, b) \mid (A, B) \in Y_W \ \wedge \ b \in B\} \ \cup \{(i_W, t) \mid t \in T_I\} \ \cup \{(t, o_W) \mid t \in T_O\}$, and Verbindungen
8. $\alpha(W) = (P_W, T_W, F_W)$. Petri-Netz

α-Algorithmus – Beispiel

Ursprungs-Log:
{ABCD, ACBD, AED}

1. $T_W = \{A,B,C,D,E\}$
2. $T_I = \{A\}$
3. $T_O = \{D\}$,
4. $X_W = \{(\{A\}, \{B\}), (\{A\}, \{C\}), (\{A\}, \{E\}), (\{B\}, \{D\}),$
   $(\{C\},\{D\}), (\{E\}, \{D\}), (\{A\}, \{B, E\}), (\{A\}, \{C, E\}), (\{B, E\}, \{D\}),$
   $(\{C, E\}, \{D\}) \}$
5. $Y_W = \{(\{A\}, \{B, E\}), (\{A\}, \{C, E\}), (\{B, E\}, \{D\}),$
   $(\{C, E\},\{D\})\}$
6. $P_W = \{i_W, o_W, p(\{A\},\{B,E\}), p\{A\},\{C,E\}), p(\{B,E\},\{D\}),$
   $p(\{C,E\},\{D\})\}$,
7. $F_W = \{(i_W, A), (A, p(\{A\},\{B,E\})), (p(\{A\},\{B,E\}), B),$
   $\ldots, (D, o_W)\}$
8. $a(W) = (P_W, T_W, F_W)$

α-Algorithmus – Beispiel-Netz

Ursprungs-Log:
{ABCD, ACBD, AED}

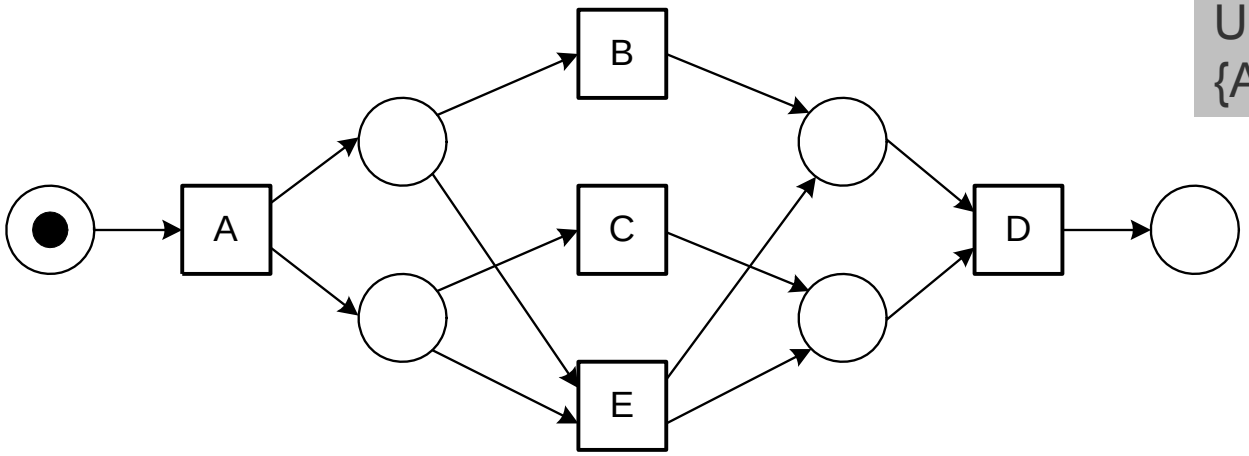

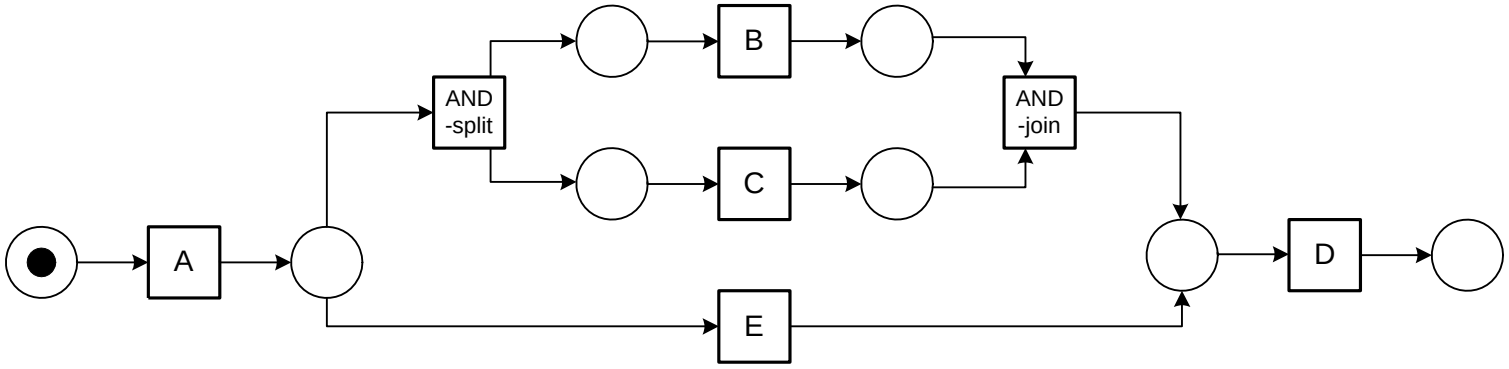

α-Algorithmus – Unzulänglichkeiten (1)

- Es können nur „beobachtbare“ Netzwerke erzeugt werden.
  - Splits und Joins nicht immer direkt beobachtbar.
  - Beobachtetes Verhalten wird aber korrekt wiedergegeben.
- Anderes Problem: ‚E‘ nicht sichtbar
  - {AD} nicht ausführbar

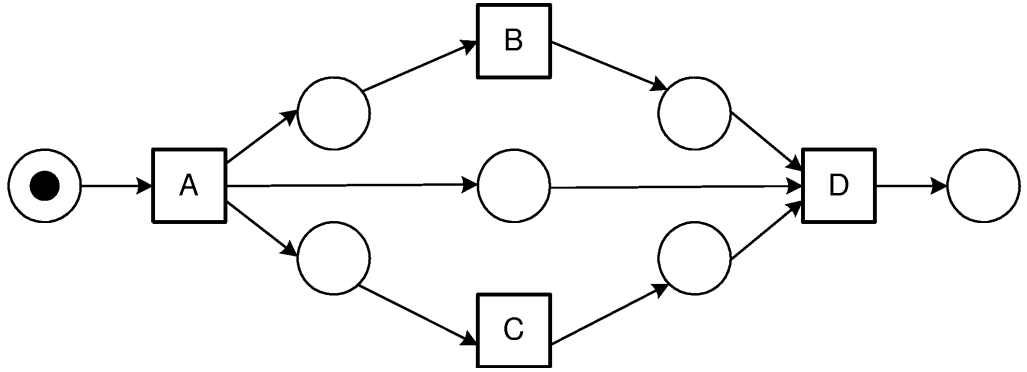

α-Algorithmus – Unzulänglichkeiten (2)

- Mehrfach auftretende Aktivitäten
  - Schwierig, der α-Algorithmus konstruiert nur eine Transition pro Aktivität.
- Iterationen
  - Führen zu mehrfach auftretenden Aktivitäten.
  - Müssen ggf. extra erkannt werden.
    - Mitunter sehr schwierig!
- Verrauschte Daten
  - Lösung z.B. durch Betrachtung der Häufigkeit.
- …

Demo: ProM

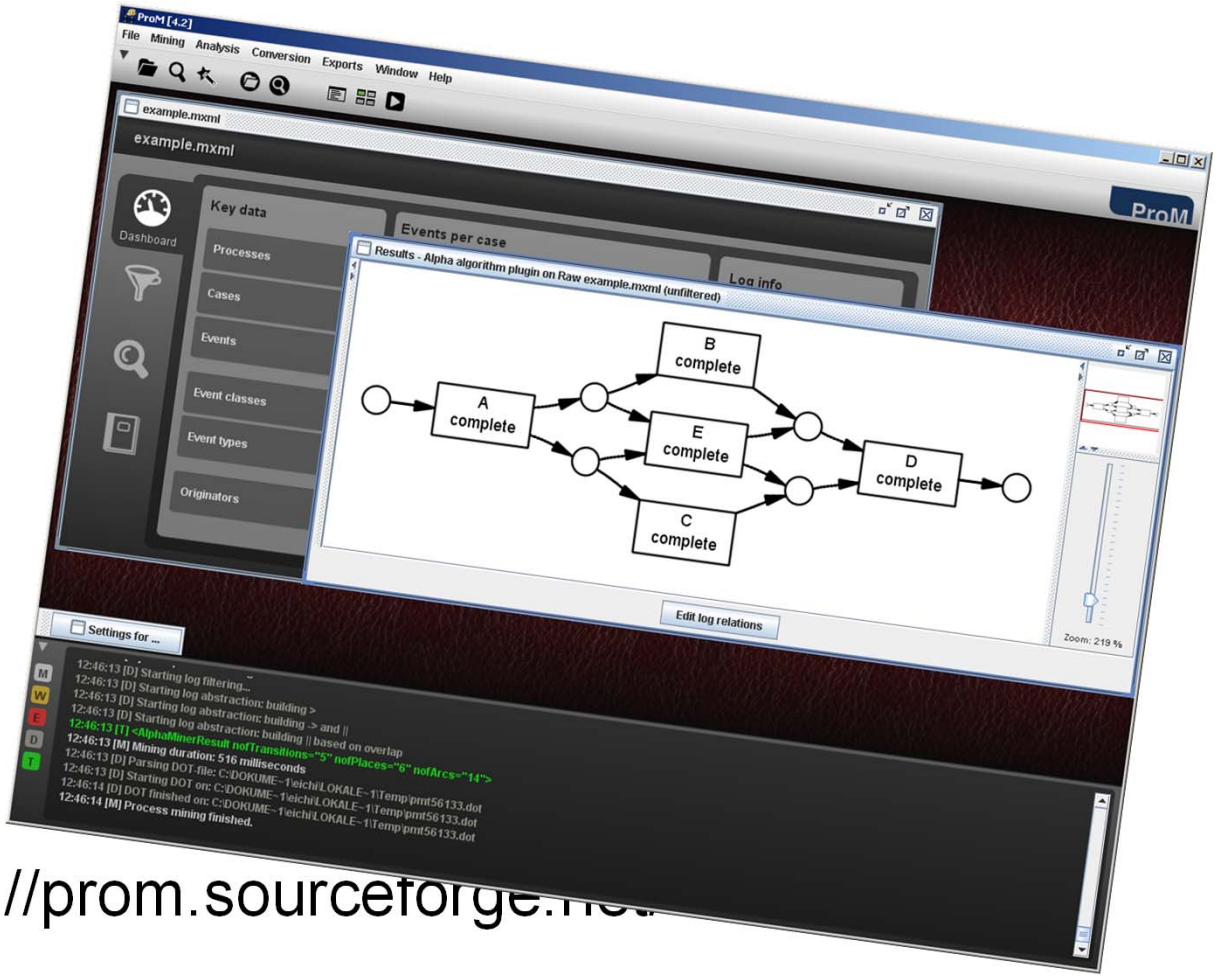

http://prom.sourceforge.net

Workflow Mining

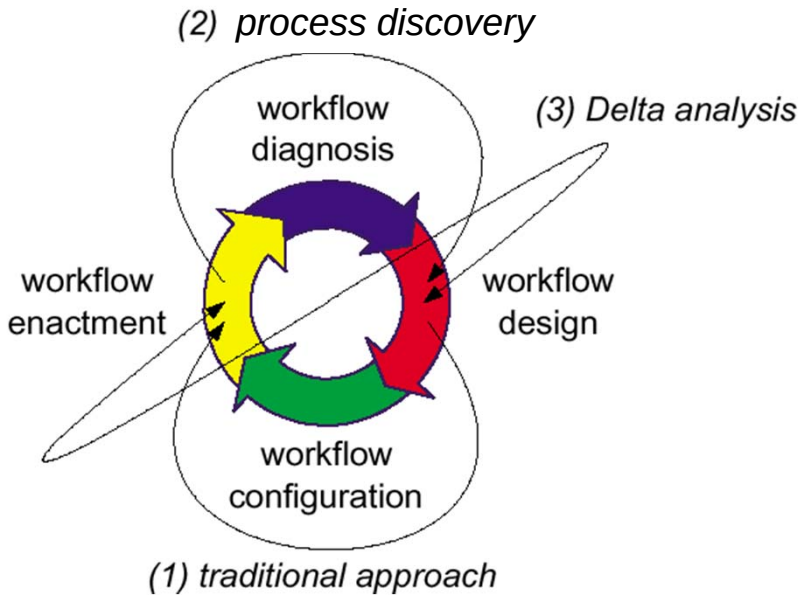

- Verschiedene Aspekte:
  - Process Discovery (2) – Wie sieht der Prozess (wirklich) aus?
  - Delta Analysis (3) – Passiert das, was spezifiziert wurde?
  - Performance Analysis – Wie können wir den Workflow verbessern?
- Nächster Schritt („workflow diagnosis“):
  - Welche Pfade sind häufig?
  - Welche Instanzen werden wahrscheinlich abgebrochen?

Workflow-Diagnose mit Graph Mining (1)

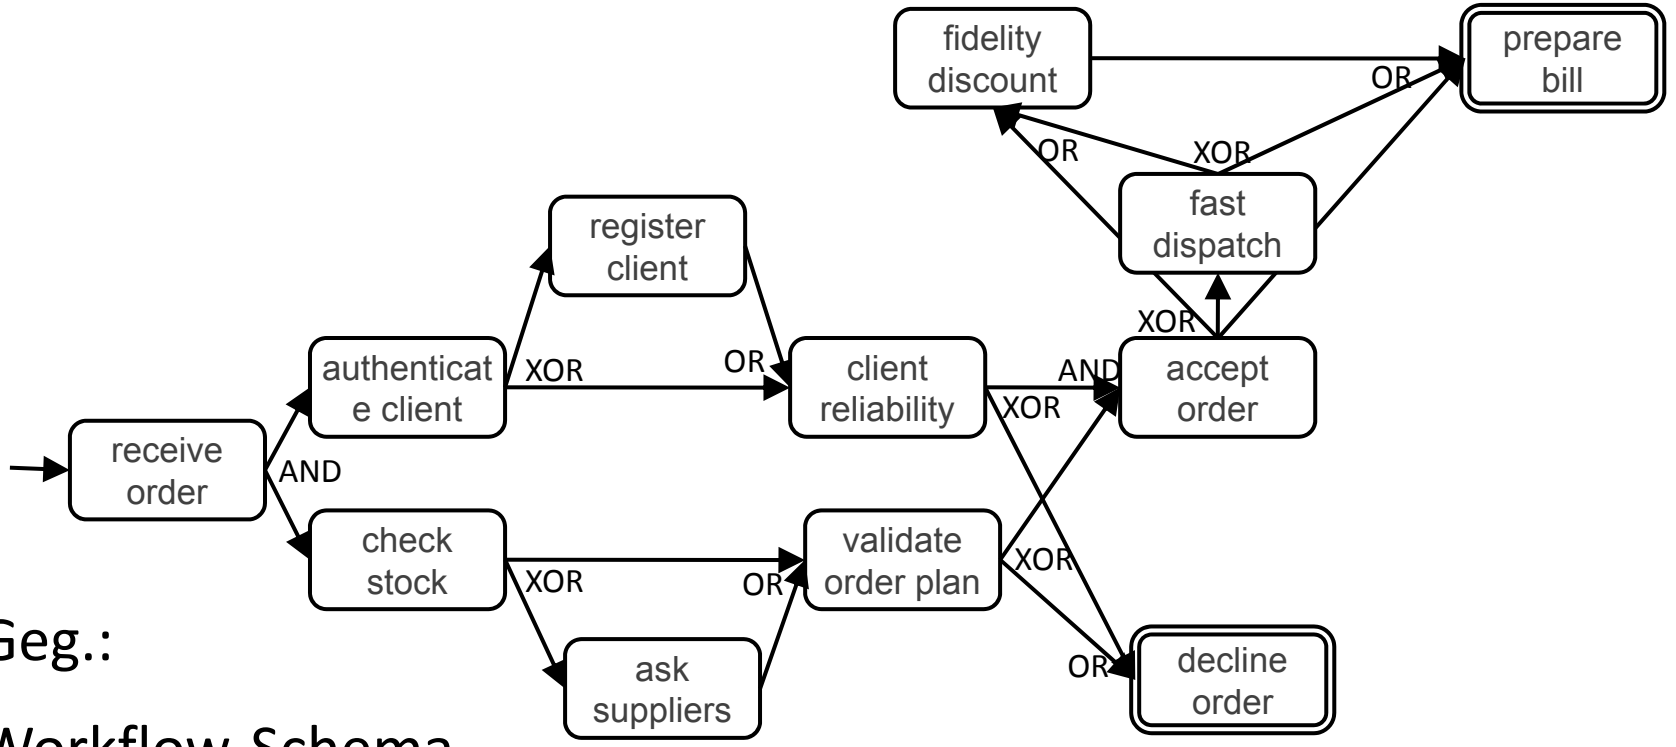

Geg.:

Workflow-Schema

Workflow-Diagnose mit Graph Mining (2)

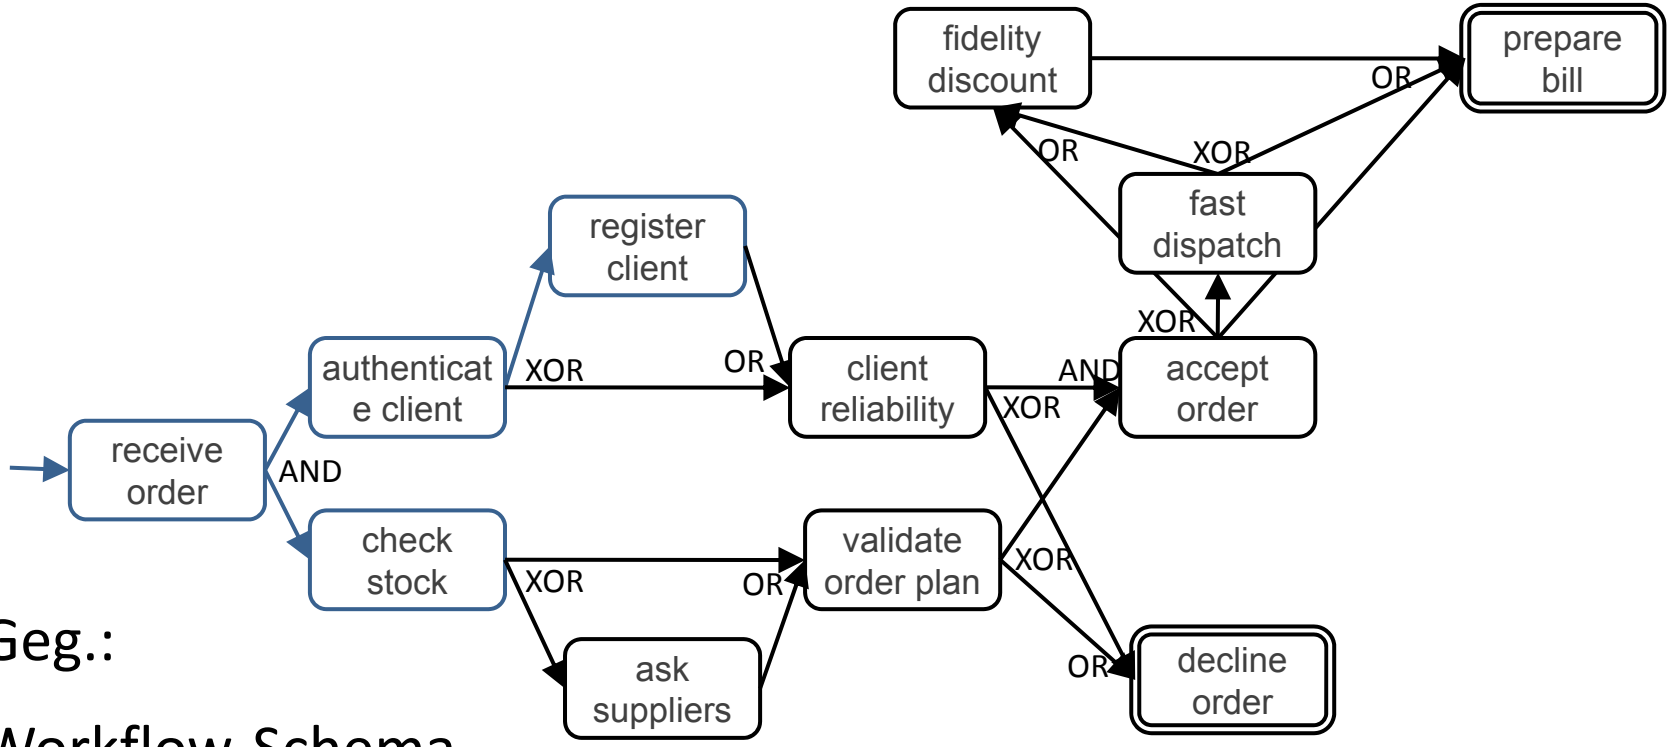

Geg.:

Workflow-Schema

Führt diese Teilausführung möglicherweise zu einem *erfolgreichen* Verkaufsvertrag?

Workflow-Diagnose mit Graph Mining (3)

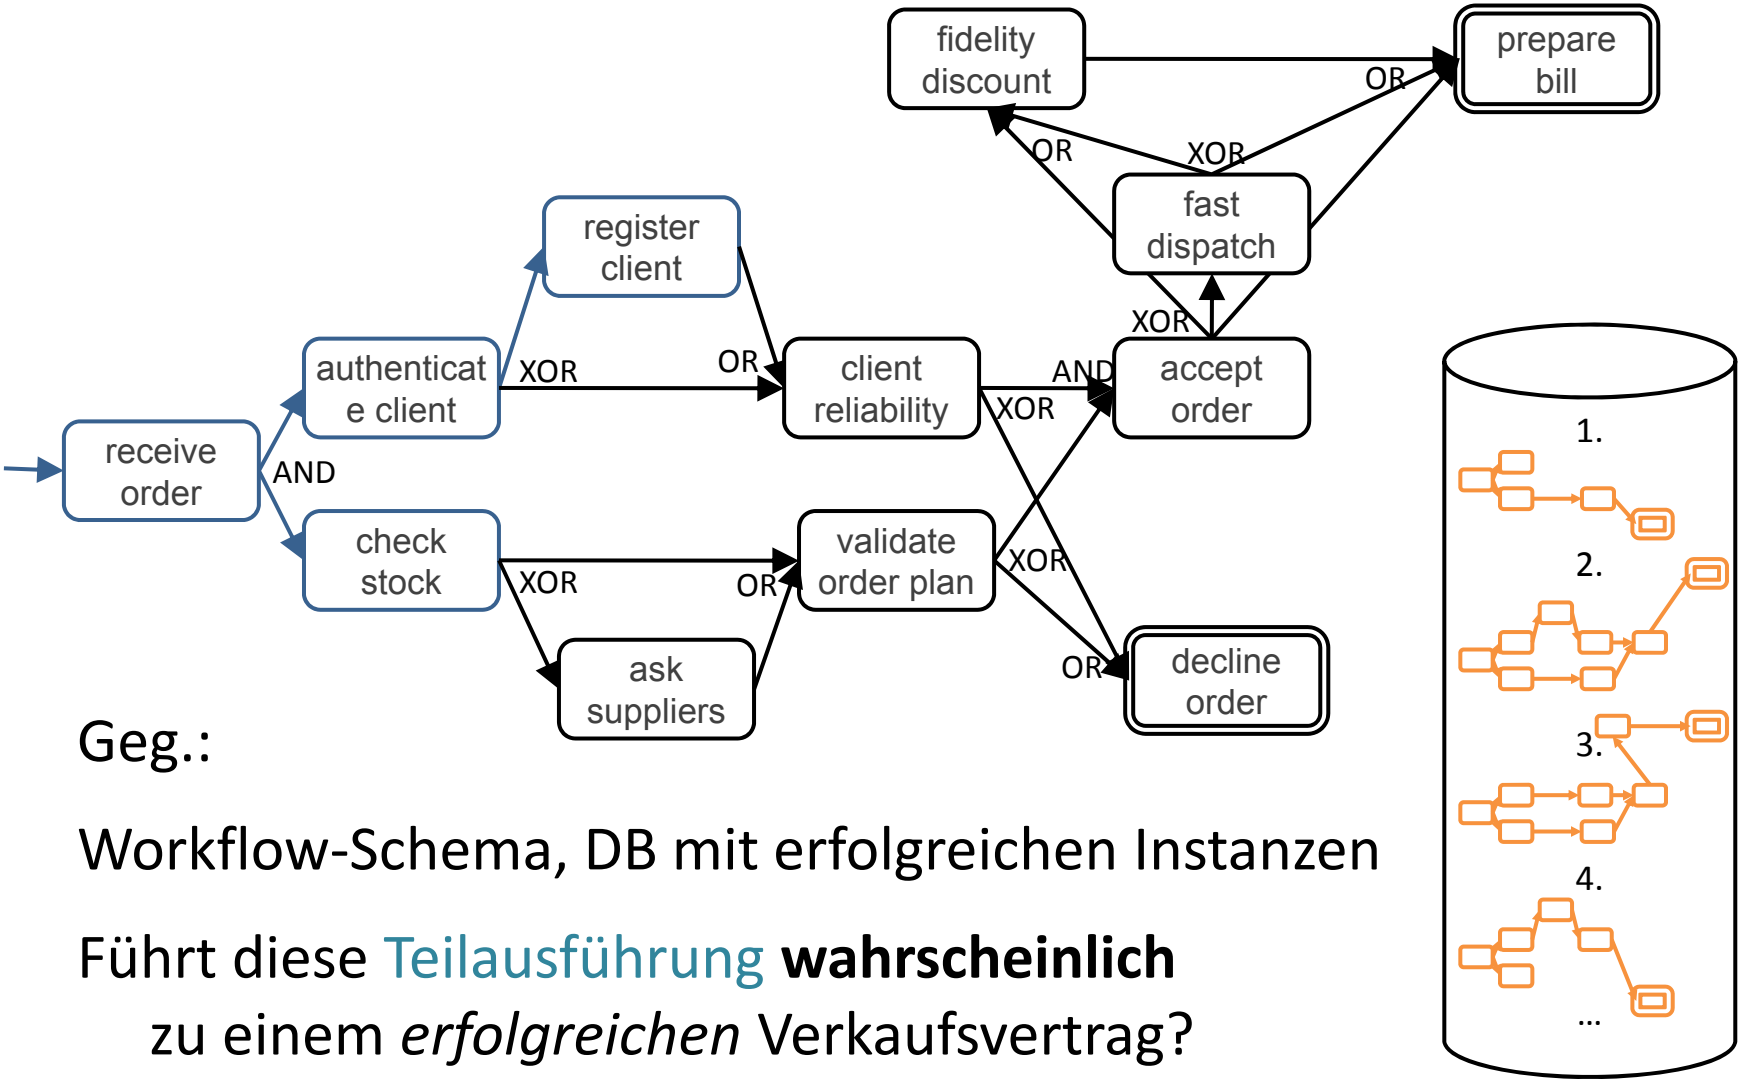

Geg.:

Workflow-Schema, DB mit erfolgreichen Instanzen

Führt diese Teilausführung **wahrscheinlich** zu einem *erfolgreichen* Verkaufsvertrag?

Workflow-Diagnose mit Graph Mining (4)

- Weitere interessante Fragestellungen
  - Fehlerfreie Workflow-Ausführung?
  - Workflow-Ausführung mit geringem oder normalem Ressourcenverbrauch?
  - Identifikation kritischer Aktivitäten (besonders hoher Ressourcenverbrauch).
  - Wie sehen häufige/typische Ausführungen aus?
- Verwertung der Information
  - Zur Laufzeit: Scheduling
  - Information für Management/Optimierung (BPR, CPI)
- Ansatz: Ermitteln von *frequent patterns* bei gegebenem Workflow-Schema und Prozess-Logs.

Graph Mining

- Finden von *häufigen Subgraphen* in einer Menge von Graphen (Graph-Datenbank).
  - Häufig: Ein Graph G ist Subgraph von mindestens *minSup* Graphen der Graph-Datenbank.
- Typische Anwendungen
  - Chemie und Pharmaforschung (Moleküle)
  - Softwaretechnik (Call-Graphen)
  - Soziale Netzwerke etc.
- Auch Workflow-Schemata und -Instanzen sind Graphen!

Einschränkungen bei Workflow-Graphen

- AND-Join / OR-Join

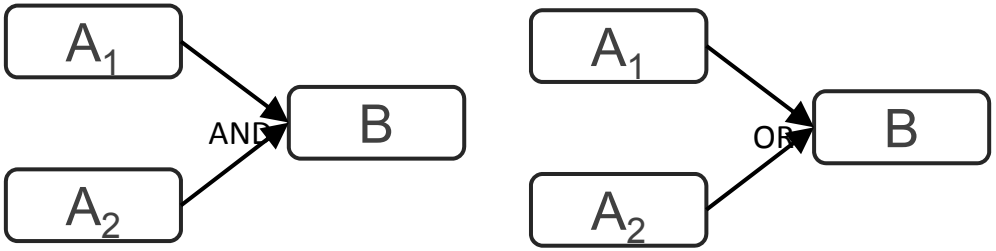

- Full Fork (OR) / Exlusive Fork (XOR) / Deterministic Fork (AND)

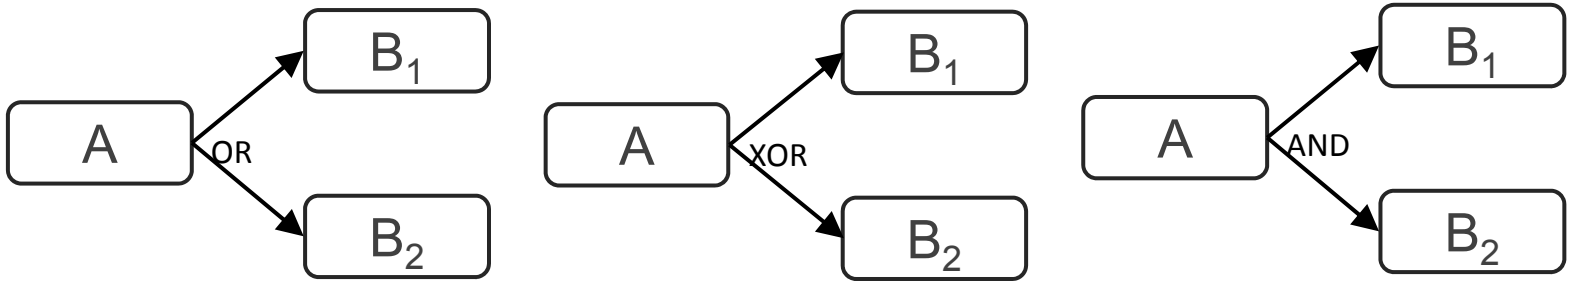

Graph Mining - Beispiel

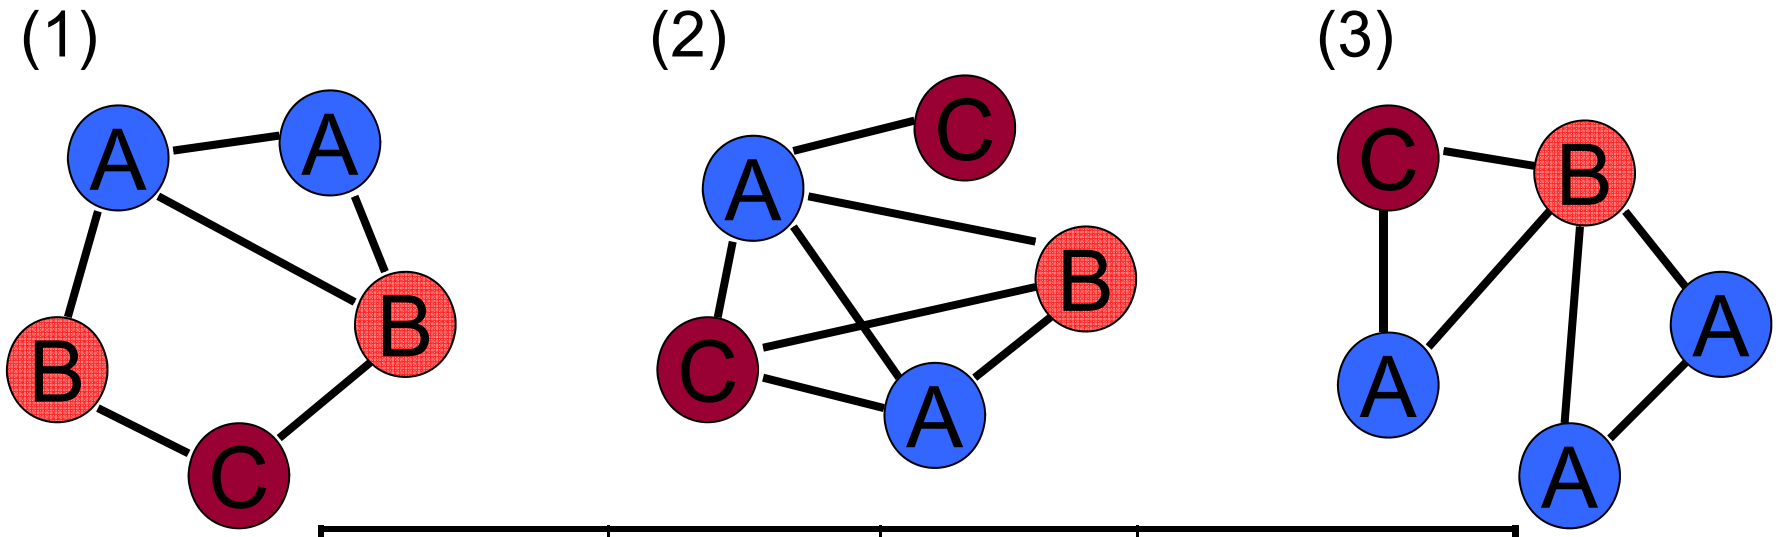

Support	1	2	3
Teilgraph	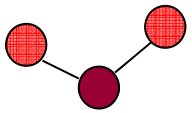	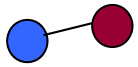	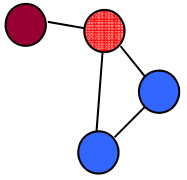

Apriori-Prinzip: G häufig → Alle Subgraphen häufig!

Apriori Graph Mining Algorithmus

- Iteratives Vorgehen (Breitensuche):
  1. Suche alle häufigen Kanten in der Graph-Datenbank (n=1)
  2. Generieren von Kandidaten der Größe n+1 aus häufigen Subgraphen der Größe n
  3. Überprüfen der Häufigkeit der Kandidaten in der Graph-Datenbank
  4. Wiederhole 2+3 solange häufige Graphen gefunden werden
- Kandidatengenerierung durch Join von n-1–Kernen:

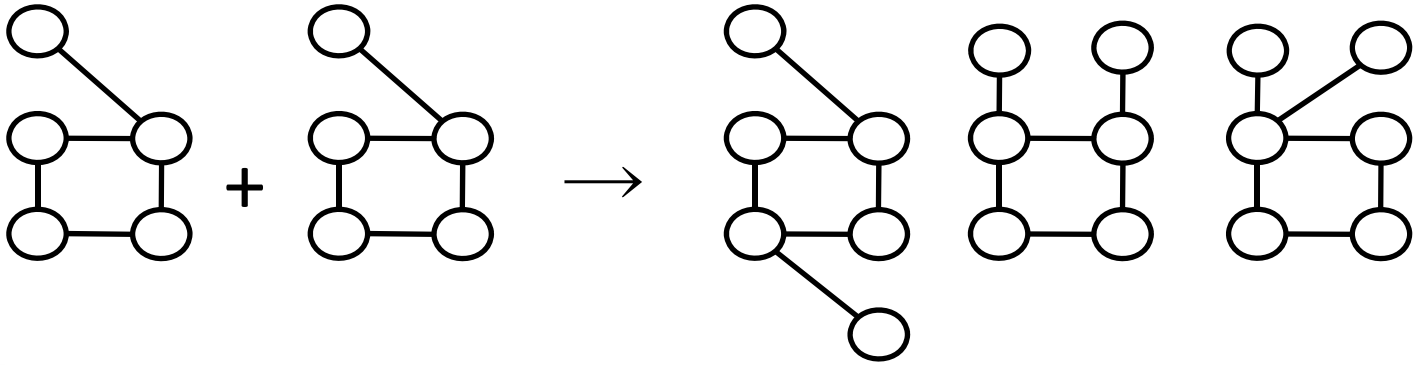

Nachteile von Apriori-basiertem Graph Mining

- Aufwändige Kandidatengenerierung
  - Jeder Graph der Größe n wird mit jedem verglichen.
  - Finden gemeinsamer Kerne beinhaltet Subgraphisomorphie.
  - Mergen der Kerne beinhaltet Suche nach Automorphien.
- Aufwändige Kandidatenüberprüfung
  - Es entstehen im allgemeinen sehr viele Kandidaten.
  - Jede Überprüfung beinhaltet Subgraphisomorphie.
- Subgraphisomorphie ist NP-vollständig.

- **Kein Skalieren für große Workflow-Netze.**
  - Es existieren andere Graph Mining Algorithmen, die besser skalieren (PatternGrowth-Ansatz). Nicht Gegenstand heute.

Algorithmus *w-find*

- Graph Mining-Algorithmus *w-find* nach GRECO
  - Finden von *frequent patterns* bzw. häufigen Teilprozessen
  - Apriori-ähnlich
  - Effizienzsteigerung durch Nutzung der Workflow-spezifischen Einschränkungen
    - Nicht sämtliche häufige Aktivitäten Grundlage der Kandidatengenerierung, sondern häufige *weak patterns*, welche die Regeln des Workflow-Schemas erfüllen.

Funktionsweise *w-find*

1. Finden von *elementary weak patterns*:

   Ausgehend von einzelnen Aktivitäten Erweiterung auf ein zusammenhängendes *weak pattern*, in dem AND-Joins und AND-Verzweigungen (deterministic fork) erfüllt sein müssen.

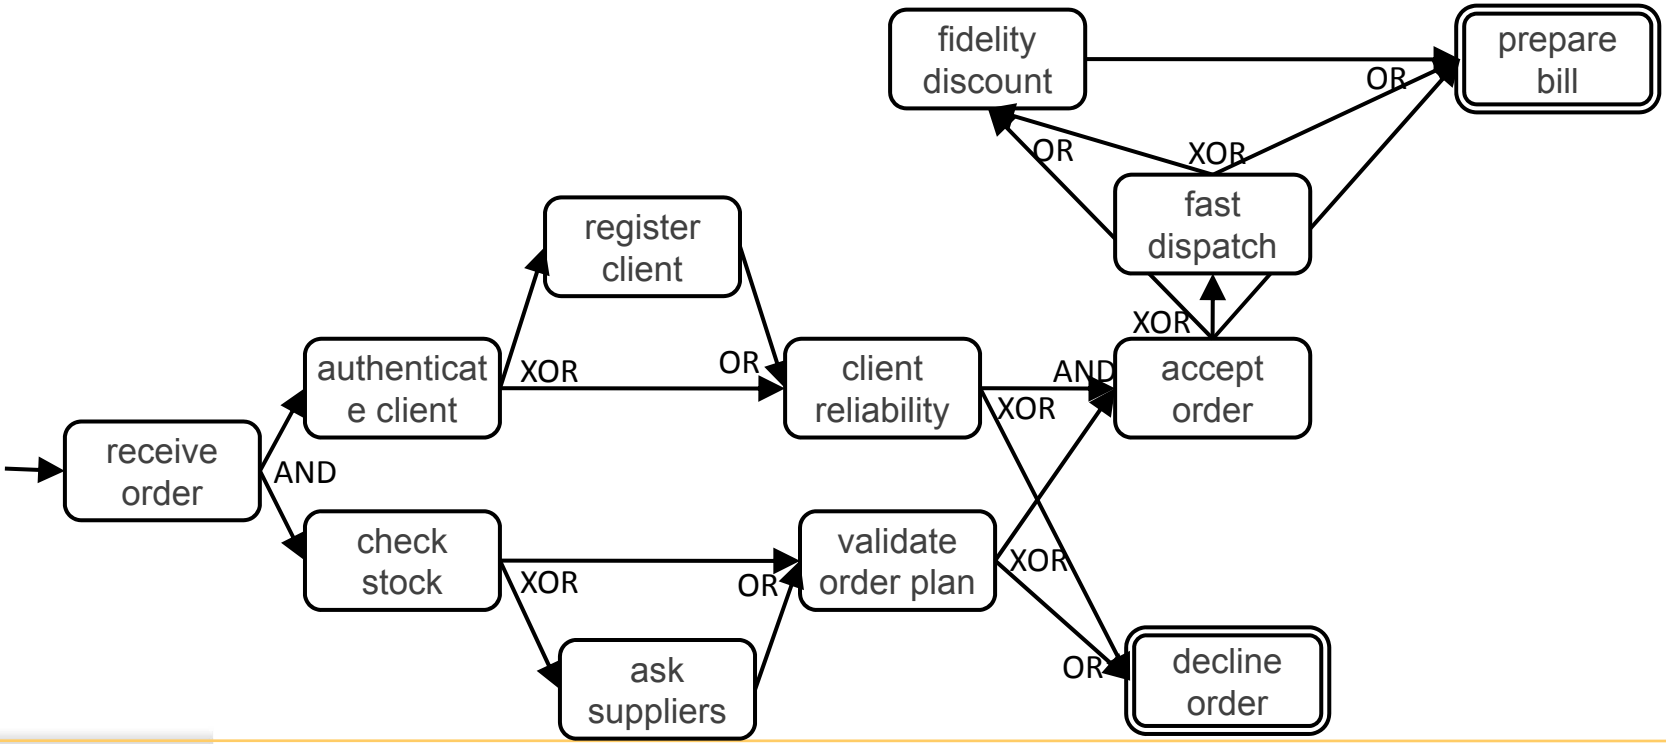

Funktionsweise *w-find*

2. Identifikation der *frequent weak patterns*:

   Berücksichtige nur weak patterns mit einer bestimmten Häufigkeit (*minSup*).

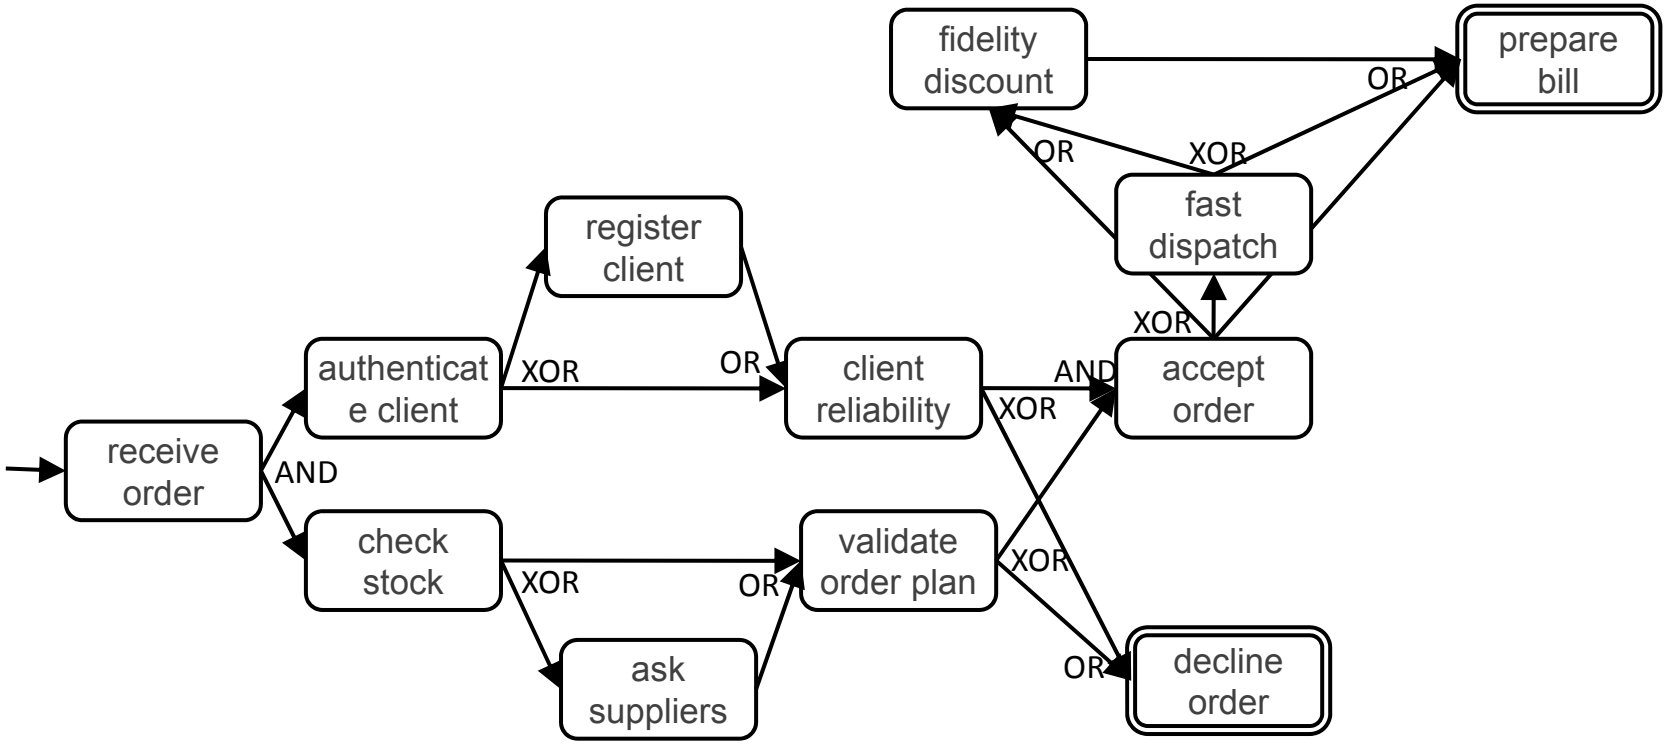

Funktionsweise *w-find*

3. Erweitern der Menge der *frequent patterns* durch
   - Hinzufügen von Kanten aus dem Workflow-Schema.
   - Verschmelzung oder Verbindung zweier weak patterns.

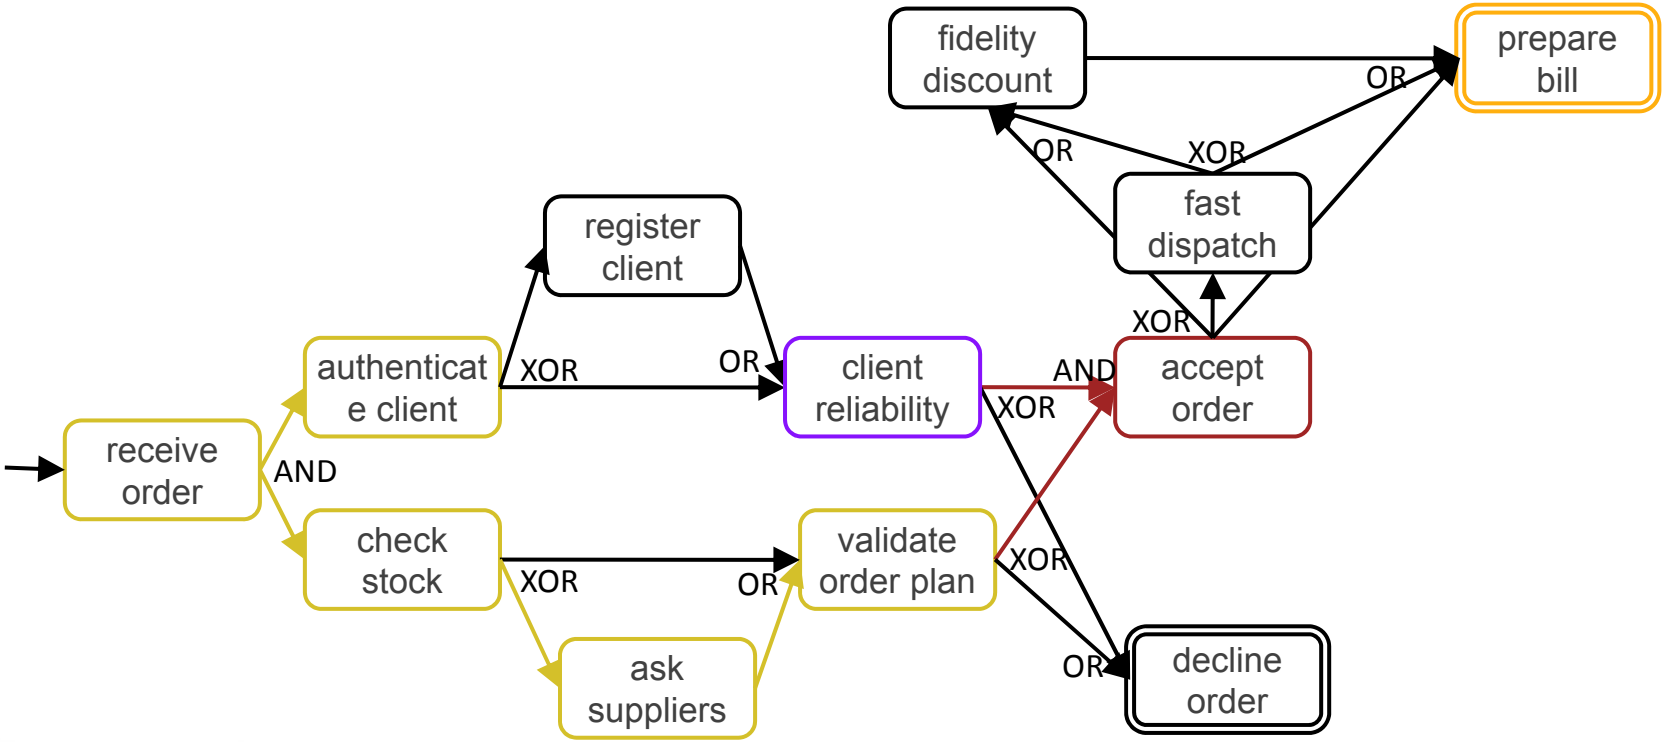

Exemplarische Fragen zu Kapitel 13

- Wozu kann Process Mining genutzt werden?
- Wie sehen zu Grunde liegende Verfahren aus?
- Auf welchen Informationen basieren die Verfahren, wie erhält man diese Informationen?

Ergänzende Literatur zu Kapitel 13

- W.M.P. van der Aalst and A.J.M.M. Weijters: Process Mining; M. Dumas, W.M.P. van der Aalst, and A.H.M. ter Hofstede (Eds.), Process-Aware Information Systems: Bridging People and Software through Process Technology, pages 235-255. Wiley & Sons, 2005
- A.K.A. de Medeiros, W.M.P. van der Aalst, and A.J.M.M. Weijters: Workflow Mining: Current Status and Future Directions; R. Meersman et al. (Eds.): CoopIS/DOA/ODBASE 2003, LNCS 2888, pages 389-406, 2003;
- W.M.P. van der Aalst, A.J.M.M. Weijters, and L. Maruster: Workflow Mining: Discovering Process Models from Event Logs; QUT Technical report, FIT-TR-2003-03, Queensland University of Technology, Brisbane, 2003; http://rug.nl/staff/l.maruster/ieee-tkde2004_aalstweijtersmaruster.pdf
- Wil van der Aalst: Process Mining: Discovering processes from event logs; Talk at the CTIT BPM day, University of Twente, April 29th, 2005
- Alexander Fritz: Graph Mining für Workflows; Seminar Workflowmodellierung, Workflow-Mining und Identitätsmanagement, Institut für Programmstrukturen und Datenorganisation (IPD), Universität Karlsruhe (TH), Februar 2008; http://dbis.ipd.uka.de/956.php
- Greco, G.; Guzzo, A.; Manco, G.; Pontieri, L. & Saccà, D.: Mining Constrained Graphs: The Case of Workflow Systems; Proceedings of the Workshop on Inductive Databases and Constraint Based Mining, 2004, 155-171
- Demo ProM (Alpha-algorithm), http://prom.sourceforge.net;