LEHRSTUHL 14
SOFTWARE ENGINEERING

Vorlesung

Methodische Grundlagen des Software-Engineering

im Sommersemester 2013

Prof. Dr. Jan Jürjens

TU Dortmund, Fakultät Informatik, Lehrstuhl XIV

Teil 2.5: Prozessextraktion

v. 27.05.2013

2.5 Prozessextraktion

**[mit freundlicher Genehmigung basierend
auf einem englischen Foliensatz von
Prof. Dr. Wil van der Aalst (TU Eindhoven)]
[inkl. Beiträge von Jutta Mülle und Dr. Silvia von Stackelberg,
LS Prof. Böhm, Karlsruher Institut für Technologie]**

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 5**

Einordnung
2.5: Prozessextraktion

- Geschäftsprozessmodellierung
- Process-Mining
  - Einführung: Process-Mining
  - Petrinetze
  - Prozessmodellierung und Analyse
  - Data-Mining
  - Datenbeschaffung
  - Prozessextraktion
  - Konformanzanalyse
  - Mining: Zusätzliche Perspektiven
  - Betriebsunterstützung
  - Werkzeugunterstützung
  - Analysiere „Lasagne Prozesse“
  - Analysiere „Spaghetti Prozesse“
  - Kartographie und Navigation
  - Epilog
- Modellbasierte Softwareentwicklung
- Modellbasierte Entwicklung sicherer Software

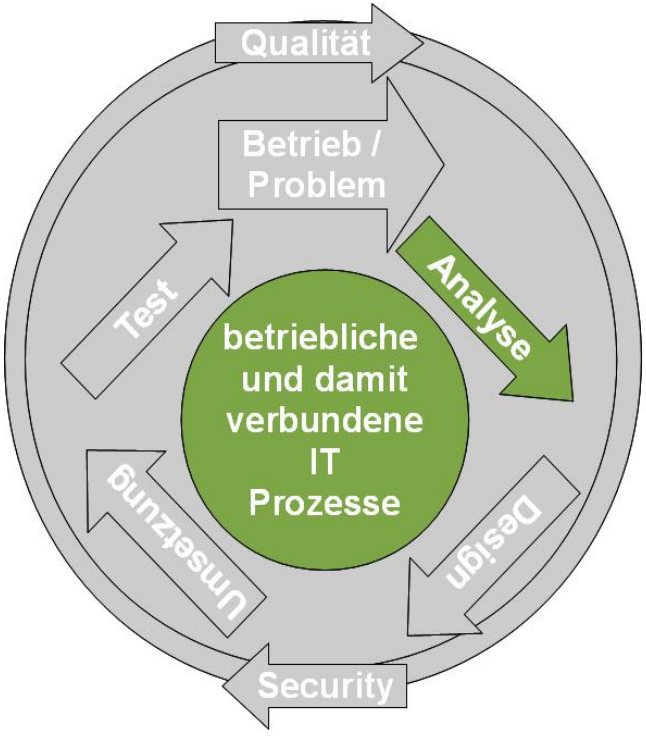

Überblick
2.5 Prozessextraktion

- Einführung und Beispiel
- α-Algorithmus
  - Idee und Vorbereitungen
  - Formalisierung
  - Beispiel
  - Weitere Beispiele
  - Einschränkungen
- Allgemeine Herausforderungen beim Process-Mining

Prozessextraktion

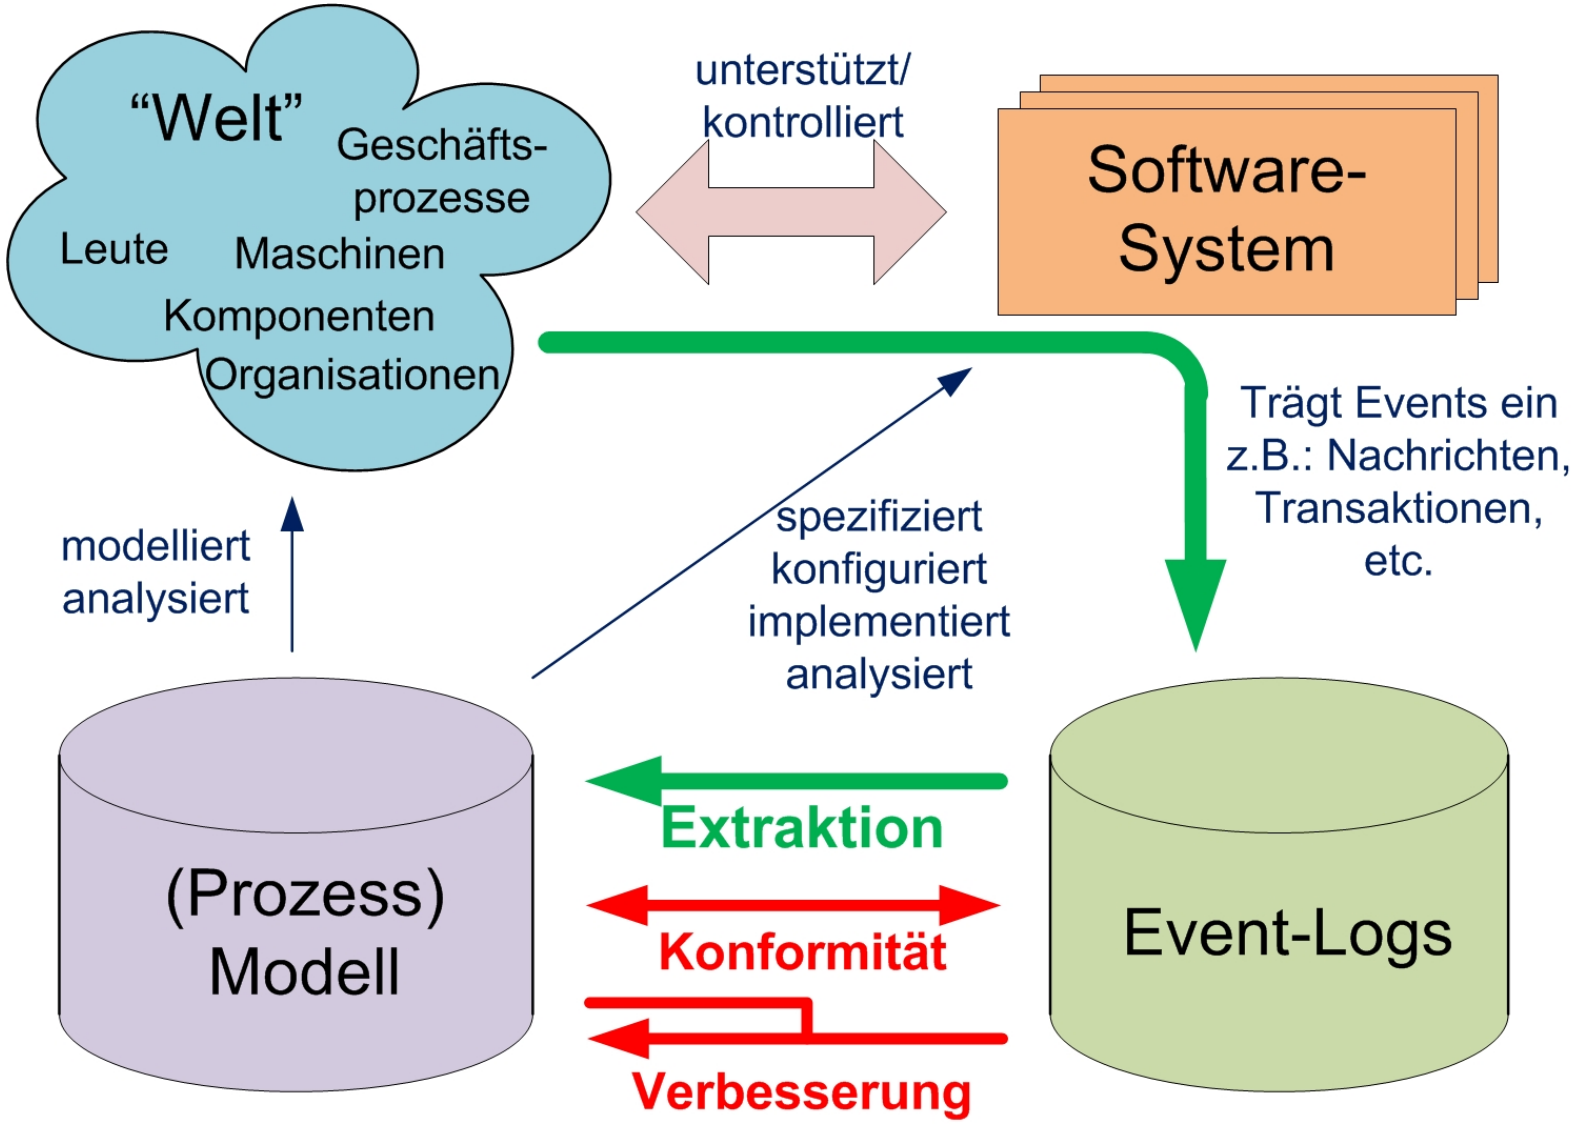

Prozessextraktion = Play-In

Play-In

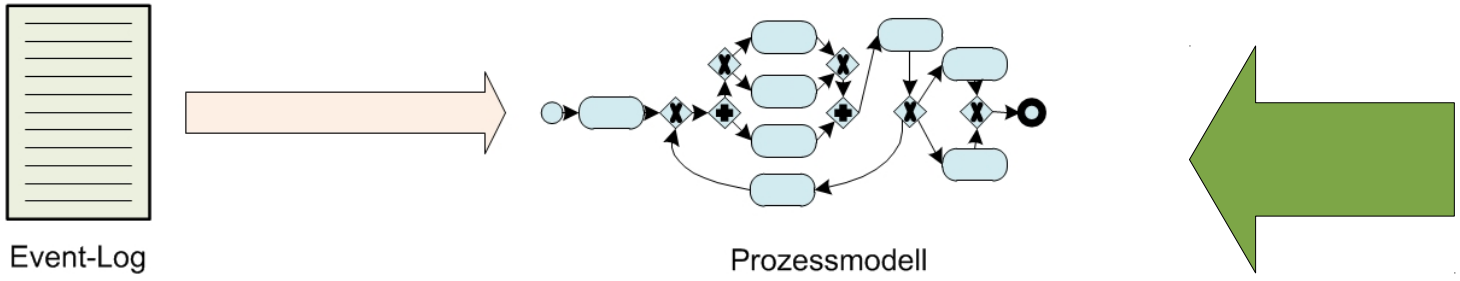

Play-Out

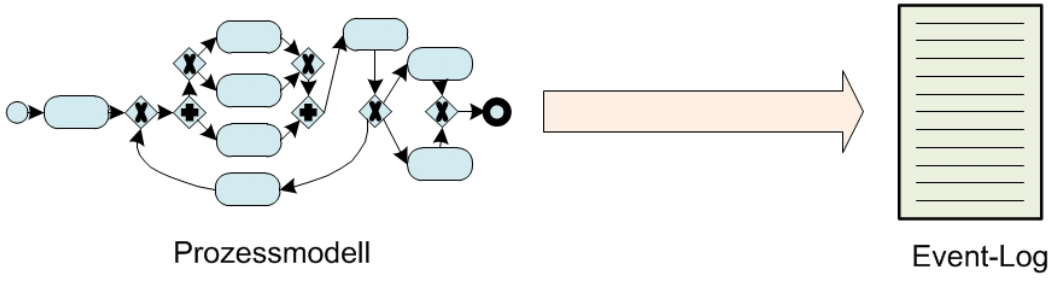

Replay

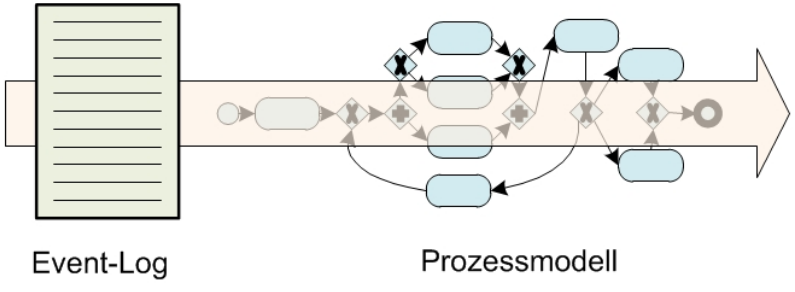

- Erweitertes Modell zeigt: Zeiten, Frequenzen, etc.
- Diagnosen
- Vorhersagen
- Empfehlungen

Prozessextraktion: Idee und Anforderungen

Idee: Umdrehen des traditionellen Ansatzes

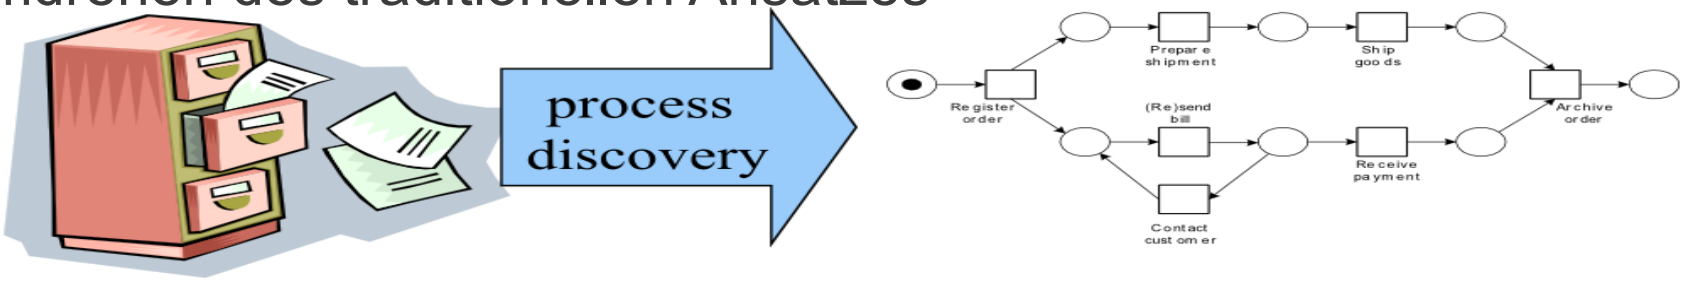

Ausgangspunkt: **Logfile** (= Folge von Log-Daten)

- **Minimal**: Nummer der GP-Instanz („case“ / Fall), GP-Aktivität, zeitliche Ordnung
- **Optional**: Genaue Zeit, Nutzer, assoziierte Daten etc.
- „**Rauschfrei**“: GP-Instanznr. erlaubt es, irrelevante Daten wegzufiltern.
- **Vollständig**: Alle relevante Daten für die verschiedenen GP-Instanzen sind vorhanden.

Ergebnis: Workflow-Modell als **Petri-Netz.**

Beispiel-Logfile

Die abgebildete Logdatei enthält folgende Folgen von Logdaten für die verschiedene GP-Instanzen (cases):

Log-Datei:

```
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
```

Beispiel-Logfile

Die abgebildete Logdatei enthält folgende Folgen von Logdaten für die verschiedene GP-Instanzen (cases):

- ABCD (case 1,

Log-Datei:

```
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
```

Beispiel-Logfile

Die abgebildete Logdatei enthält folgende Folgen von Logdaten für die verschiedene GP-Instanzen (cases):

- ABCD (case 1, case 3)
- ACBD (case 2, case 4)
- AED (case 5)

Zugehöriges Petri-Netz ?

Log-Datei:

```
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
```

- Abstrahiert von „cases“ (insbes. von mehreren gleichen Abläufen).
- (Relativ) „Minimal“: nicht einfach o.g. Folgen durch OR-Verzweigungen auflisten.

Beispiel-Logfile

Die abgebildete Logdatei enthält folgende Folgen von Logdaten für die verschiedene GP-Instanzen (cases):

- ABCD (case 1, case 3)
- ACBD (case 2, case 4)
- AED (case 5)

Zugehöriges Petri-Netz:

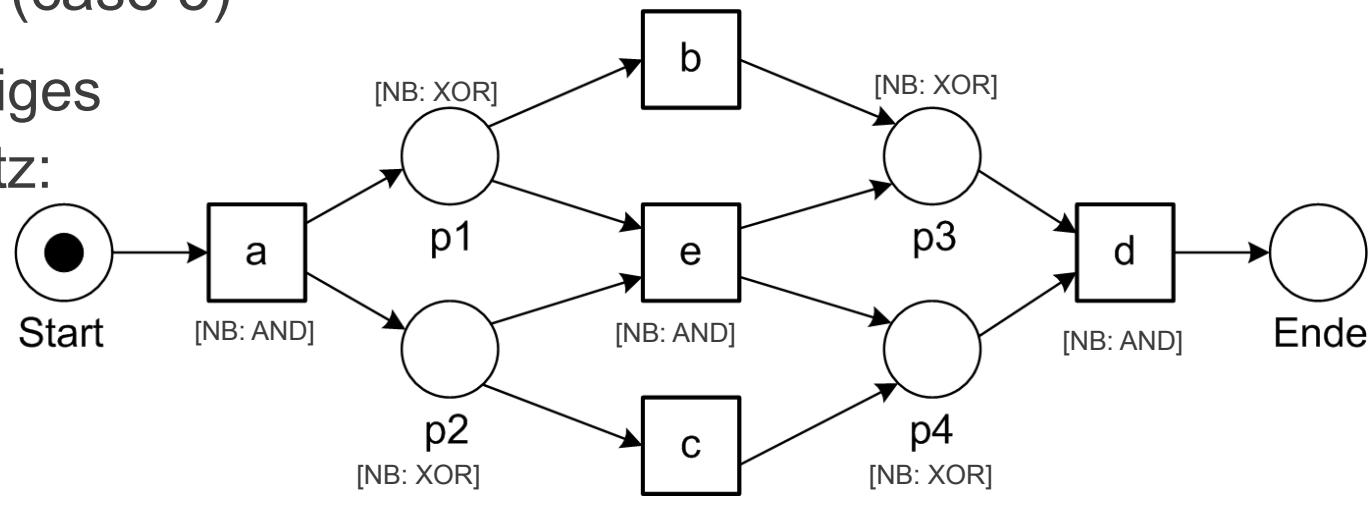

Log-Datei:

```
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
```

- Abstrahiert von „cases“ (insbes. von mehreren gleichen Abläufen).
- (Relativ) „Minimal“: nicht einfach o.g. Folgen durch OR-Verzweigungen auflisten.

Zugehöriges Petrinetz: Alternative Darstellungen

$$L_1 = [\langle a,b,c,d\rangle^3, \langle a,c,b,d\rangle^2, \langle a,e,d\rangle]$$

Obiger Event-Log ist in der Menge aller möglichen Modell-Ausführungen enthalten. Hier auch umgekehrt (d.h. Modell wird genau durch Event-Log charakterisiert); im Allgemeinen nicht (s. nächste Folie).

Superscript von Event-Folge: Häufigkeit des Auftretens.

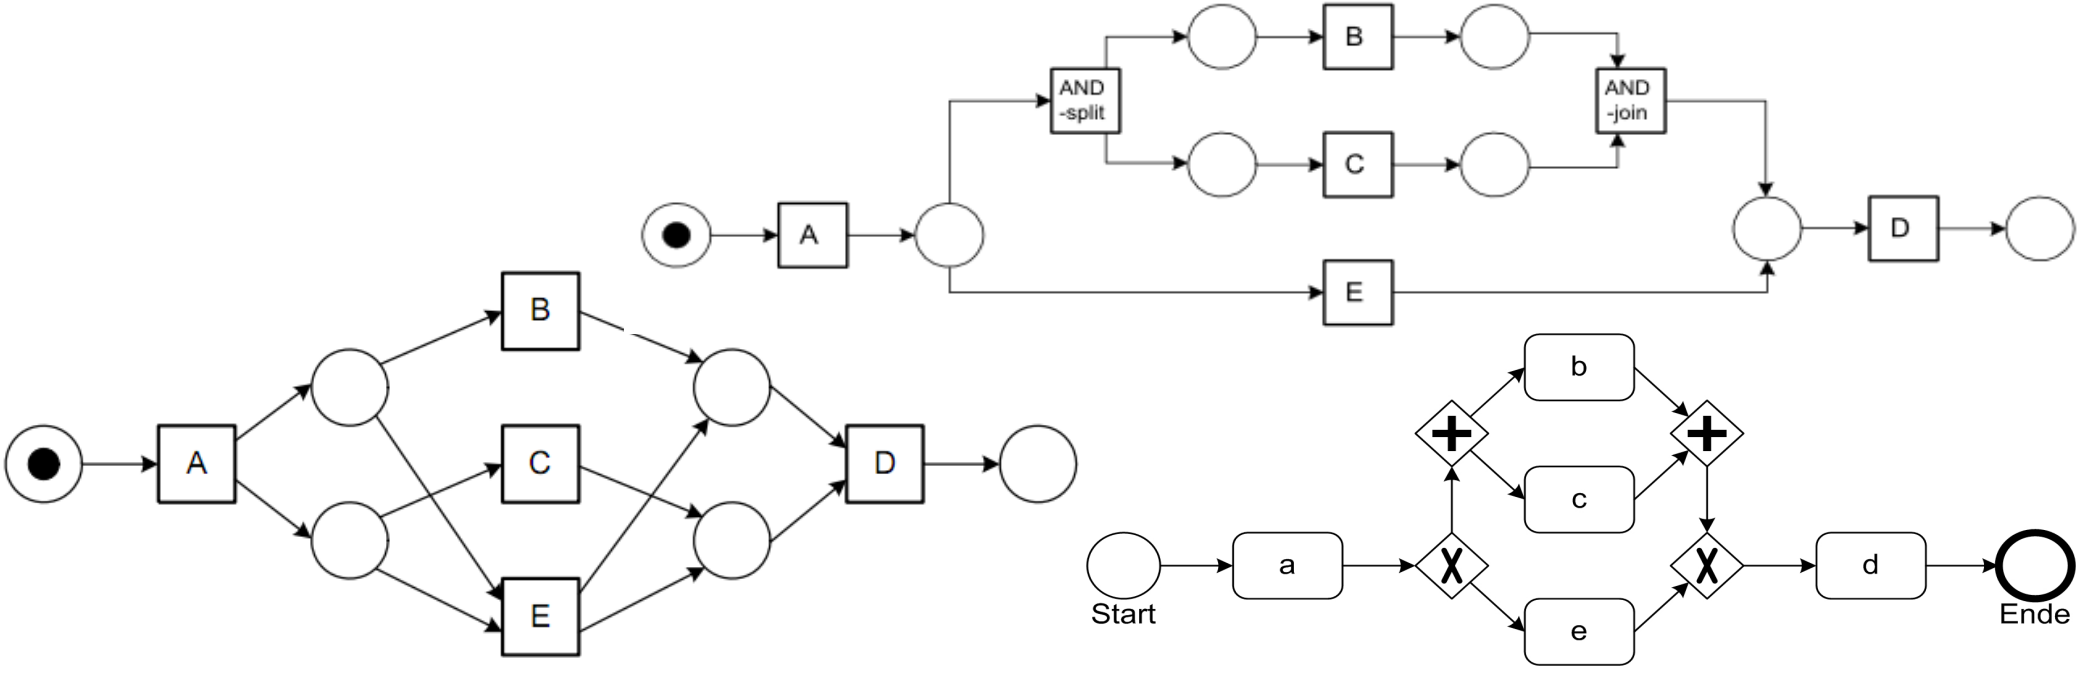

Weiteres Beispiel vs. BPMN

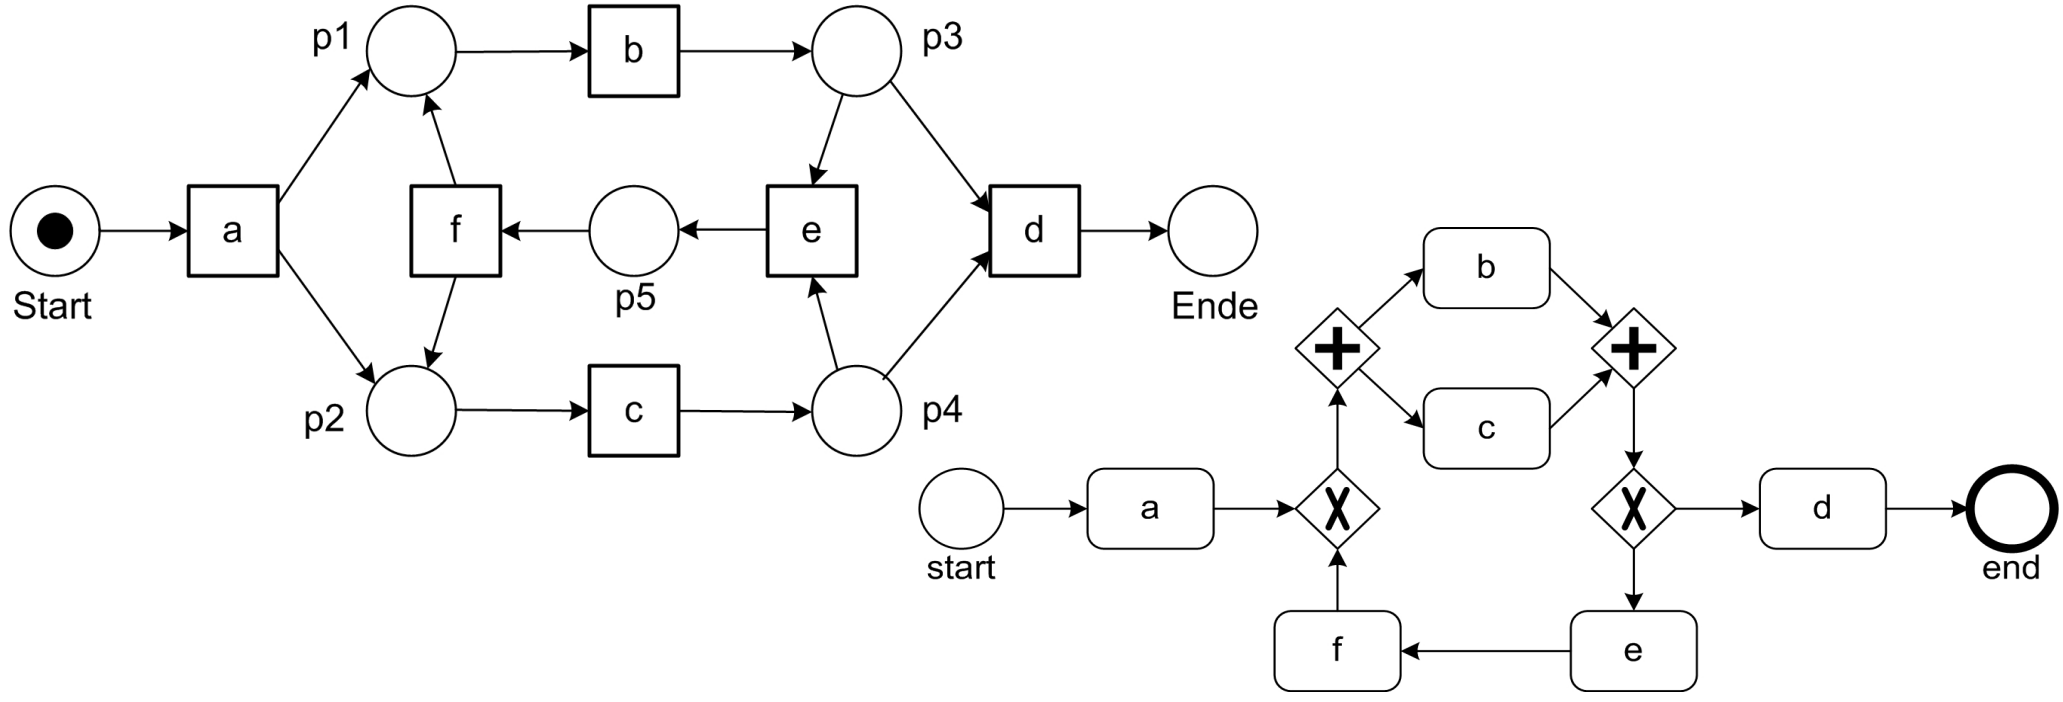

$$L_2 = [\langle a,b,c,d\rangle^3, \langle a,c,b,d\rangle^4, \langle a,b,c,e,f,b,c,d\rangle^2, \langle a,b,c,e,f,c,b,d\rangle,$$
$$\langle a,c,b,e,f,b,c,d\rangle^2, \langle a,c,b,e,f,b,c,e,f,c,b,d\rangle]$$

Hier: Event-Log enthält nur eine Teilmenge von allen möglichen Traces eines Modells, d.h. Modell ist eine Verallgemeinerung der Log-Daten, das weiteres Verhalten zulässt. (Welches z.B. ?)

Herausforderung

Trade-off zwischen Qualitätskriterien: **Entdecktes Modell soll** ...

- Angemessenheit (Fitness):
  ... Verhalten des Event-Logs zulassen.
- Genauigkeit (Precision) - vermeide Unteranpassung (underfitting):
  ... kein Verhalten ohne Bezug zu Inhalt des Event-Logs zulassen.
- Verallgemeinerung (Generalization) - vermeide Überanpassung (overfitting):
  … Verallgemeinerung des Beispiel-Verhaltens im Event-Log sein.
- Einfachheit (Simplicity):
  … so einfach wie möglich sein.

Überblick
2.5 Prozessextraktion

- Einführung und Beispiel
- α-Algorithmus
  - Idee und Vorbereitungen
  - Formalisierung
  - Beispiel
  - Weitere Beispiele
  - Einschränkungen
- Allgemeine Herausforderungen beim Process-Mining

α-Algorithmus: Idee

α-Algorithmus: aus Menge von Folgen von Log-Daten (zu gegebenem GP) GP-Modell als Petri-Netz extrahieren.

Idee:

- Benötigte Informationen über **Abfolge der Aktivitäten** (über die gegebene Menge von Folgen von Log-Daten hinweg) durch Verwendung geeigneter **Ordnungs-Relationen** sammeln.
- Auf Basis dieser Relationen Petri-Netz konstruieren.
- Betrifft insbesondere, ob Aktivitäten in verschiedenen Folgen (= verschiedenen Ausführungen des GPs) in **Kausal-Beziehung** stehen, oder **parallel** bzw. **unabhängig** voneinander sind.

Korrektheit des Algorithmus und benötigter Eigenschaft der Ordnungsrelationen nicht-trivial; wird hier nicht betrachtet.

α-Algorithmus: Annahmen

Annahmen an zu erzeugende Petri-Netze:

- Bei **Ausführung** erzeugt jede **Transition** jeweils ein **Ereignis** in der **Log-Datei**, mit derselben **Bezeichnung** wie im **Petrinetz**.
- Bezeichnungen der Transitionen unterschiedlich (immer der Fall in Petri-Netzen; erzwingt „Minimalität“).
- Keine Bogen-Vielfachheiten, Iterationen, Bedingungen an Verzweigungen.
- Verzweigungen nicht beobachtbar.

Annahmen an Folge von Log-Daten:

- Log-Daten alle vom relevanten GP erzeugt.
- GP durch Petrinetz modellierbar.
- Aufteilung der Log-Daten auf Folgen in gegebener Menge entsprechen verschiedenen GP-Instanzen.
- Abstrahieren von mehrfachen GP-Instanzen mit demselben Verlauf (und insbesondere von GP-Instanznummern).

Ordnungs-Relationen

Für eine Menge W von Folgen σ von Log-Daten (Folge entspricht einer GP-Instanz) und Elemente x,y in diesen Folgen (mit x≠y) definieren wir:

- **Direkte Nachfolge**: $\mathbf{x >_w y}$

  $\exists\ \sigma \in W$ worin y direkt auf x folgt
- **Kausalität**: $\mathbf{x \rightarrow_w y}$

  $x >_w y$ und nicht $y >_w x$
- **Parallelität**: $\mathbf{x \|_w y}$

  $x >_w y$ und $y >_w x$
- **Unabhängigkeit**: $\mathbf{x \#_w y}$

  nicht $x >_w y$ und nicht $y >_w x$

- Im Beispiel {ABCD, ACBD, AED}:

[Index W kann weggelassen werden, wenn klar ist, welche Log-Datei gemeint ist.]

Ordnungs-Relationen

Für eine Menge W von Folgen σ von Log-Daten (Folge entspricht einer GP-Instanz) und Elemente x,y in diesen Folgen (mit x≠y) definieren wir:

- **Direkte Nachfolge**: $\mathbf{x >_w y}$

  $\exists\ \sigma \in W$ worin y direkt auf x folgt
- **Kausalität**: $\mathbf{x \rightarrow_w y}$

  $x >_w y$ und nicht $y >_w x$
- **Parallelität**: $\mathbf{x \|_w y}$

  $x >_w y$ und $y >_w x$
- **Unabhängigkeit**: $\mathbf{x \#_w y}$

  nicht $x >_w y$ und nicht $y >_w x$

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

[Index W kann weggelassen werden, wenn klar ist, welche Log-Datei gemeint ist.]

Ordnungs-Relationen

Für eine Menge W von Folgen σ von Log-Daten (Folge entspricht einer GP-Instanz) und Elemente x,y in diesen Folgen (mit x≠y) definieren wir:

- **Direkte Nachfolge**: $\mathbf{x >_w y}$

  $\exists\ \sigma \in W$ worin y direkt auf x folgt
- **Kausalität**: $\mathbf{x \rightarrow_w y}$

  $x >_w y$ und nicht $y >_w x$
- **Parallelität**: $\mathbf{x \|_w y}$

  $x >_w y$ und $y >_w x$
- **Unabhängigkeit**: $\mathbf{x \#_w y}$

  nicht $x >_w y$ und nicht $y >_w x$

- 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

[Index W kann weggelassen werden, wenn klar ist, welche Log-Datei gemeint ist.]

Ordnungs-Relationen

Für eine Menge W von Folgen σ von Log-Daten (Folge entspricht einer GP-Instanz) und Elemente x,y in diesen Folgen (mit x≠y) definieren wir:

- **Direkte Nachfolge**: $\mathbf{x >_w y}$

  $\exists\ \sigma \in W$ worin y direkt auf x folgt
- **Kausalität**: $\mathbf{x \rightarrow_w y}$

  $x >_w y$ und nicht $y >_w x$
- **Parallelität**: $\mathbf{x \|_w y}$

  $x >_w y$ und $y >_w x$
- **Unabhängigkeit**: $\mathbf{x \#_w y}$

  nicht $x >_w y$ und nicht $y >_w x$

- 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 (und symm.)

[Index W kann weggelassen werden, wenn klar ist, welche Log-Datei gemeint ist.]

Ordnungs-Relationen

Für eine Menge W von Folgen σ von Log-Daten (Folge entspricht einer GP-Instanz) und Elemente x,y in diesen Folgen (mit x≠y) definieren wir:

- **Direkte Nachfolge**: $\mathbf{x >_w y}$

  $\exists\ \sigma \in W$ worin y direkt auf x folgt
- **Kausalität**: $\mathbf{x \rightarrow_w y}$

  $x >_w y$ und nicht $y >_w x$
- **Parallelität**: $\mathbf{x \|_w y}$

  $x >_w y$ und $y >_w x$
- **Unabhängigkeit**: $\mathbf{x \#_w y}$

  nicht $x >_w y$ und nicht $y >_w x$

- 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 (und symm.)
- A#D, B#E, C#E (und symm.)

[Index W kann weggelassen werden, wenn klar ist, welche Log-Datei gemeint ist.]

Anmerkungen

I) **Kausalität**, **Parallelität** und **Unabhängigkeit** definieren die vier Möglichkeiten, wie zwei Elemente durch > in Relation stehen können.

II) **Korrektheit** des α-Algorithmus beruht darauf, dass unter gegebenen Annahmen an die Log-Daten und das Petri-Netz...

1) ... die Folgen von Log-Daten sich durch die oben definierten Ordnungs-Relationen **charakterisieren** lassen (ggf. inkl. Verallgemeinerung).
2) … aus den Ordnungs-Relationen ein („minimales“) **Petri-Netz abgeleitet** werden kann, sodass die von dem Petri-Netz zur Laufzeit gefeuerten Folgen von Transitionen die ursprünglich gegebenen Folgen von Log-Daten enthalten (evt. auch andere !).

(Verzichten hier auf (nicht-trivialen) Beweis.)

Patterns für Erzeugung eines Petri-Netzes: Kausalität

(Wie) kann aus diesen Relationen nun ein Petri-Netz abgeleitet werden, dass diese Aussagen bestätigt ?

Einfachster Fall: **Kausalität** $\mathbf{x} \rightarrow \mathbf{y}$ („sequence pattern“)
Welches („minimale“) (Teil-)Petri-Netz erzeugt bei Ausführung Folgen von Transitionen, die durch diese eine Relation charakterisiert sind ?

Patterns für Erzeugung eines Petri-Netzes: Kausalität

(Wie) kann aus diesen Relationen nun ein Petri-Netz abgeleitet werden, dass diese Aussagen bestätigt ?

Einfachster Fall: **Kausalität** **x** → **y** („sequence pattern“)
Welches („minimale“) (Teil-)Petri-Netz erzeugt bei Ausführung Folgen von Transitionen, die durch diese eine Relation charakterisiert sind ?

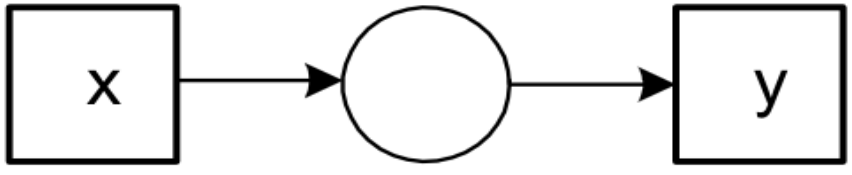

Patterns für Erzeugung eines Petri-Netzes (2)

Welches („minimale“) (Teil-)Petri-Netz erzeugt Folgen von Transitionen, die jeweils durch die folgenden Relationen charakterisiert sind ?

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

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

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

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

Patterns für Erzeugung eines Petri-Netzes (2)

Welches („minimale“) (Teil-)Petri-Netz erzeugt Folgen von Transitionen, die jeweils durch die folgenden Relationen charakterisiert sind ?

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

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

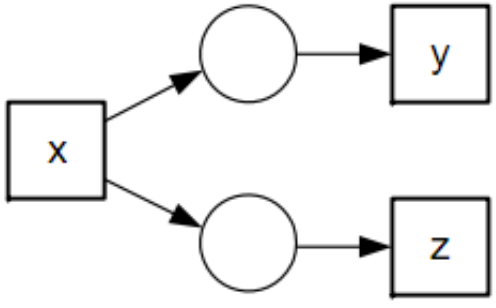

AND-split pattern

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

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

Patterns für Erzeugung eines Petri-Netzes (2)

Welches („minimale“) (Teil-)Petri-Netz erzeugt Folgen von Transitionen, die jeweils durch die folgenden Relationen charakterisiert sind ?

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

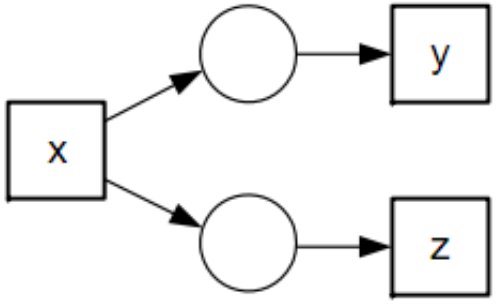

AND-split pattern

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

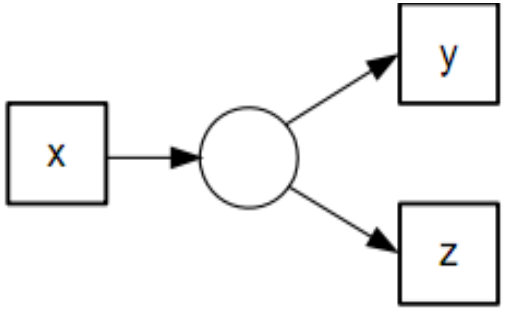

XOR-split pattern

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

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

Patterns für Erzeugung eines Petri-Netzes (2)

Welches („minimale“) (Teil-)Petri-Netz erzeugt Folgen von Transitionen, die jeweils durch die folgenden Relationen charakterisiert sind ?

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

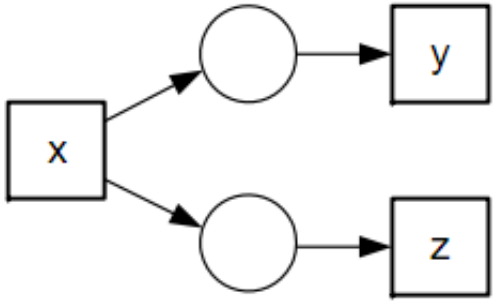

AND-split pattern

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

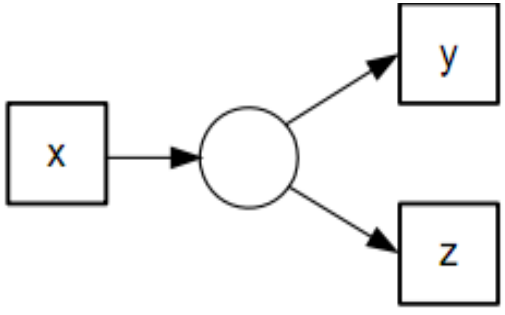

XOR-split pattern

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

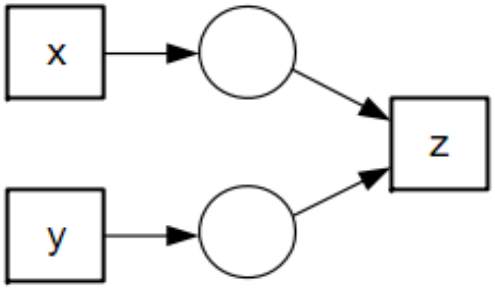

AND-join pattern

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

Patterns für Erzeugung eines Petri-Netzes (2)

Welches („minimale“) (Teil-)Petri-Netz erzeugt Folgen von Transitionen, die jeweils durch die folgenden Relationen charakterisiert sind ?

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

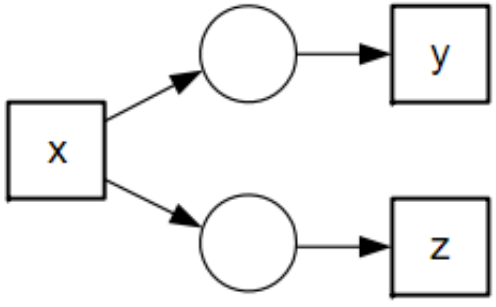

AND-split pattern

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

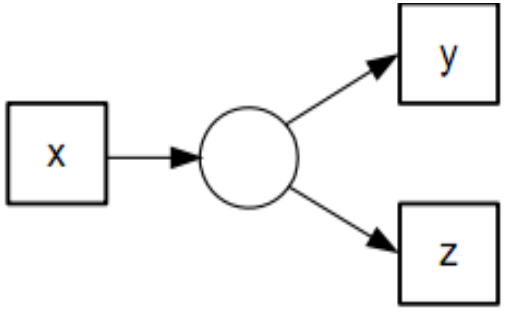

XOR-split pattern

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

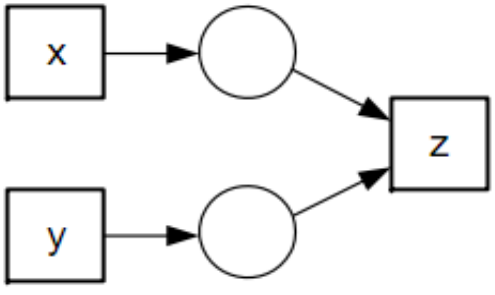

AND-join pattern

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

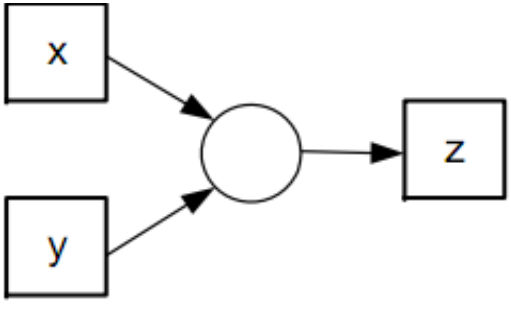

XOR-join pattern

Überblick: Patterns für Erzeugung eines Petri-Netzes

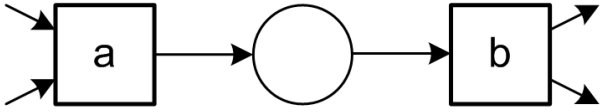

(a) sequence pattern: a→b

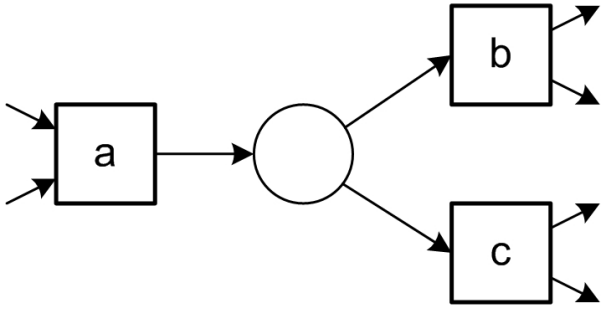

(b) XOR-split pattern:
a→b, a→c, and b#c

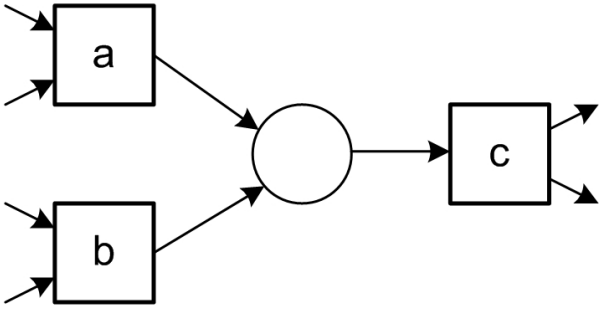

(c) XOR-join pattern:
a→c, b→c, and a#b

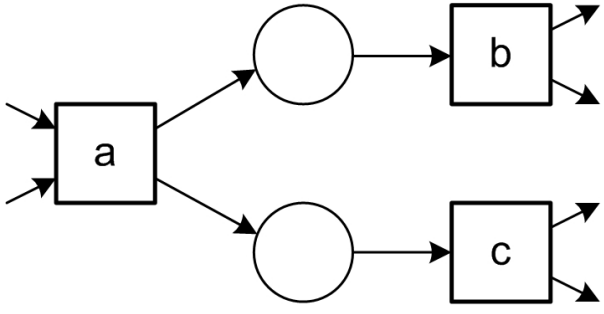

(d) AND-split pattern:
a→b, a→c, and b||c

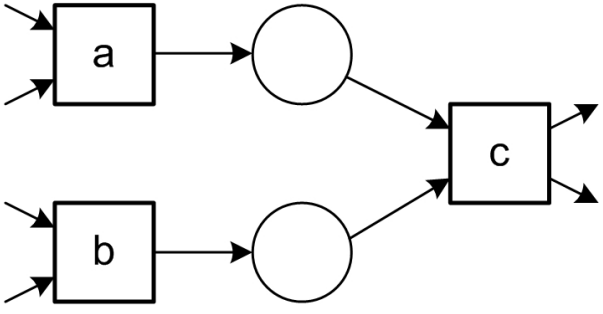

(e) AND-join pattern:
a→c, b→c, and a||b

Überblick
2.5 Prozessextraktion

- Einführung und Beispiel
- α-Algorithmus
  - Idee und Vorbereitungen
  - Formalisierung
  - Beispiel
  - Weitere Beispiele
  - Einschränkungen
- Allgemeine Herausforderungen beim Process-Mining

Der α-Algorithmus Schritt 1-3: Transitionen

Gegeben: **Workflow-Log** W = Menge von Folgen σ von Log-Daten (z.B. ABCD).

Gesucht: Workflow-Schema als **Petri-Netz**
$\alpha(W) = (\text{Stellen } P_W, \text{ Transitionen } T_W, \text{ Verbindungen } F_W)$

Schritte 1-3 (Transitionen)

Annahme (zur Erinnerung):

- Bei Ausführung erzeugt jede Transition jeweils ein Ereignis in der Log-Datei, mit derselben Bezeichnung wie im Petrinetz.

=> Wie demnach Menge der Transitionen im Petrinetz definieren ?

Der α-Algorithmus Schritt 1-3: Transitionen

Gegeben: **Workflow-Log** W = Menge von Folgen σ von Log-Daten (z.B. ABCD).

Gesucht: Workflow-Schema als **Petri-Netz**

α(W) = (Stellen P_W, Transitionen T_W, Verbindungen F_W)

Schritte 1-3 (Transitionen):

1. $T_W = \{t \in T \mid \exists_{\sigma \in W}\, t \in \sigma\}$ **Transitionen** (= Vereinigung der Transitionsmengen der Log-Daten)
2. $T_I = \{t \in T \mid \exists_{\sigma \in W}\, t = first(\sigma)\}$ **Start-Transitionen**
3. $T_O = \{t \in T \mid \exists_{\sigma \in W}\, t = last(\sigma)\}$ **End-Transitionen**

Der α-Algorithmus Schritt 4: Kandidaten für Stellen (Idee)

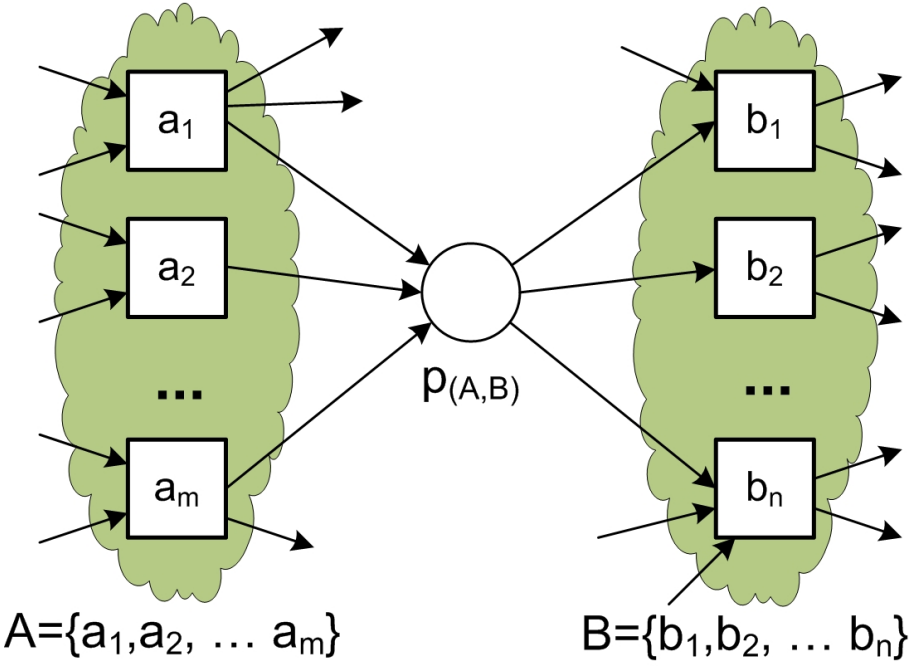

	a_1	a_2	…	a_m	b_1	b_2	…	b_n
a_1								
a_2								
…								
a_m								
b_1								
b_2								
…								
b_n								

Welche Relationen (wie vorher definiert) zwischen Transitionen $a_1,\ldots,a_m$, $b_1,\ldots,b_n$ würde man in dieser Situation in der Logdatei erwarten ?

Wie könnte man dann die Stelle $p_{(A,B)}$ aus der Logdatei ableiten ?

Der α-Algorithmus Schritt 4: Kandidaten für Stellen (Idee)

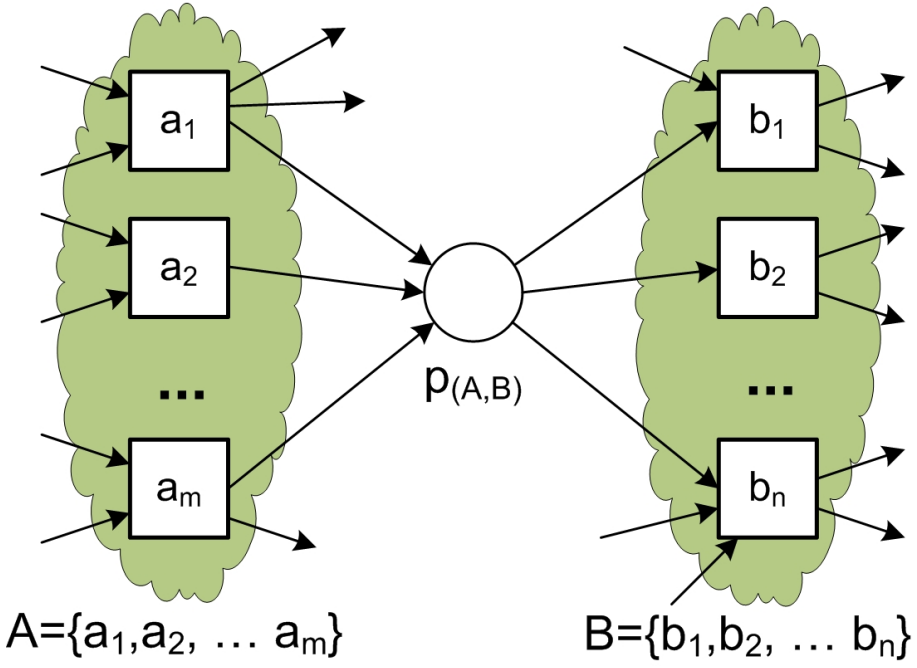

=> $p_{(A,B)}$=(A,B) Kandidat für **Stellen**, die Paare von **kausal aufeinander-folgenden Transitionen** verbinden (gleichzeitig möglich wegen Unabhängigkeit).

Via Transitionsmengen (A,B), weil Stelle nicht direkt in Logdaten beobachtbar.

Wie allgemein definieren ?

	a_1	a_2	...	a_m	b_1	b_2	...	b_n
a_1	#	#	...	#	→	→	...	→
a_2	#	#	...	#	→	→	...	→
...	...	...	...	...	...	...	...	...
a_m	#	#	...	#	→	→	...	→
b_1	←	←	...	←	#	#	...	#
b_2	←	←	...	←	#	#	...	#
...	...	...	...	...	...	...	...	...
b_n	←	←	...	←	#	#	...	#

Der α-Algorithmus Schritt 4: Kandidaten für Stellen

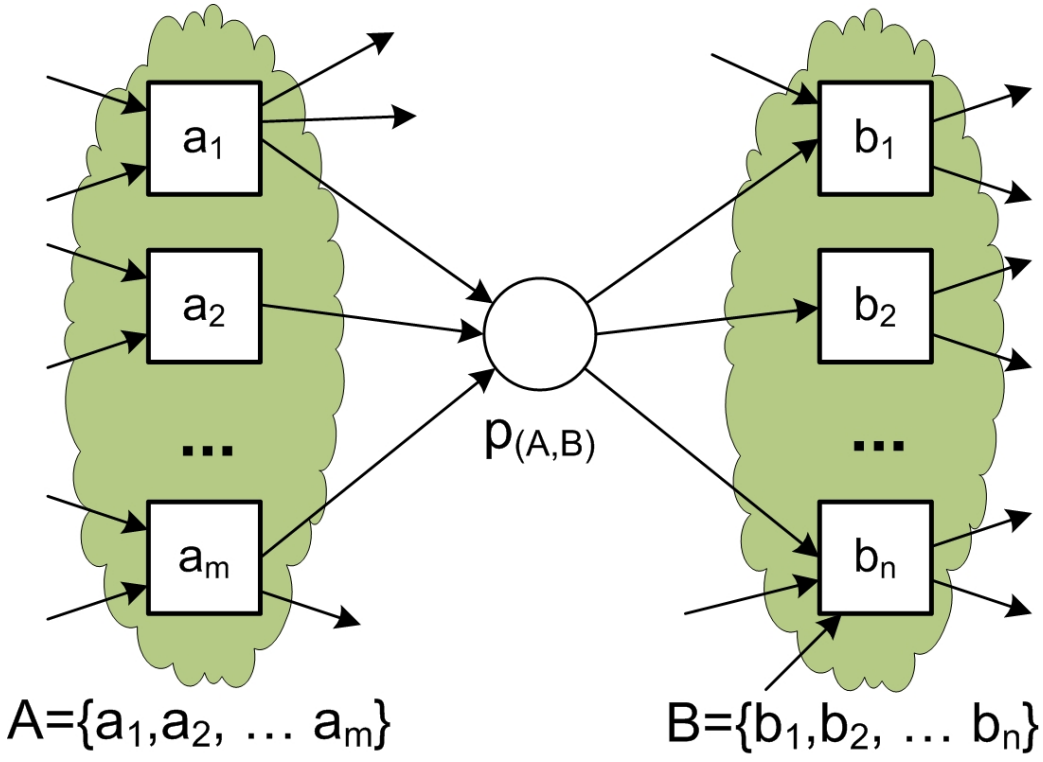

X_W: **„verallgemeinerte Kausalitätsrelationen“**:

Kandidaten für **Stellen**, um Paare von **kausal aufeinanderfolgenden Transitionen** zu verbinden.

Beispiele:

$(\{a\},\{b\}) \in X_W$ für alle $a \rightarrow b$

„Kandidaten“ weil teilweise noch gegenseitig redundant (Teilmengen (A',B') auch alle dabei).

Wie könnte man das reparieren ?.

$$4.\ X_W = \{ (A,B) \mid A \subseteq T_W \wedge A \neq \emptyset \wedge B \subseteq T_W \wedge B \neq \emptyset \wedge \forall_{a \in A} \forall_{b \in B}\ a \rightarrow_W b \wedge \forall_{a1,a2 \in A}\ a_1 \#_W a_2 \wedge \forall_{b1,b2 \in B}\ b_1 \#_W b_2 \}$$

Der α-Algorithmus Schritt 5-6: Stellen

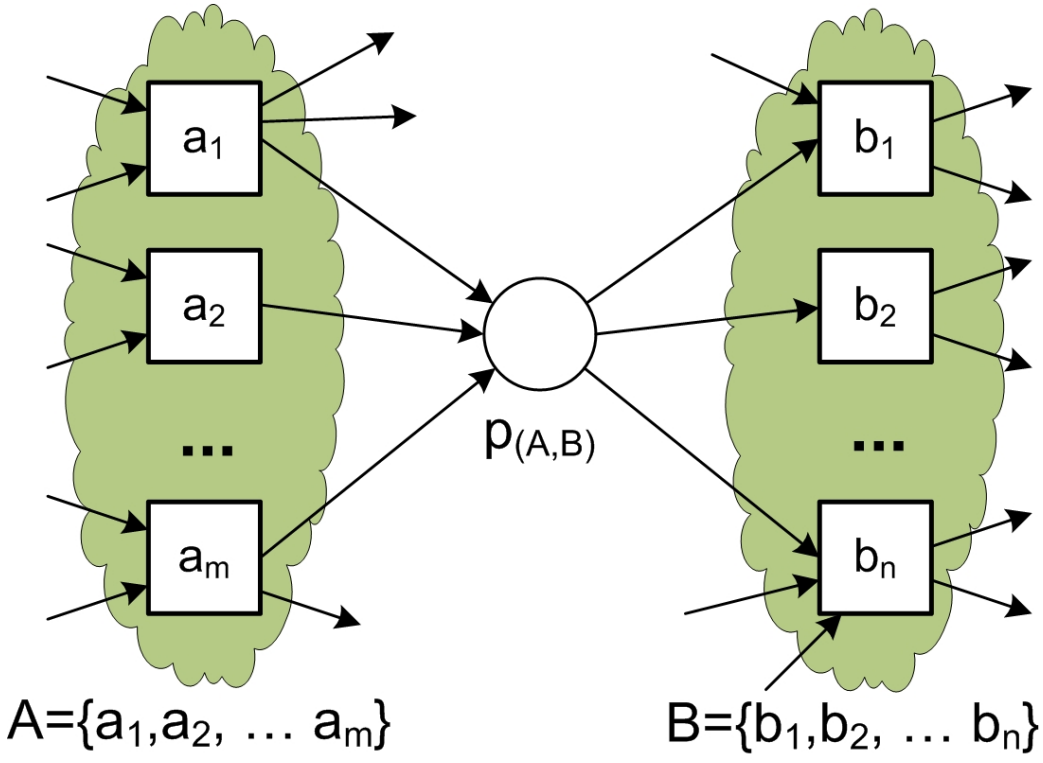

Y_W: **„Maximale Kausalitätsrelationen“.**

Bringen auch **Minimalität** des **Petri-Netzes:** minimale Anzahl von Stellen, die notwendig, um Paare von kausal aufeinander-folgenden Transitionen zu verbinden.

5. $Y_W = \{(A,B) \in X_W \mid \forall_{(A',B') \in X_W} A \subseteq A' \wedge B \subseteq B' \Rightarrow (A,B) = (A',B')\}$

6. $P_W = \{(p_{(A,B)}) \mid (A,B) \in Y_W\} \cup \{i_W, o_W\}$

Stellen: Jede maximale Kausalitätsrelation definiert genau eine Stelle.
Zusätzlich: i_W, o_W: eine Start- und eine Endstelle

Der α-Algorithmus: Abschluss

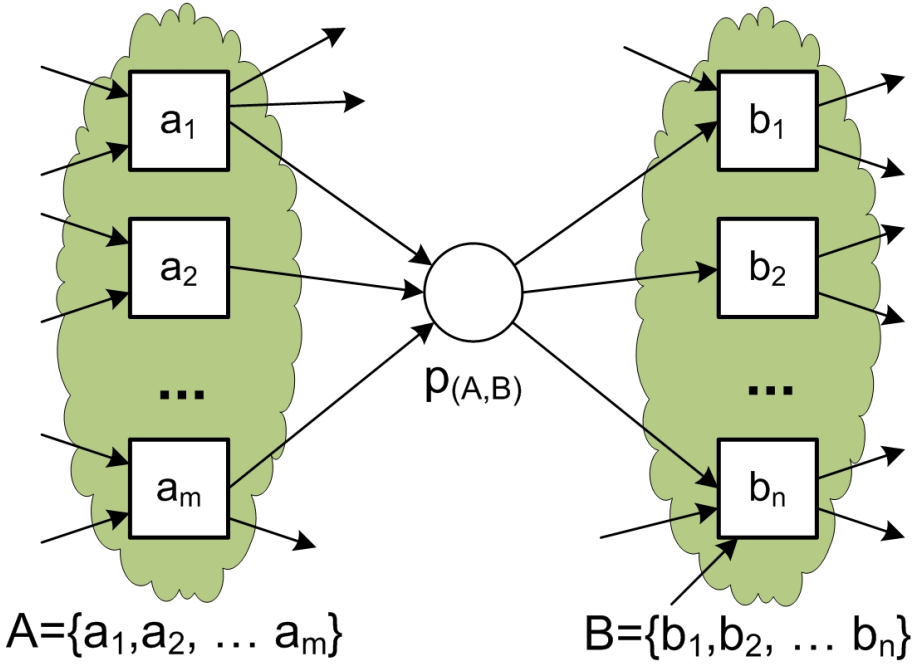

Haben Transitionen und Stellen.

Was fehlt noch für Petrinetz und wie könnte man das aus Logdatei ableiten ?

	a_1	a_2	…	a_m	b_1	b_2	…	b_n
a_1	#	#	…	#	→	→	…	→
a_2	#	#	…	#	→	→	…	→
…	…	…	…	…	…	…	…	…
a_m	#	#	…	#	→	→	…	→
b_1	←	←	…	←	#	#	…	#
b_2	←	←	…	←	#	#	…	#
…	…	…	…	…	…	…	…	…
b_n	←	←	…	←	#	#	…	#

Der α-Algorithmus Schritt 7-8: Stellen und Verbindungen

7. $F_W = \{(a, p_{(A,B)}) | (A,B) \in Y_W \wedge a \in A\} \cup$
$\{p_{(A,B)}, b | (A,B) \in Y_W \wedge b \in B\} \cup$
$\{(i_W, t) | t \in T_I\} \cup$
$\{(t, o_W) | t \in T_O\}$

Verbindungen: Die durch die Kausalitätsrelationen definierten Verbindungen.
Zusätzlich Verbindungen zwischen Start- bzw. Endstellen und Start- bzw. Endtransitionen.

8. $\alpha(W) = (P_W, T_W, F_W)$ Resultierendes **Petri-Netz**.

.

α-Algorithmus: Diskussion

Frage:

Wie würde man zeigen, dass der Algorithmus **korrekt** ist ?

α-Algorithmus: Diskussion

Frage:

Wie würde man zeigen, dass der Algorithmus **korrekt** ist ?

Antwort:

Zu zeigen wäre, dass das erhaltene Petrinetz bei Ausführung die ursprüngliche Folgen von Logdaten ausgibt.

Gilt i.A. nur unter o.g. Annahmen (z.B. dass Logdaten tatsächlich von einem Petrinetz generiert wurden).

Das Petrinetz kann im Allgemeinen noch andere Folgen von Logdaten ausgeben !

Überblick
2.5 Prozessextraktion

- Einführung und Beispiel
- α-Algorithmus
  - Idee und Vorbereitungen
  - Formalisierung
  - Beispiel
  - Weitere Beispiele
  - Einschränkungen
- Allgemeine Herausforderungen beim Process-Mining

α-Algorithmus – Beispiel

1. $T_W = \{$

Ursprungs-Log:
{ABCD, ACBD, AED}

$$T_W = \{ t \in T \mid \exists_{\sigma \in W} t \in \sigma \}$$

Extrahiere alle Transitionen aus dem Log

α-Algorithmus – Beispiel

1. T_W = {A,B,C,D

Ursprungs-Log:
{ABCD, ACBD, AED}

$$T_W = \{t \in T \mid \exists_{\sigma \in W}\, t \in \sigma\}$$

Extrahiere alle Transitionen aus dem Log

α-Algorithmus – Beispiel

1. $T_W = \{A,B,C,D,E\}$

Ursprungs-Log:
{ABCD, ACBD, AED}

$$T_W = \{t \in T \mid \exists_{\sigma \in W}\, t \in \sigma\}$$

Extrahiere alle Transitionen aus dem Log

α-Algorithmus – Beispiel

1. $T_W = \{A,B,C,D,E\}$
2. $T_I = \{$

Ursprungs-Log:
{ABCD, ACBD, AED}

$$T_I = \{ t \in T \mid \exists_{\sigma \in W}\, t = first(\sigma) \}$$

Sammle Starttransitionen aus den einzelnen Logs

α-Algorithmus – Beispiel

1. $T_W = \{A,B,C,D,E\}$
2. $T_I = \{A\}$

Ursprungs-Log:
{ABCD, ACBD, AED}

$$T_I = \{t \in T \mid \exists_{\sigma \in W}\, t = first(\sigma)\}$$

Sammle Starttransitionen aus den einzelnen Logs

α-Algorithmus – Beispiel

1. $T_W = \{A,B,C,D,E\}$
2. $T_I = \{A\}$
3. $T_O = \{$

Ursprungs-Log:
{ABCD, ACBD, AED}

$T_I = \{t \in T \mid \exists_{\sigma \in W}\, t = last(\sigma)\}$
Sammle Endtransitionen aus den einzelnen Logs

α-Algorithmus – Beispiel

1. $T_W = \{A,B,C,D,E\}$
2. $T_I = \{A\}$
3. $T_O = \{D\}$

Ursprungs-Log:
{ABCD, ACBD, AED}

$T_I = \{t \in T \mid \exists_{\sigma \in W}\, t = last(\sigma)\}$
Sammle Endtransitionen aus den einzelnen Logs

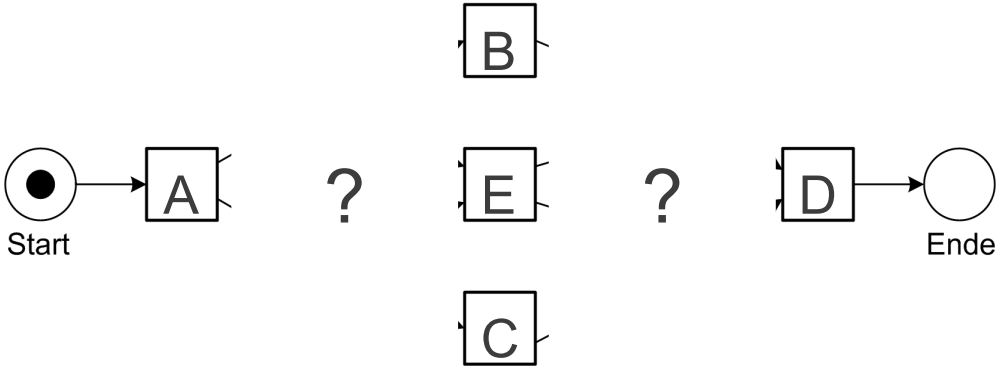

α-Algorithmus – Beispiel

1. T_W =
2. T_I = {
3. T_O =

Bilde Kandidaten für Stellen.

Ursprungs-Log: {ABCD, ACBD, AED}

4. X_W = {

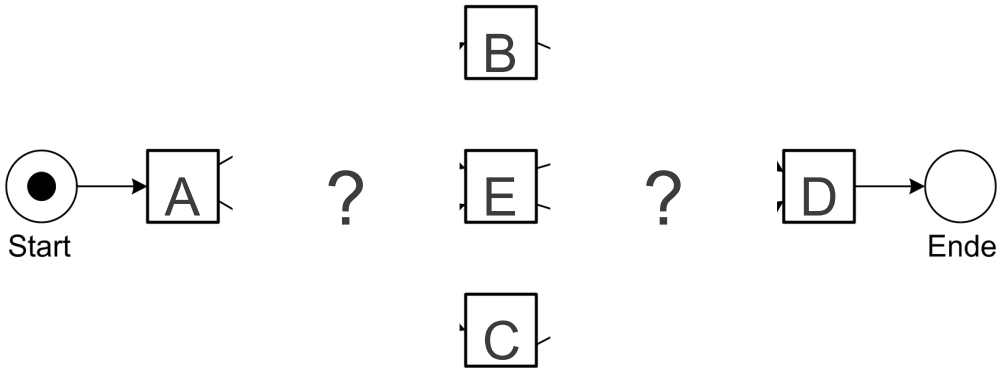

$$X_W = \{(A, B) \mid A \subseteq T_W \wedge B \subseteq T_W \wedge \forall_{a \in A} \forall_{b \in B}\, a \rightarrow_W b \wedge \forall_{a_1, a_2 \in A}\, a_1 \#_W a_2 \wedge \forall_{b_1, b_2 \in B}\, b_1 \#_W b_2\}$$

NB:

A: Event / Transition

A: Menge von Events / Transitionen

α-Algorithmus – Beispiel

Bilde Kandidaten für Stellen:
Bilde Teilmengen mit unabhängigen Elementen als Kandidaten für Mengen ***A*** und ***B***

Ursprungs-Log:
{ABCD, ACBD, AED}

4. X_W = {

a>b	a→b	b‖c	b#e
a>c	a→c	c‖b	e#b
a>e	a→e		c#e
b>c	b→d		a#d
b>d	c→d		…
c>b	e→d		
c>d			
e>d			

$$X_W = \{(A,B) \mid A \subseteq T_W \wedge B \subseteq T_W \wedge \forall_{a \in A} \forall_{b \in B} a \rightarrow_W b \wedge \boxed{\forall_{a_1, a_2 \in A} a_1 \#_W a_2 \wedge \forall_{b_1, b_2 \in B} b_1 \#_W b_2}\}$$

α-Algorithmus – Beispiel

Bilde Kandidaten für Stellen:
Bilde Teilmengen mit unabhängigen Elementen als Kandidaten für Mengen ***A*** und ***B***
{A},{A,D}

Ursprungs-Log:
{ABCD, ACBD, AED}

Alle andere Transitionen abhängig von A, bis auf D

3. $T_O = \{D\}$

4. $X_W = \{$

a>b	a→b	b‖c	b#e
a>c	a→c	c‖b	e#b
a>e	a→e		c#e
b>c	b→d		a#d
b>d	c→d		…
c>b	e→d		
c>d			
e>d			

$$X_W = \{(A,B) \mid A \subseteq T_W \wedge B \subseteq T_W \wedge \forall_{a \in A} \forall_{b \in B} a \rightarrow_W b \wedge \forall_{a_1, a_2 \in A} a_1 \#_W a_2 \wedge \forall_{b_1, b_2 \in B} b_1 \#_W b_2\}$$

α-Algorithmus – Beispiel

Bilde Kandidaten für Stellen:
Bilde Teilmengen mit unabhängigen Elementen als Kandidaten für Mengen ***A*** und ***B***
{A},{A,D},{B},{B,E}

Ursprungs-Log:
{ABCD, ACBD, AED}

A,C,D abhängig von B
E unabhängig

3. $T_O = \{D\}$

4. $X_W = \{$

a>b	a→b	b||c	b#e
a>c	a→c	c||b	e#b
a>e	a→e		c#e
b>c	b→d		a#d
b>d	c→d		…
c>b	e→d		
c>d			
e>d			

$$X_W = \{(A,B) \mid A \subseteq T_W \wedge B \subseteq T_W \wedge \forall_{a \in A} \forall_{b \in B} a \rightarrow_W b \wedge \forall_{a_1, a_2 \in A} a_1 \#_W a_2 \wedge \forall_{b_1, b_2 \in B} b_1 \#_W b_2\}$$

α-Algorithmus – Beispiel

Bilde Kandidaten für Stellen:
Bilde Teilmengen mit unabhängigen Elementen als Kandidaten für Mengen ***A*** und ***B***
{A},{A,D},{B},{B,E},{C},{C,E},{D},{E}

Ursprungs-Log:
{ABCD, ACBD, AED}

3. T_O = {D}

4.

a>b	a→b	b‖c	b#e
a>c	a→c	c‖b	e#b
a>e	a→e		c#e
b>c	b→d		a#d
b>d	c→d		…
c>b	e→d		
c>d			
e>d			

{A,D} nicht relevant obwohl unabhängig, weil kein gemeinsamer Vorgänger / Nachfolger

$$X_W = \{(A,B) \mid A \subseteq T_W \wedge B \subseteq T_W \wedge \forall_{a \in A} \forall_{b \in B} a \rightarrow_W b \wedge \forall_{a_1, a_2 \in A} a_1 \#_W a_2 \wedge \forall_{b_1, b_2 \in B} b_1 \#_W b_2\}$$

α-Algorithmus – Beispiel

Bilde Kandidaten für Stellen:
Bilde Paare (***A***,***B***), sodass Menge ***A*** nur kausale Vorgänger der Elemente in Menge ***B*** enthält:
{A},{A,D},{B},{B, E},{C},{C,E},{D},{E}

Ursprungs-Log:
{ABCD, ACBD, AED}

3. $T_O = \{D\}$

4. $X_W = \{(\{A\}, \{B\}), (\{A\}, \{C\}), (\{A\}, \{E\}), (\{A\}, \{B, E\}), (\{A\}, \{C, E\}),$

$$X_W = \{(A,B) \mid A \subseteq T_W \wedge B \subseteq T_W \wedge \boxed{\forall_{a \in A} \forall_{b \in B}\, a \rightarrow_W b} \wedge \forall_{a_1, a_2 \in A}\, a_1 \#_W a_2 \wedge \forall_{b_1, b_2 \in B}\, b_1 \#_W b_2\}$$

a>b	a→b	b‖c	b#e
a>c	a→c	c‖b	e#b
a>e	a→e		c#e
b>c	b→d		a#d
b>d	c→d		…
c>b	e→d		
c>d			
e>d			

α-Algorithmus – Beispiel

Bilde Kandidaten für Stellen:
Bilde Paare (***A***,***B***), sodass Menge ***A*** nur kausale Vorgänger der Elemente in Menge ***B*** enthält:
{A},{A,D},{B},{B, E},{C},{C,E},{D}

Ursprungs-Log:
{ABCD, ACBD, AED}

{C} nicht wegen BC und CB: Abfolge nicht eindeutig

3. $T_O = \{D\}$

4. $X_W = \{(\{A\}, \{B\}), (\{A\}, \{C\}), (\{A\}, \{E\}), (\{B\}, \{D\}),$
$(\{A\}, \{B, E\}), (\{A\}, \{C, E\}),$

$$X_W = \{(A,B) \mid A \subseteq T_W \wedge B \subseteq T_W \wedge \boxed{\forall_{a \in A} \forall_{b \in B}\, a \rightarrow_W b} \wedge \forall_{a_1, a_2 \in A}\, a_1 \#_W a_2 \wedge \forall_{b_1, b_2 \in B}\, b_1 \#_W b_2\}$$

a>b	a→b	b‖c	b#e
a>c	a→c	c‖b	e#b
a>e	a→e		c#e
b>c	b→d		a#d
b>d	c→d		…
c>b	e→d		
c>d			
e>d			

α-Algorithmus – Beispiel

X_W : Kandidaten für Stellen.

Ursprungs-Log:
{ABCD, ACBD, AED}

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}) }

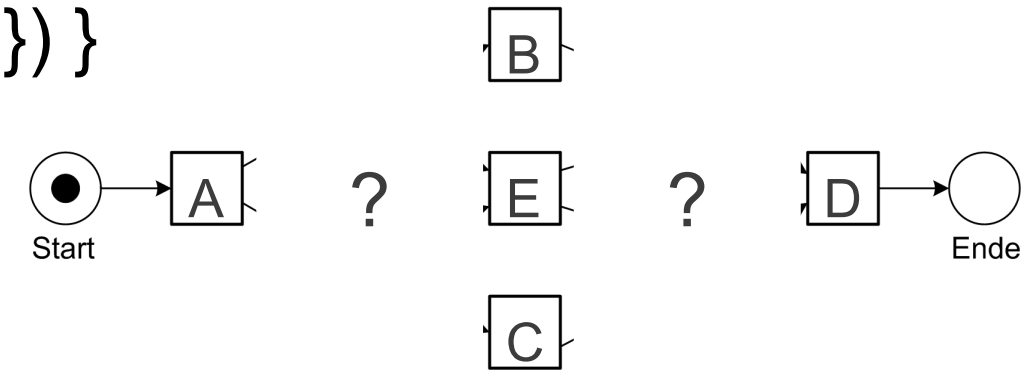

$$X_W = \{(A,B) \mid A \subseteq T_W \wedge B \subseteq T_W \wedge \forall_{a \in A} \forall_{b \in B}\, a \rightarrow_W b \wedge \forall_{a_1, a_2 \in A}\, a_1 \#_W a_2 \wedge \forall_{b_1, b_2 \in B}\, b_1 \#_W b_2\}$$

α-Algorithmus – Beispiel

Ursprungs-Log:
{ABCD, ACBD, AED}

1. T_W = {A,B,C,D,E}

2. T_I = {A}

$$Y_W = \{(A,B) \in X_W \mid \forall_{(A',B') \in X_W} A \subseteq A' \wedge B \subseteq B' \Rightarrow (A,B) = (A',B')\}$$

Entferne alle Paare (*A*,*B*) aus X_W, die Teilmenge eines anderen Paares sind.

3. T_O =

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 = {

α-Algorithmus – Beispiel

Ursprungs-Log:
{ABCD, ACBD, AED}

1. T_W = {A,B,C,D,E}

2. T_I = {A}

$$Y_W = \{(A,B) \in X_W \mid \forall_{(A',B') \in X_W} A \subseteq A' \wedge B \subseteq B' \Rightarrow (A,B) = (A',B')\}$$

Entferne alle Paare (*A*,*B*) aus X_W, die Teilmenge eines anderen Paares sind.

3. T_O =

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}),

α-Algorithmus – Beispiel

Ursprungs-Log:
{ABCD, ACBD, AED}

1. T_W = {A,B,C,D,E}

2. T_I = {A}

$$Y_W = \{(A,B) \in X_W \mid \forall_{(A',B') \in X_W} A \subseteq A' \wedge B \subseteq B' \Rightarrow (A,B) = (A',B')\}$$

Entferne alle Paare (*A*,*B*) aus X_W, die Teilmenge eines anderen Paares sind.

3. T_O =

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})}

α-Algorithmus – Beispiel

Ursprungs-Log:
{ABCD, ACBD, AED}

1. T_W = {A,B,C,D,E}

2. T_I = {A}

$$Y_W = \{(A,B) \in X_W \mid \forall_{(A',B') \in X_W} A \subseteq A' \wedge B \subseteq B' \Rightarrow (A,B) = (A',B')\}$$

Entferne alle Paare (*A*,*B*) aus X_W, die Teilmenge eines anderen Paares sind.

3. T_O =

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})}

α-Algorithmus – Beispiel

5. Y_W = {({A}, {B, E}), ({A}, {C, E}), ({B, E}, {D}), ({C, E},{D})}

6. P_W = {

$P_W = \{(p_{(A,B)}) \mid (A,B) \in Y_W\} \cup \{i_W, o_W\}$

Füge für jedes Paar (A,B) eine Stelle, sowie eine Start- und Endstelle ein.

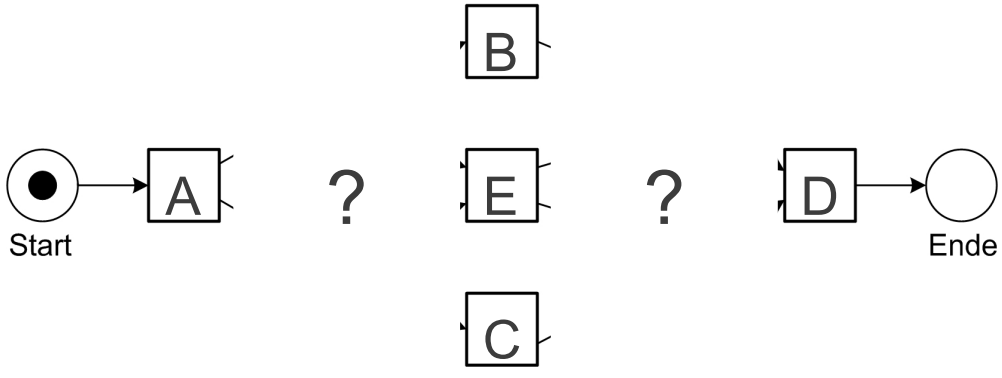

α-Algorithmus – Beispiel

5. Y_W = {({A}, {B, E}), ({A}, {C, E}), ({B, E}, {D}), ({C, E},{D})}

6. P_W = {i_W, o_W,

$P_W = \{(p_{(A,B)}) \mid (A,B) \in Y_W\} \cup \boxed{\{i_W, o_W\}}$

Füge für jedes Paar (*A*,*B*) eine Stelle, sowie eine Start- und Endstelle ein.

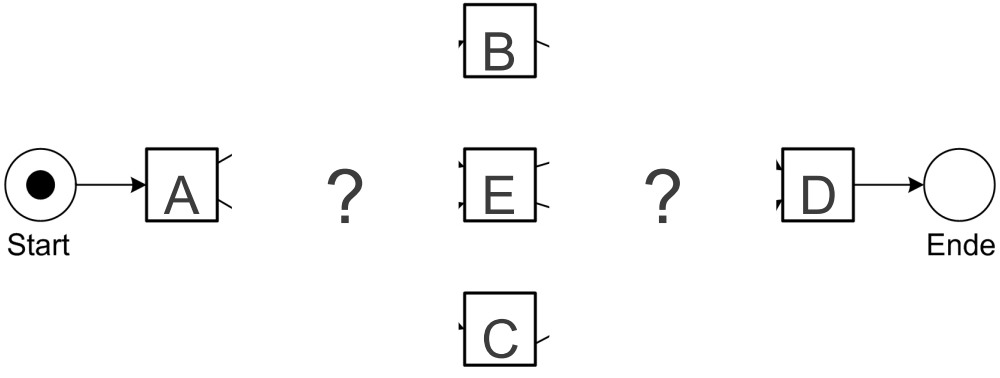

α-Algorithmus – Beispiel

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}),

$P_W = \{(p_{(A,B)}) \mid (A,B) \in Y_W\} \cup \{i_W, o_W\}$

Füge für jedes Paar (*A*,*B*) eine Stelle, sowie eine Start- und Endstelle ein.

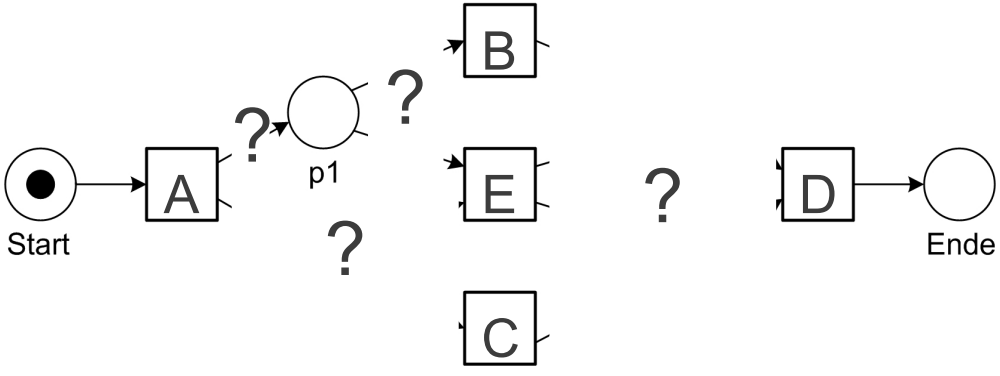

α-Algorithmus – Beispiel

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})},

$P_W = \{(p_{(A,B)}) \mid (A,B) \in Y_W\} \cup \{i_W, o_W\}$
Füge für jedes Paar (*A*,*B*) eine Stelle, sowie eine Start- und Endstelle ein.

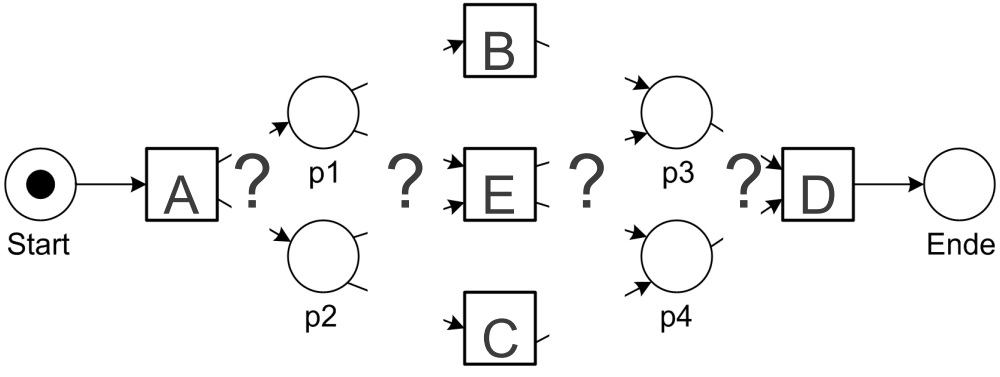

α-Algorithmus – Beispiel

1. $T_W = \{A,B,C,D,E\}$

2. $T_I = \{A\}$ 3. $T_O = \{D\}$

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. $F_W = \{$

$$F_W = \{(a, p_{(A,B)}) \mid (A,B) \in Y_W \wedge a \in A\} \cup \{p_{(A,B)}, b \mid (A,B) \in Y_W \wedge b \in B\} \cup \{(i_W, t) \mid t \in T_I\} \cup \{(t, o_W) \mid t \in T_O\}$$

Füge die zugehörigen Bögen ein.

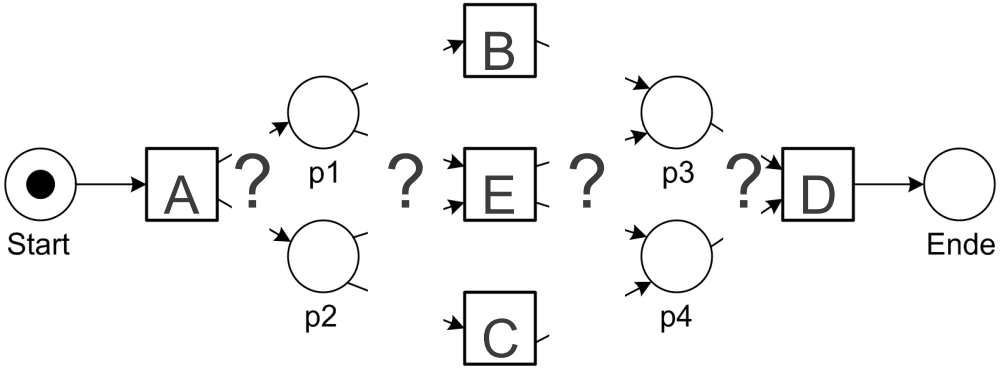

α-Algorithmus – Beispiel

1. $T_W = \{A,B,C,D,E\}$

$$F_W = \{(a, p_{(A,B)}) \mid (A,B) \in Y_W \wedge a \in A\} \cup \{p_{(A,B)}, b \mid (A,B) \in Y_W \wedge b \in B\} \cup \{(i_W, t) \mid t \in T_I\} \cup \{(t, o_W) \mid t \in T_O\}$$

Füge die zugehörigen Bögen ein
Verbinde Startstelle mit Starttransitionen
Verbinde Endstelle mit Starttransitionen

({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. $F_W = \{(i_W, A),$

$\ldots, (D, o_W)$

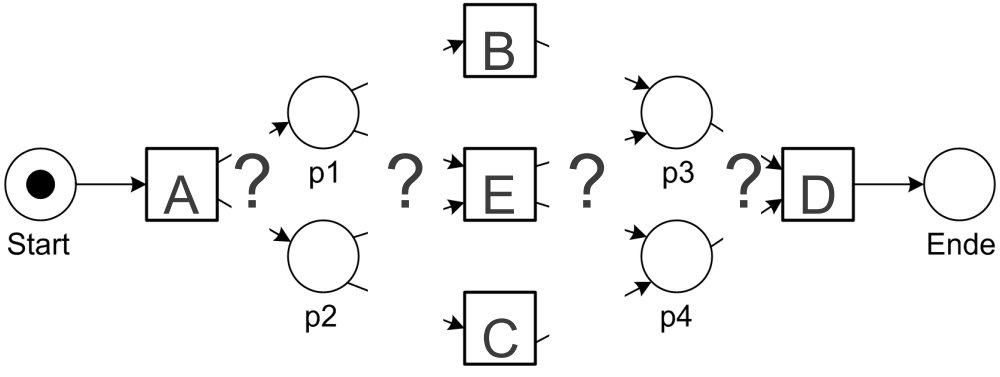

α-Algorithmus – Beispiel

1. $T_W = \{A,B,C,D,E\}$

2. $T_I = \{A\}$ 3. $T_O = \{D\}$

$$F_W = \{(a, p_{(A,B)}) \mid (A,B) \in Y_W \wedge a \in A\} \cup \{p_{(A,B)}, b \mid (A,B) \in Y_W \wedge b \in B\} \cup \{(i_W, t) \mid t \in T_I\} \cup \{(t, o_W) \mid t \in T_O\}$$

Füge die zugehörigen Bögen ein:
Verbinde Elemente aus A eines Y_W – Tupels mit der zugehörigen Stelle

6. $P_W = \{i_W, o_W, p(\{A\},\{B,E\}), p(\{A\},\{C,E\}), p(\{B,E\},\{D\}), p(\{C,E\},\{D\})\}$,

7. $F_W = \{(i_W, A), (A, p(\{A\},\{B,E\}))$ ..., (D, o_W)

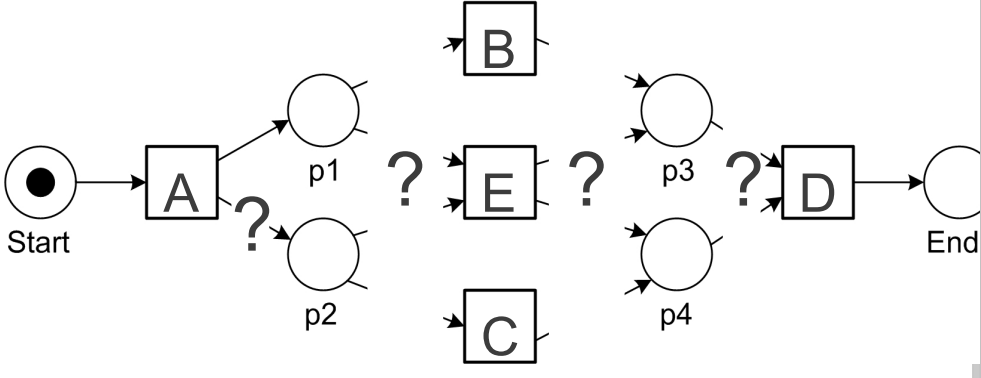

α-Algorithmus – Beispiel

1. $T_W = \{A,B,C,D,E\}$

2. $T_I = \{A\}$ 3. $T_O = \{D\}$

$F_W = \{(a, p_{(A,B)}) \mid (A,B) \in Y_W \wedge a \in A\} \cup$
$\{p_{(A,B)}, b \mid (A,B) \in Y_W \wedge b \in B\} \cup$
$\{(i_W, t) \mid t \in T_I\} \cup$
$\{(t, o_W) \mid t \in T_O\}$

Füge die zugehörigen Bögen ein:
Verbinde zugehörigen Stelle eines Y_W – Tupels mit den Elementen aus B

6. $P_W = \{i_W, o_W, p(\{A\},\{B,E\}), p(\{A\},\{C,E\}), p(\{B,E\},\{D\}), p(\{C,E\},\{D\})\}$,

7. $F_W = \{(i_W, A), (A, p(\{A\},\{B,E\})), (p(\{A\},\{B,E\}),B), \ldots, (D, o_W)$

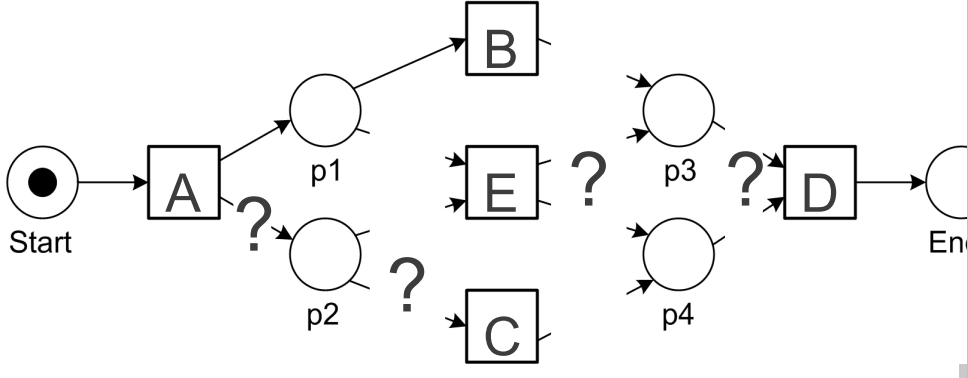

α-Algorithmus – Beispiel

$$F_W = \{(a, p_{(A,B)}) \mid (A,B) \in Y_W \wedge a \in A\} \cup \{p_{(A,B)}, b \mid (A,B) \in Y_W \wedge b \in B\} \cup \{(i_W, t) \mid t \in T_I\} \cup \{(t, o_W) \mid t \in T_O\}$$

1. $T_W = \{A,B,C,D,E\}$

2. $T_I = \{A\}$ 3. $T_O = \{D\}$

5. [illegible] E}), ({B, E}, {D}),

(

Füge die zugehörigen Bögen ein: Etc.

6. $P_W = \{i_W, o_W, p(\{A\},\{B,E\}), p(\{A\},\{C,E\}), p(\{B,E\},\{D\}), p(\{C,E\},\{D\})\}$,

7. $F_W = \{(i_W, A), (A, p(\{A\},\{B,E\})), (p(\{A\},\{B,E\}),B),\ldots, (D, o_W)$

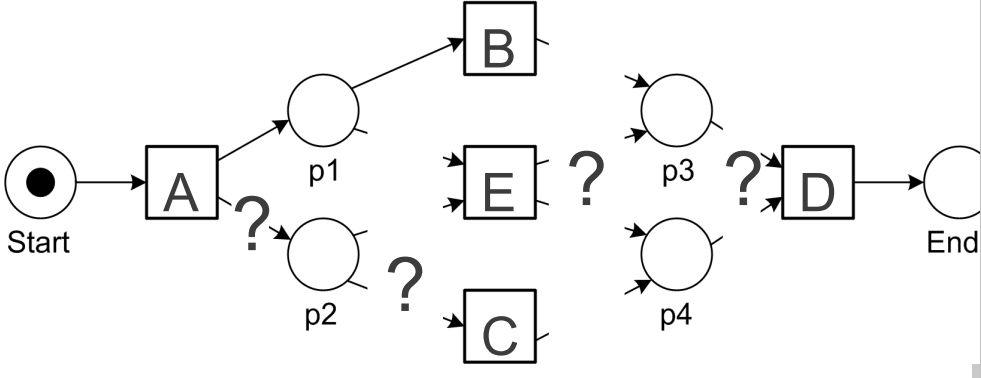

α-Algorithmus – Beispiel

5. $\boldsymbol{Y_W}$ = {({A}, {B, E}), ({A}, {C, E}), ({B, E}, {D}), ({C, E},{D})}

6. $\boldsymbol{P_W}$ = {i_W, o_W, p({A},{B,E}), p({A},{C,E}), p({B,E},{D}), p({C,E},{D})},

7. $\boldsymbol{F_W}$ = {(i_W, A), (A, p({A},{B,E})), (p({A},{B,E}), B), …, (D, o_W)}

8. $\boldsymbol{a(W)} = (\boldsymbol{P_W}, \boldsymbol{T_W}, \boldsymbol{F_W})$

$\alpha(\boldsymbol{W}) = (\boldsymbol{P_W}, \boldsymbol{T_W}, \boldsymbol{F_W})$
Das extrahierte Petrinetz ist nun definiert.

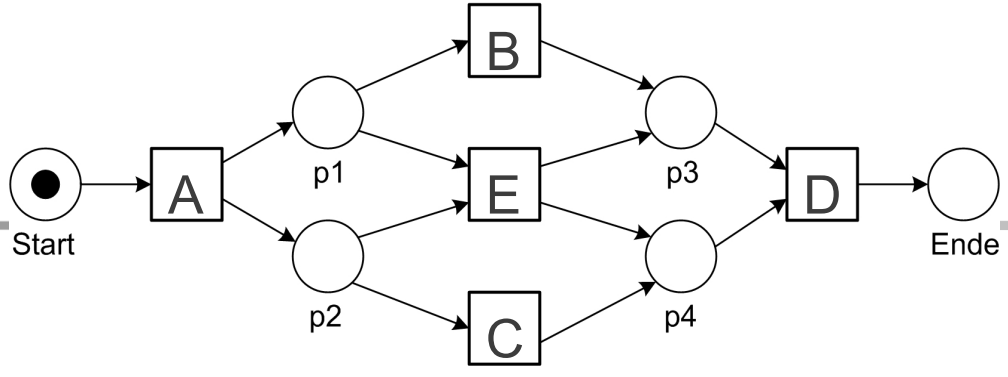

Überblick
2.5 Prozessextraktion

- Einführung und Beispiel
- α-Algorithmus
  - Idee und Vorbereitungen
  - Formalisierung
  - Beispiel
  - Weitere Beispiele
  - Einschränkungen
- Allgemeine Herausforderungen beim Process-Mining

2. Beispiel: L_2

$$L_2 = [\langle a,b,c,d\rangle^3, \langle a,c,b,d\rangle^4, \langle a,b,c,e,f,b,c,d\rangle^2, \langle a,b,c,e,f,c,b,d\rangle, \langle a,c,b,e,f,b,c,d\rangle^2, \langle a,c,b,e,f,b,c,e,f,c,b,d\rangle]$$

	a	b	c	d	e	f
a	#	$\rightarrow$	$\rightarrow$	#	#	#
b	$\leftarrow$	#	$\parallel$	$\rightarrow$	$\rightarrow$	$\leftarrow$
c	$\leftarrow$	$\parallel$	#	$\rightarrow$	$\rightarrow$	$\leftarrow$
d	#	$\leftarrow$	$\leftarrow$	#	#	#
e	#	$\leftarrow$	$\leftarrow$	#	#	$\rightarrow$
f	#	$\rightarrow$	$\rightarrow$	#	$\leftarrow$	#

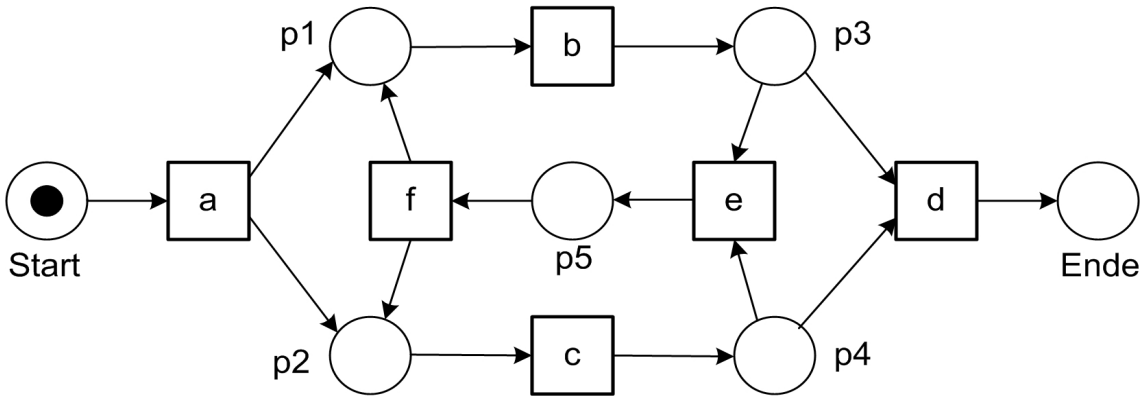

Welches zusätzliche Verhalten ergibt sich aus Petrinetz im Vergleich zu ursprünglichen Logdaten ?

3. Beispiel: L_3

$$L_3 = [\langle a,b,c,d,e,f,b,d,c,e,g\rangle, \langle a,b,d,c,e,g\rangle^2, \langle a,b,c,d,e,f,b,c,d,e,f,b,d,c,e,g\rangle]$$

	a	b	c	d	e	f	g
a	#	$\rightarrow$	#	#	#	#	#
b	$\leftarrow$	#	$\rightarrow$	$\rightarrow$	#	$\leftarrow$	#
c	#	$\leftarrow$	#	$\parallel$	$\rightarrow$	#	#
d	#	$\leftarrow$	$\parallel$	#	$\rightarrow$	#	#
e	#	#	$\leftarrow$	$\leftarrow$	#	$\rightarrow$	$\rightarrow$
f	#	$\rightarrow$	#	#	$\leftarrow$	#	#
g	#	#	#	#	$\leftarrow$	#	#

Welches zusätzliche Verhalten ergibt sich aus Petrinetz im Vergleich zu ursprünglichen Logdaten ?

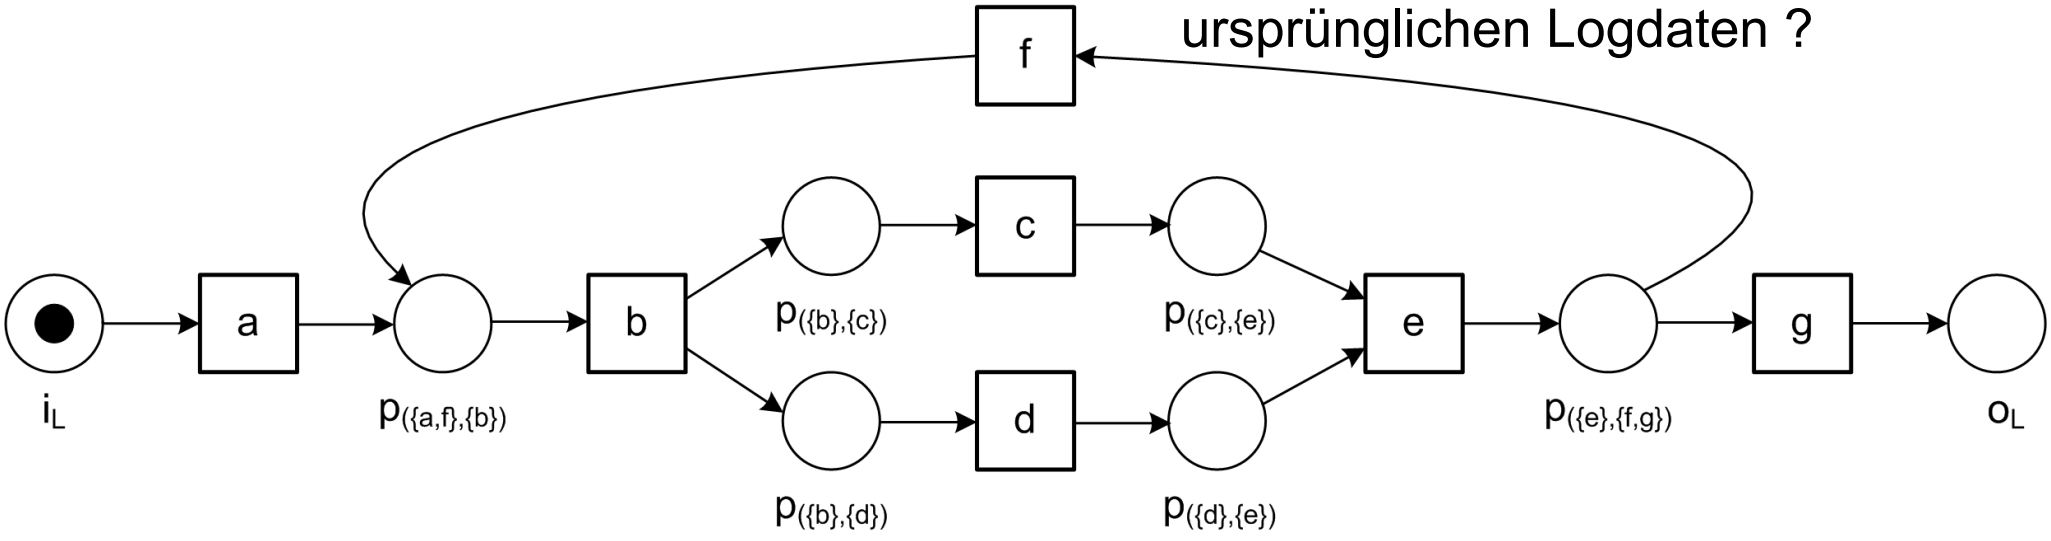

4. Beispiel: L_4

$$L_4 = [\langle a,c,d\rangle^{45}, \langle b,c,d\rangle^{42}, \langle a,c,e\rangle^{38}, \langle b,c,e\rangle^{22}]$$

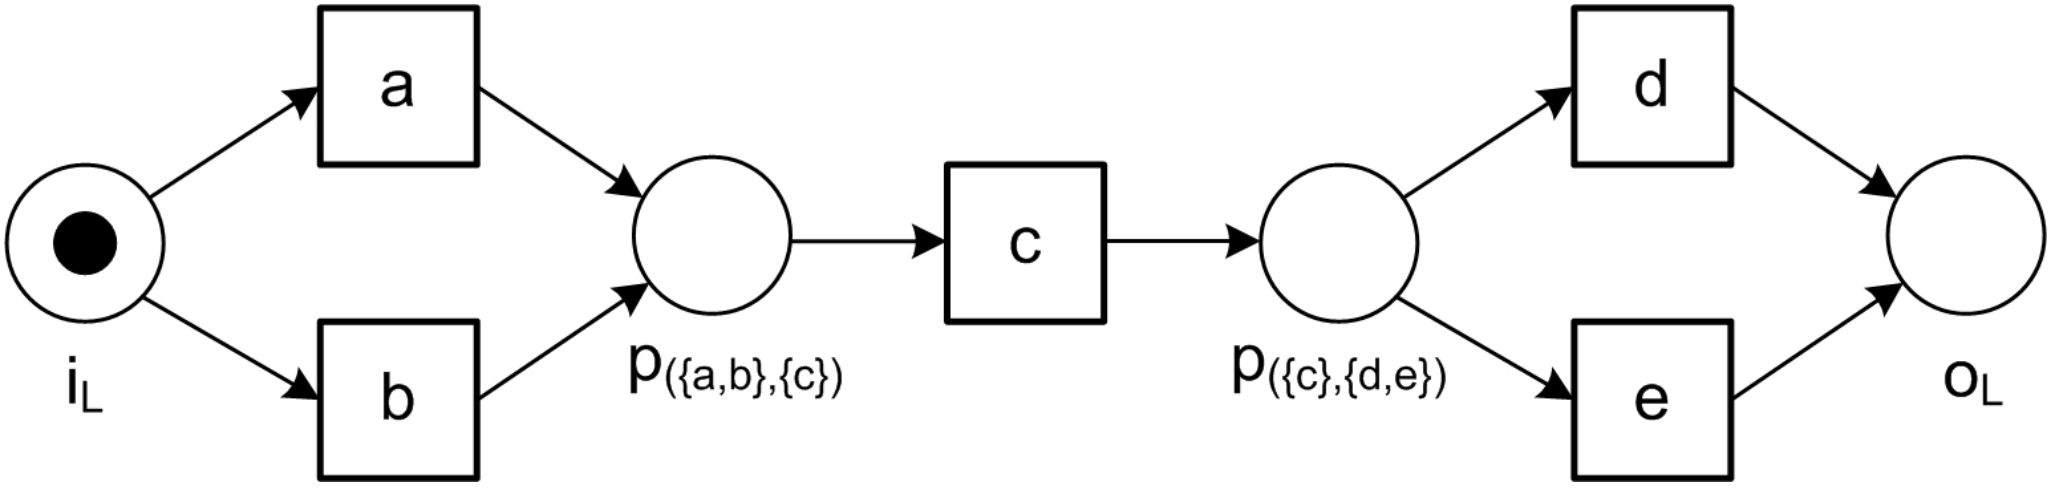

5. Beispiel L_5: Event-Log und Relationen

$$L_5 = [\langle a,b,e,f\rangle^2, \langle a,b,e,c,d,b,f\rangle^3, \langle a,b,c,e,d,b,f\rangle^2, \langle a,b,c,d,e,b,f\rangle^4, \langle a,e,b,c,d,b,f\rangle^3]$$

	a	b	c	d	e	f
a	$\#$	$\rightarrow$	$\#$	$\#$	$\rightarrow$	$\#$
b	$\leftarrow$	$\#$	$\rightarrow$	$\leftarrow$	$\parallel$	$\rightarrow$
c	$\#$	$\leftarrow$	$\#$	$\rightarrow$	$\parallel$	$\#$
d	$\#$	$\rightarrow$	$\leftarrow$	$\#$	$\parallel$	$\#$
e	$\leftarrow$	$\parallel$	$\parallel$	$\parallel$	$\#$	$\rightarrow$
f	$\#$	$\leftarrow$	$\#$	$\#$	$\leftarrow$	$\#$

5. Beispiel L_5: Durchführung α-Algorithmus

$$T_L = \{a,b,c,d,e,f\}$$

$$T_I = \{a\}$$

$$T_I = \{f\}$$

$$X_L = \{(\{a\},\{b\}),(\{a\},\{e\}),(\{b\},\{c\}),(\{b\},\{f\}),(\{c\},\{d\}),$$
$$(\{d\},\{b\}),(\{e\},\{f\}),(\{a,d\},\{b\}),(\{b\},\{c,f\})\}$$

$$Y_L = \{(\{a\},\{e\}),(\{c\},\{d\}),(\{e\},\{f\}),(\{a,d\},\{b\}),(\{b\},\{c,f\})\}$$

$$P_L = \{p_{(\{a\},\{e\})},p_{(\{c\},\{d\})},p_{(\{e\},\{f\})},p_{(\{a,d\},\{b\})},p_{(\{b\},\{c,f\})},i_L,o_L\}$$

$$F_L = \{(a,p_{(\{a\},\{e\})}),(p_{(\{a\},\{e\})},e),(c,p_{(\{c\},\{d\})}),(p_{(\{c\},\{d\})},d),$$
$$(e,p_{(\{e\},\{f\})}),(p_{(\{e\},\{f\})},f),(a,p_{(\{a,d\},\{b\})}),(d,p_{(\{a,d\},\{b\})}),$$
$$(p_{(\{a,d\},\{b\})},b),(b,p_{(\{b\},\{c,f\})}),(p_{(\{b\},\{c,f\})},c),(p_{(\{b\},\{c,f\})},f),$$
$$(i_L,a),(f,o_L)\}$$

$$\alpha(L) = (P_L,T_L,F_L)$$

5. Beispiel L_5: Extrahiertes Petrinetz

$$L_5 = [\langle a,b,e,f\rangle^2, \langle a,b,e,c,d,b,f\rangle^3, \langle a,b,c,e,d,b,f\rangle^2, \langle a,b,c,d,e,b,f\rangle^4, \langle a,e,b,c,d,b,f\rangle^3]$$

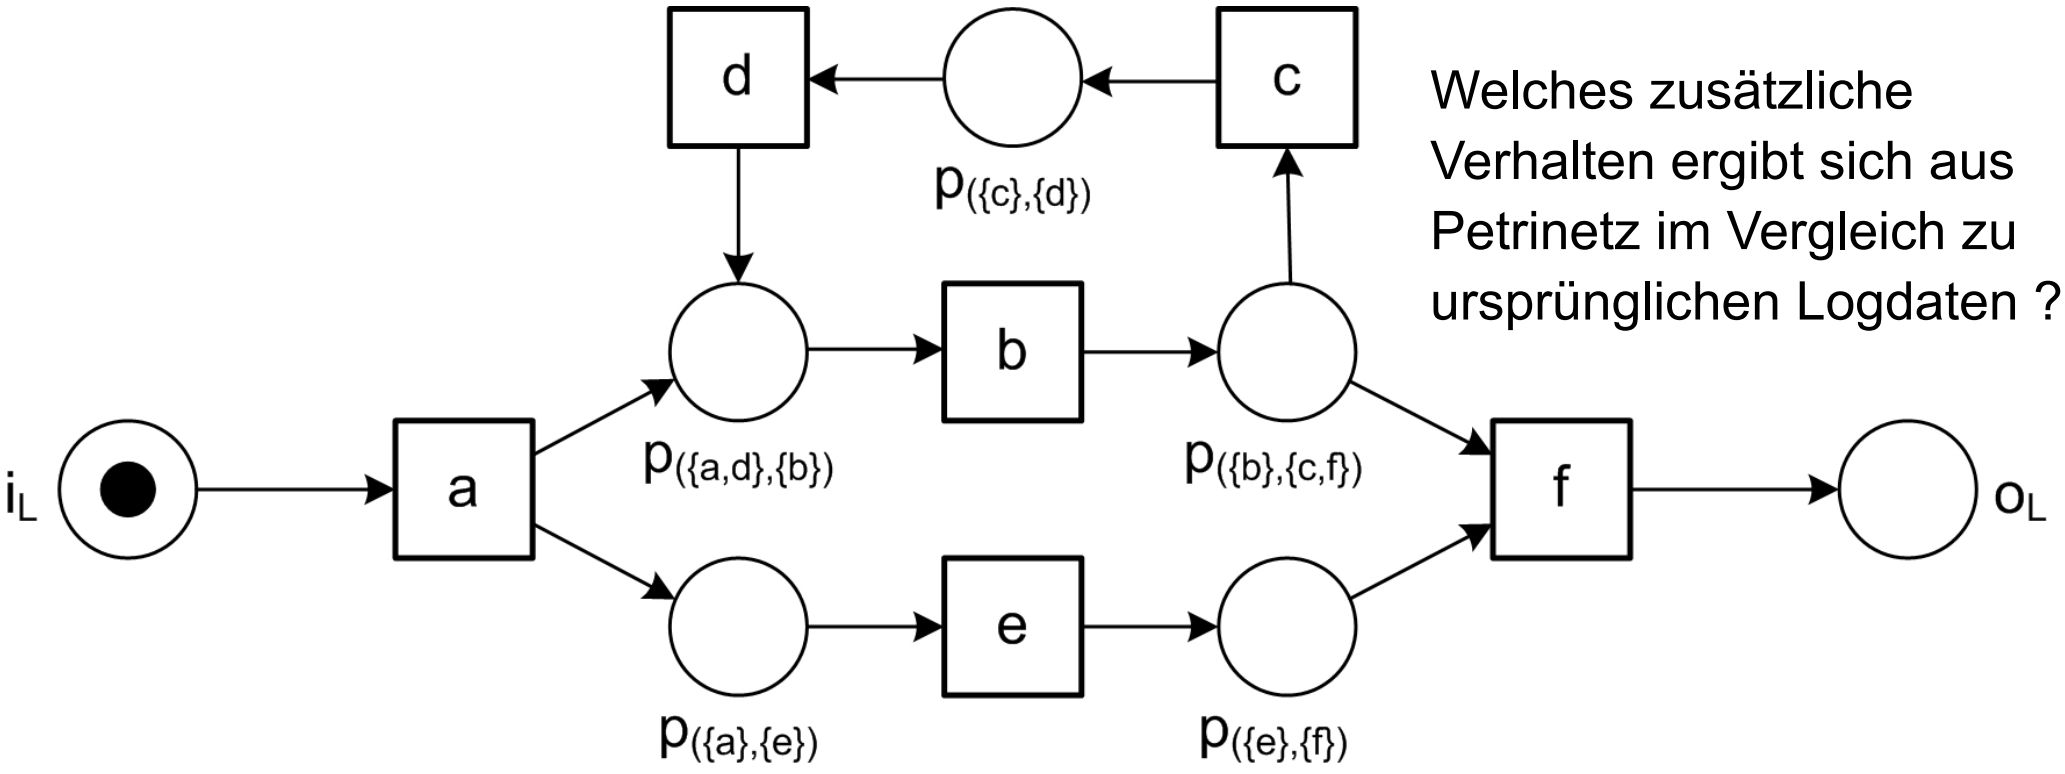

Welches zusätzliche Verhalten ergibt sich aus Petrinetz im Vergleich zu ursprünglichen Logdaten ?

Überblick
2.5 Prozessextraktion

- Einführung und Beispiel
- α-Algorithmus
  - Idee und Vorbereitungen
  - Formalisierung
  - Beispiel
  - Weitere Beispiele
  - Einschränkungen
- Allgemeine Herausforderungen beim Process-Mining

Re-Extraktion von Prozessmodellen

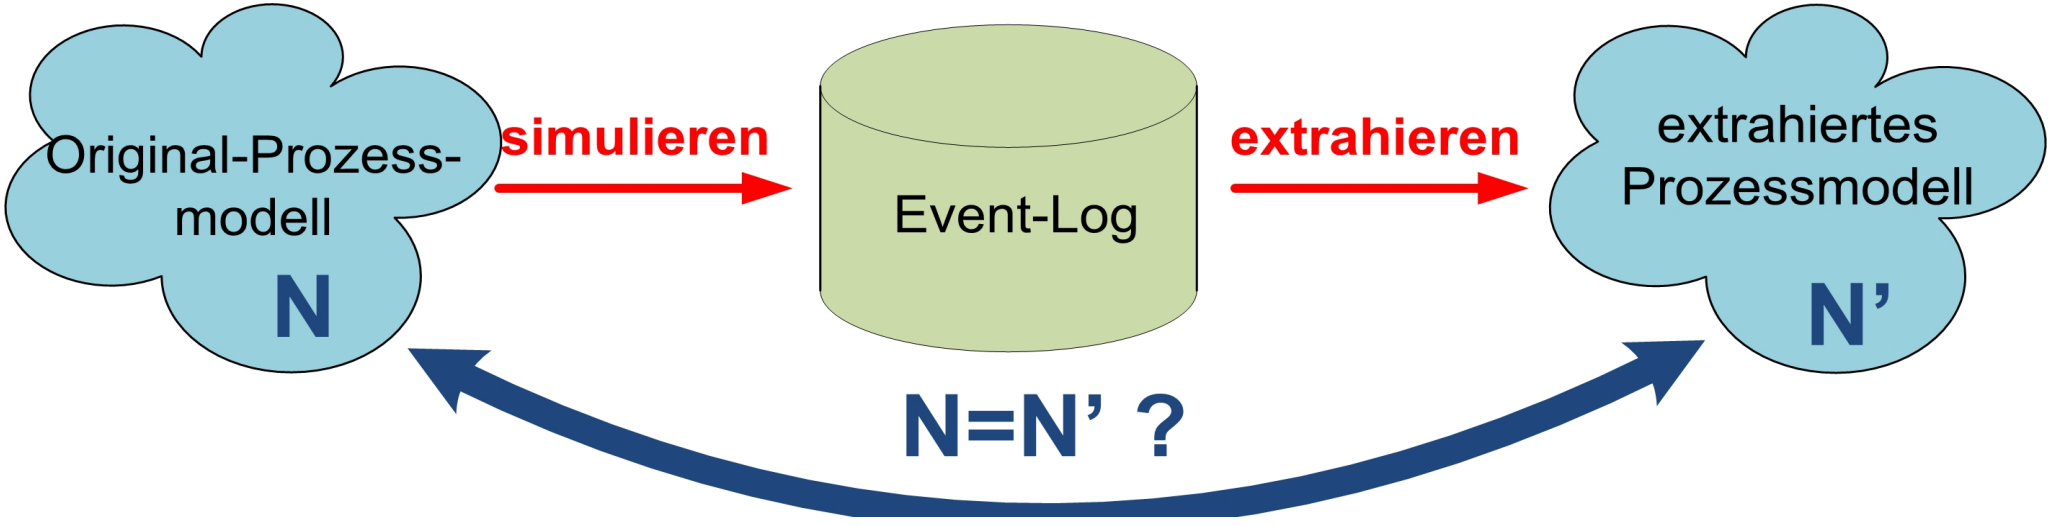

Das Re-Extraktionsproblem:

Entdeckte Modell N' äquivalent zum Original-Modell N?

Log-Daten vs. Kontrollflussverzweigungen

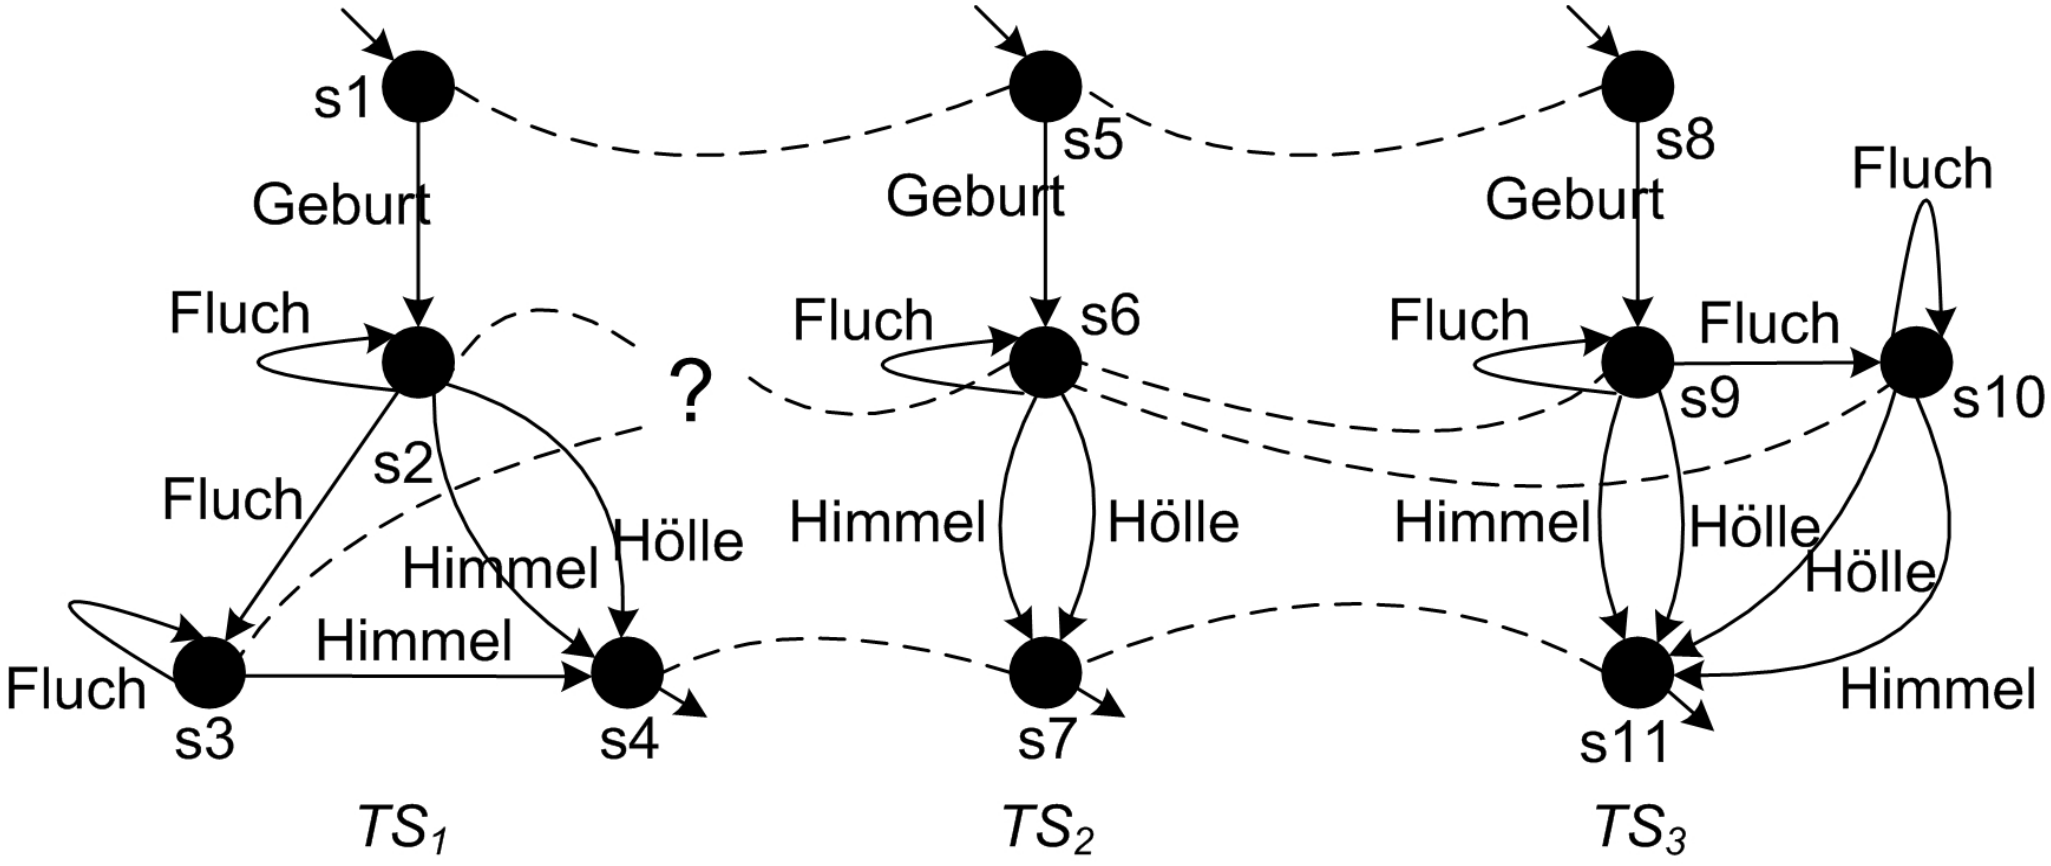

Allgemeines Problem: **Log-Daten abstrahieren** von **Kontrollflussverzweigungen**.

Beispiel: TS_1,...,TS_3 **spuräquivalent** (trace equivalent). TS_2 und TS_3 auch bisimilar.

Aber: TS_1 und TS_2 **nicht bisimilar**: Fehlende Transition Hölle:s3->s4.

Eindeutigkeit der Re-Extraktion

- => Log-Daten können im Allgemeinen von **mehr als einem** Petri-Netz erzeugt werden.
- α-Algorithmus erzeugt Petri-Netz mit **minimaler Anzahl Stellen** (= maximale Kandidatenmengen).
- Nur „**beobachtbare**“ Netzwerke werden erzeugt.
  - **Splits** und **Joins** nicht immer direkt beobachtbar.
  - Beobachtetes Verhalten aber korrekt wiedergegeben.

Implizite Stellen

$$L_6 = [\langle a,c,e,g\rangle^2, \langle a,e,c,g\rangle^3, \langle b,d,f,g\rangle^2, \langle b,f,d,g\rangle^4]$$

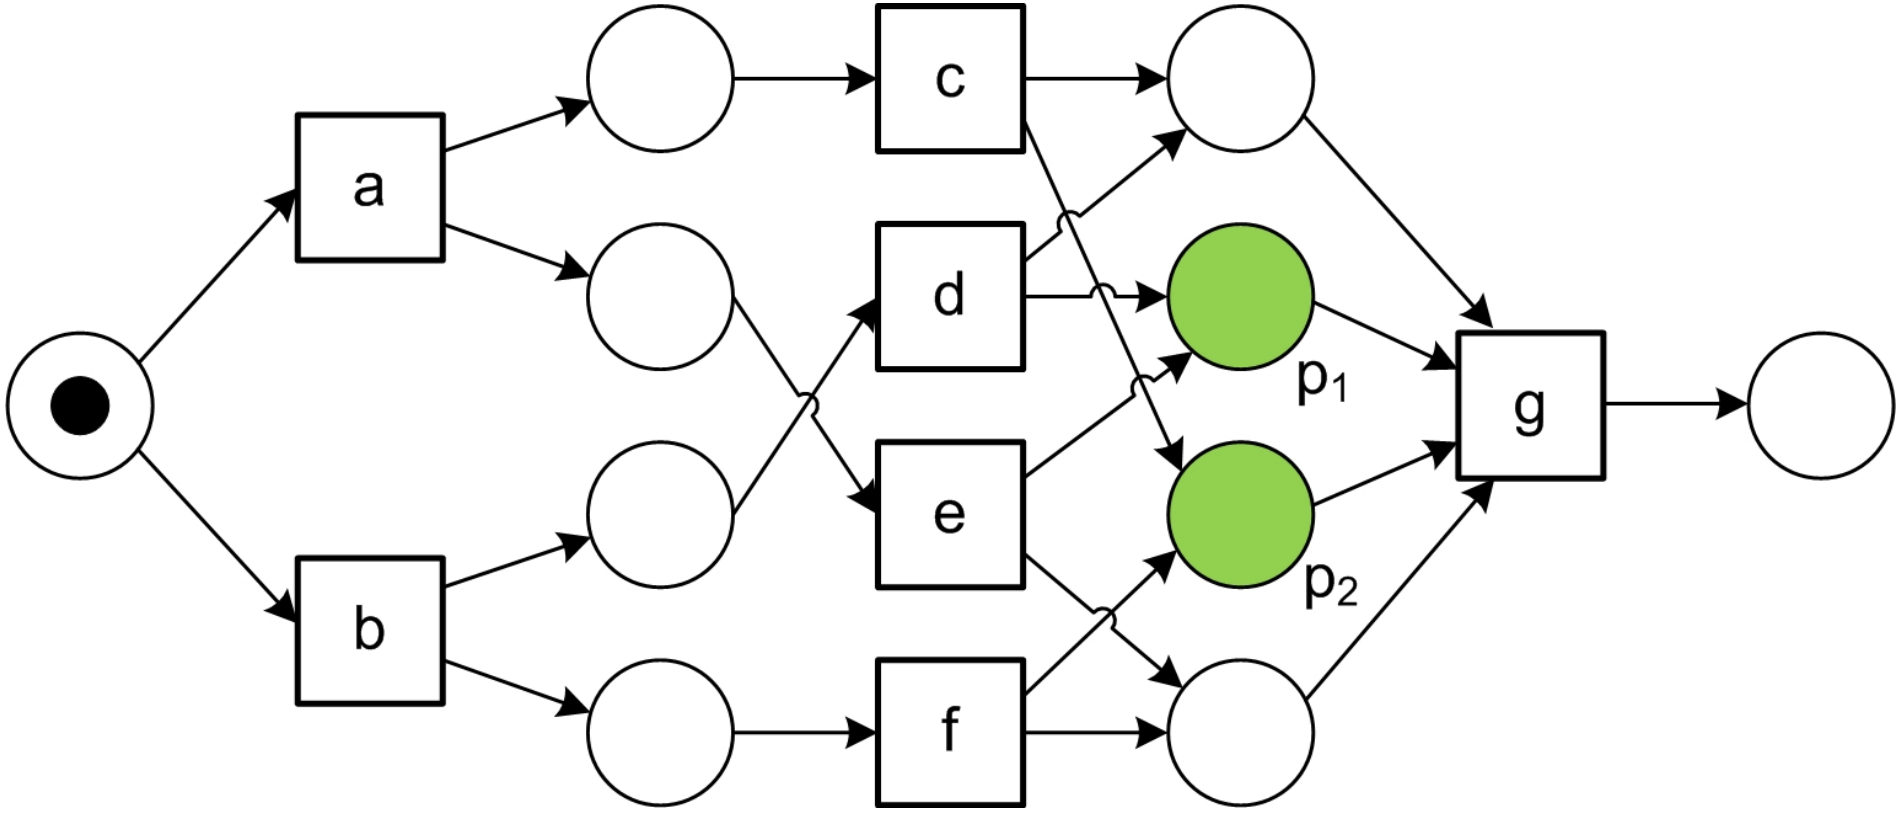

Grüne Stellen **implizit**: Werden im Petrinetz eigentlich nicht benötigt; werden aufgrund Symmetrie der Logdaten erzeugt.

Nicht-lokale Abhängigkeiten

$$L_9 = [\langle a,c,d\rangle^{45}, \langle b,c,e\rangle^{42}]$$

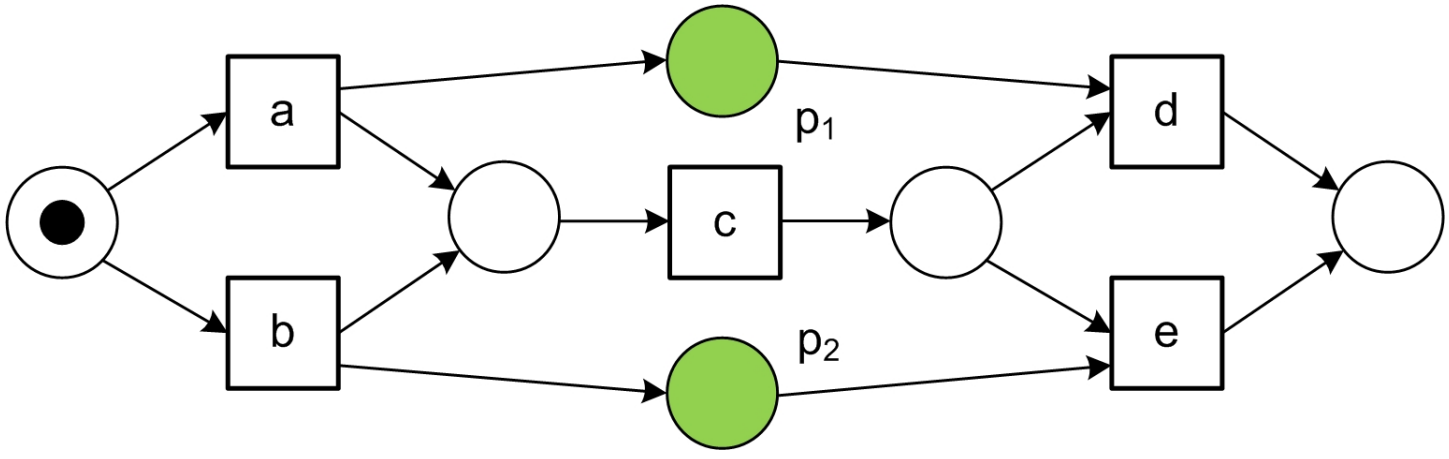

Grüne Stellen werden **nicht entdeckt** !
Extrahiertes Petrinetz also dasselbe wie für:

$$L_4 = [\langle a,c,d\rangle^{45}, \langle b,c,d\rangle^{42}, \langle a,c,e\rangle^{38}, \langle b,c,e\rangle^{22}]$$

Eindeutigkeit der Transitionsbezeichner

- **Eindeutigkeit der Bezeichner** nach o.g. Annahme:
  Jeder Transitionsname taucht nur einmal im Petri-Netz auf.

=> **Nicht jede Folge** von Transitionen aus wohlgeformten Petri-Netz **erzeugbar** !

NB: Ohne o.g. Annahme kann immer Petri-Netz als XOR-Verknüpfung über Transitionen, die je eine Sequenz erzeugen, darzustellen.

Mehrfach auftretende Aktivitäten:

- Schwierig; α-Algorithmus konstruiert nur eine Transition pro Aktivität.

Eindeutigkeit der Transitionen: Beispiel

$$L_{10} = [\langle a, a \rangle^{55}]$$

Wie durch Petrinetz darstellen, das jeden Transitionsbezeichner jeweils nur einmal enthält ?

Eindeutigkeit der Transitionen: Beispiel

$$L_{10} = [\langle a, a \rangle^{55}]$$

Naheliegend (aber nicht mit eindeutigen Transitionsbezeichnungen):

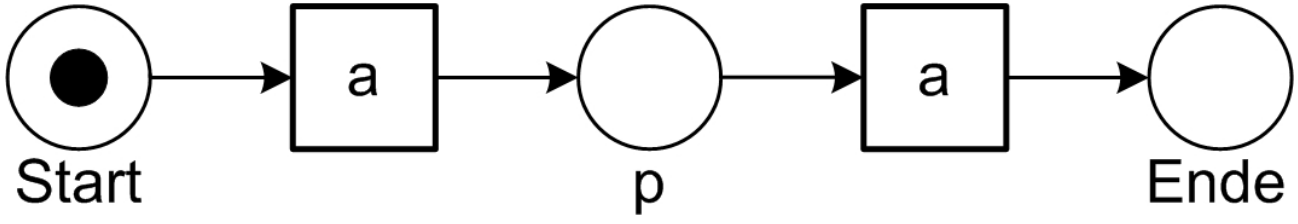

Gibt kein WF-net mit eindeutigen Transitionsbezeichnungen, welches (exakt) dieses Verhalten darstellt.

Beobachtbarkeit der Transitionen

Insbesondere hinsichtlich Abstraktion („unsichtbar machen“) von Transitionen:

Wegabstrahieren der Transition E in **Log-Daten** im obigen Beispiel führt zu Log-Daten, die (unter o.g. Annahme) **nicht** durch ein **Petri-Netz darstellbar** sind.

Zum Beispiel erzeugt folgendes Petrinetz nur [<ABCD>,<ACBD>] (nicht auch <AD>, wie durch Abstrahieren von E aus <AED> erhalten):

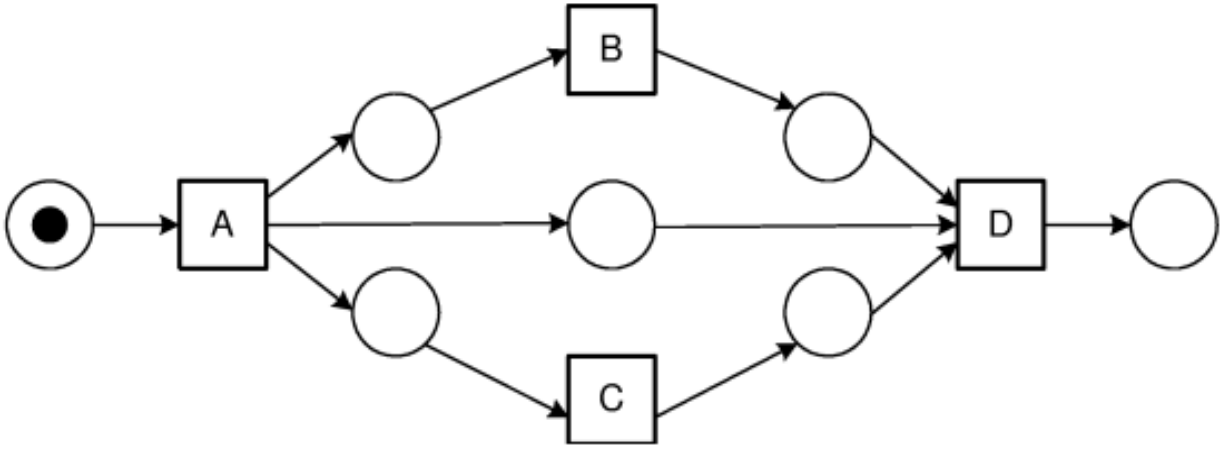

Eindeutigkeit / Beobachtbarkeit der Transitionen: Beispiel

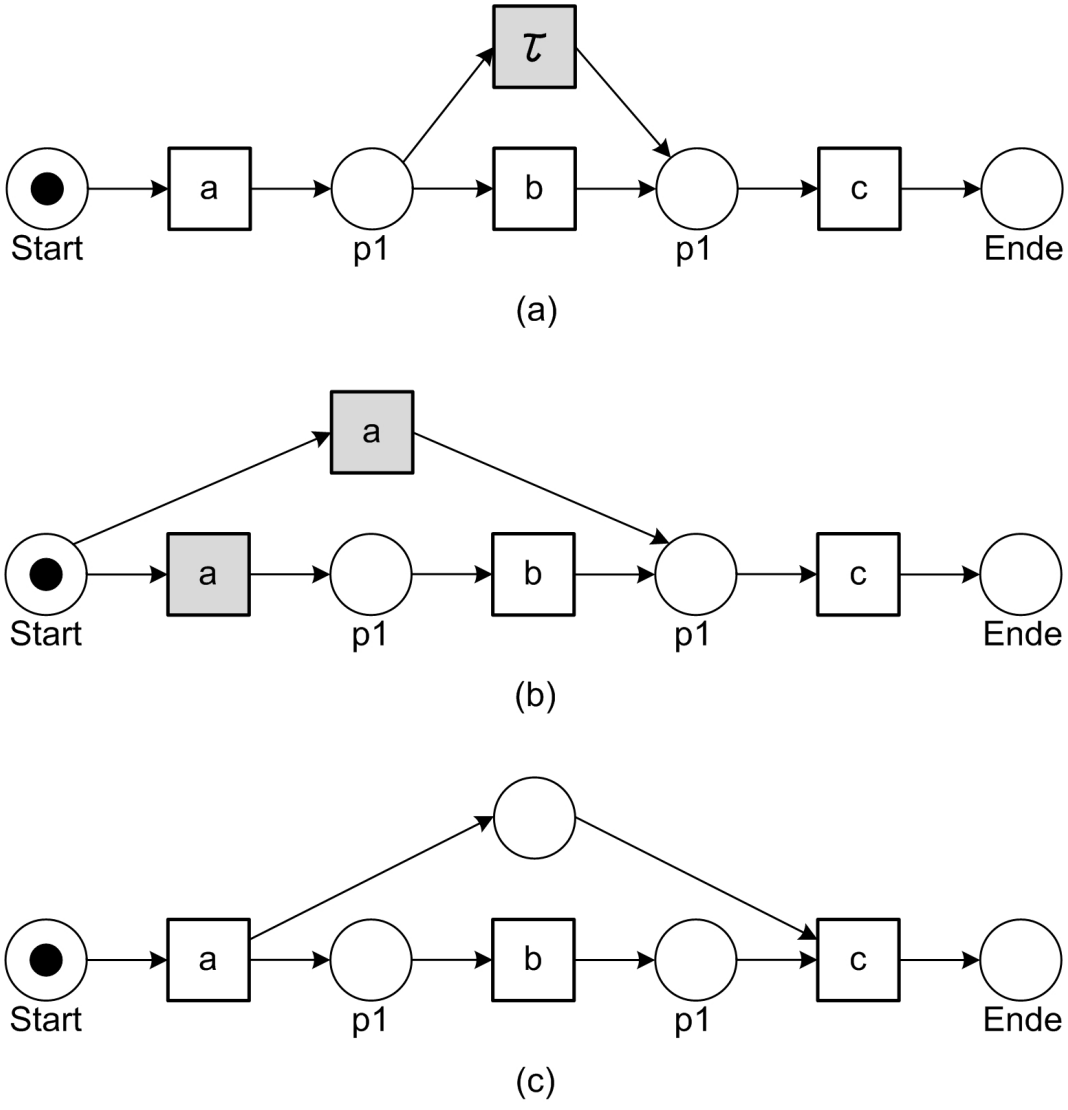

$$L_{11} = [\langle a,b,c\rangle^{20}, \langle a,c\rangle^{30}]$$

Welches Petrinetz extrahiert **α-Algorithmus** aus $\mathbf{L_{11}}$?

Welche Logdaten erzeugt das Petrinetz bei Ausführung ?

Eindeutigkeit / Beobachtbarkeit der Transitionen: Beispiel

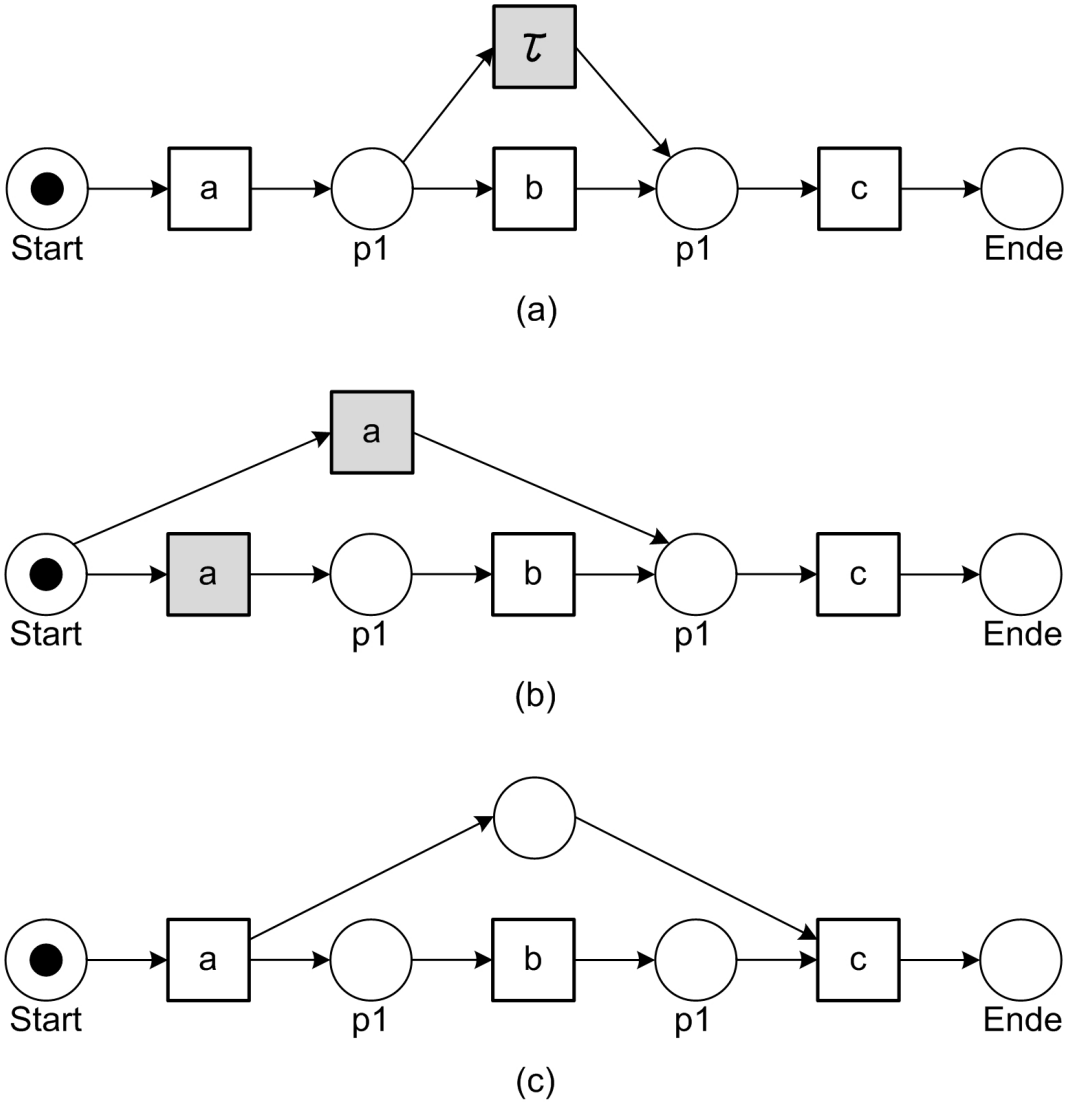

$$L_{11} = [\langle a,b,c\rangle^{20}, \langle a,c\rangle^{30}]$$

Gibt **kein WF-net** mit **eindeutigen** und **sichtbaren** Bezeichnungen, welches (genau) dieses Verhalten darstellt.

(a) **Unsichtbares** Ereignis τ

(b) Ereignis a **mehrfach**

(c) Extrahiert mit **α-Algorithmus** aus $\mathbf{L_{11}}$.

Erzeugt nur [**<a,b,c>**].

Einschränkungen: Weiteres Beispiel

$$L_7 = [\langle a,c\rangle^2, \langle a,b,c\rangle^3, \langle a,b,b,c\rangle^2, \langle a,b,b,b,b,c\rangle^1]$$

Welches Petrinetz extrahiert der α-Algorithmus aus o.g. Logdaten ?

Welches Petrinetz generiert die o.g. Logdaten ?

Schleifen der Länge 1: Beispiel

$$L_7 = [\langle a,c\rangle^2, \langle a,b,c\rangle^3, \langle a,b,b,c\rangle^2, \langle a,b,b,b,b,c\rangle^1]$$

Petrinetz **extrahiert** von **α-Algorithmus**:

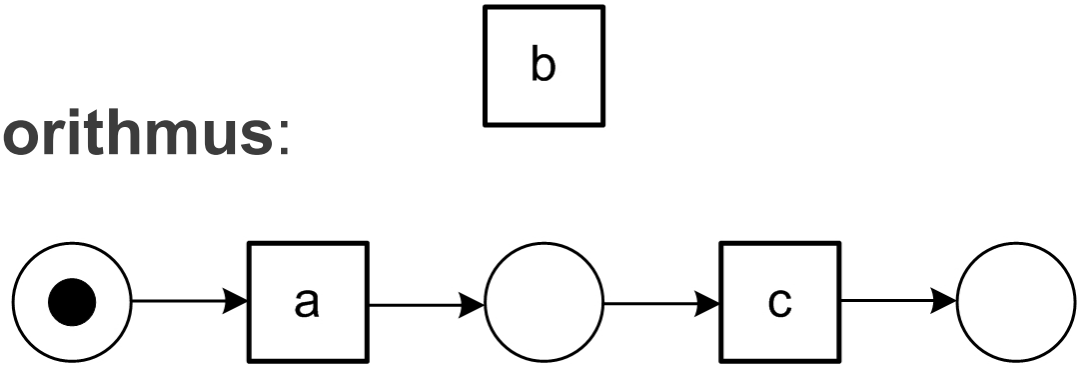

Petrinetz, das tatsächlich o.g. **Logdaten generiert** (und weitere):

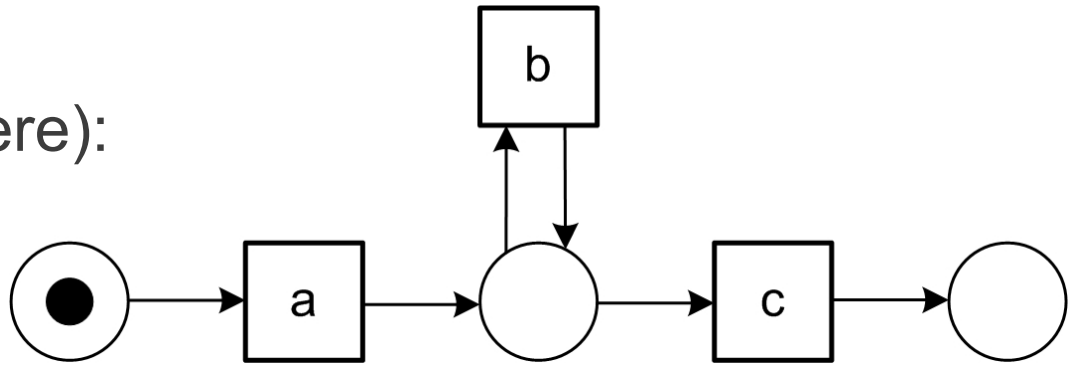

Iterationen

Iterationen:

- Führen zu mehrfach auftretenden Aktivitäten.
- Müssen ggf. extra erkannt werden.
  - Mitunter sehr schwierig !
- Eigentlich keine Beschränkung des Algorithmus, sondern einfach die Tatsache, dass **Schleifen** durch **endliche Logdatenmengen** nur **unvollständig** charakterisiert werden.

Schleifen der Länge 2: Beispiel

$$L_8 = [\langle a,b,d\rangle^3, \langle a,b,c,b,d\rangle^2, \langle a,b,c,b,c,b,d\rangle]$$

Petrinetz **extrahiert** von **α-Algorithmus**:

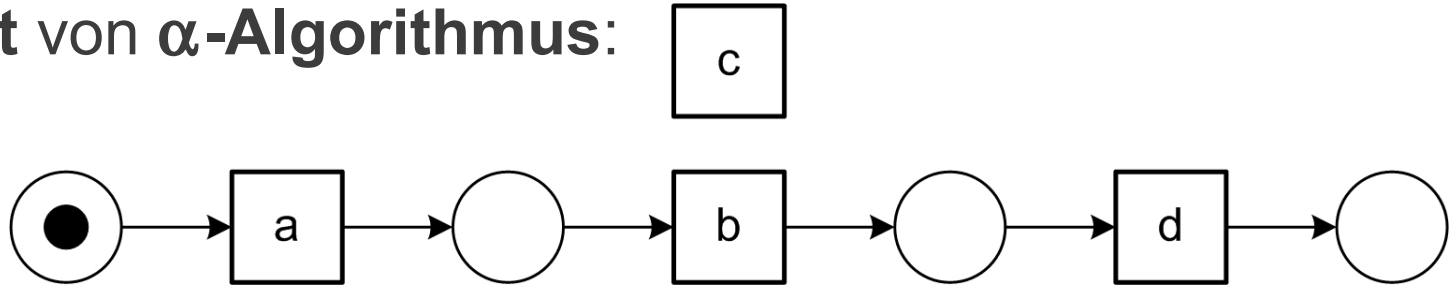

Petrinetz, das tatsächlich o.g.
Logdaten generiert (und weitere):

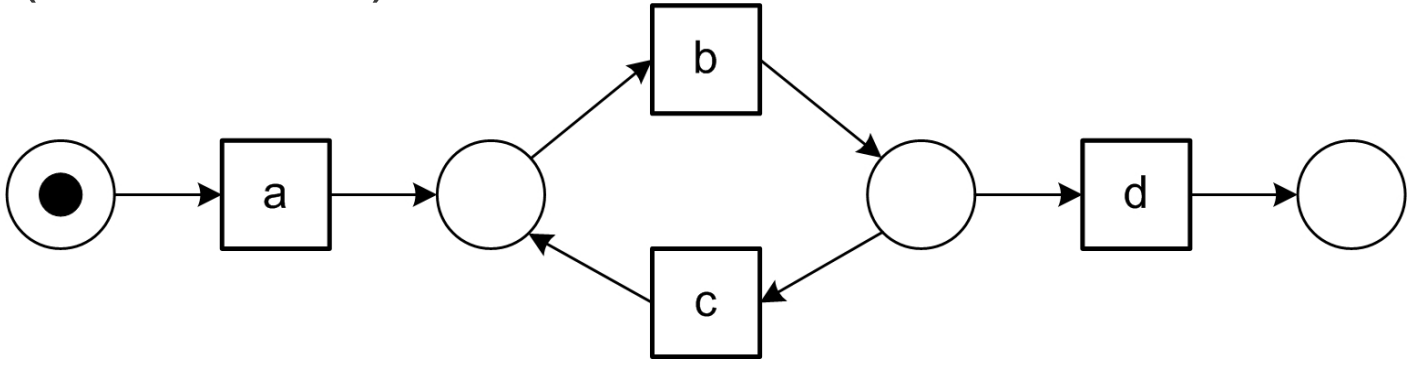

Überblick
2.5 Prozessextraktion

- Einführung und Beispiel
- α-Algorithmus
  - Idee und Vorbereitungen
  - Formalisierung
  - Beispiel
  - Weitere Beispiele
  - Einschränkungen
- Allgemeine Herausforderungen beim Process-Mining

Herausforderung: Rauschen und Unvollständigkeit

Um passendes Prozessmodell zu finden, wird angenommen, dass Event-Log repräsentative Verhaltensmenge enthält.

Zwei verwandte Phänomene:

- Rauschen: Event-Log enthält seltenes und unregelmäßiges Verhalten, welches **nicht typisches Verhalten** des Prozesses repräsentiert.
  - Lösung z.B. durch Betrachtung der **Häufigkeit**.
- Unvollständigkeit: Event-Log enthält **zu wenig Events**, um alle Kontrollflüsse zu erfassen.
  - Siehe auch Teil 2.3 (cross-validation, precision, recall, etc.).

Mehr zu Unvollständigkeit

Beispiel zu Relevanz von **Vollständigkeit**:

Betrachte Prozess aus 10 Aktivitäten.

- Annahme: Können parallel ausgeführt werden.

Gegeben entsprechender Log mit Informationen über 10.000 Fälle.

- Anzahl mögliche Kombinationen (10 nebenläufige Aktivitäten): 10! = 3.628.800.
- Unmöglich jede Kombination im Log enthalten:
  - Im Log weniger Fälle (10.000) als mögliche Traces (3.628.800).
- Selbst bei 3.628.800 Fällen im Log:
  - Extrem unwahrscheinlich, dass alle Variationen vorhanden.
  - Analogie: Bei 365 Menschen sehr unwahrscheinlich, dass jeder an anderen Tag Geburtstag hat:
    Wahrscheinlichkeit bei $365!/365^{365} \approx 1.454955 \times 10^{-157}$.
  - Anzahl von Atomen im Universum ungefähr 10^{79}.

Herausforderung: Vier divergierende Qualitätskriterien

"Replay des Event-Logs möglich"

Angemessenheit

"Occam's razor"

Einfachheit

Prozess-extraktion

Verallgemeinerung

"Log nicht überanpassen"

Genauigkeit

"Log nicht unteranpassen"

Endlose Überwachung eines stabilen Prozesses

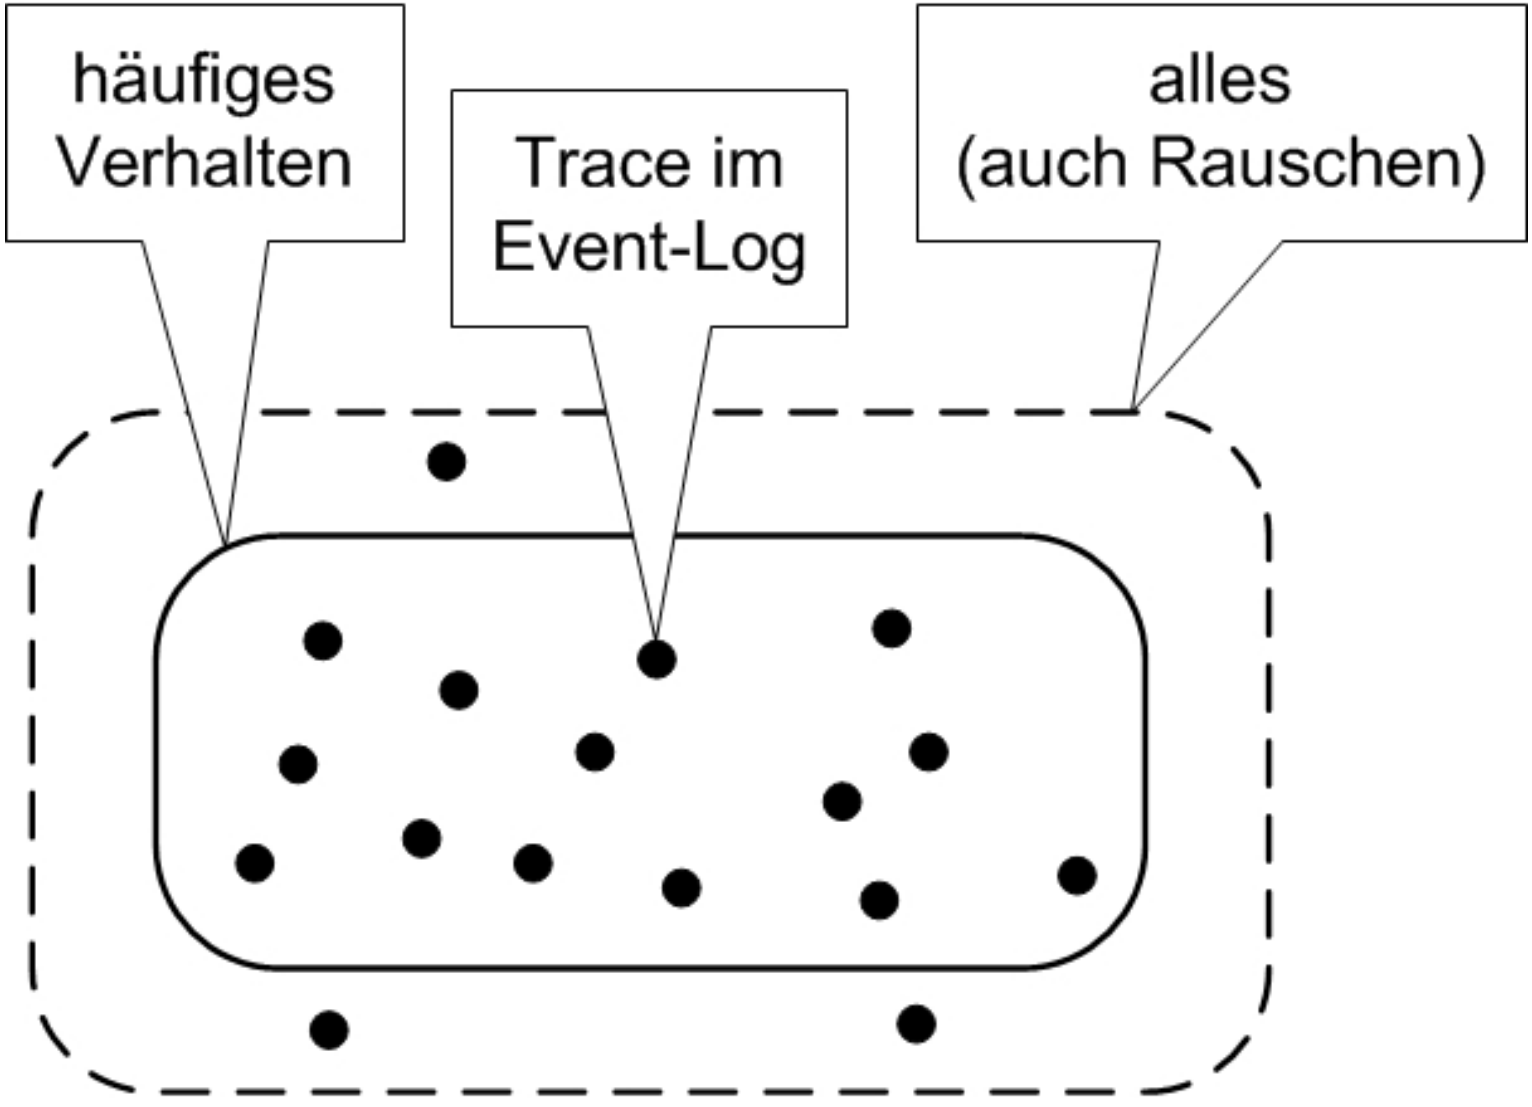

Zielmodell

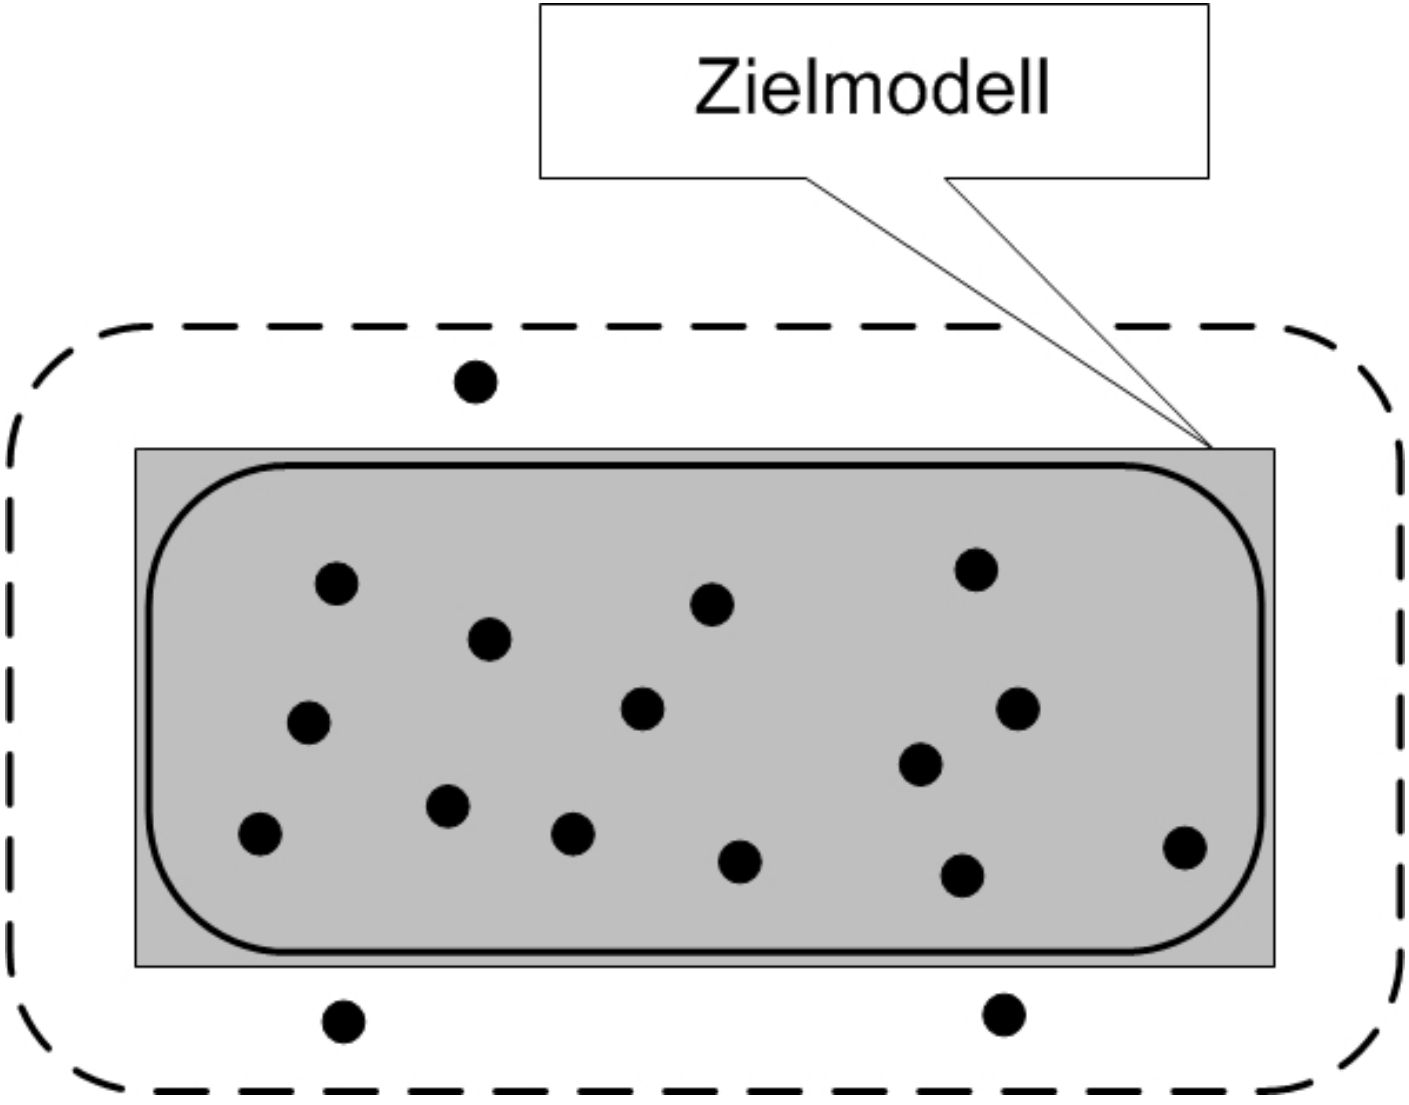

Unpassendes Modell

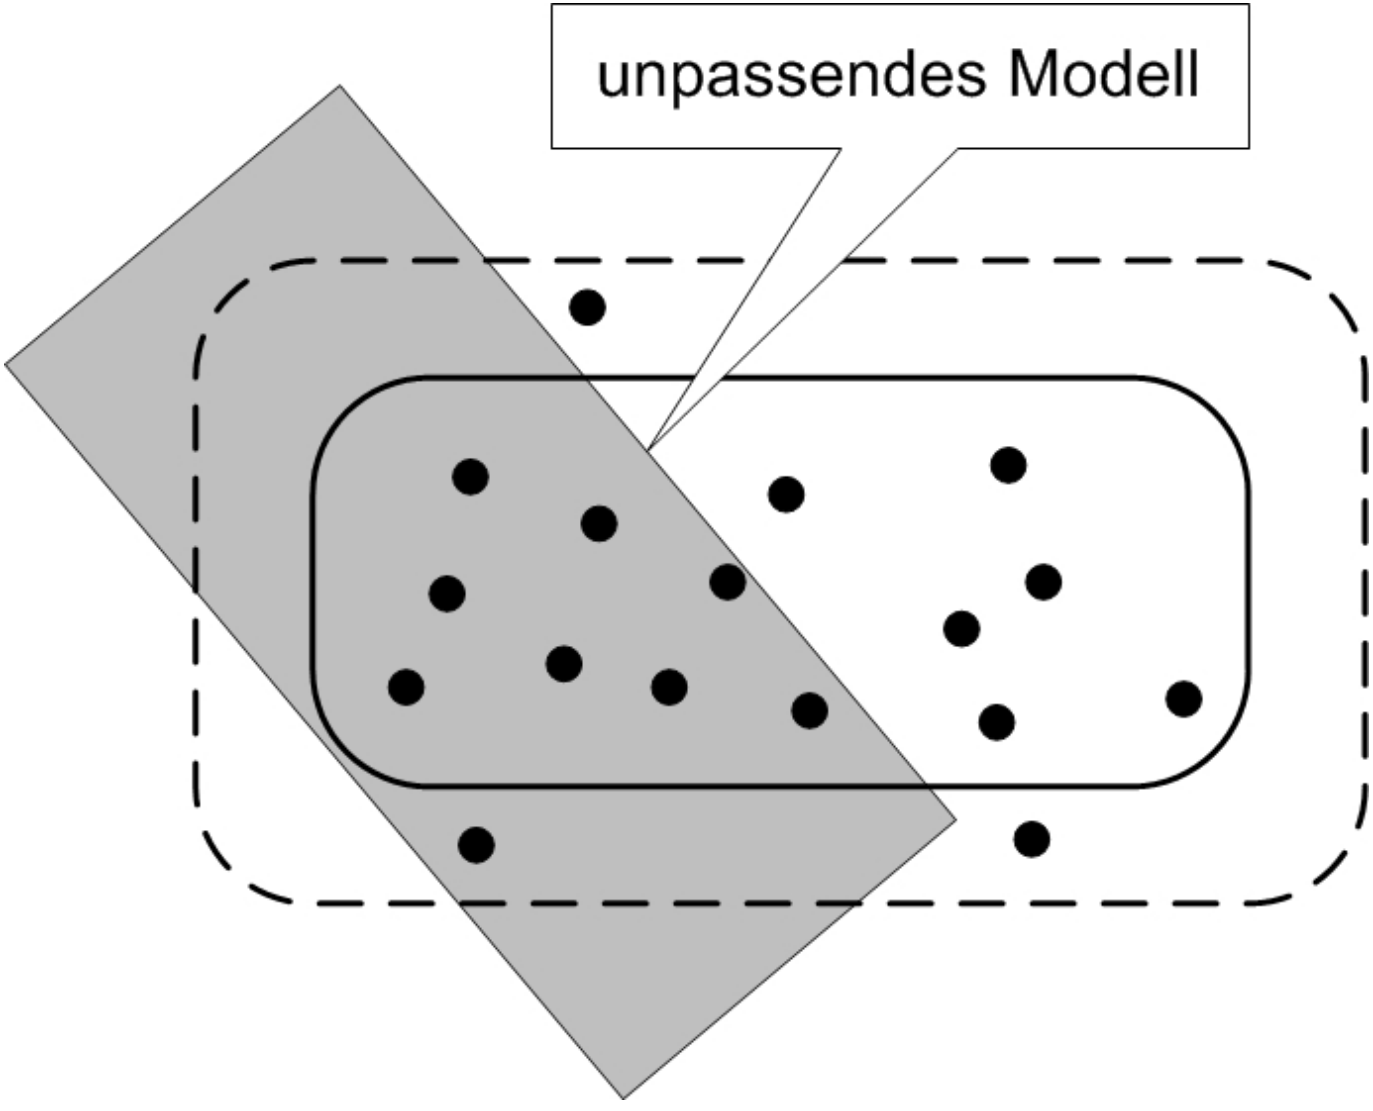

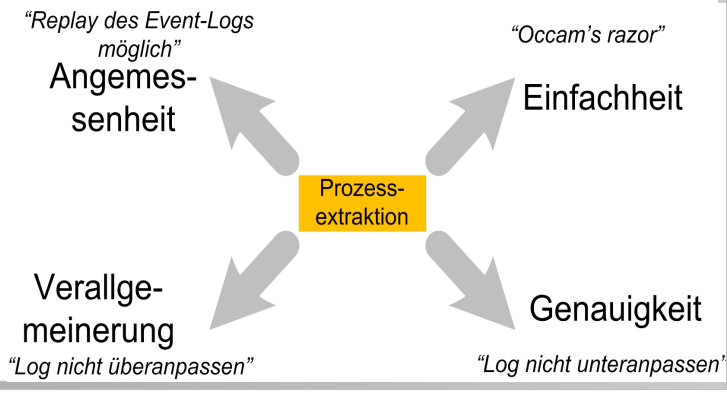

Besondere Herausforderung: Balance zwischen Unteranpassung und Überanpassung

Überangepasstes Modell

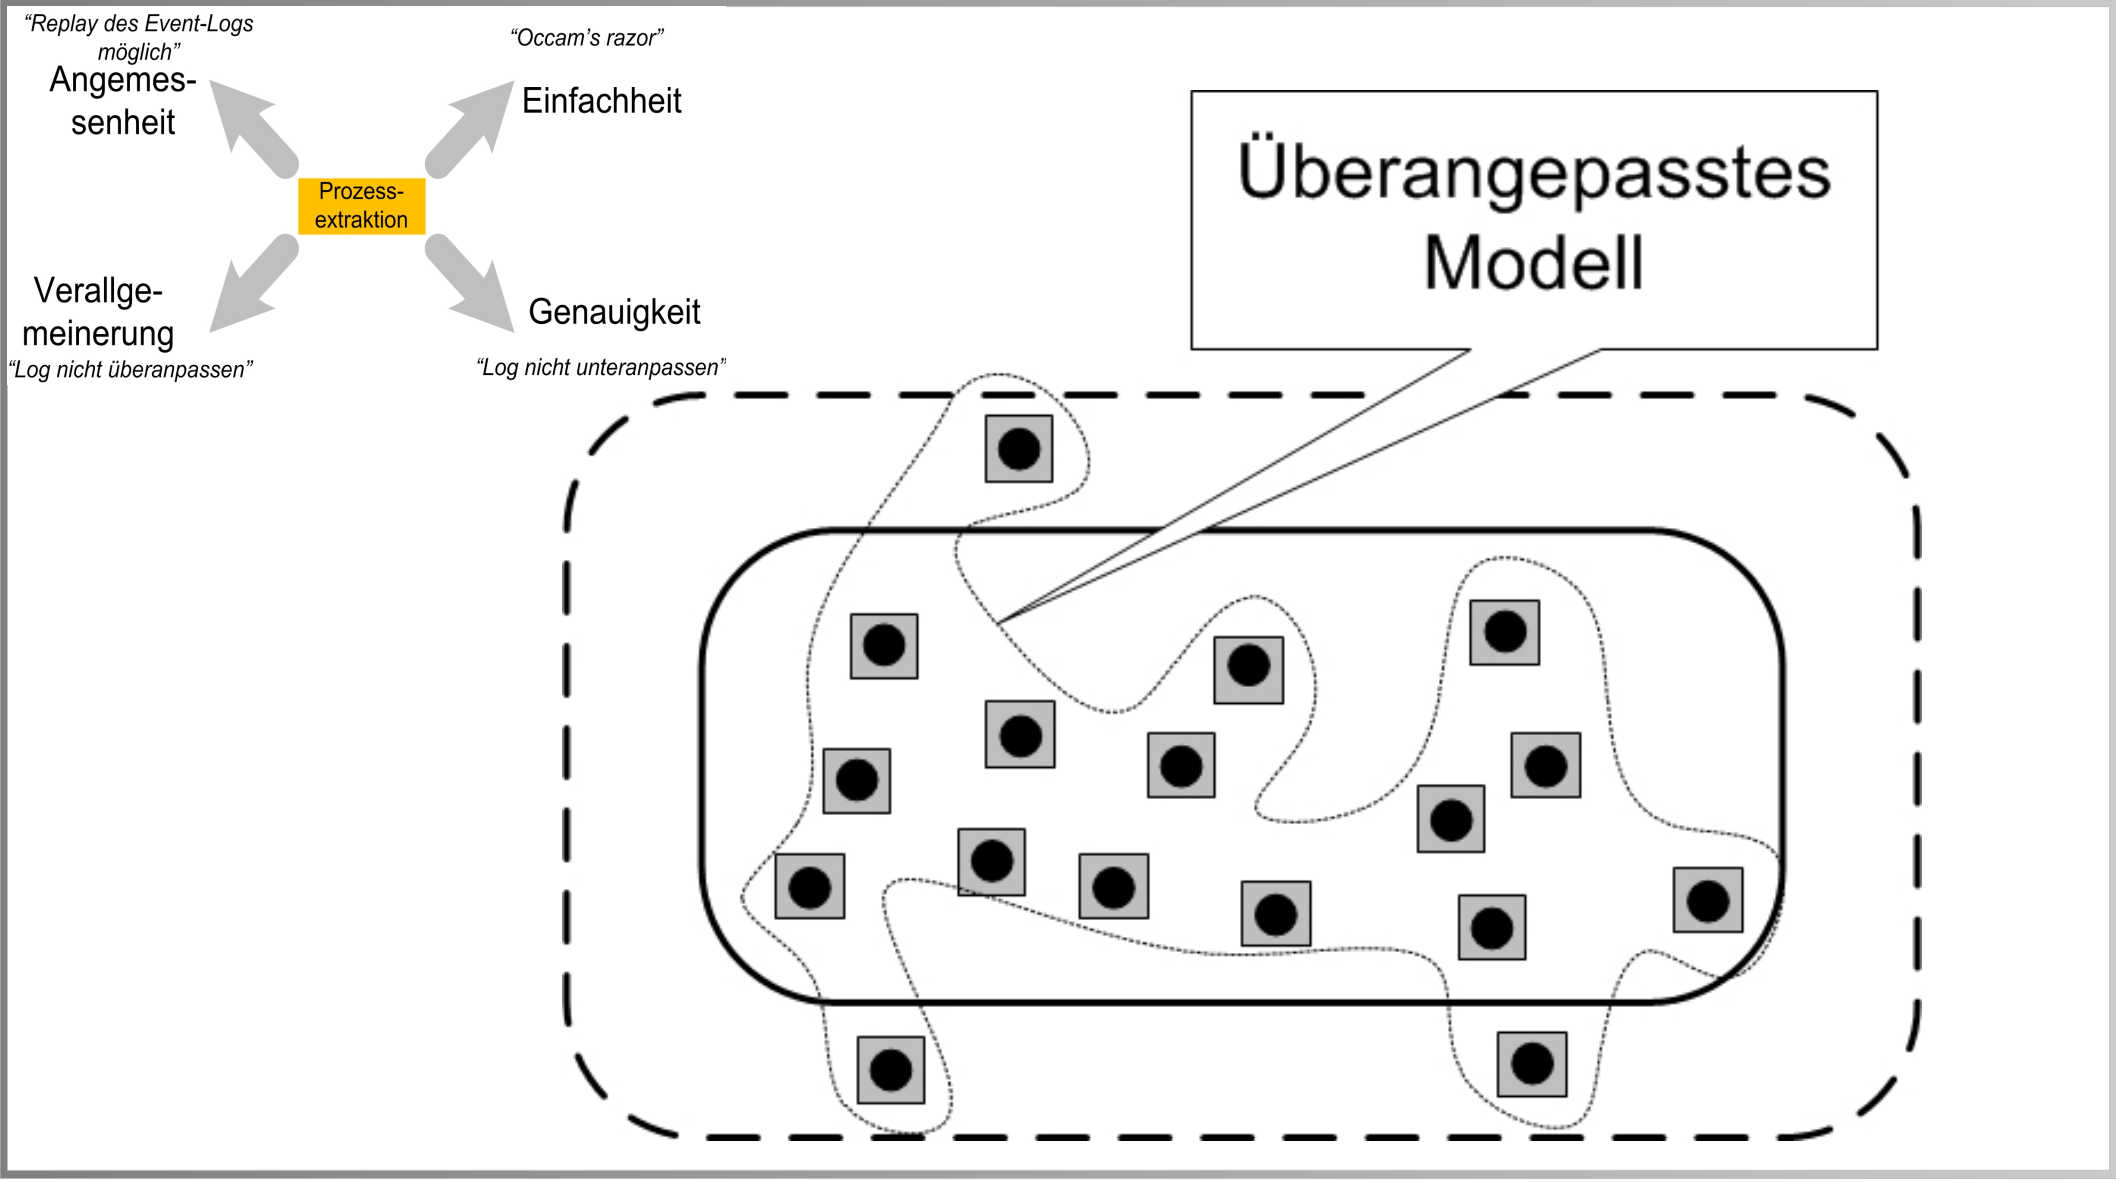

Unterangepasstes Modell

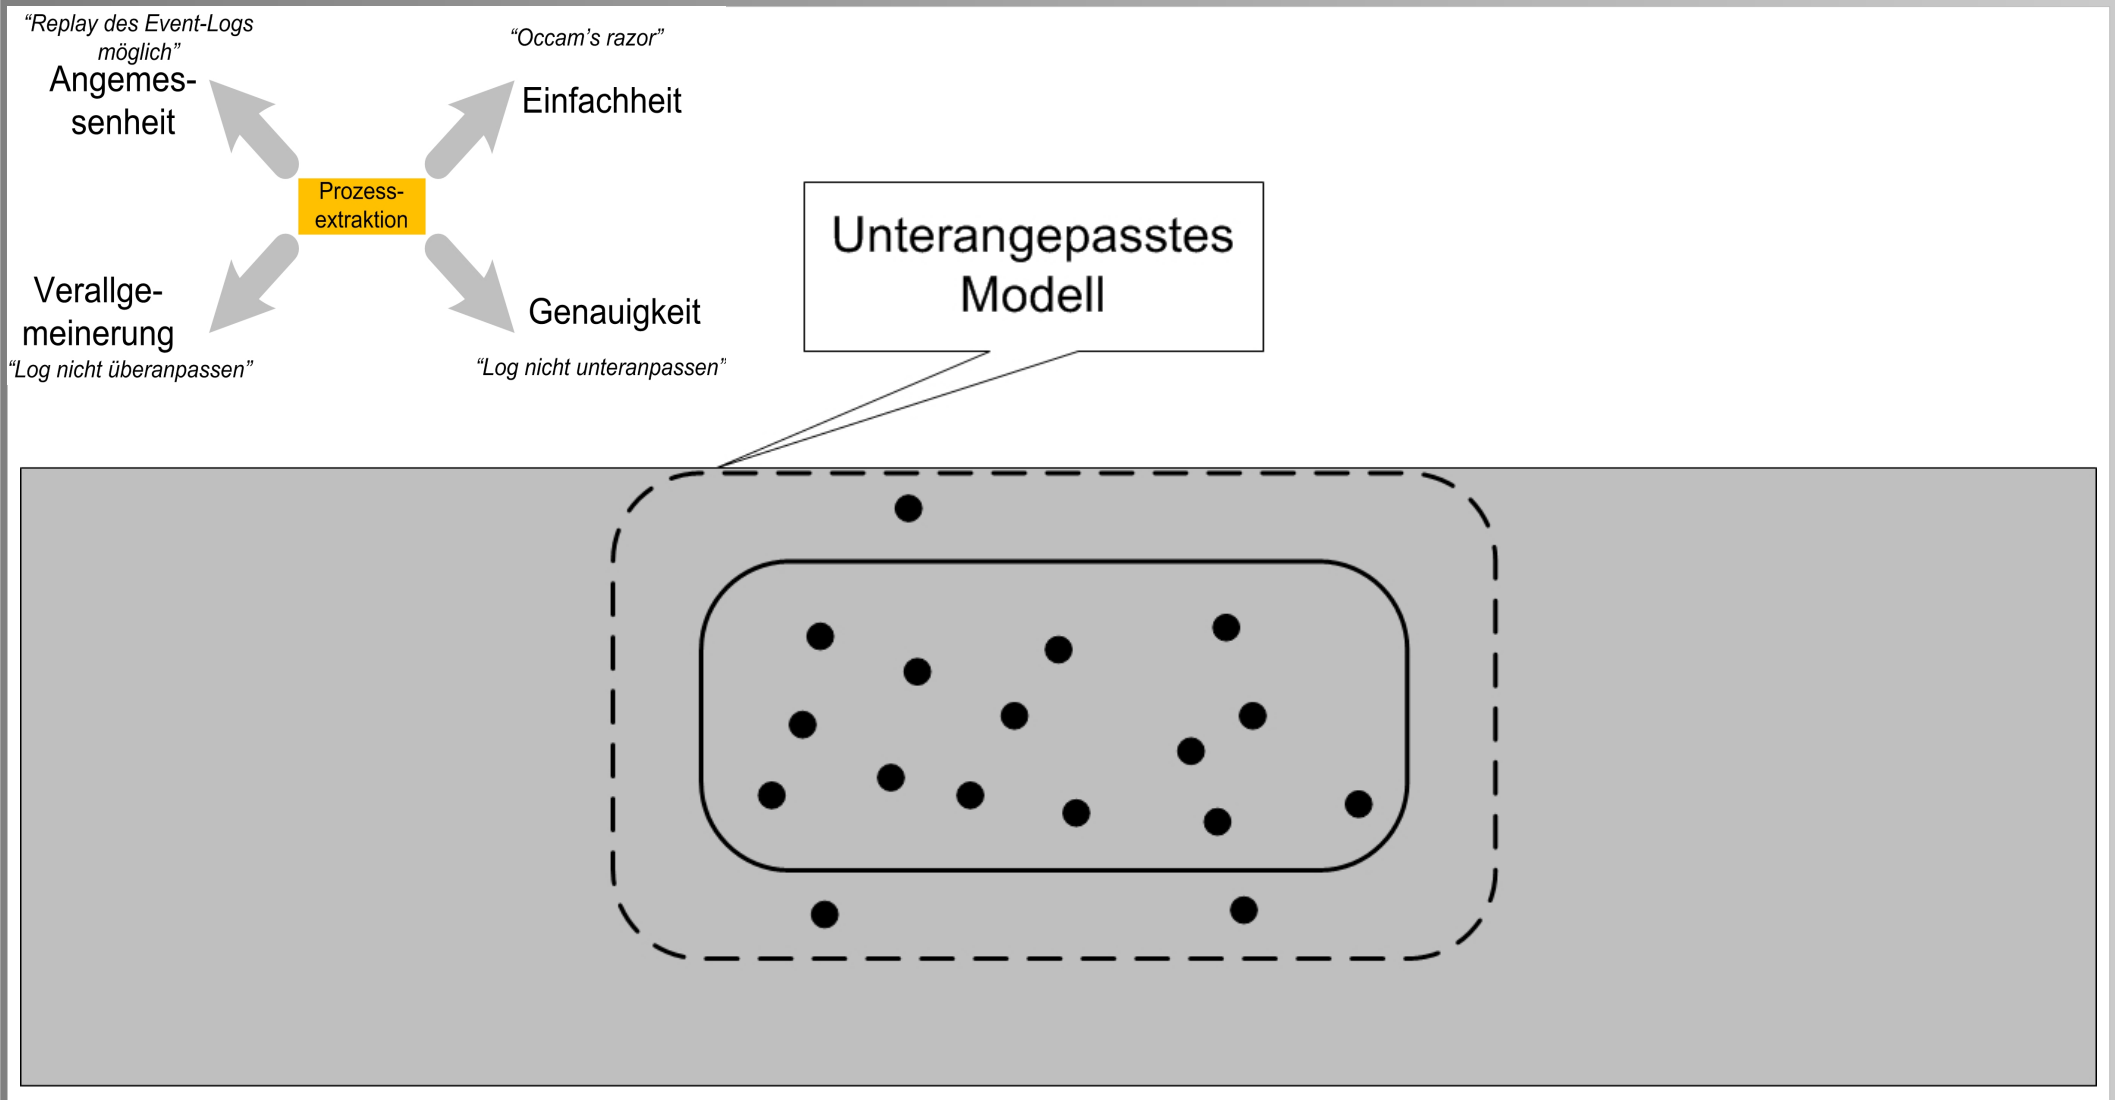

„Blumen-Modell“

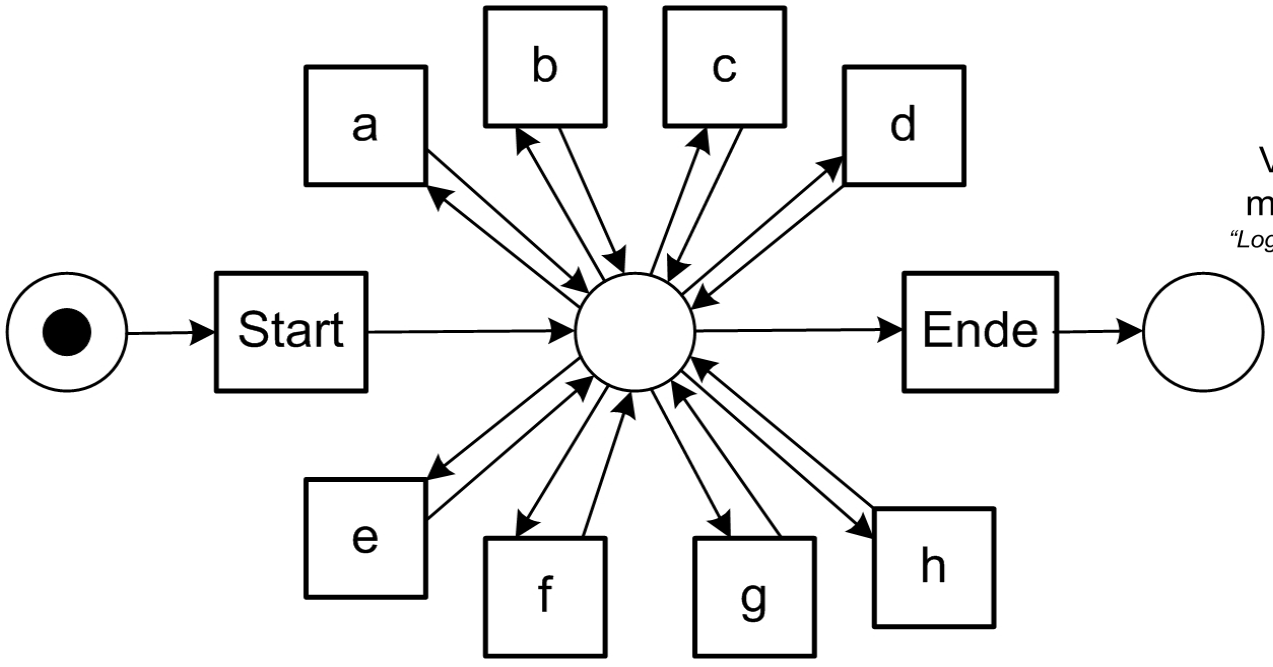

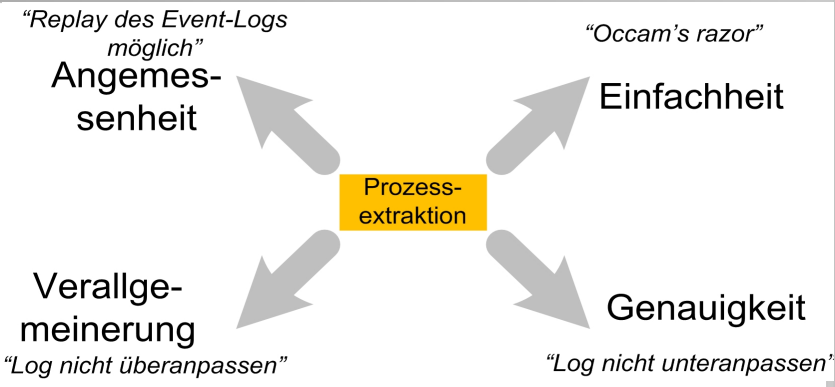

Welche der Qualitätskriterien erfüllt dieses Modell in besonderer Weise ?

„Blumen-Modell“

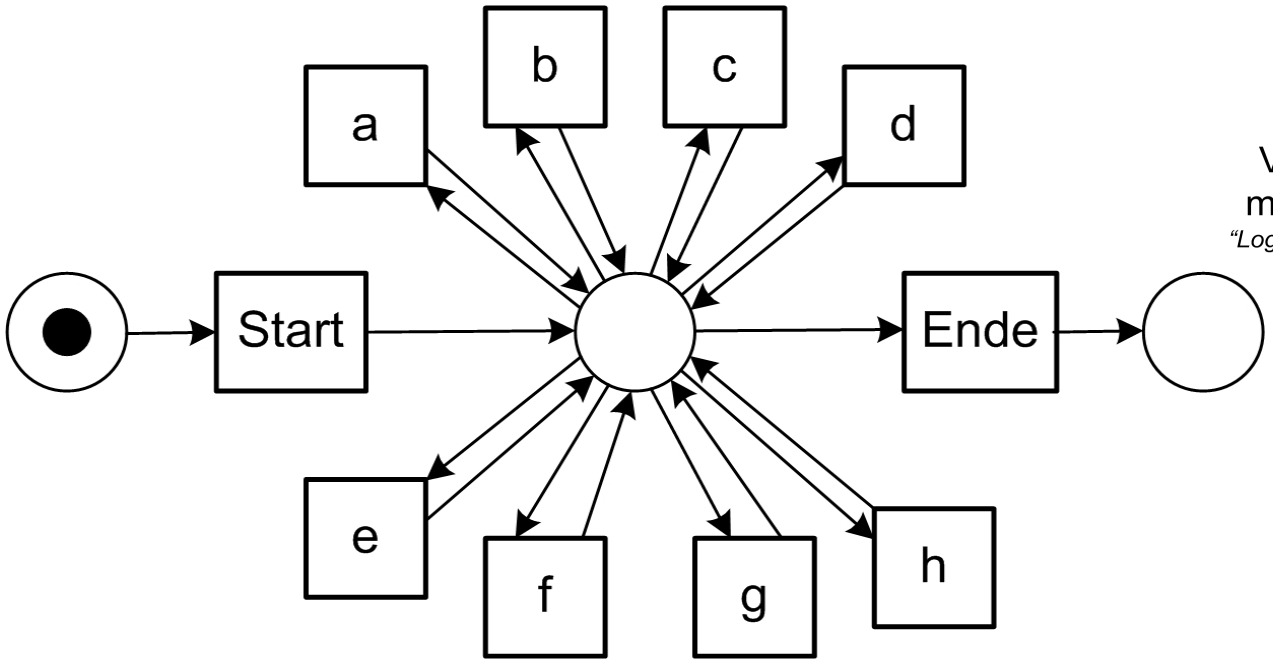

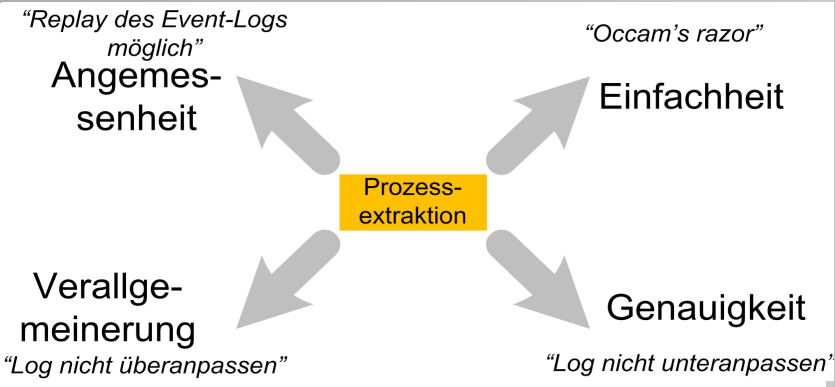

Welche der Qualitätskriterien erfüllt dieses Modell in besonderer Weise ?

Paradebeispiel für unterangepasstes Modell:
jedes Verhalten auf Basis der Ereignisse a, …, h zulässig.

Welches ist das beste Modell?

ACD	99
ACE	0
BCE	85
BCD	0

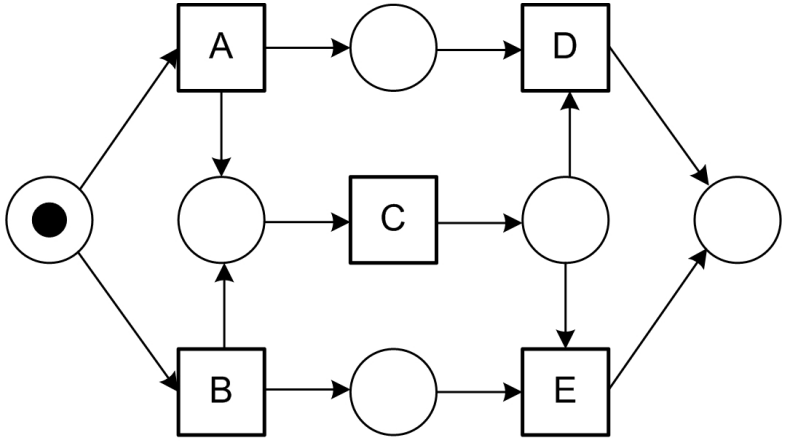

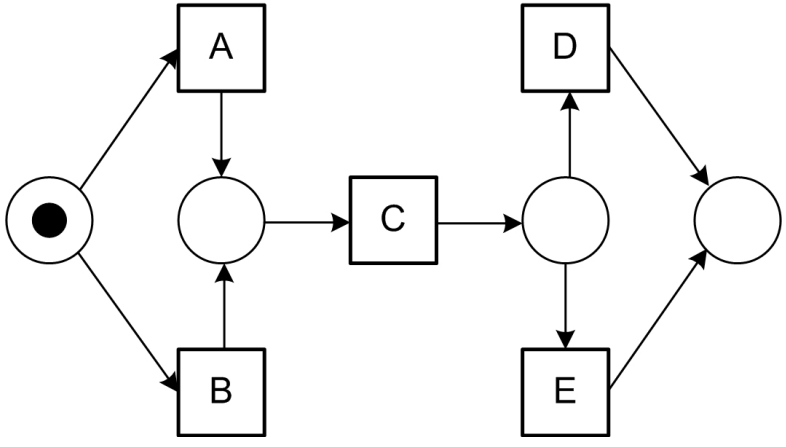

?

Welches ist das beste Modell?

ACD	99
ACE	0
BCE	85
BCD	0

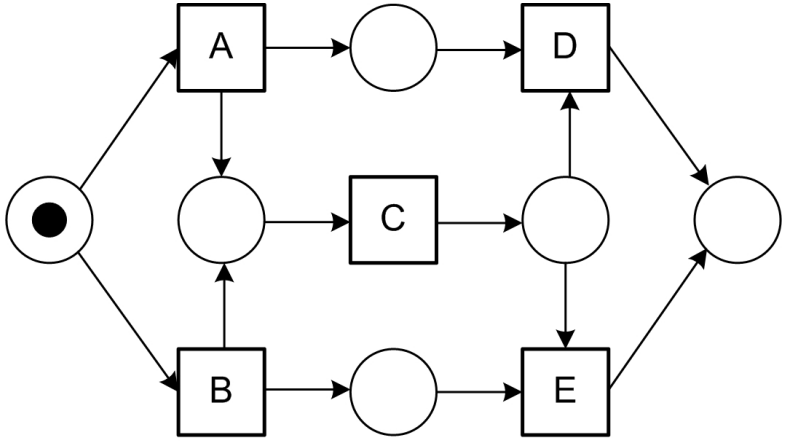

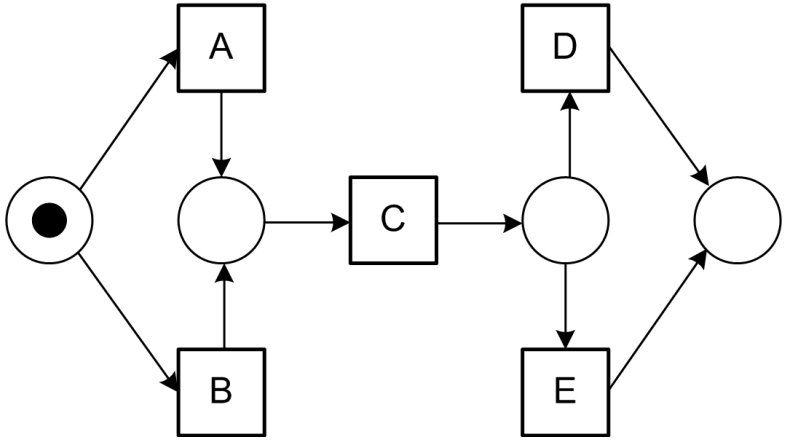

Welches ist das beste Modell?

ACD	99
ACE	88
BCE	85
BCD	78

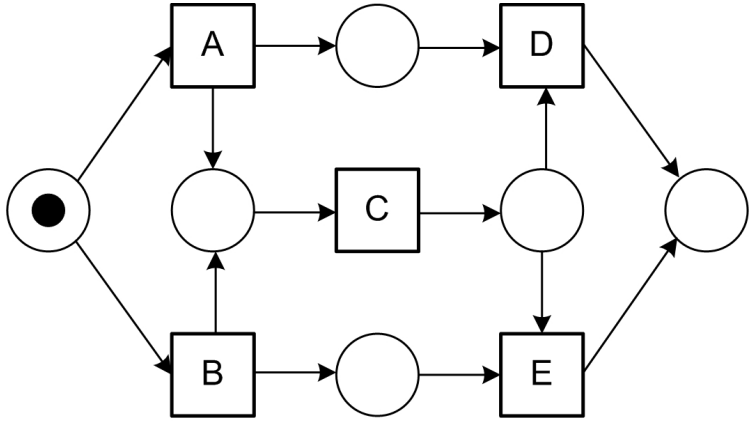

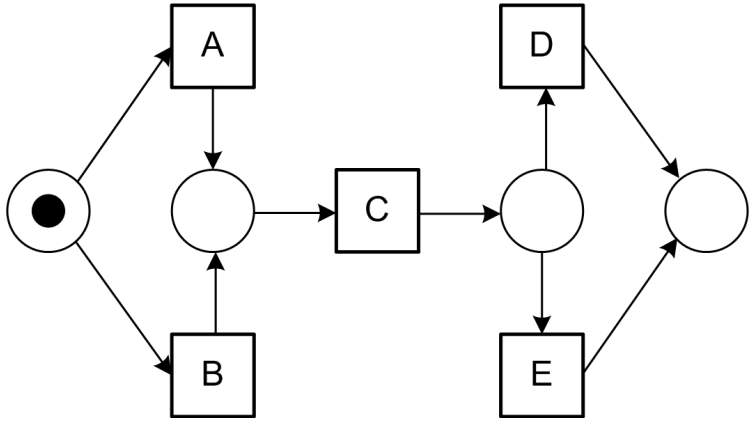

?

Welches ist das beste Modell?

ACD	99
ACE	88
BCE	85
BCD	78

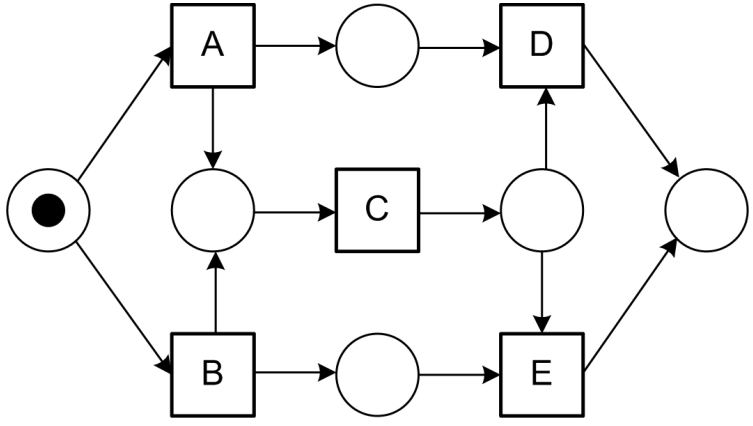

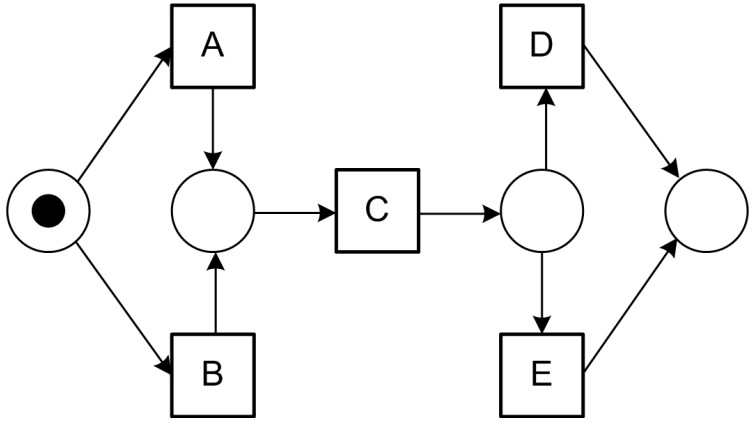

Welches ist das beste Modell?

ACD	99
ACE	2
BCE	85
BCD	3

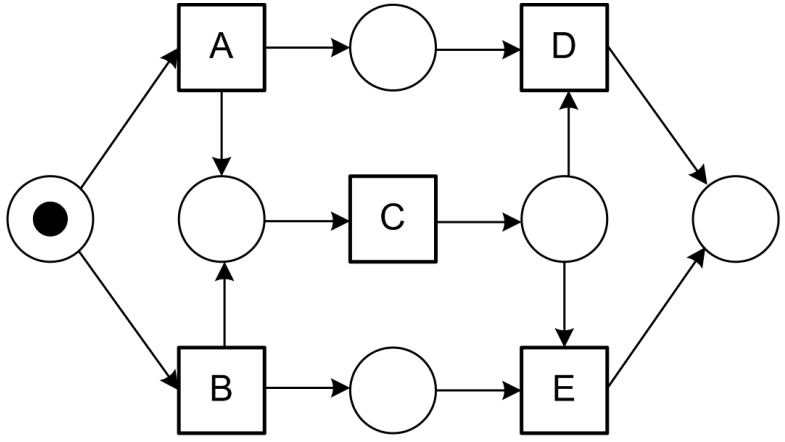

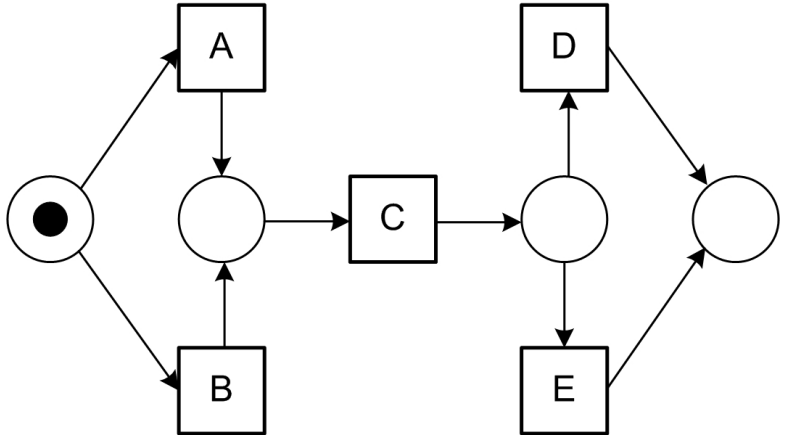

?

Beispiel: Ein Log, vier Modelle

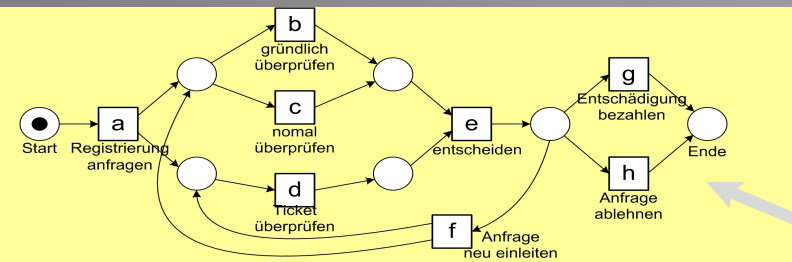

N_1 : *Angemessenheit = +, Genauigkeit = +, Verallgemeinerung = +, Einfachheit = +*

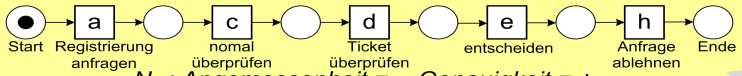

N_2 : *Angemessenheit = -, Genauigkeit = +, Verallgemeinerung = -, Einfachheit = +*

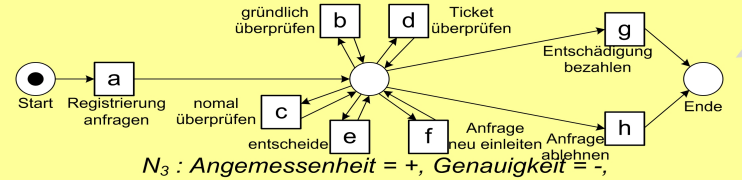

N_3 : *Angemessenheit = +, Genauigkeit = -, Verallgemeinerung = +, Einfachheit = +*

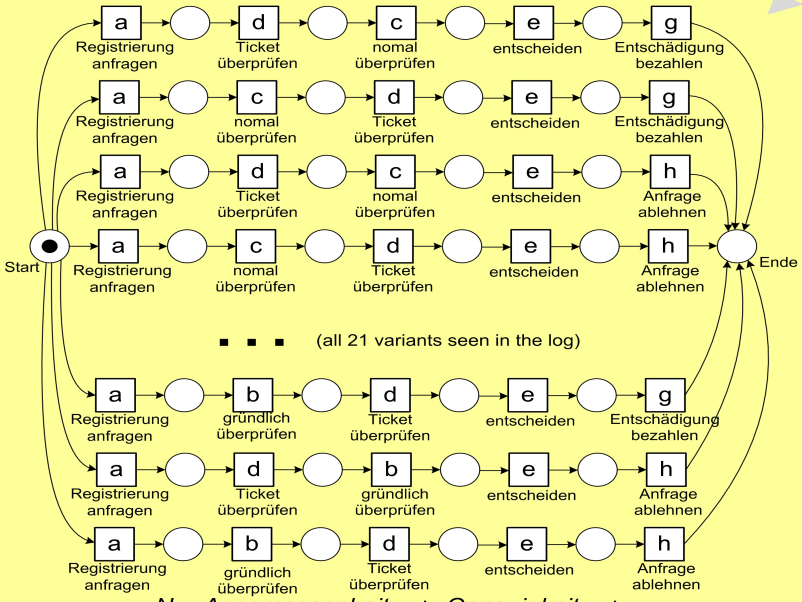

N_4 : *Angemessenheit = +, Genauigkeit = +, Verallgemeinerung = -, Einfachheit = -*

#	Trace
455	acdeh
191	abdeg
177	adceh
144	abdeh
111	acdeg
82	adceg
56	adbeh
47	acdefdbeh
38	adbeg
33	acdefbdeh
14	acdefbdeg
11	acdefdbeg
9	adcefcdeh
8	adcefdbeh
5	adcefbdeg
3	acdefbdefdbeg
2	adcefdbeg
2	adcefbdefbdeg
1	adcefdbefbdeh
1	adbefbdefdbeg
1	adcefdbefcdefdbeg
1391	

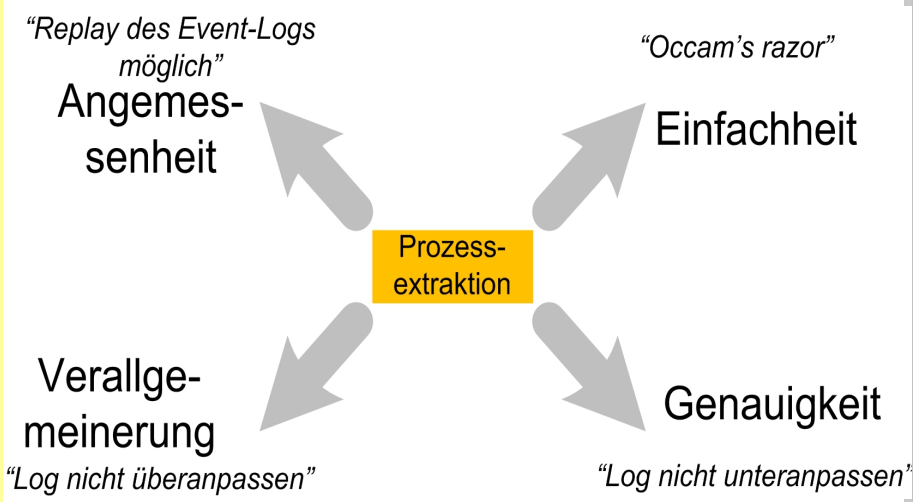

#	trace
455	acdeh
191	abdeg
177	adceh
144	abdeh
111	acdeg
82	adceg
56	adbeh
47	acdefdbeh
38	adbeg
33	acdefbdeh
14	acdefbdeg
11	acdefdbeg
9	adcefcdeh
8	adcefdbeh
5	adcefbdeg
3	acdefbdefdbeg
2	adcefdbeg
2	adcefbdefbdeg
1	adcefdbefbdeh
1	adbefbdefdbeg
1	adcefdbefcdefdbeg
1391	

Modell 1

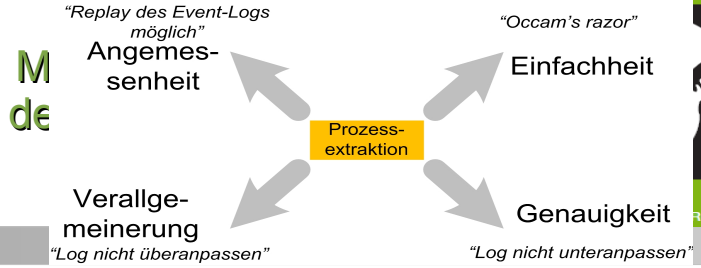

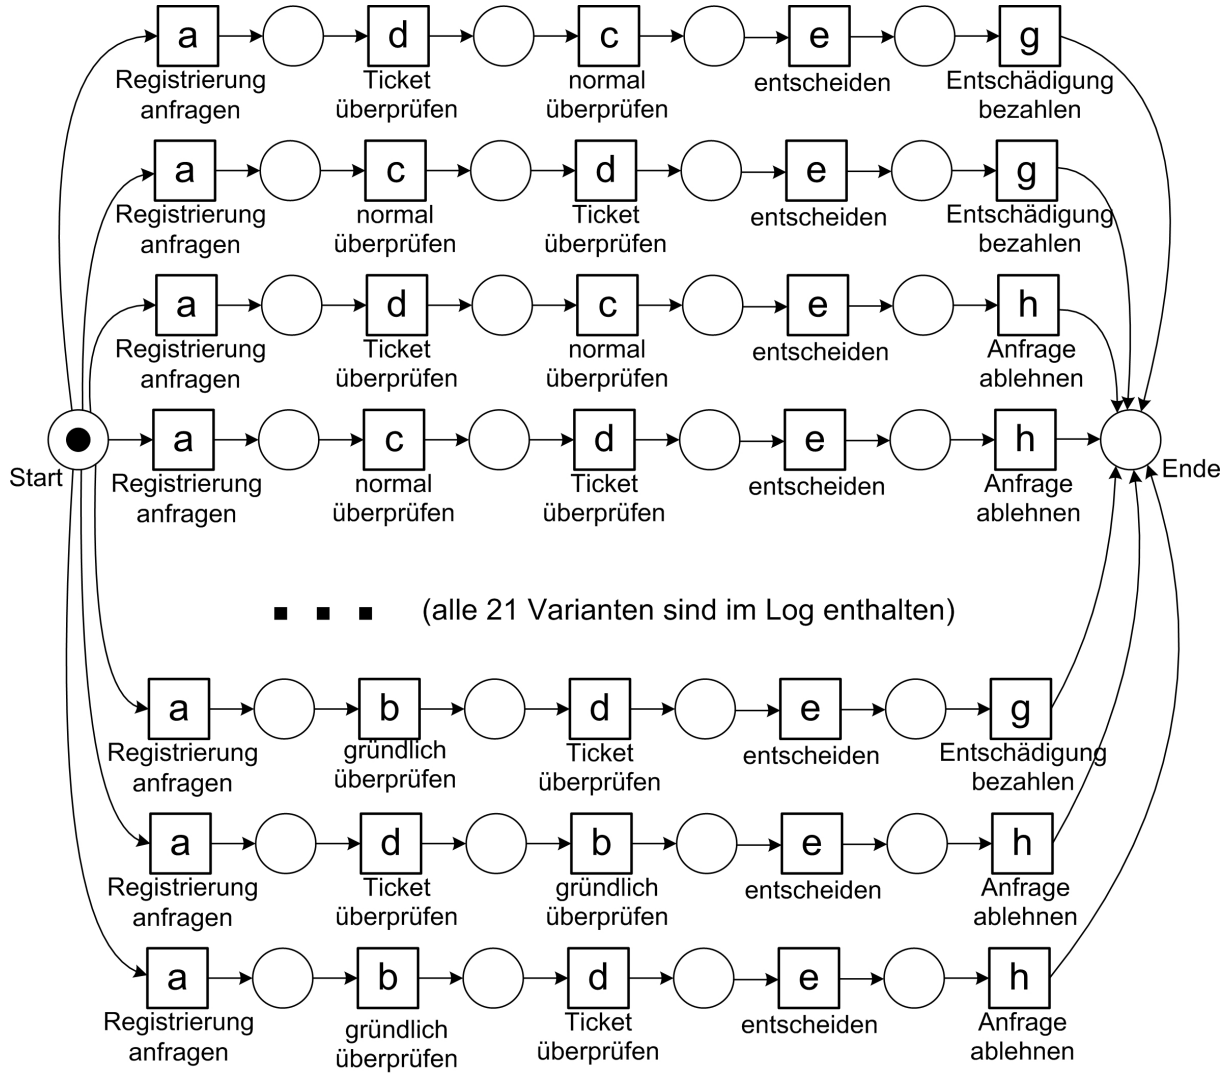

Wie schneidet das Modell bzgl. der 4 Qualitätskriterien ab ?

#	trace
455	acdeh
191	abdeg
177	adceh
144	abdeh
111	acdeg
82	adceg
56	adbeh
47	acdefdbeh
38	adbeg
33	acdefbdeh
14	acdefbdeg
11	acdefdbeg
9	adcefcdeh
8	adcefdbeh
5	adcefbdeg
3	acdefbdefdbeg
2	adcefdbeg
2	adcefbdefbdeg
1	adcefdbefbdeh
1	adbefbdefdbeg
1	adcefdbefcdefdbeg
1391	

Modell 1

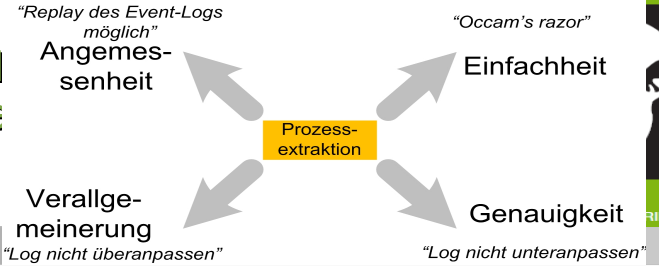

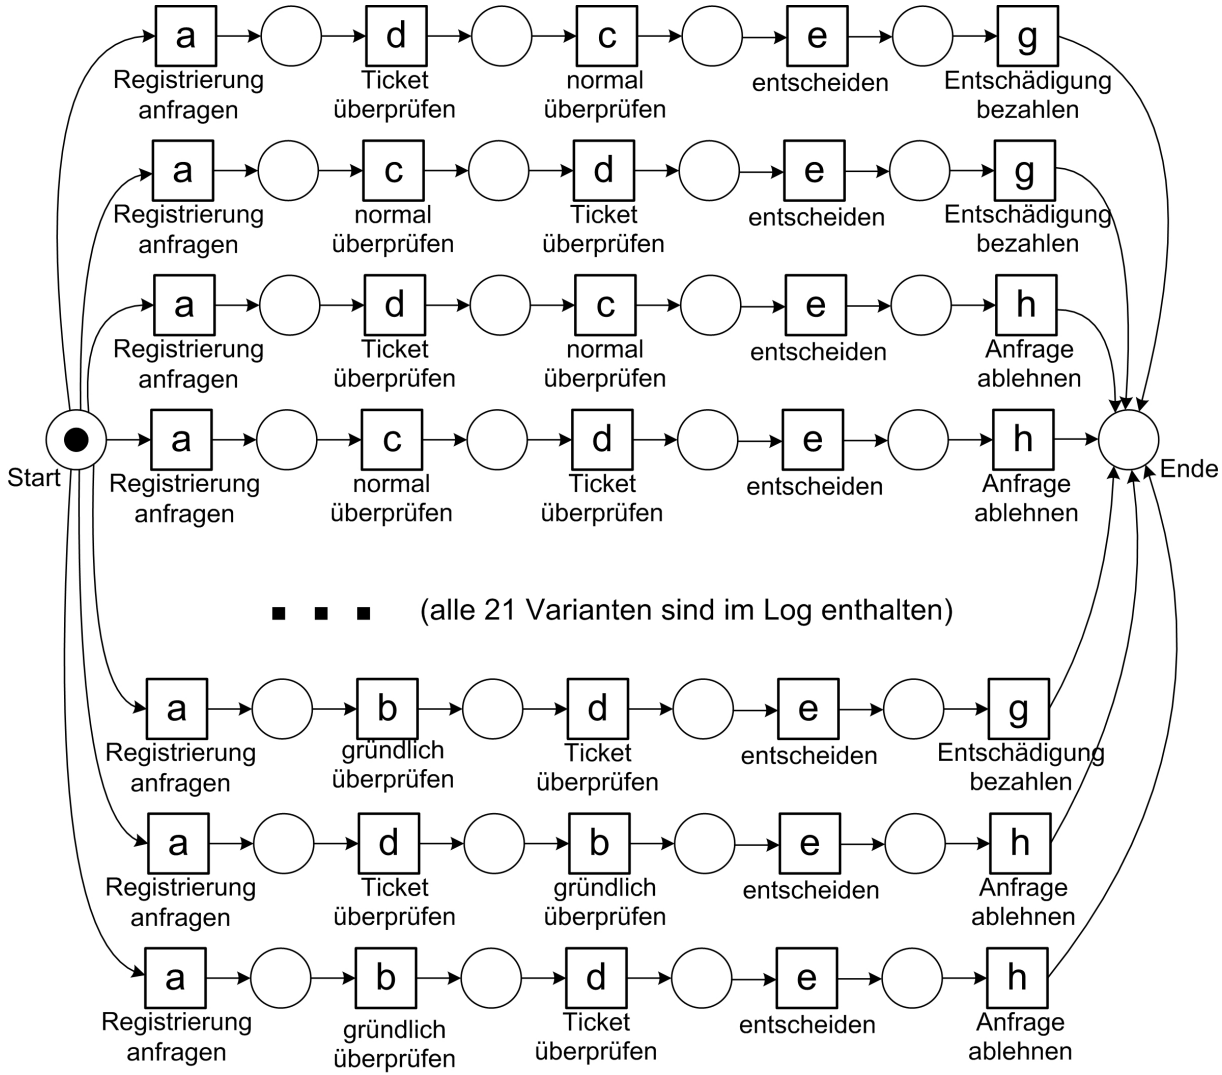

Angemessenheit: + *Genauigkeit: +*

Verallgemeinerung: - *Einfachheit: -*

Modell 2

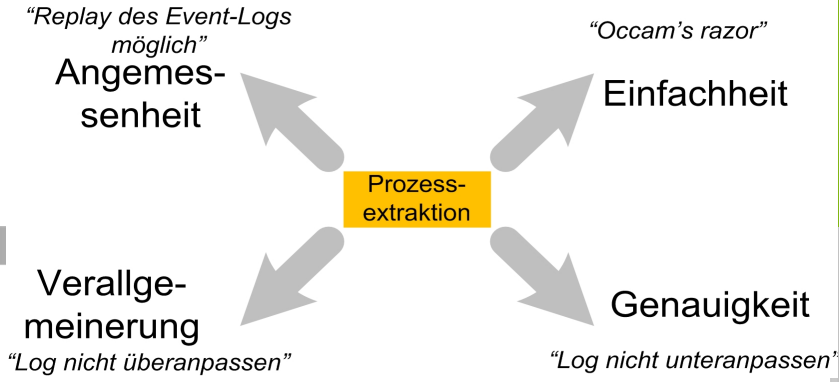

#	trace
455	acdeh
191	abdeg
177	adceh
144	abdeh
111	acdeg
82	adceg
56	adbeh
47	acdefdbeh
38	adbeg
33	acdefbdeh
14	acdefbdeg
11	acdefdbeg
9	adcefcdeh
8	adcefdbeh
5	adcefbdeg
3	acdefbdefdbeg
2	adcefdbeg
2	adcefbdefbdeg
1	adcefdbefbdeh
1	adbefbdefdbeg
1	adcefdbefcdefdbeg
1391	

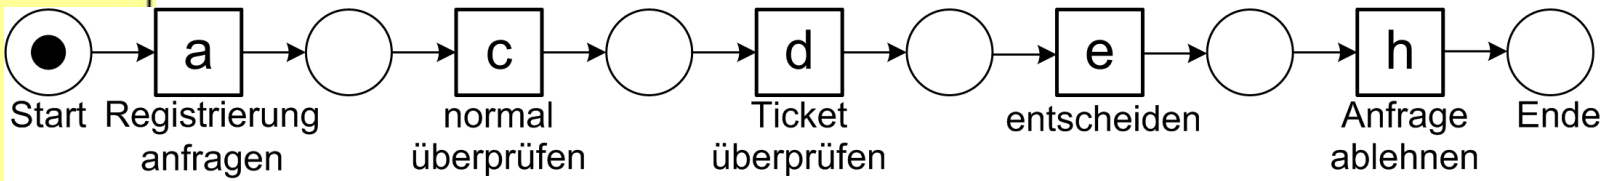

Wie schneidet das Modell bzgl. der 4 Qualitätskriterien ab ?

Modell 2

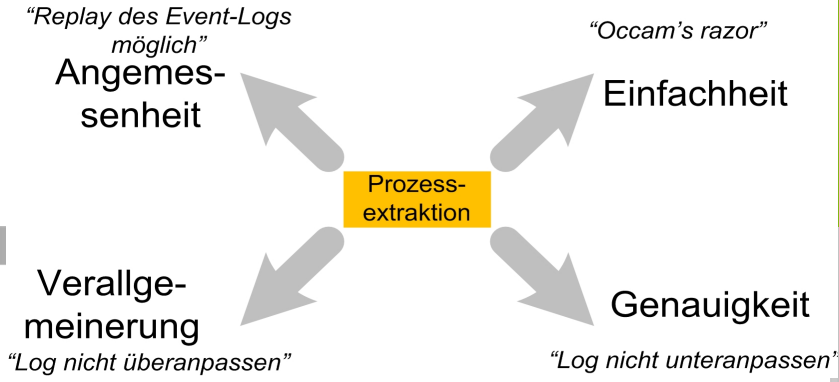

#	trace
455	acdeh
191	abdeg
177	adceh
144	abdeh
111	acdeg
82	adceg
56	adbeh
47	acdefdbeh
38	adbeg
33	acdefbdeh
14	acdefbdeg
11	acdefdbeg
9	adcefcdeh
8	adcefdbeh
5	adcefbdeg
3	acdefbdefdbeg
2	adcefdbeg
2	adcefbdefbdeg
1	adcefdbefbdeh
1	adbefbdefdbeg
1	adcefdbefcdefdbeg
1391	

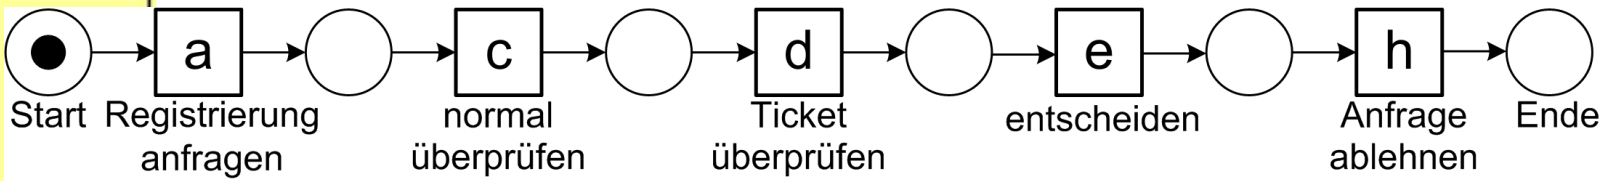

Angemessenheit: - *Genauigkeit: +*

Verallgemeinerung: - *Einfachheit: +*

Modell 3

#	trace
455	acdeh
191	abdeg
177	adceh
144	abdeh
111	acdeg
82	adceg
56	adbeh
47	acdefdbeh
38	adbeg
33	acdefbdeh
14	acdefbdeg
11	acdefdbeg
9	adcefcdeh
8	adcefdbeh
5	adcefbdeg
3	acdefbdefdbeg
2	adcefdbeg
2	adcefbdefbdeg
1	adcefdbefbdeh
1	adbefbdefdbeg
1	adcefdbefcdefdbeg
1391	

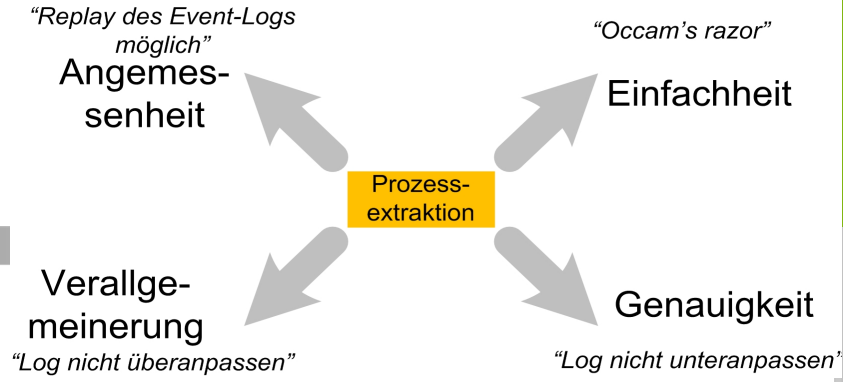

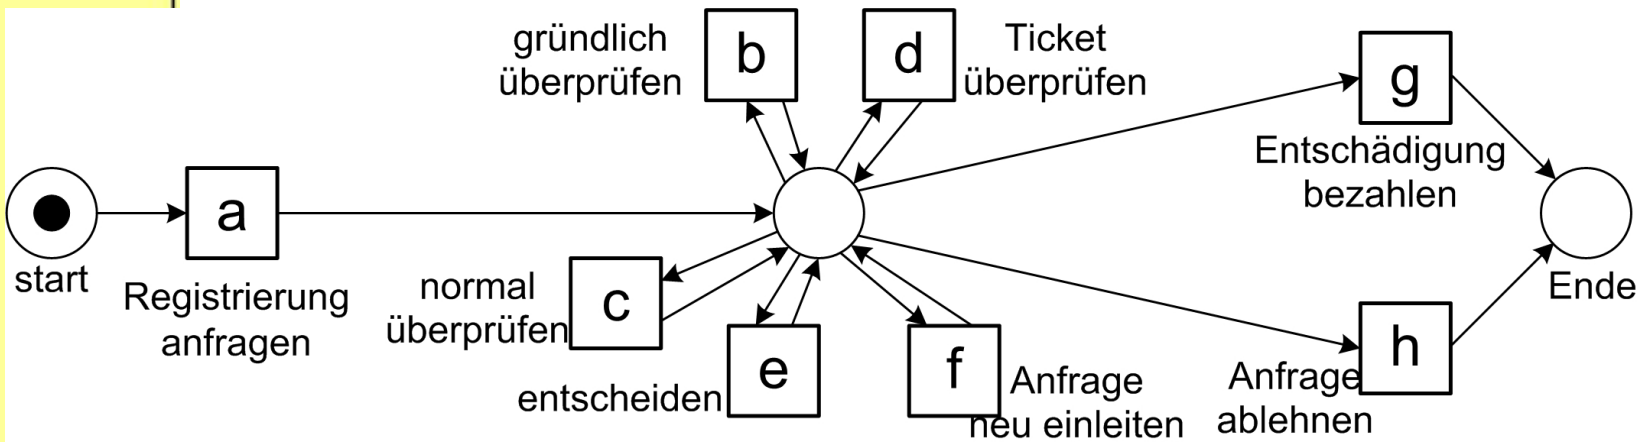

Wie schneidet das Modell bzgl. der 4 Qualitätskriterien ab ?

Modell 3

#	trace
455	acdeh
191	abdeg
177	adceh
144	abdeh
111	acdeg
82	adceg
56	adbeh
47	acdefdbeh
38	adbeg
33	acdefbdeh
14	acdefbdeg
11	acdefdbeg
9	adcefcdeh
8	adcefdbeh
5	adcefbdeg
3	acdefbdefdbeg
2	adcefdbeg
2	adcefbdefbdeg
1	adcefdbefbdeh
1	adbefbdefdbeg
1	adcefdbefcdefdbeg
1391	

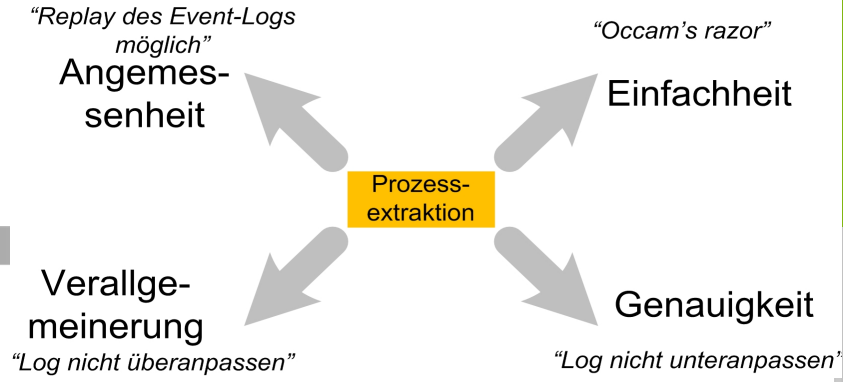

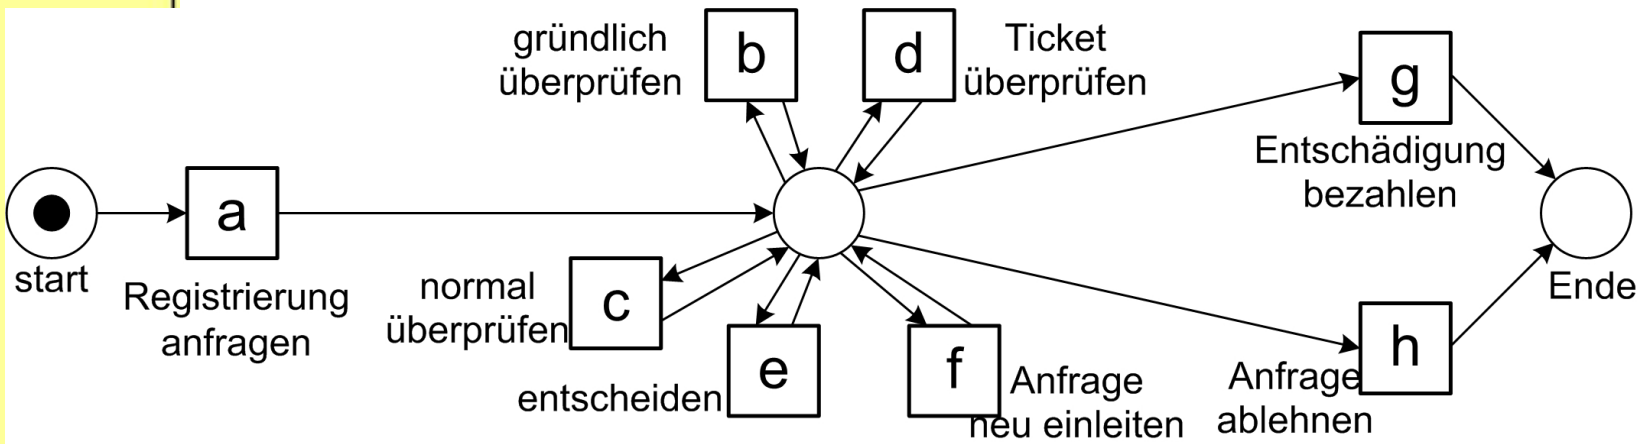

Angemessenheit: + *Genauigkeit: -*

Verallgemeinerung: + *Einfachheit: +*

Modell 4

#	trace
455	acdeh
191	abdeg
177	adceh
144	abdeh
111	acdeg
82	adceg
56	adbeh
47	acdefdbeh
38	adbeg
33	acdefbdeh
14	acdefbdeg
11	acdefdbeg
9	adcefcdeh
8	adcefdbeh
5	adcefbdeg
3	acdefbdefdbeg
2	adcefdbeg
2	adcefbdefbdeg
1	adcefdbefbdeh
1	adbefbdefdbeg
1	adcefdbefcdefdbeg
1391	

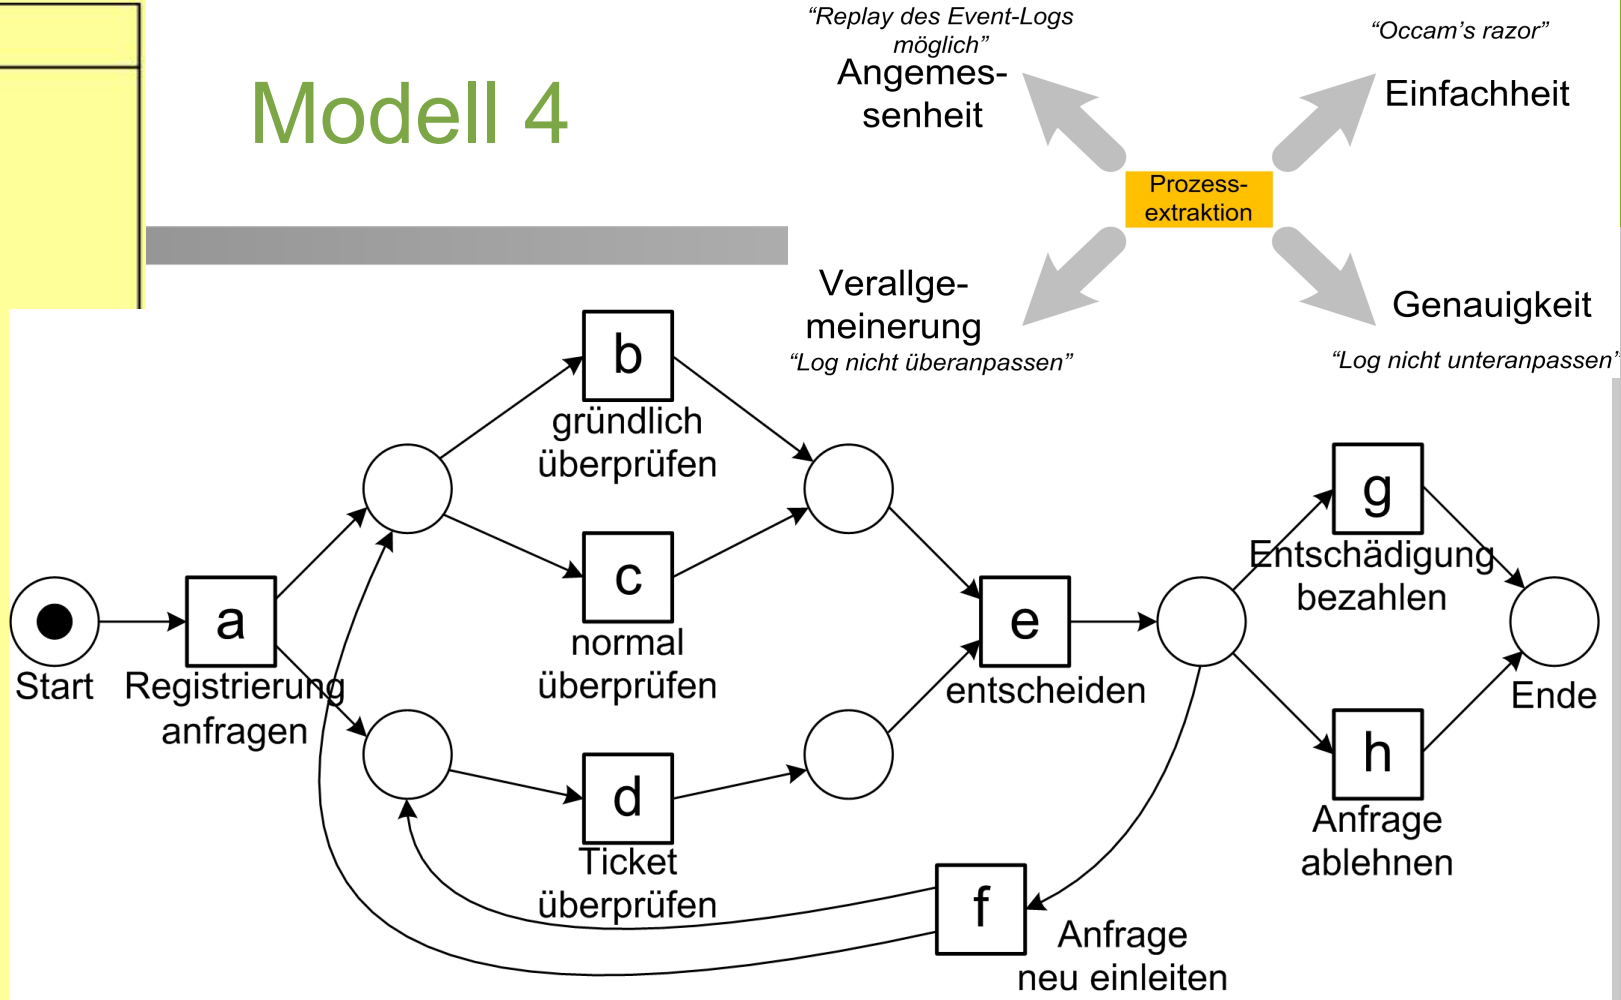

Wie schneidet das Modell bzgl. der 4 Qualitätskriterien ab ?

#	trace
455	acdeh
191	abdeg
177	adceh
144	abdeh
111	acdeg
82	adceg
56	adbeh
47	acdefdbeh
38	adbeg
33	acdefbdeh
14	acdefbdeg
11	acdefdbeg
9	adcefcdeh
8	adcefdbeh
5	adcefbdeg
3	acdefbdefdbeg
2	adcefdbeg
2	adcefbdefbdeg
1	adcefdbefbdeh
1	adbefbdefdbeg
1	adcefdbefcdefdbeg
1391	

Modell 4

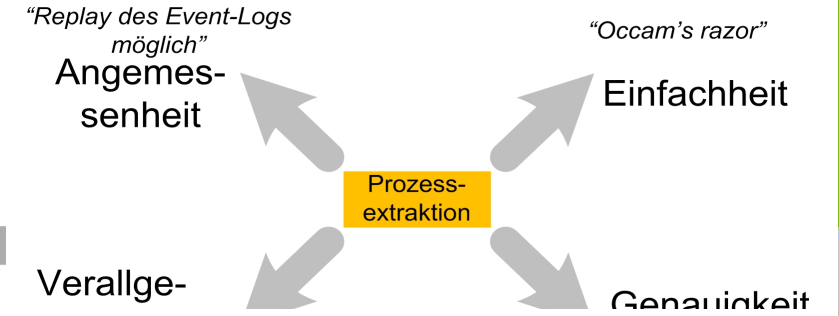

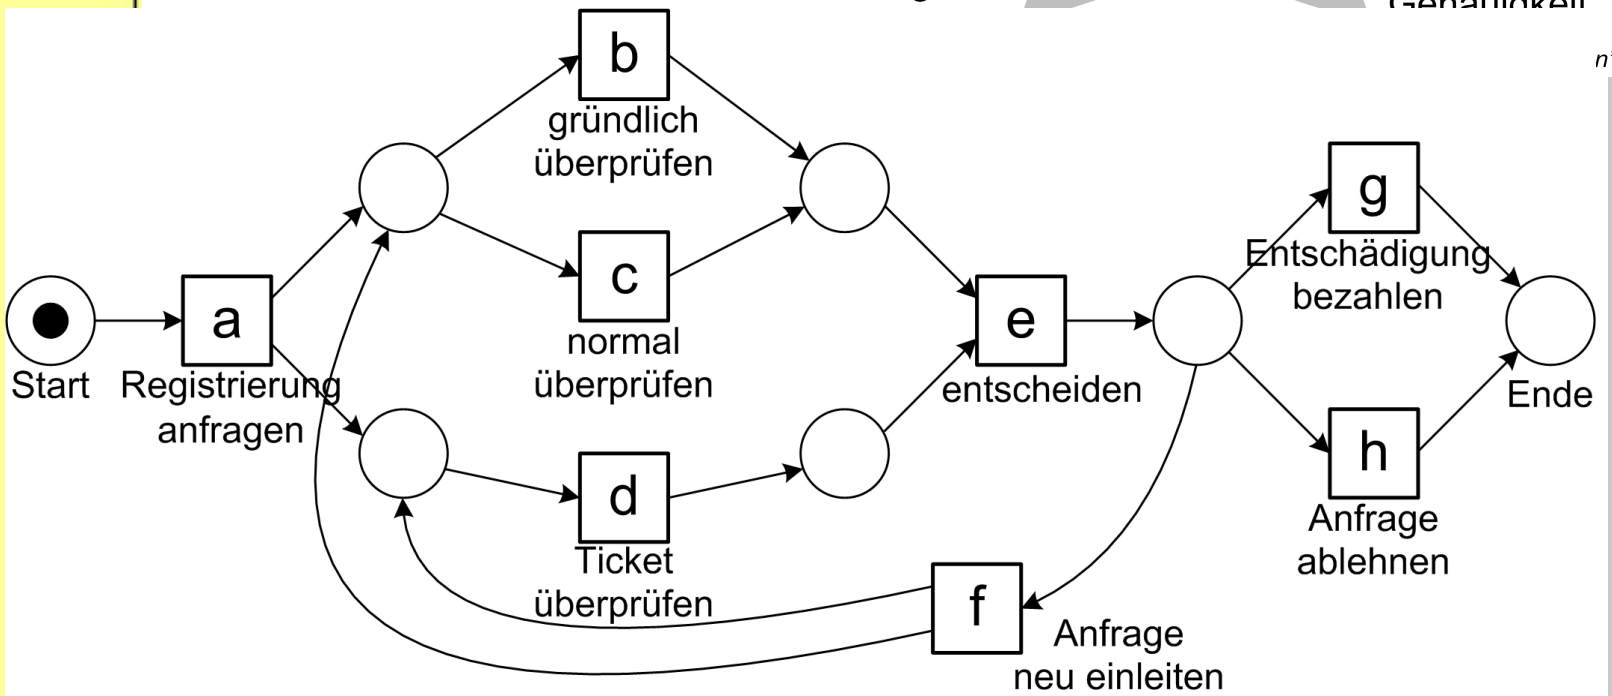

Angemessenheit: + *Genauigkeit:* +

Verallgemeinerung: + *Einfachheit:* +

Was macht Process-Mining zu so einem schweren Problem?

- Keine negativen Beispiele:
  Logs zeigen, was geschah. Aber nicht: was nicht passieren kann.
- Durch Nebenläufigkeit, Schleifen, Verzweigungen:
  Suchraum hat komplexe Struktur.
  Log enthält typischerweise nur Teil des möglichen Verhaltens.
- Kein klarer Zusammenhang zwischen **Größe des Modells** und seinem **Verhalten**.
  - Kleines Modell kann mehr oder weniger Verhalten generieren.
  - Klassische Analyse- und Evaluations-Methoden erwarten typischerweise Monotonie-Eigenschaften.

Zusammenfassung
2.5 Prozessextraktion

- Einführung und Beispiel
- α-Algorithmus
  - Idee und Vorbereitungen
  - Formalisierung
  - Beispiel
  - Weitere Beispiele
  - Einschränkungen
- Allgemeine Herausforderungen beim Process-Mining