

# Luento 2

## Todennäköisyyslaskennan perusteet, bayesiläinen analyysi

Jan-Erik Holmberg  
Systeemianalyysin laboratorio  
Matematiikan ja systeemianalyysin laitos  
Aalto-yliopiston perustieteiden korkeakoulu  
PL 11100, 00076 Aalto  
[jan-erik.holmberg@aalto.fi](mailto:jan-erik.holmberg@aalto.fi)

# Boolean algebra

- Muuttujat  $A, B, \dots$  voivat olla *joukkoja, tapahtumia* tai *lauseita*
- Kullakin voi olla kaksi tilaa, joita yleensä merkitään 1 ja 0
- $\varphi(A) = 1$  tarkoittaa “kuuluu joukkoon  $A$ ”, “ $A$  ei ole toimintakunnossa” tai “Lause  $A$  tosi”
- $\varphi(A) = 0$  tarkoittaa “ei kuulu joukkoon  $A$ ”, “ $A$  on toimintakunnossa” tai “Lause  $A$  epätosi”
- Perusoperaatiot:

	Joukko	Lause	Tapahtuma	
Unioni	$A \cup B$	$A$ tai $B$	$A + B$	Looginen summa
Leikkaus	$A \cap B$	$A$ ja $B$	$A \cdot B$	Looginen tulo
Negaatio	$\neg A$	ei $A$	$\bar{A}$	Komplementti

- Luotettavuusteoriassa käytetään yleensä merkintöjä  $+$ ,  $\cdot$ ,  $-$

## Boolean algebra

- $\Omega$  = täydellinen joukko, varma tapahtuma tai aina tosi lause, joka saa arvon 1 aina (riippumatta A:n ja B:n “arvosta”)
- $\phi$  = tyhjä joukko, aina epätosi, mahdoton tapahtuma, joka saa “arvon” 0 aina
- $\varphi(\Omega) = 1, \varphi(\phi) = 0$

# Boolean algebran lisämääritelmiä

- $B - A = \bar{A} \cdot B$
- A ja B ovat *toisensa poissulkevia*,  
joss  $A \cdot B = \phi$ 
  - esim. A ja  $\bar{A}$  ovat toisensa poissulkevia

# Boolean algebran laskentalait

- $A + \bar{A} = \Omega$
- $A \cdot \bar{A} = \phi$
- $A + \Omega = \Omega$
- $A + \phi = A$
- $\Omega \cdot A = A$
- $\phi \cdot A = \phi$

## Vaihdantalait

- $A \cdot B = B \cdot A$
- $A + B = B + A$

## Liitälait

- $A \cdot (B \cdot C) = (A \cdot B) \cdot C$
- $A + (B + C) = (A + B) + C$

## Osittelulait

- $A \cdot (B + C) = A \cdot B + A \cdot C$
- $A + (B \cdot C) = (A + B) \cdot (A + C)$

## Supistuslait

- $A \cdot A = A$
- $A + A = A$

## Absorptiolait

- $A + AB = A$
- $A \cdot (A + B) = A$

## de Morganin säännöt

- $\overline{A \cdot B} = \bar{A} + \bar{B}$
- $\overline{A + B} = \bar{A} \cdot \bar{B}$

# Summan esittäminen toisensa poissulkevan termin avulla

- $A + B = A + \bar{A} \cdot B$
- Hyödyllinen luotettavuustekniikan sovelluksissa
- $A$  ja  $\bar{A} \cdot B$  ovat toisensa poissulkevia

# Todennäköisyysteoria

- Todennäköisyys on joukon, tapahtuman tai lauseen totuuden mitta
- $P(A)$  = Todennäköisyys sille, että tapahtuma kuuluu joukkoon  $A$ , eli että  $\varphi(A) = 1$
- Frekvenssitulkinta on suhteellinen osuus suuressa määrässä tilanteita, joissa mahdollisuusjoukko toistuu antaen tapahtuman  $A$  (lause  $A$  toteutuu)  
$$P(A) = \lim_{N \rightarrow \infty} N(A)/N$$
- Subjekttiivinen tulkinta:  $P(A)$  on mitta sille kuinka vahvasti uskotaan tapahtuman  $A$  toteutuvan

# Kolmogorovin aksioomat

- $0 \leq P(A)$
- $P(\Omega) = 1$
- Kaikille toisensa poissulkeville tapahtumille A ja B  
( $A \cap B = \phi$ )  
$$P(A \cup B) = P(A) + P(B)$$



# Ehdollinen todennäköisyys

$P(A|C)$  = A:n ehdollinen todennäköisyys, ehdolla C  
= tapahtumien A osuus niiden tapahtumien joukossa joissa C tapahtuu

= niiden tapahtumien osuus, joissa tapahtuu sekä A että C jaettuna niiden tapahtumien osuudella, joissa C tapahtuu

$$P(A|C) = P(A \cdot C) / P(C), \text{ vastaavasti } P(C|A) = P(A \cdot C) / P(A)$$

$$P(A \cdot C) = P(C) \cdot P(A|C) = P(A) \cdot P(C|A)$$

- Usein C edustaa jotakin syysuuretta ja A havaintosuuretta ja kiinnostaa tietää millä todennäköisyydellä syy C on aiheuttanut havainnon A

## Bayesin kaava

- $P(C|A) = P(A|C) \cdot P(C) / P(A)$
- sovelletaan myöhemmin luotettavuusparametrien estimoinnissa

# Tilastollinen riippumattomuus

## Määritelmä

- B on riippumaton (tilastollisesti riippumaton) A:sta, jos  $P(B | A) = P(B)$

## Seuraus

- Jos B on riippumaton A:sta niin A on riippumaton B:stä
- Keskenään riippumattomille A ja B siis on  $P(A \cdot B) = P(A) \cdot P(B)$
- Ei ole sama asia kuin toisensa poissulkevuus!

# Satunnaismuuttuja ja todennäköisyysjakauma

- Satunnaismuuttuja  $X$  on reaaliarvoinen
- Sen realisaatio  $x$  voi saada arvoja joukossa  $\mathbb{R}$  eli  $\Omega = \{-\infty, \infty\}$
- Satunnaismuuttujan todennäköisyysjakauma
$$F(x) = P(X \leq x) \Rightarrow P(X > x) = 1 - F(x)$$
- Ollakseen todennäköisyysjakauma  $F(x)$ :lle pätee
  - $F(x) \geq 0$
  - $F(\infty) = 1$
  - $F(x)$  on monotonisesti kasvava:  $x > y \Rightarrow F(x) \geq F(y)$

## Jatkuva satunnaismuuttuja

- Satunnaismuuttuja  $X$  on jatkuva, jos  $F(x)$  on kaikkialla jatkuva
- $X$ :n todennäköisyystiheys on
  - $f(x) = dF(x) / dx$


# Diskreetti satunnaismuuttuja

- Satunnaismuuttuja  $X$  on diskreetti, jos se voi saada vain erillisiä arvoja tai numeroituvan määrän  $\Omega = \{x_1, x_2, \dots\}$
- Tällöin  $F(x)$  on porraskäyrä, joka kasvaa epäjatkovasti pisteissä  $x_i$  ja on vakio pisteiden välillä
- Todennäköisyysjakauma esitetään pistetodennäköisyysfunktion  $p_i = P(X = x_i)$  avulla
  - $0 \leq p_i \leq 1$
  - $F(x) = \sum_{x_i \leq x} p_i$
  - $\sum_i p_i = 1$

# Jakauman keskikohdan mittoja

Odotusarvo (keskiarvo)  $m_1 = E(X)$

- $E(X) = \int x f(x) dx$  tai
- $E(X) = \sum_i p_i x_i$



Mediaani  $x_{50}$

- $F(x_{50}) = 0,5$

Moodi

- todennäköisin arvo, tiheysfunktion maksimikohta

# Jakauman leveyden mittoja

Fraktiili (persentiili), esim.  $\alpha$ -fraktiili

- $F(x_\alpha) = \alpha$
- tyypillisesti kiinnostavat  $x_{05}$  ja  $x_{95}$

Varianssi  $V(x)$

- $V(x) = E[(x - m_1)^2]$
- Keskihajonta on varianssin neliöjuuri

Epävarmuuskerroin EF (Error Factor)

- lognormaalijakaumassa  $EF = x_{95}/x_{50} = x_{50}/x_{05}$
- muutoin yleensä  $x_{95}/x_{50} \neq x_{50}/x_{05}$ , jolloin  $EF = x_{95}/x_{50}$   
tai  $EF = x_{50}/x_{05}$  tai  $EF = \sqrt{x_{95}x_{05}}$



## Yhteisjakauma

- $F_{XY}(x, y) = P(X \leq x, Y \leq y)$
- tiheysfunktio  $f_{XY}(x, y)$

### Reunajakauma

- $f_X(x) = \int f_{XY}(x, y) dy$

### Ehdollinen jakauma

- $f(x|y) = f_{XY}(x, y) / f_Y(y)$

Jos  $X$  ja  $Y$  ovat tilastollisesti riippumattomia

$$f_{XY}(x, y) = f_X(x)f_Y(y)$$

# Satunnaismuuttujien summan $Z = X + Y$ jakauma

- Tunnetaan  $f_x(x)$  ja  $f_y(y)$
- Mikä on  $f_z(z)$ ?
- Käsitellään erityistapaus, että  $x$  ja  $y$  toisistaan riippumattomia
- Tällöin  $f_z(z)$  voidaan lasketaan konvoluutiointegraalina

$$f_z(z) = \int_{-\infty}^z f_x(z - y) f_y(y) dy$$

- Luotettavuustekniikassa kyseistä kaavaa tarvitaan esim. kahden peräkkäisen vikavälin tai vikaantumisajan ja korjausajan summan jakauman laskemiseksi

# Esimerkki diskreetistä jakaumasta

## Bernoullin jakauma

- $X$ :llä on kaksi mahdollista arvoa  $\{0,1\}$
- $P(X = 1) = p$
- $P(X = 0) = q = 1 - p$

Tunnusluvut:

- $EX = p$
- $\text{Var}(X) = p(1 - p)$


# Esimerkki diskreetistä jakaumasta

## binomijakauma

- $n$ :n toisistaan riippumattoman Bernoulli-jakautuneen muuttujan summa
- $Y = X_1 + \dots + X_n$
- $p(Y = k) = \binom{n}{k} p^k (1 - p)^{n-k}, k = 0, \dots, n$

Tunnusluvut:

- $EY = np$
- $\text{Var}(Y) = np(1 - p)$



# Multinomiaalijakauma

- Yleistys binomijakaumasta, joka on summa Booleanarvoisten muuttujien lukumäärästä
- Yleisemmin muuttujalla on diskreetti äärellinen määrä arvoja  $j = 1, \dots, k$
- Todennäköisyys  $P(X_i = j) = p_j$ , ja  $p_j$ :tten summa on 1
- Soveltuu esim. luokiteltuun vikadataan, jossa on useampia toisensa poissulkevia vikamoodeja
- Jokaisen luokan  $j$  reunajakauma on binomijakauma


# Esimerkki jatkuvasta jakaumasta

## Ekspontiaalijakauma

- Tiheysfunktio  $f(t) = \lambda \cdot \exp\{-\lambda t\}$ ,  $t \geq 0$
- Kertymäfunktio  $F(t) = 1 - \exp\{-\lambda t\}$

Tunnusluvut:

- $ET = 1/\lambda$
- $\text{Var}(T) = 1/\lambda^2$



# Esimerkki jatkuvasta jakaumasta


## Erlangin jakauma

- $n$ :n toisistaan riippumattoman eksponentiaalijakautuneen muuttujan summa  $S = T_1 + \dots + T_n$

$$f(s) = \lambda \frac{(\lambda s)^{n-1}}{(n-1)!} e^{-\lambda s}$$

- Tunnusluvut:  
 $E[S] = n / \lambda$   
 $\text{Var}[S] = n / \lambda^2$
- kuuluu gammajakaumien perheeseen

$$f(s) = \lambda \frac{\beta^\alpha}{\Gamma(\alpha)} x^\alpha e^{-\beta x}$$



# Todennäköisyystulkinnat (1/2)

- Subjekttiivinen todennäköisyys
  - Kuvastaa kaiken käytettävissä olevan tietämyksen varaan perustuvaa näkemystä siitä, miten mahdollisena tapahtuman toteutumista pidetään
  - Näkökohtia
    - » ”Kaikkea tietämystä” vaikea hankkia
    - » Näkemykset voi poiketa toisistaan tai olla ristiriitaisia
    - » Näkemykset päivitettävissä Bayesin kaavalla

$$P(H|E) = \frac{P(E|H)P(H)}{P(E)},$$

- » missä  $P(H)$  = Hypoteesin a priori tn  
 $P(E)$  = Evidenssin saamisen tn  
 $P(H|E)$  = Hypoteesin posteriori tn
- Todennäköisyydet riskianalyysissä
  - Ilmiöt monesti harvinaisia eivätkä toistettavissa
  - Sovelletaan usein subjektiivisia todennäköisyyksiä
  - Hyödynnetään käytettävissä olevia ja relevantteja tilastoja



# Todennäköisyystulkinnat (2/2)

- Frekventistinen tulkinta

- Todennäköisyys on raja-arvo, joka saadaan tarkastelemalla tilastollisesti äärettömän isoksi kasvavaa aineistoa
- Esim. kruunan (eng. head) todennäköisyys saadaan raja-arvona sarjasta

$$P_H = \frac{N_H}{N}, N \rightarrow \infty,$$

jossa kolikkoa heitetään äärettömän monesti ja

jossa  $N$  = kaikkien heittojen määrä ja  
 $N_H$  = saatujen klaavojen määrä

- Näkökohtia

- Reaali-ilmiöillä riittäviä toistoja ei voida tehdä
  - » Mahdotonta, liian kallista, liian hidasta
  - » Esim. tuotannonohjaus, koronnostot, suojavallit
- Toistot eivät tapahdu identtisissä olosuhteissa
- Tilastot antavat kuitenkin tukea muille analyyseille

# Luotettavuusparametrien estimointi

- Klassinen estimointi
- Bayes

# Klassinen estimointi

- Satunnaismuuttuja  $X$
- Kertymäfunktio  $F(x; \theta_1, \dots, \theta_r)$
- Parametrit  $(\theta_1, \dots, \theta_r)$  tuntemattomia
- Otos eli havainnot  $(x_1, \dots, x_n)$
- Mitkä parametrien arvot kuvaavat parhaiten  $X$ :n todennäköisyysteoreettista käyttäytymistä?
- Estimointi tapahtuu sijoittamalla havainnot kaavaan eli estimaattoriin, jonka antama tulosta käytetään parametrin estimaattina
- Piste-estimaatti on estimaattorin antama likiarvo estimoitavalle parametrille
- Väliestimaatti on otoksen ja estimaattorin määräämä väli, jonka sisäpuolella estimoitavan parametrin todellinen arvo jää annetulla todennäköisyydellä

# Maximum likelihood eli suurimman uskottavuuden menetelmä

- Likelihoodfunktio  $L(\theta) = f(x_1 ; \theta) \cdot \dots \cdot f(x_n ; \theta)$ , missä  $f(x_1 ; \theta)$  on tiheysfunktio
- Maximum likelihood –estimaatti on se joka maksimoi likelihoodfunktion eli havaittu otos on todennäköisin sillä arvolla

# Momenttimenetelmä

- Satunnaismuuttujan momentti

$$m_k(\theta) = E[X^k] = \int_{-\infty}^{\infty} x^k f(x) dx$$

- Esimerkiksi  $m_1$  on odotusarvo

- Otosmomentti

$$\hat{m}_k = \frac{1}{n} \sum_{i=1}^n X_i^k$$

- Jos parametreja on yksi, ratkaistaan  $m_1(\theta) = \hat{m}_1$
- Jos parametreja on  $k$  kpl, muodostetaan yhtälöryhmä momenteista  $i = 1, \dots, k$

## Binomijakauman $p$

- Otos  $n$  havaintoa, joista  $k$  kpl 1:ä ja  $n-k$  0:a
- Satunnaismuuttuja  $X$  on 1:sten lukumäärä, ja on binomijakautunut parametrilla  $p$
- Likelihoodfunktio

$$L(p) = P(X = k; p) = \binom{n}{k} p^k (1 - p)^{n-k}$$

- Derivoimalla  $p$ :n suhteen saadaan maksimi

$$\hat{p} = \frac{k}{n}$$

# Poisson-prosessin (eksponenttijakauman)

## $\lambda$

- Otos  $n$  havaintoa ajanjaksolla  $T$
- Satunnaismuuttuja  $X$  on havaintojen lukumäärä ja se on Poisson-jakautunut parametrilla  $\lambda T$
- Likelihoodfunktio

$$L(\lambda) = P(X = n; \lambda T) = \frac{(\lambda T)^n}{n!} \exp(-\lambda T)$$

- Derivoimalla  $\lambda$ :n suhteen saadaan maksimi

$$\hat{\lambda} = \frac{n}{T}$$

# Bayes

- Parametrit  $(\theta_1, \dots, \theta_r)$  käsitellään satunnaismuuttujina
- Likelihoodfunktio on ehdollinen todennäköisyys havaita otos  $(x_1, \dots, x_n)$  ehdolla tietyt parametrin arvot
- Parametrien priorijakauma päivitetään Bayesin kaavan avulla

$$P(\theta | E) = \frac{L(E|\theta)p(\theta)}{\int_{\theta \in \Theta} L(E|\theta)p(\theta)d\theta}$$



# Bayesiläinen analyysi, binomijakauman $p$

- Havainnot  $E = \{k_1, \dots, k_n\}$  ovat Bernoullijakaumasta (0 tai 1),  $P(k_i = 1) = p$
- Jos havainnot ovat riippumattomia, on likelihoodfunktio

$$L(p) = P(X = k; p) = \binom{n}{k} p^k (1 - p)^{n-k}$$

- Priorijakaumaksi valitaan tässä tapauksessa yleensä betajakauma, koska se on konjugaattijakauma binomiotannalle => Posteriorijakauma on myös beta

$$f(p; \alpha, \beta) = \frac{\Gamma(\alpha + \beta)}{\Gamma(\alpha)\Gamma(\beta)} p^{\alpha-1} (1 - p)^{\beta-1}$$

$$p \sim \text{Beta}(\alpha, \beta)$$

# Binomijakauman $p$ posteriorijakauman

- Posteriorijakaumaksi tulee

$$p \sim \text{Beta}(\alpha + k, \beta + n - k)$$

# Binomijakauman $p:n$ priorijakauma

- Kirjallisuudessa esitetään erilaisia vaihtoehtoja
  - Beta(0;0) = toimii vain jos  $0 < k < n$
  - Beta(0,5;0,5) = ns. epäinformatiivinen prior
  - Beta(1; 1) = tasajakauma
- Beta(0,5;0,5) on yleisimmin käytetty
- Posteriorijakauman odotusarvo

$$E[p|k, n] = \frac{k + 1/2}{n + 1}$$

# Poisson-prosessin lambda

- Satunnaismuuttuja  $X$  on havaintojen lukumäärä ja se on Poisson-jakautunut parametrilla  $\lambda T$
- Likelihoodfunktio

$$L(\lambda) = P(X = n; \lambda T) = \lambda^n \exp(-\lambda T)$$

- Priorijakaumaksi valitaan tässä tapauksessa yleensä gammajakauma, koska se on konjugaattijakauma Poisson-otannalle => Posteriorijakauma on myös gamma

$$f(\lambda; \alpha, \beta) = \frac{\beta^{\alpha-1}}{\Gamma(\alpha)} \lambda^{\alpha-1} e^{-\beta\lambda}$$

$$\lambda \sim \text{Gamma}(\alpha, \beta)$$

# Poisson-prosessin lambda posteriorijakauma

- Posteriorijakaumaksi tulee

$$p \sim \text{Gamma}(\alpha + k, \beta + T)$$

# Poisson-prosessin lambdan priorijakauma

- Gamma(0,5;0) = epäinformatiivinen priori ja yleisimmin käytetty
- Posteriorijakauman odotusarvo


$$E[\lambda|k, T] = \frac{k + 1/2}{T}$$

# Kaksivaiheinen estimointi heterogeenisestä populaatiosta

- Vikatapahtumia kerätään useammalta laitokselta
- Laitoskohtainen data homogeenista
- Laitosten välillä eroa
  
- Esim. komponentin vikatodennäköisyys  $p_i$  laitoksella  $i$ ,  $i = 1, \dots, M$
- Parametrit  $p_i$ ,  $i = 1, \dots, M$  estimoidaan yhteisesti kaikkien laitosten datasta, mutta oletetaan että  $p_i$  voi vaihdella laitoksittain
- Laitoskohtaisesti likelihoo-funktio kuten edellisissä kalvoissa
- Käytössä on erilaisia tapoja tehdä ”hierarkkinen” estimointi

# Kaksivaiheinen bayesiläinen analyysi

- Laitoskohtaiset havainnot  $E = \{(k_1, T_1), \dots, (k_M, T_M)\}$  noudattaa Poissonjakaumaa parametreilla  $\{\lambda_1, \dots, \lambda_M\}$
- Parametrit  $\{\lambda_1, \dots, \lambda_M\}$  ovat otos jostain populaatiosta  $p(\lambda | \theta)$
- $\theta$  kutsutaan hyperparametriksi ja sen jakaumaan hyperprioriksi






# Bayesian networks (BN)

The following slides have been prepared by  
Alessandro Mancuso

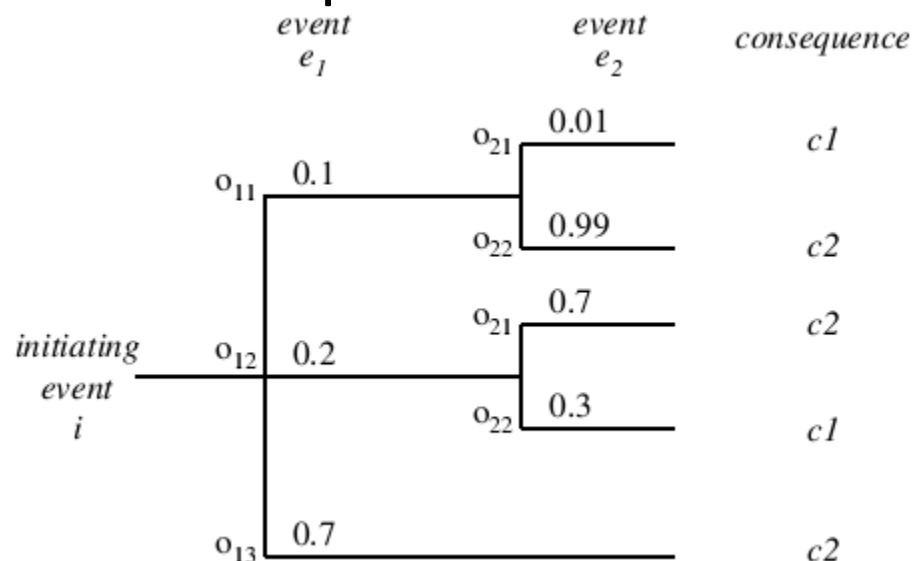
# Fault tree analysis (FTA)

- Events are binary events (operating/not-operating)
- Events are statistically independent
- Relationships between events and causes are represented by logical AND and OR gates
- The undesirable event, called Top Event, is postulated and the possible ways for the occurrence of this event are systematically deduced



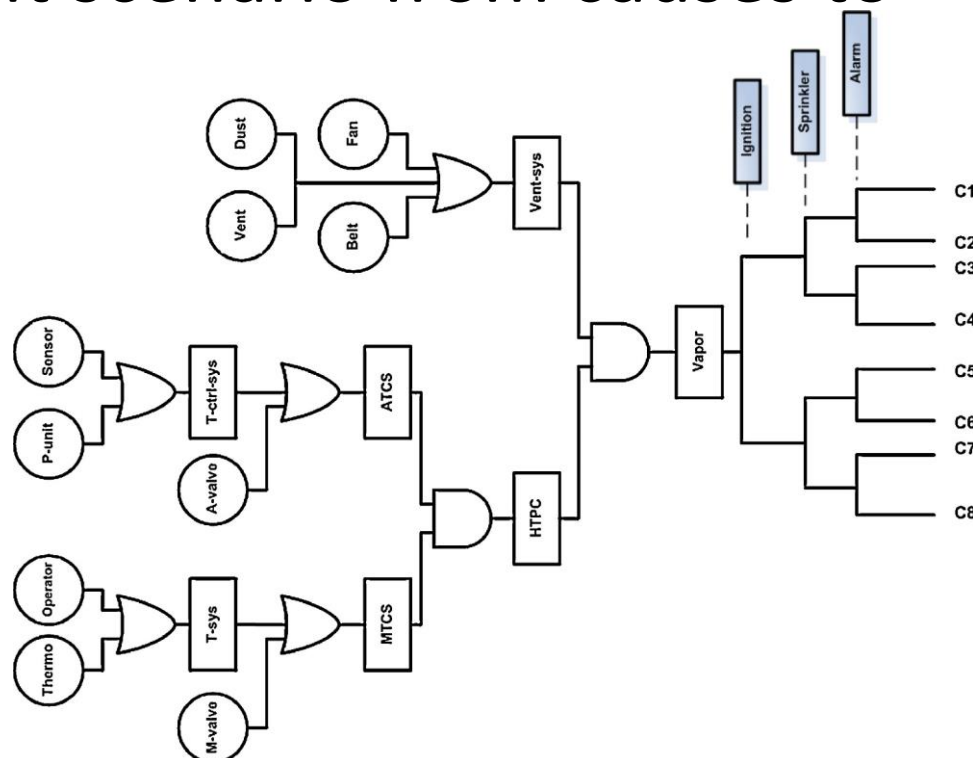
# Event tree analysis (ETA)

- System evolution following the hazardous occurrence is divided into discrete events
- System evolution starts from an initiating event
- Each event has a finite set of outcomes (commonly there are two outcomes: occurring event or not occurring) associated with the occurrence probabilities
- The leaves of the ET represent the consequence scenarios to be analyzed



# Bow-Tie analysis

- Bow-Tie (BT) combines the scenario modeling and quantification of FT and ET
- It represents an accident scenario from causes to effects




# Bayesian Networks (BN)

- Also called Bayesian Belief Nets (BBN)
- Formally, a BN is a directed acyclic graph consisting of:
- Nodes  $V = \{1, \dots, N\}$ , shown as circles, represent random events
- Directed arcs  $E \subseteq \{(i, j) \mid i, j \in V, i \neq j\}$  indicate conditional dependencies among nodes
  - the arc  $(i, j) \in E$  which connects node  $j \in V$  to node  $i \in V$  shows that the event at node  $j$  is conditionally dependent to the event at node  $i$


## Why Bayesian Networks?

- BNs are probabilistic graphical models, which offers a convenient and efficient way of generating joint distribution of all its events
  - Convenient: causal relationships between events are easy to model
  - Efficient: no redundancies in terms of graphical modelling and probability computations
  - Flexible: capable of handling imprecise information by capturing quantitative and qualitative data
- **Wide applicability, for instance:**
  - Diagnosis: Microsoft trouble shooting wizard, Medical expert system
  - Classification: Spam email classification
  - Voice recognition


# Mapping fault trees into BN




FAULT - TREE: OR Gate



BAYESIAN NETWORK: OR Node



FAULT - TREE: AND Gate



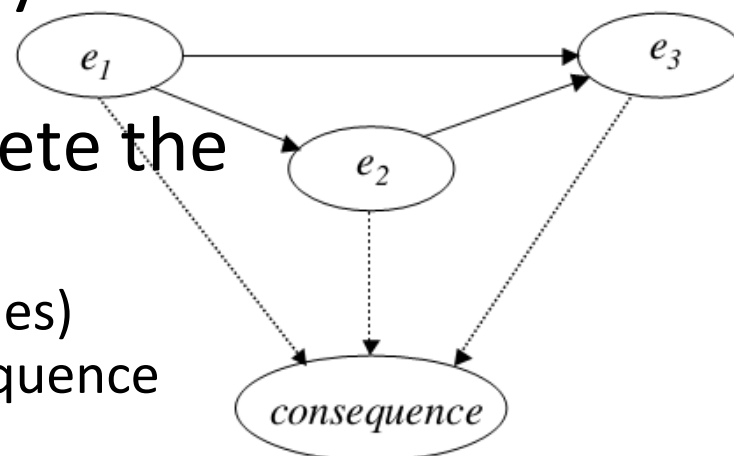
BAYESIAN NETWORK: AND Node

**Switching  
from binary  
logic to  
probabilistic  
logic!**

**Reference:** Bobbio A., Portinale L., Minichino M., Ciancamerla E., “*Improving the analysis of dependable systems by mapping fault trees into Bayesian networks*”, Reliability Engineering and System Safety 71, pp. 249–260 (2001) .

# Mapping event trees into BN


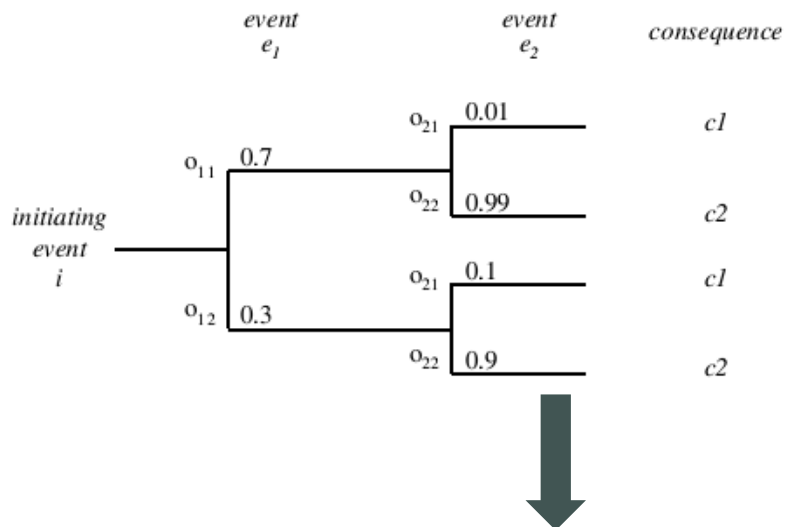
- Any event tree with three events  $e_1$ ,  $e_2$ , and  $e_3$  can be represented by the BN shown below
- Two types of directed arc complete the network:
  - Consequence arcs (shown as dotted lines) connect each event node to the consequence node
    - » This relationship is deterministic: the probability table for the consequence node encodes the logical relationship between the events and the consequences.
  - Causal arcs (shown as solid lines) connect each event node to all events later in time
    - » For instance, event  $e_1$  is a causal factor for event  $e_2$ , thus it influences the probability of event  $e_2$ .



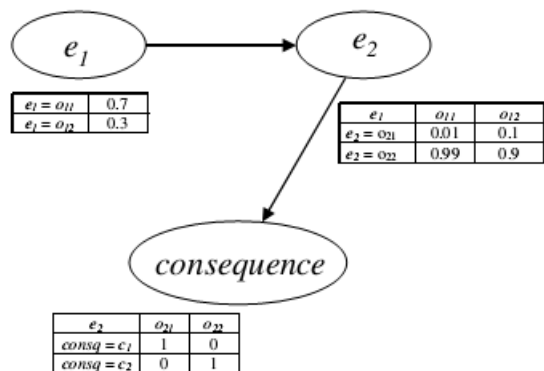
**Reference:** Bearfield G., Marsh W., “Generalizing Event Trees Using Bayesian Networks with a Case Study of Train Derailment”, Computer Safety, Reliability, and Security (2005).



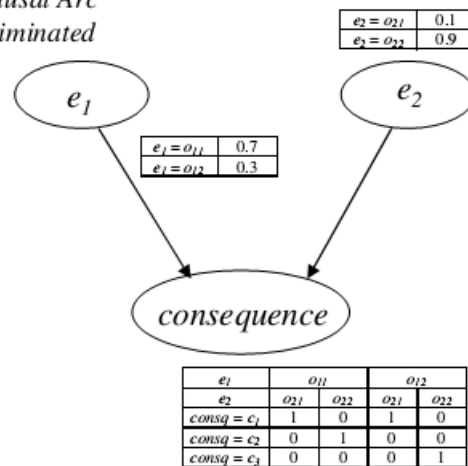
# Mapping ET into BN (alternatives)



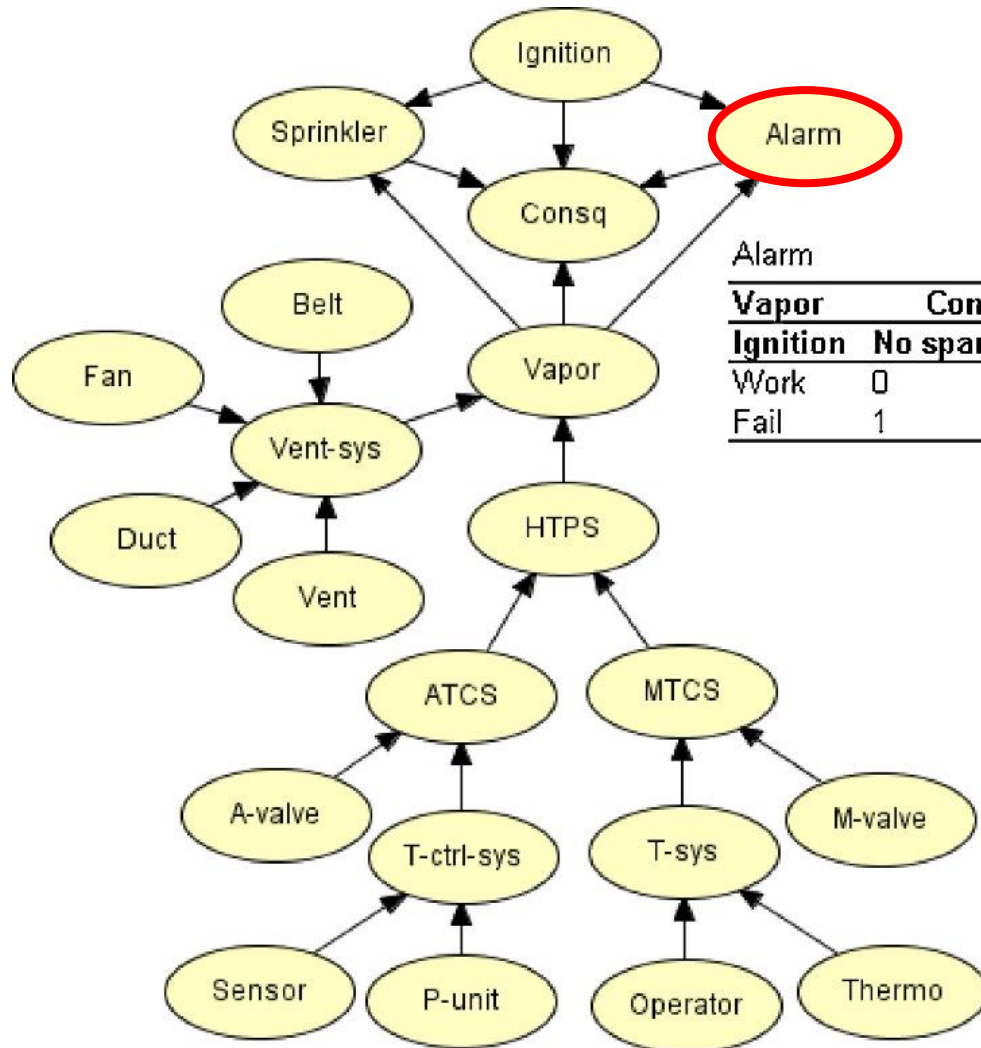
Consequence Arc Eliminated



Causal Arc Eliminated



# Advantages of Bayesian Networks



Mapping of Bow Tie (slide 4) into **BN**

Alarm

	Controlled		Overflow	
Vapor	No spark	Spark	No spark	Spark
Work	0	0	0.775	0.9987
Fail	1	1	0.225	0.0013

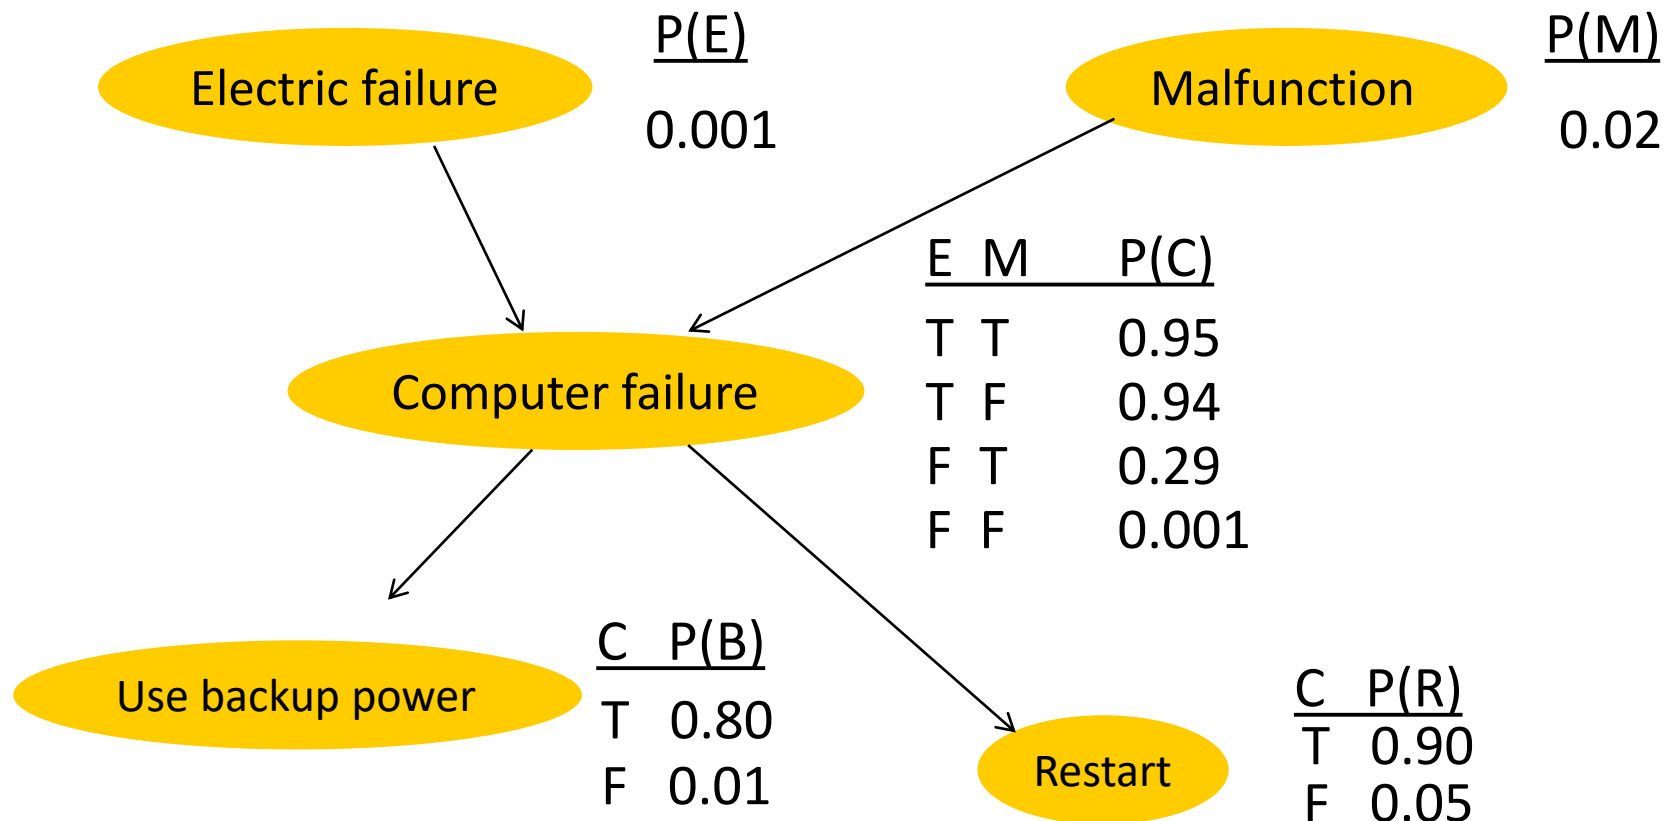
## Advantages

- Multi-state modelling
- Extension of concepts of AND/OR gates through probability distributions
- Combining expert judgement and quantitative knowledge to estimate the risk

# Failure probabilities

- Information sources
  - Information provided by AND/OR gates
  - Statistical analyses / Simulations
  - Expert elicitation
- The probabilities of events are defined as follows:
  - Initiating events → failure probabilities of system components
  - Intermediate and top events → conditional probability tables (CPT)

# Bayesian Network representation

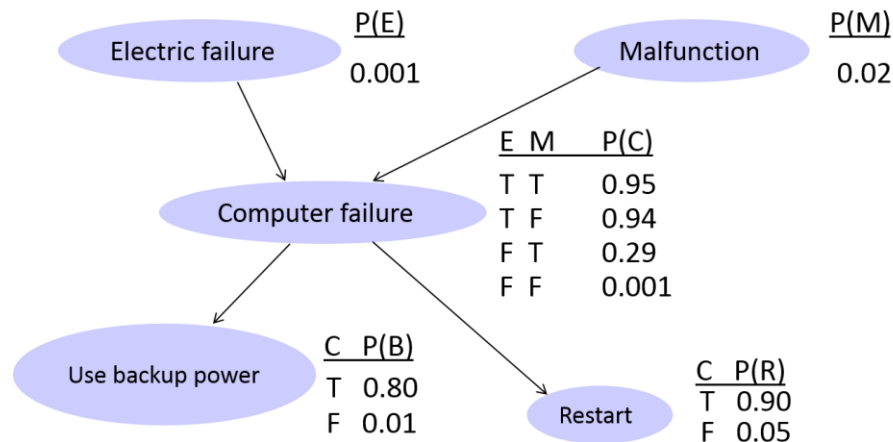


# Inference on Bayesian Networks

- Query: Assuming to collect some observations (evidence) from the system, how would this evidence impact the probabilities of the events?
- The conditional probability of a random event given the evidence is known as a posteriori belief, useful in case of:
  - Prediction: computing the probability of an outcome event given the starting condition → Target is a descendent of the evidence!
  - Diagnosis: computing the probability of disease/fault given symptoms → Target is an ancestor of the evidence!
- Note: the direction between variables does not restrict the directions of the queries → Probabilistic inference can combine evidence from all parts of the network!

# Examples of inference: Prediction

- For the computer failure example, what is the probability that the backup power is working given an electrical failure?



$$P(B|E) = P(B|C)P(C|E) + P(B|\bar{C})P(\bar{C}|E)$$

$$P(C|E) = P(C|\bar{M}, E)P(\bar{M}) + P(C|M, E)P(M)$$

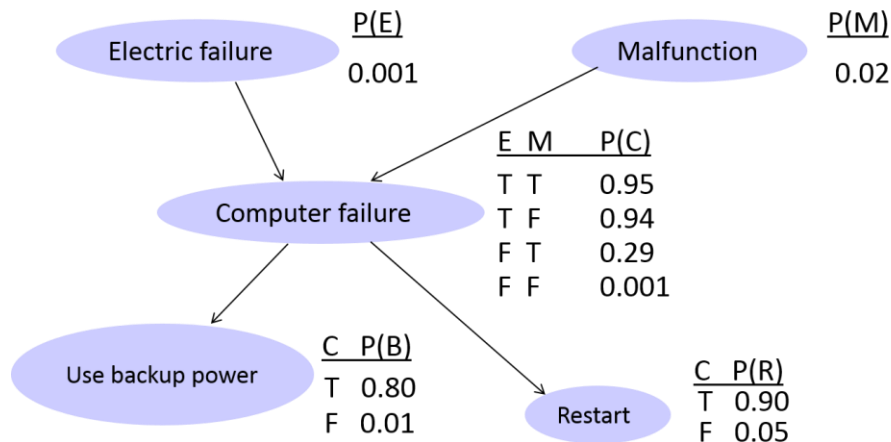
$$P(C|E) = 0.98 \cdot 0.94 + 0.02 \cdot 0.95 = 0.94$$

$$P(B|E) = P(C|E) \cdot 0.8 + P(\bar{C}|E) \cdot 0.01$$

$$P(B|E) = 0.94 \cdot 0.8 + 0.06 \cdot 0.01 = \mathbf{0.75}$$

# Examples of inference: Diagnosis

- For the computer failure example, what is the probability that the electricity is working given a backup power failure?



$$P(E|B) = \frac{P(B|E)P(E)}{P(B)}$$


$$P(E|B) = \frac{0.75 \cdot 0.001}{0.0161} = 0.0468$$

$$\begin{aligned}
 P(C) &= P(C|E, M)P(E)P(M) \\
 &+ P(C|E, \bar{M})P(E)P(\bar{M}) \\
 &+ P(C|\bar{E}, M)P(\bar{E})P(M) \\
 &+ P(C|\bar{E}, \bar{M})P(\bar{E})P(\bar{M}) = 0.0077
 \end{aligned}$$

$$P(B) = P(B|C)P(C) + P(B|\bar{C})P(\bar{C})$$

$$P(B) = 0.8 \cdot 0.0077 + 0.01 \cdot 0.9923 = 0.0161$$

# Illustrative example




Accident scenario of a **vapor cloud ignition** at Universal Form Clamp in Illinois, US on June 14 2006.

Component	Failure probability
Sensor	0.0400
Pneumatic unit	0.2015
Temperature control system	OR-gate
Operator	0.0200
Infrared thermometer	0.0468
Temperature measurement system	OR-gate
Manual steam valve	0.0243
Automatic steam valve	0.0276
Automatic temperature control system	OR-gate
Manual temperature control system	OR-gate
High temperature protection system	AND-gate
Ventilation	0.0150
Fan	0.0100
Belt	0.0500
Duct	0.0010
Ventilation system	OR-gate
Vapour overflow	AND-gate
Ignition barrier	0.1000
Water sprinkler system	0.040, 0.3000
Alarm system	0.0013, 0.2250

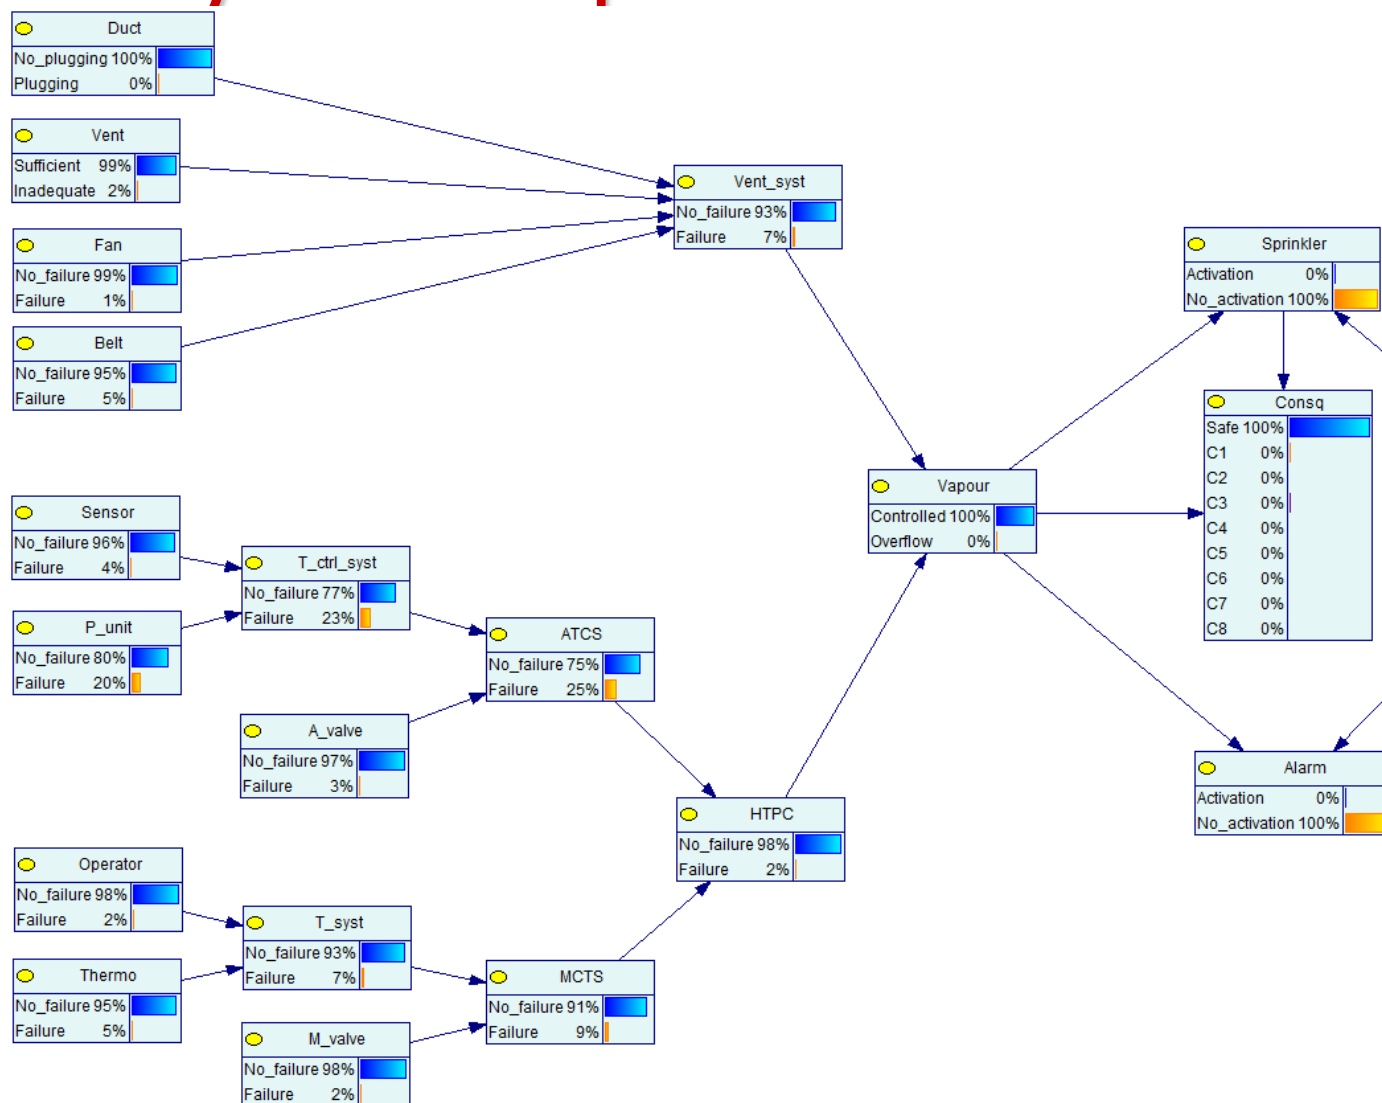


# Accident scenarios

Accident scenarios are traditionally represented through Fault Tree and Event Tree



# Bayesian representation

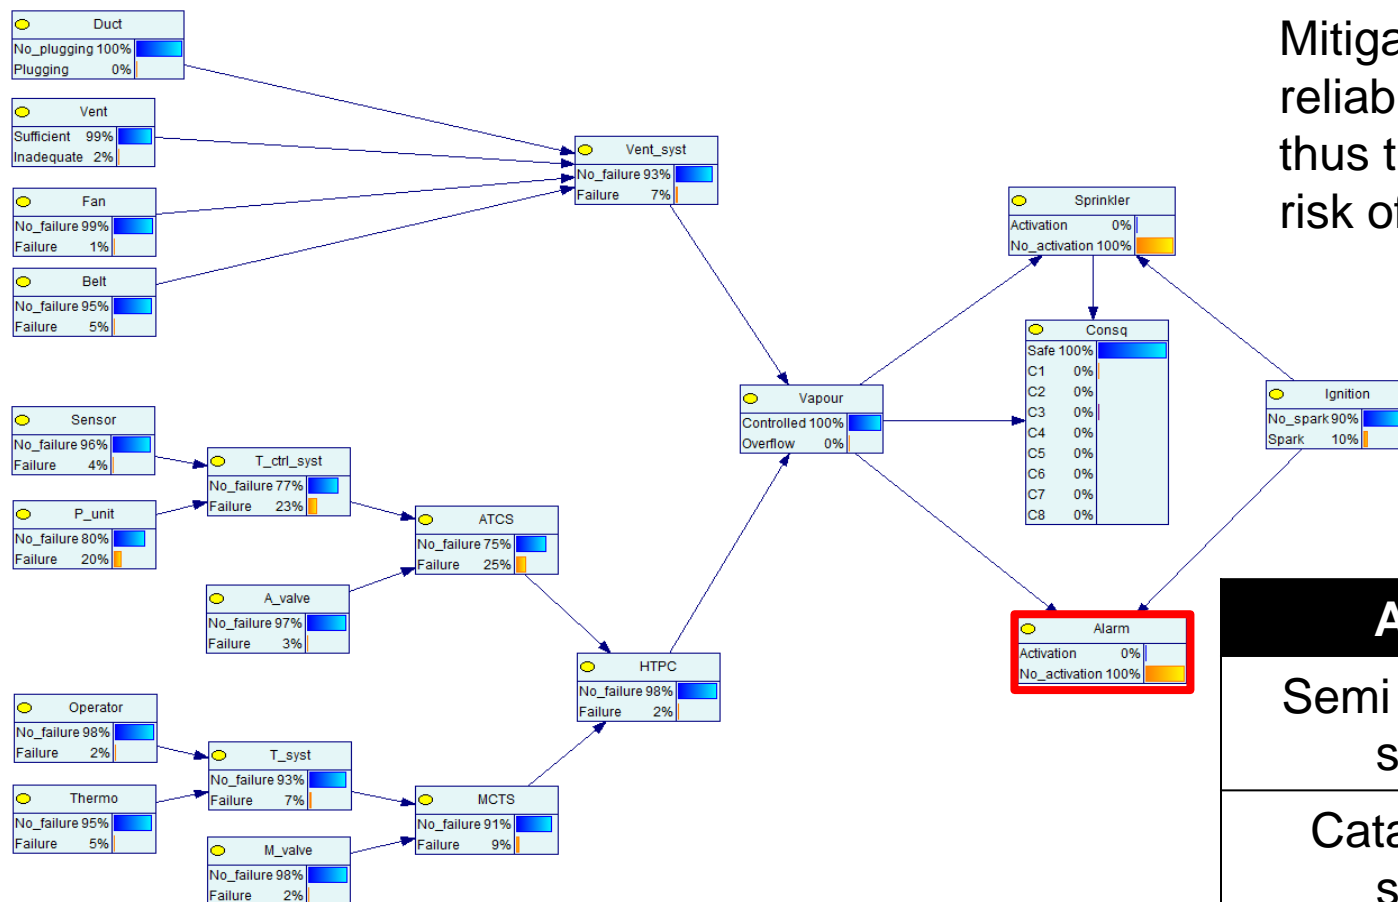


To analyze the failure scenarios, the Fault Tree is mapped into a **Bayesian Network**.

## Advantages

- Probabilistic representation of multi-state events.
- Combining expert judgement and quantitative knowledge.

# Definition of mitigation actions



Mitigation actions improve the reliability of the components, thus they mitigate the residual risk of the *overall system*.

Action	Cost	Prob
Semi conductor sensor	60	0.2
Catalytic gas sensor	80	0.15
Electrochemical cells	110	0.1

# Results

Minimum residual risk for the optimal portfolios of actions at different budget levels.

Larger budget

⇒ more effective actions

⇒ lower residual risk of failure

