Eksponencijalna distribucija

Najjednostavnija, jedna od prvih korištenih u analizama i danas često korištena (vrlo često i pogrešno ako je jedini razlog njena korišenja sama jednostavnost) je Eksponencijalana distribucija. Ovom se distribucijom modeliraju kvarovi koji su potpuno slučajni. Funkcija pdf jednoparametarske eksponencijalne respodjele je:

$$f(t) = \lambda e^{-\lambda t}$$

Gdje je:

- λ = konstantna učestalost kvarova (Engl. *constant failure rate, in failures per unit of measurement, e.g. failures per hour, per cycle, etc*)
- t = vrijeme rada, broj ciklusa, prijeđenih kilometara, broja uključivanja,…..

Slučajna se događaji mogu opisati: "Ništa što se desilo u prošlosti ne može pomoći u predviđanju budućnosti". Stoga eksponencijalni model ne pamti, tj. njime nije moguće modelirati istrošenje, zamor ili starenje. Prema eksponencijalnome modelu, vjerojatnost rada komponente bez kvara za neki period ne ovisi o tome kada će taj period započeti. Takovo je ponašanje karakteristično za kvarove koji primarno ne ovise o istrošenju nego o izvanrednim vanjskim opetrećenjima. To se može matematički opisati koristeći funkciju uvijetne pouzdanosti:

$$R(\Delta T \mid T) = \frac{R(T + \Delta T)}{R(T)} = \frac{e^{-\lambda(T+\Delta T)}}{e^{-\lambda T}} = \frac{e^{-\lambda T} \cdot e^{-\lambda \Delta T}}{e^{-\lambda T}} = e^{-\lambda \Delta T} = R(\Delta T)$$

Iz toga se vidi da kod eksponencijalnog modela prethodni period vremena T nema nikakovog utjecaja na pouzdanost rada u narednom periodu ΔT .

Eksponencijalnim modelom nije moguće opisati starosti komponente. Distribucija kao što su Normalna, Log-Normalna i Weibullova, su prikladne za modele kojima se opisuje ukupno vrijeme korištenja. Ako se Weibuillovim modelom dobije paremetar oblika $\beta = 1$ tada je modelirana distribucija jednaka Eksponencijalnoj te analiziranu komponentu nema smisla održavati preventivno jer su uzroci kvarova slučajne prirode ili se u zapisuju vremena kvarova zbog različitih uzroka.