


Sistemi probabilistici e stocastici

«Alcune scelte sono più probabili di altre»



Alcune definizioni:

Definizione 1.1.1. Una σ -algebra è un sottoinsieme \mathcal{F} delle parti di un insieme Ω tale che

1. $\Omega \in \mathcal{F}$;
2. se $A \in \mathcal{F}$, allora $A^c \in \mathcal{F}$;
3. se $(A_n)_{n \geq 1} \subseteq \mathcal{F}$, allora $\bigcup_n A_n \in \mathcal{F}$.

Un'algebra è definita analogamente, ma è chiusa per unioni finite (invece che unioni numerabili).

$$\begin{aligned} \text{Esempio: } \Omega &= \{a,b,c,d\} \\ \mathcal{F} &= \{ \emptyset, \{a,b\}, \{c,d\}, \{a,b,c,d\} \} \end{aligned}$$

Alcune definizioni:

Definizione 1.1.2. Dato Ω un insieme e \mathcal{F} una σ -algebra, $\mu : \mathcal{F} \rightarrow [0, +\infty]$ è una *misura* se

- $\mu(A) \geq 0 \forall A \in \mathcal{F}$;
- è σ -additiva: $(A_n)_{n \geq 1} \subseteq \mathcal{F}$ a due a due disgiunti, allora $\mu\left(\bigsqcup_n A_n\right) = \sum_n \mu(A_n)$;

In generale per una misura μ vale che:

- se $\mu(\Omega) < \infty$, allora μ è finita;
- se Ω è unione di una famiglia numerabile di insiemi (di \mathcal{F}) di misura finita, allora μ è σ -finita;
- se $\mu(\Omega) = 1$, allora μ è una *probabilità*.

$(\Omega, \mathcal{F}, \mathbb{P})$ SPAZIO DI PROBABILITÀ

PROPRIETÀ:

- Principio di inclusione e esclusione:

$$P(\Omega \setminus A) = 1 - P(A)$$

$$P(A_1 \cup A_2) = P(A_1) + P(A_2) - P(A_1 \cap A_2)$$

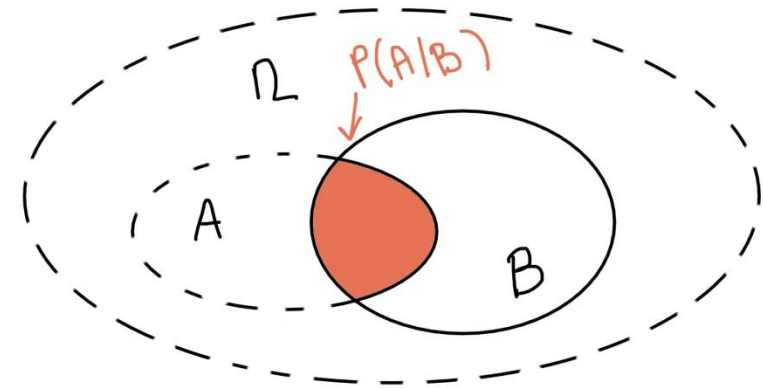
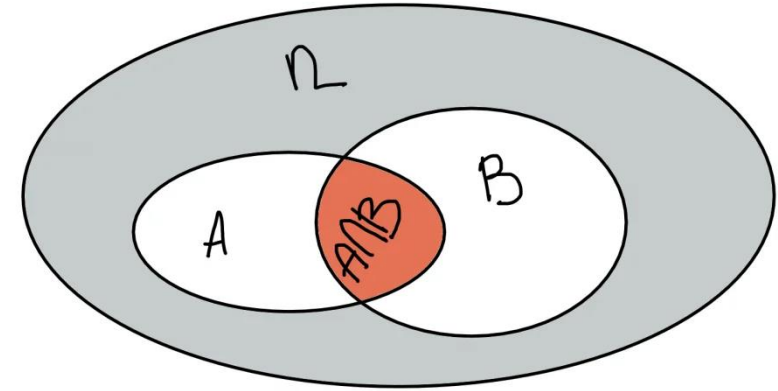
$$P(A_1 \cap A_2) = P(A_1) + P(A_2) - P(A_1 \cup A_2)$$

- Probabilità condizionata:

$$P(A|B) = \frac{P(A \cap B)}{P(B)}$$

$$P(A \cap B) = P(A|B) \cdot P(B) = P(B|A) \cdot P(A)$$

$$P(B|A) = \frac{P(A|B) \cdot P(B)}{P(A)}$$



Variabili aleatorie continue:

Dato (Ω, \mathcal{A}, P) spazio di probabilità, una funzione misurabile $X : \Omega \rightarrow \mathbb{R}$ è una **variabile aleatoria** reale se

$$\forall x \in \mathbb{R}. \{\omega \in \Omega \mid X(\omega) \leq x\} \in \mathcal{A}$$

E si definisce la **funzione di ripartizione**

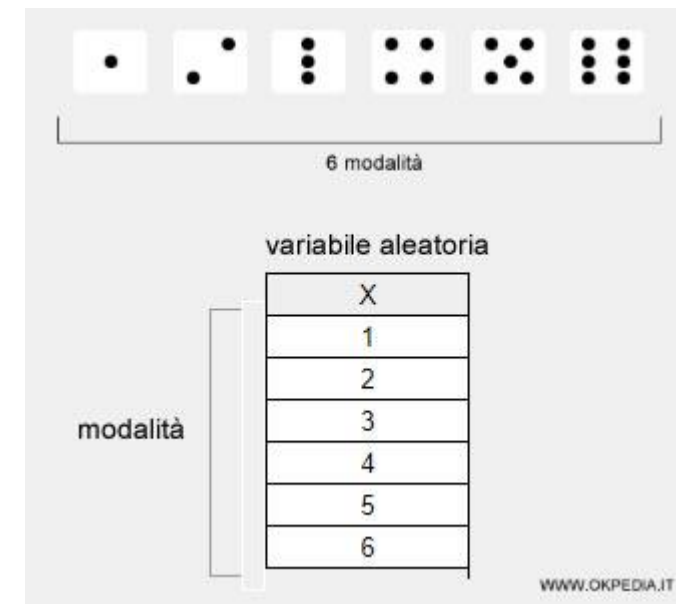
$$F_X(x) \triangleq P(X \leq x) = P(\{\omega \in \Omega \mid X(\omega) \leq x\})$$

Proprietà:

$$P(X \leq a) = F_X(a)$$

$$P(X > a) = 1 - F_X(a)$$

$$P(a < X \leq b) = F_X(b) - F_X(a)$$



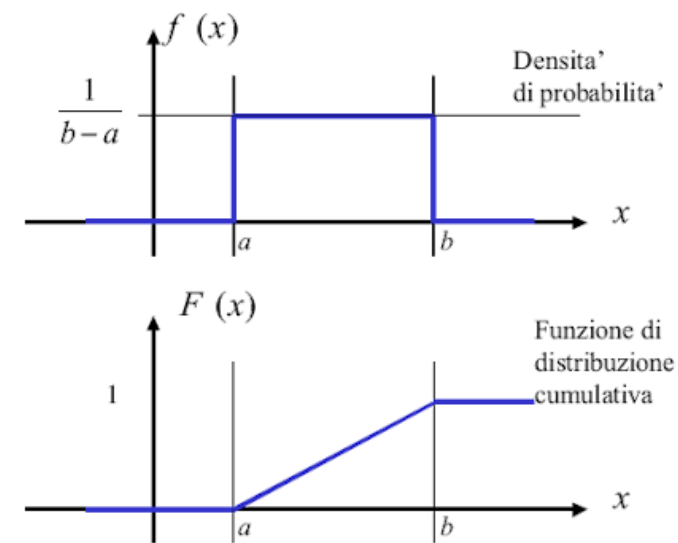
Variabili aleatorie continue:

Dato (Ω, \mathcal{A}, P) spazio di probabilità e data una variabile aleatoria reale $X : \Omega \rightarrow \mathbb{R}$, una funzione integrabile $f_X : \mathbb{R} \rightarrow [0, +\infty)$ si dice **densità di probabilità** se è tale che

$$F_X(a) = \int_{-\infty}^a f_X(x) dx$$

Vale anche che

$$P(a < X \leq b) = \int_a^b f_X(x) dx$$





Distribuzione esponenziale e proprietà

La distribuzione esponenziale è così definita

$$F_X(x) = \begin{cases} 1 - e^{-\lambda x} & \text{if } x \geq 0 \\ 0 & x < 0 \end{cases}$$

$$f_X(x) = \begin{cases} \lambda e^{-\lambda x} & \text{if } x \geq 0 \\ 0 & x < 0 \end{cases}$$



Proprietà distribuzione esponenziale:

Memoryless: Sia X una variabile aleatoria esponenziale di parametro λ , allora

$$P(X \leq t_0 + t \mid X > t_0) = P(X \leq t)$$

Proof. Since X is exponentially distributed, its probability law is

$$F_X(t) = \int_0^t \lambda e^{-\lambda x} dx$$

so we need to prove

$$\frac{P(t_0 < X \leq t_0 + t)}{P(X > t_0)} = \frac{\int_{t_0}^{t_0+t} \lambda e^{-\lambda x} dx}{\int_{t_0}^{\infty} \lambda e^{-\lambda x} dx} \stackrel{?}{=} \int_0^t \lambda e^{-\lambda x} dx = P(X \leq t)$$

Since $\int_a^b \lambda e^{-\lambda x} dx = [-e^{-\lambda x}]_a^b = [e^{-\lambda x}]_b^a$ it follows that

$$\frac{\int_{t_0}^{t_0+t} \lambda e^{-\lambda x} dx}{\int_{t_0}^{\infty} \lambda e^{-\lambda x} dx} = \frac{[e^{-\lambda x}]_{t_0+t}^{t_0}}{[e^{-\lambda x}]_{\infty}^{t_0}} = \frac{e^{-\lambda t_0} - e^{-\lambda t} \cdot e^{-\lambda t_0}}{e^{-\lambda t_0}} = \frac{\cancel{e^{-\lambda t_0}}(1 - e^{-\lambda t})}{\cancel{e^{-\lambda t_0}}} = 1 - e^{-\lambda t}$$

We conclude by

$$\int_0^t \lambda e^{-\lambda x} dx = [e^{-\lambda x}]_t^0 = 1 - e^{-\lambda t}$$

□

Proprietà distribuzione esponenziale:

Siano X_1 e X_2 due variabili aleatorie esponenziali di parametri λ_1 e λ_2 , allora

$$P(\min\{X_1, X_2\} \leq t) = 1 - e^{-(\lambda_1 + \lambda_2)t}$$

Proof. We recall that for any two events (not necessarily disjoint) we have

$$P(A \cup B) = P(A) + P(B) - P(A \cap B)$$

and that for two independent events we have

$$P(A \cap B) = P(A) \times P(B)$$

Then

$$\begin{aligned} P(\min\{X_1, X_2\} \leq t) &= P(X_1 \leq t \vee X_2 \leq t) \\ &= P(X_1 \leq t) + P(X_2 \leq t) - P(X_1 \leq t \wedge X_2 \leq t) \\ &= P(X_1 \leq t) + P(X_2 \leq t) - P(X_1 \leq t) \times P(X_2 \leq t) \\ &= (1 - e^{-\lambda_1 t}) + (1 - e^{-\lambda_2 t}) - (1 - e^{-\lambda_1 t})(1 - e^{-\lambda_2 t}) \\ &= 1 - e^{-\lambda_1 t} e^{-\lambda_2 t} \\ &= 1 - e^{-(\lambda_1 + \lambda_2)t} \end{aligned}$$

□

Proprietà distribuzione esponenziale:

Siano X_1 e X_2 due variabili aleatorie esponenziali di parametri λ_1 e λ_2 , allora

$$P(X_1 < X_2) = \frac{\lambda_1}{\lambda_1 + \lambda_2}$$

Proof. Imagine you are at some time t and neither of the two variables has fired. The probability that X_1 fires in the infinitesimal interval dt while X_2 fires in some later instant is

$$\lambda_1 e^{-\lambda_1 t} \left(\int_t^\infty \lambda_2 e^{-\lambda_2 t_2} dt_2 \right) dt$$

from which we derive

$$\begin{aligned} P(X_1 < X_2) &= \int_0^\infty \lambda_1 e^{-\lambda_1 t_1} \left(\int_{t_1}^\infty \lambda_2 e^{-\lambda_2 t_2} dt_2 \right) dt_1 \\ &= \int_0^\infty \lambda_1 e^{-\lambda_1 t_1} \left[e^{-\lambda_2 t_2} \right]_\infty^{t_1} dt_1 \end{aligned}$$

$$\begin{aligned} &= \int_0^\infty \lambda_1 e^{-\lambda_1 t_1} \cdot e^{-\lambda_2 t_1} dt_1 \\ &= \int_0^\infty \lambda_1 e^{-(\lambda_1 + \lambda_2) t_1} dt_1 \\ &= \left[\frac{\lambda_1}{\lambda_1 + \lambda_2} e^{-(\lambda_1 + \lambda_2) t} \right]_0^\infty \\ &= \frac{\lambda_1}{\lambda_1 + \lambda_2} \end{aligned}$$

Processi stocastici

Sia (Ω, \mathcal{A}, P) uno spazio di probabilità, e sia T un insieme. Allora un processo stocastico è una funzione $X : \Omega \times T \rightarrow \mathbb{R}$ tale che


$$\forall t \in T. X(\cdot, t) : \Omega \rightarrow \mathbb{R} \text{ è una variabile aleatoria}$$

Se $T \subseteq \mathbb{N}$, allora il processo stocastico si dice **discreto**.

Se $T \subseteq \mathbb{R}$, allora il processo stocastico si dice **continuo**.

L'insieme degli stati è

$$S = \{x \mid \exists \omega \in \Omega, t \in T. X(\omega, t) = x\}$$



Catene di Markov

Se $T \subseteq \mathbb{N}$ \rightarrow DTCM
Se $T \subseteq \mathbb{R}$ \rightarrow CTCM

Sia (Ω, \mathcal{A}, P) spazio di probabilità, $\{X_t\}_{t \in T}$ processo stocastico è una Catena di Markov se $\forall t_0 < t_1 < \dots < t_n < t$ possibili tempi e $\forall x, x_0, x_1, \dots, x_n$ possibili stati si ha

$$P(X_{t_{n+1}} = x \mid X_{t_n} = x_n, \dots, X_{t_0} = x_0) = P(X_{t_{n+1}} = x \mid X_{t_n} = x_n)$$

Consideriamo solo il caso di Catene di Markov omogenee, ovvero che non dipendono dal tempo. Quindi possiamo riformulare

$$P(X_t = x \mid X_{t_n} = x_n) = P(X_{t-t_n} = x \mid X_0 = x_n)$$

Catene di Markov Discrete (DTCM)

Possiamo rappresentare la DTMC attraverso matrici e LTS così definiti:

$$P = \begin{bmatrix} a_{1,1} & a_{1,2} & \cdots & a_{1,N} \\ a_{2,1} & a_{2,2} & \cdots & a_{2,N} \\ \vdots & \vdots & & \vdots \\ a_{N,1} & a_{N,2} & \cdots & a_{N,N} \end{bmatrix} \quad i \xrightarrow{a_{i,j}} j$$


$$a_{i,j} = P(X_1 = j | X_0 = i)$$

Probabilità di transizione


$$\forall i, j \in \{1, \dots, N\}. 0 \leq a_{i,j} \leq 1$$

$$\forall i \in \{1, \dots, N\}. \sum_{j=1}^N a_{i,j} = 1$$

PTS



(a)



(b)

Un **PTS** è un LTS le cui etichette sono le probabilità di transizione.

La **funzione di transizione** è così definita:

$$\alpha_D(s) = \begin{cases} \lambda s'. P(X_1 = s' | X_0 = s) & \text{if } s \text{ is not a deadlock state} \\ * & \text{otherwise} \end{cases}$$


Cioè

$$a_{i,j} = P(X_1 = j | X_0 = i) = \alpha_D(s_i)(s_j)$$

Possiamo adesso sfruttare le proprietà di algebra lineare per capire come evolve il sistema, infatti

$$\pi^{(t+1)} = \pi^{(t)} P = \begin{pmatrix} \pi_1^{(t)} & \pi_2^{(t)} & \pi_3^{(t)} \end{pmatrix} \begin{vmatrix} a_{1,1} & a_{1,2} & a_{1,3} \\ a_{2,1} & a_{2,2} & a_{2,3} \\ a_{3,1} & a_{3,2} & a_{3,3} \end{vmatrix}$$

$$P = \begin{bmatrix} 4/5 & 1/5 & 0 \\ 0 & 1/3 & 2/3 \\ 1 & 0 & 0 \end{bmatrix}$$



$$\pi^{(t)} = |1/3 \ 1/3 \ 1/3|$$

La somma fa 1

$$\pi^{(t+1)} = |1/3 \ 1/3 \ 1/3| \begin{bmatrix} 4/5 & 1/5 & 0 \\ 0 & 1/3 & 2/3 \\ 1 & 0 & 0 \end{bmatrix} = |3/5 \ 8/45 \ 2/9|$$

Esempio:

Come possiamo
calcolare la probabilità di
andare dallo stato 1 -> 2
-> 3 -> 1 ?

FINITE PATH PROBABILITY:

$$P(1 \ 2 \ 3 \ 1) = a_{1,2} \cdot a_{2,3} \cdot a_{3,1} = \frac{1}{5} \cdot \frac{2}{3} \cdot 1 = \frac{2}{15}$$

Distribuzione stazionaria

Si definisce la distribuzione stazionaria $\pi = |\pi_1 \dots \pi_n|$ di una DTTCM come

$$\forall i \in [1, n]. \pi_i = \lim_{t \rightarrow \infty} \pi_i^{(t)}$$

quando tale limite esiste.

Catene di Markov Ergodiche


Una catena di Markov si dice **Ergodica** se:

- è irriducibile: ovvero ogni stato è raggiungibile da ogni altro stato;
- è aperiodica: ovvero il massimo comune divisore delle lunghezze di tutti i cammini è 1.

In questo caso, la distribuzione stazionaria si calcola risolvendo il sistema lineare

$$\begin{cases} \pi = \pi \cdot P \\ \sum_{i=1}^N \pi_i = 1 \end{cases}$$

$$P = \begin{bmatrix} 4/5 & 1/5 & 0 \\ 0 & 1/3 & 2/3 \\ 1 & 0 & 0 \end{bmatrix}$$



$$\begin{cases} \frac{4}{5}\pi_1 + \pi_3 = \pi_1 \\ \frac{1}{5}\pi_1 + \frac{1}{3}\pi_2 = \pi_2 \\ \frac{2}{3}\pi_2 = \pi_3 \\ \pi_1 + \pi_2 + \pi_3 = 1 \end{cases}$$



$$\pi = [2/3 , 1/5 , 2/15]$$

Esempio:

Catene di Markov Continue (CTCM)

Sia (Ω, \mathcal{A}, P) spazio di probabilità, $\{X_t\}_{t \in \mathbb{R}}$ CTCM tale che

$$P(X_{t_n + \Delta t} = x | X_{t_n} = x_n, \dots, X_{t_0} = x_0) = P(X_{\Delta t} = x | X_0 = x_n)$$

Sia $T_{i,j}$ il tempo speso nello stato i prima di andare nello stato j , allora

$$P(T_{i,j} > t + \Delta t | T_{i,j} > t) = P(T_{i,j} > \Delta t)$$

Cioè è una variabile memoryless, ovvero una variabile esponenziale di parametro $\lambda_{i,j}$

Catene di Markov Continue (CTCM)

Con le condizioni

$$T_i = \min_{j \neq i} T_{i,j} \quad \lambda_i = \sum_{j \neq i} \lambda_{i,j}$$

si definisce l'**embedded DTCM** di CTCM la catena di Markov discreta rappresentata dalla matrice

$$P = \begin{bmatrix} 0 & p_{1,2} & \cdots & p_{1,N} \\ p_{2,1} & 0 & \cdots & p_{2,N} \\ \vdots & \vdots & & \vdots \\ p_{N,1} & p_{N,2} & \cdots & 0 \end{bmatrix} = \begin{bmatrix} 0 & \lambda_{1,2}/\lambda_1 & \cdots & \lambda_{1,N}/\lambda_1 \\ \lambda_{2,1}/\lambda_2 & 0 & \cdots & \lambda_{2,N}/\lambda_2 \\ \vdots & \vdots & & \vdots \\ \lambda_{N,1}/\lambda_N & \lambda_{N,2}/\lambda_N & \cdots & 0 \end{bmatrix}$$

dove

$$p_{i,j} = P \left(T_{i,j} < \min_{k \neq i,j} T_{i,k} \right) = \frac{\lambda_{i,j}}{\lambda_i}$$

CTCM Bisimilarità

Dato un LTS definiamo la funzione γ che preso uno stato p , un'azione l e un insieme di stati I restituisce **true** se esiste uno stato q in I tale che q è raggiungibile da p tramite l ; restituisce **false** altrimenti.

$$\gamma(p, l, I) \stackrel{\text{def}}{=} \exists q \in I. p \xrightarrow{l} q$$

Ora prendiamo l'equivalenza \equiv_R indotta da una relazione R .

Sia S_{\equiv_R} l'insieme delle classi di equivalenza.


Se $J \in S_{\equiv_R}$, $p, q \in J$ (cioè appartengono alla stessa classe di equivalenza)

$$\begin{array}{ll} \text{if } p \xrightarrow{\mu} p' \text{ for some } \mu, p' & \text{then } q \xrightarrow{\mu} q' \text{ for some } q' \text{ with } p' \equiv_{\mathbf{R}} q' \\ \text{(and vice versa)} & \text{(i.e. } \exists I \in S_{\equiv_{\mathbf{R}}} \cdot p', q' \in I) \end{array}$$

CTCM Bisimilarità

Se consideriamo la funzione $\Phi : \wp(S \times S) \rightarrow \wp(S \times S)$

$$p \Phi(\mathbf{R}) q \triangleq \forall I \in S_{|\equiv \mathbf{R}}. \gamma(p, I) = \gamma(q, I)$$




Allora una bisimulazione è tale che $\mathbf{R} \subseteq \Phi(\mathbf{R})$ ← CTCM BISIMULAZIONE

$\simeq \triangleq \bigcup_{\mathbf{R} \subseteq \Phi(\mathbf{R})} \mathbf{R}$ è la più grande bisimulazione ← CTCM BISIMILARITA'


DTCM Bisimilarità

- Senza stallo, banale;
- Con stallo, analoga con la condizione che:
 1. Due qualsiasi stati di stallo sono bisimili;
 2. Ogni stato di stallo non è bisimile ad uno stato di non stallo.



WWW.ANDREAMININI.ORG

Esempio:



$$\equiv_{\mathbf{R}} = \{ \{a_1, a_2\}, \{b_1, b_2, b_3\}, \{c_1, c_2\}, \{d_1, d_2\} \}$$


Reactive PTS

$$\alpha_R : S \rightarrow L \rightarrow \mathbb{D}(S) \cup \{\star\}$$

Sono Catene di Markov che eseguono azioni.

La bisimilarità è analoga a quella già introdotta.

.



Larsen-Skou Logic


$\varphi ::= true \mid \varphi_1 \wedge \varphi_2 \mid \neg\varphi \mid \langle \ell \rangle_q \varphi.$

Teorema

Due stati di un reactive probabilist system sono bisimili se e solo se soddisfano le stesse formule della logica di Larsen-Skou senza la negazione.

$s \models true$
 $s \models \varphi_1 \wedge \varphi_2$ if $s \models \varphi_1$ and $s \models \varphi_2$
 $s \models \neg\varphi$ if $\neg s \models \varphi$
 $s \models \langle \ell \rangle_q \varphi$ if $\gamma_r(s)(\ell) \llbracket \varphi \rrbracket \geq q$ where $\llbracket \varphi \rrbracket = \{s' \in S \mid s' \models \varphi\}$

Consiste nell'abilità di raggiungere un nuovo stato attraverso la formula φ con un'azione ℓ con probabilità almeno q



$$s_1 \stackrel{?}{\models} \langle 1\text{€} \rangle_{\frac{1}{2}} \langle \text{coffee} \rangle_1 \mathbf{tt} \quad \gamma_R(s_1, 1\text{€}, \llbracket \langle \text{coffee} \rangle_1 \mathbf{tt} \rrbracket) \stackrel{?}{\geq} \frac{1}{2}$$

$$\begin{aligned} \llbracket \langle \text{coffee} \rangle_1 \mathbf{tt} \rrbracket &= \{u \mid u \models \langle \text{coffee} \rangle_1 \mathbf{tt}\} \\ &= \{u \mid \gamma_R(u, \text{coffee}, \llbracket \mathbf{tt} \rrbracket) \geq 1\} \\ &= \{u \mid \gamma_R(u, \text{coffee}, S) \geq 1\} \\ &= \{s_2\} \end{aligned}$$

$$\gamma_R(s_1, 1\text{€}, \{s_2\}) = \frac{2}{3} \geq \frac{1}{2}$$

Esempio:

GRAZIE PER L'ATTENZIONE!

Bibliografia: Roberto Bruni, Ugo Montanari, "Models of Computation", Springer Texts in Computer Science, 2017.