

Uvažujme kostičkový svět níže. Agent (žlutý) se pohybuje světem pomocí akcí (N-North, W-West, E-East, S-South, a speciální akce D-Depart v terminálních stavech Exit). Reward/odměnu dostane pouze v případě opuštění cílového stavu (zelená a červená políčka). Předpokládejme discount factor  $\gamma = 1$ .

3	-10	100
2		
1	-70	-90
	1	2
	2	3

Agent začíná v levém horním rohu. Vyzkouší několik trénovacích epizod, níže v tabulce. Každý řádek v tabulce trénovací epizody je n-tice  $(s, a, s', r)$ .

Episode 1	Episode 2	Episode 3	Episode 4	Episode 5
(1,3), S, (1,2), 0	(1,3), S, (1,2), 0	(1,3), S, (1,2), 0	(1,3), S, (1,2), 0	(1,3), S, (1,2), 0
(1,2), E, (2,2), 0	(1,2), E, (2,2), 0	(1,2), E, (2,2), 0	(1,2), E, (2,2), 0	(1,2), E, (2,2), 0
(2,2), E, (3,2), 0	(2,2), N, (2,3), 0	(2,2), S, (2,1), 0	(2,2), S, (2,1), 0	(2,2), E, (3,2), 0
(3,2), S, (3,1), 0	(2,3), Exit, (D), -10	(2,1), Exit, (D), -90	(2,1), Exit, (D), -90	(3,2), N, (3,3), 0
(3,1), Exit, (D), 20				(3,3), Exit, (D), 100

Vypočte Q hodnoty níže pomocí **přímé evaluace** (direct evaluation/estimation) z trénovacích epizod:

$$Q((3,2), \text{S}) = \underline{\hspace{2cm}} \quad Q((2,2), \text{E}) = \underline{\hspace{2cm}} \quad Q((1,2), \text{E}) = \underline{\hspace{2cm}}$$