

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΕΡΓΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Ενισχυτική Μάθηση με Προσεγγιστικές Μεθόδους:

- 1. Μάθηση Χρονικών Διαφορών, TD (Temporal Difference) Learning**
- 2. Στοχαστικός Αλγόριθμος Q-Learning**
- 3. Κατανεμημένη Υλοποίηση Ενισχυτικής Μάθησης**
- 4. Αλγόριθμος Bellman-Ford, Δρομολόγηση BGP στο Internet**

καθ. Βασίλης Μάγκλαρης

maglaris@netmode.ntua.gr

www.netmode.ntua.gr

Αίθουσα 002, Νέα Κτίρια ΣΗΜΜΥ

Τρίτη 2/5/2023

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Σύνοψη Εννοιών Δυναμικού Προγραμματισμού (1/2)

D. P. Bertsekas & J. Tsitsiklis, “Neuro-Dynamic Programming,” Athena MA 1996

R. S. Sutton & A. G. Barto, “Reinforcement Learning,” MIT Press 2018

Βασικές Παράμετροι Δυναμικού Προγραμματισμού - Ελαχιστοποίηση Κόστους

Άμεσο Κόστος (Observed Cost) βήματος μετάβασης $i \rightarrow j$ με απόφαση a : $g(i, a, j)$

Άμεσο Αναμενόμενο Κόστος (Immediate Expected Cost) κατάστασης i , απόφασης a :

$$c(i, a) \triangleq \sum_{j=1}^N p_{ij} g(i, a, j)$$

Ορισμός **Cost-to-Go**: $J^\mu(i) = c(i, \mu(i)) + \gamma \sum_{j=1}^N p_{ij}(\mu(i)) J^\mu(j)$ για $\forall i$ και πολιτική $\mu(i)$

Βέλτιστα **Cost-to-Go (Bellman)**: $J^*(i) = \min_{a \in \mathcal{A}_i} (c(i, a) + \gamma \sum_{j=1}^N p_{ij} J^*(j)), i = 1, 2, \dots, N$

Ορισμός **Q-Factors**: $Q^\mu(i, a) \triangleq c(i, a) + \gamma \sum_{j=1}^N p_{ij}(a) J^\mu(j)$ για $\forall i$ και $\forall a \in \mathcal{A}_i$

Βασικές Παράμετροι Δυναμικού Προγραμματισμού - Μεγιστοποίηση Οφέλους

Άμεση Ανταμοιβή (Observed Reward) βήματος μετάβασης $i \rightarrow j$ με απόφαση a : $R(i, a, j)$

Άμεση Αναμενόμενη Ανταμοιβή (Immediate Expected Reward) κατάστασης i , απόφασης a :

$$r(i, a) \triangleq \sum_{j=1}^N p_{ij} R(i, a, j)$$

Ορισμός **Value Function**: $V^\mu(i) = r(i, \mu(i)) + \gamma \sum_{j=1}^N p_{ij}(\mu(i)) V^\mu(j)$ για $\forall i$ και πολιτική $\mu(i)$


Βέλτιστα **Values (Bellman)**: $V^*(i) = \max_{a \in \mathcal{A}_i} (r(i, a) + \gamma \sum_{j=1}^N p_{ij} V^*(j)), i = 1, 2, \dots, N$

Ορισμός **Q-Factors**: $Q^\mu(i, a) \triangleq r(i, a) + \gamma \sum_{j=1}^N p_{ij}(a) V^\mu(j)$ για $\forall i$ και $\forall a \in \mathcal{A}_i$

Model-based & Model-free Reinforcement Learning

https://www.is.uni-freiburg.de/ressourcen/business-analytics/13_reinforcementlearning.pdf

- Αλγόριθμοι **Model-based** βασίζονται σε γνώση μοντέλων εξέλιξης του περιβάλλοντος, δηλαδή πιθανοτήτων μετάβασης $p_{ij}(a)$ **Markov Decision Processes**, και εφαρμογή επαναληπτικών μεθόδων **Policy** ή **Value Iteration**
- Αλγόριθμοι **Model-free** βασίζονται σε απευθείας μετρήσεις ή εκτιμήσεις σειράς εναλλαγής καταστάσεων του περιβάλλοντος (π.χ. με προσομοιώσεις **Monte Carlo** τροχιών καταστάσεων) και αναζήτηση βέλτιστων πολιτικών παρέμβασης του **Agent** με βάση την αποκτούμενη γνώση του κατά τη διαδικασία μάθησης, χωρίς πρότερη γνώση παραμέτρων του δυναμικού μοντέλου του περιβάλλοντος



ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Απευθείας Προσεγγιστικές Μέθοδοι Δυναμικού Προγραμματισμού (1/3)

Οι δύο **Model-based** αλγόριθμοι Δυναμικού Προγραμματισμού (**Value Iteration** & **Policy Iteration**) προαπαιτούν γνώση των **πιθανοτήτων μεταβάσεων** $p_{ij}(a)$ και του **άμεσα αναμενόμενου κόστους** κατάστασης i και απόφασης a

$$c(i, a) = \sum_{j=1}^N p_{ij}(a) g(i, a, j)$$

εκτιμώμενου με βάση τα **γνωστά** **observed** **κόστη μετάβασης** $i \rightarrow j$ που καθορίζονται από μια πολιτική $a = \mu(i)$

$$g(i, a, j) = g(i, \mu(i), j) \triangleq g(i, j)$$

Οι απευθείας **Model-free** προσεγγιστικές μέθοδοι (**Direct Approximate Dynamic Programming Methods**) ορίζουν σε κάθε βήμα την επόμενη μετάβαση $i \rightarrow j$ με απόφαση $a = \mu(i)$ και με γνωστό κόστος $g(i, a, j)$ και εκτιμούν τα αναμενόμενα κόστη καταστάσεων - αποφάσεων $c(i, a)$ πολιτικών $a = \mu(i)$ σαν μέσες τιμές ανεξαρτήτων τροχιών (**trajectories**) που επισκέπτονται την κατάσταση i κατά τη διαδικασία μάθησης

Αντιστοιχούν στους δύο βασικούς αλγόριθμους Δυναμικού Προγραμματισμού με τις εξής **Model-free** παραλλαγές:

- Value Iteration → **Temporal-Difference TD(0) Learning**
- Policy Iteration → **Q-Learning**


Οι απευθείας προσεγγιστικές μέθοδοι θεωρούνται οι κύριες υλοποιήσεις της Ενισχυτικής Μάθησης: **Reinforcement Learning** $\cong$ **Direct Approximations of Dynamic Programming**

Ορισμοί *on-policy*, *off-policy*

- Η *on-policy* σε κάθε βήμα εκτιμά (με μετρήσεις ή προσομοιώσεις *Monte Carlo*) τα *Cost-to-Go* $J(i)$ των καταστάσεων i . Με επισκέψεις καταστάσεων κατά μήκος μιας τροχιάς (*trajectory*) οδηγούμενες από αποφάσεις $i \rightarrow a$, ανανεώνονται οι συναρτήσεις $J(i)$ και οδηγούνται προς σύγκλιση σύμφωνα με τις εξισώσεις του *Bellman*:

Value Iteration $\rightarrow$ TD(0)-Learning

Actor-Critic TD-Learning Model: *A.G. Barto, R.S. Sutton & C.W. Anderson* "Neuronlike adaptive elements that can solve difficult learning control problems," IEEE Transactions on Systems, Man and Cybernetics, vol. SMC-13, Sept. – Oct. 1983



- Η *off-policy* συγκρίνει εναλλακτικές αποφάσεις a σε καταστάσεις του περιβάλλοντος i μιας τροχιάς (*trajectory*) με εκτιμήσεις των $Q(i, a)$ ώστε σε επόμενο βήμα (επανάληψη) ο agent να επιλέξει με απληστία αποφάσεις με το ελάχιστο $Q(i, a)$ για την κατάσταση i . Το *Cost-to-Go* $J^\mu(i)$ μιας προσωρινής πολιτικής μ εκτιμώνται με μετρήσεις ή προσομοιώσεις *Monte Carlo* των *trajectories* που προέκυψαν με την παρούσα πολιτική, χωρίς να συμπεριλαμβάνονται άπληστες αποφάσεις $i \rightarrow a$ που θα προκύψουν από τα *Q-Factors* στο επόμενο βήμα:

Policy Iteration $\rightarrow$ Q-Learning

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Απευθείας Προσεγγιστικές Μέθοδοι Δυναμικού Προγραμματισμού (3/3)

Γενική Μεθοδολογία Προσομοίωσης Τροχιών Monte Carlo

- Οι προσομοιώσεις **Monte Carlo** δημιουργούν σενάρια πολλαπλών πιθανών τροχιών (**system trajectories**) της εξέλιξης του **Markov Decision Process** από μια αρχική κατάσταση i_0 μέχρι κάποια τελική $i_n \rightarrow i_T$ (T - *Terminal*: Βήμα τερματισμού τροχιάς)
- Για περιπτώσεις πεπερασμένου ορίζοντα $\{0, 1, \dots, K\}$ ορίζεται και ο όρος **επεισόδιο** για υλοποίηση πλήρους τροχιάς $i_0 \rightarrow i_K$ **κατά μήκος όλου του ορίζοντα**. Οι **τροχιές** ορίζονται για υποσύνολα της εξέλιξης του περιβάλλοντος, άρα η καταγραφή τους ισχύει και για σενάρια απείρου ορίζοντα $K \rightarrow \infty$
- Η διαδικασία μάθησης περιλαμβάνει δειγματοληπτική καταγραφή (**Monte Carlo Sampling**) πολλών ανεξάρτητων **trajectories** που δημιουργούνται σε κάθε επίσκεψη στη κατάσταση i_n με εξερεύνηση (**exploration**) εναλλακτικών επόμενης κατάστασης i_{n+1} . Οι τροχιές μπορεί να αγνοούν δυσπρόσιτες ή/και σπανίως επισκέψιμες καταστάσεις
- Οι τιμές συναρτήσεων **cost-to-go** $J^\mu(i)$ ανανεώνονται σε κάθε προσομοίωση με προσθήκη του (εκ των προτέρων **γνωστού** από τη διατύπωση του προβλήματος) **άμεσου** (**observed**) **κόστους μετάβασης** $g(i, j)$ σε επισκέψεις προσομοιωμένης τροχιάς μεταβάσεων του περιβάλλοντος από κατάσταση i προς κατάσταση j
- Οι μέθοδοι **Monte Carlo** απαιτούν γνώση της δομής του περιβάλλοντος από εμπειρία (όχι από γνώση πιθανοτήτων μετάβασης), διαχειρήσιμο αριθμό παρατηρήσιμων (**observable**) καταστάσεων και σημαντικό αριθμό από **trajectories** για καλές εκτιμήσεις

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Προσεγγιστικός Αλγόριθμος $TD(0)$ Learning (1/2)

Value Iteration $\rightarrow$ Temporal-Difference $TD(0)$ Learning

Με επανειλημμένες προσομοιώσεις **Monte Carlo** δημιουργούμε M **trajectories** (τροχιές) του περιβάλλοντος με κάποια πολιτική μ και προσεγγίζουμε τα **Costs-to-Go** $J^\mu(i_n)$ με βάση τις εξισώσεις του **Bellman** από i_n , $n < T$, προς τελική κατάσταση $i_T = 0$:

$$J^\mu(i_n) = E[g(i_n, i_{n+1}) + \gamma J^\mu(i_{n+1})] = E \left[\sum_{k=0}^{T-n-1} \gamma^k g(i_{n+k}, i_{n+k+1}) \right] = E[c(i_n)]$$

Τα $J^\mu(i_n)$ εκτιμώνται σαν **ensemble averages** του υπολειπόμενου κόστους $J(i_n)$ κατά μήκος M τροχιών $\{i_n, i_{n+1}, \dots, i_T\}$. Το κόστος μιας τροχιάς είναι $c(i_n) \triangleq \sum_{k=0}^{T-n-1} \gamma^k g(i_{n+k}, i_{n+k+1})$ και για M ανεξάρτητες τροχιές ο μέσος όρος $J(i_n) = E[c(i_n)]$ εκτιμάται σαν

$$J(i_n) = E[c(i_n)] \cong \frac{1}{M} \sum_M c(i_n)$$

Τα κόστη $J(i_n)$ συγκλίνουν μέσω **Robbins-Monro Successive Approximations** που διορθώνουν εκτιμήσεις τιμών τους (**updates**) σε κάθε επίσκεψη της κατάστασης i_n κατά την εξέλιξη μιας τροχιάς $i_n \rightarrow i_{n+1}$ με συντελεστή μάθησης (**learning rate**) η_n :

$$J(i_n) := J(i_n) + \eta_n [g(i_n, i_{n+1}) + \gamma J(i_{n+1}) - J(i_n)] = J(i_n) + \eta_n d_n$$

Το σφάλμα $d_n \triangleq g(i_n, i_{n+1}) + \gamma J(i_{n+1}) - J(i_n)$, $n = 0, 1, \dots, T - 1$ ονομάζεται χρονική διαφορά (**Temporal Difference, TD**) στο βήμα n μίας **trajectory**. Οδηγεί τα $J(i_n)$ προς σύγκλιση ελαχιστοποιώντας το σφάλμα d_n με επαναλήψεις **ανεξάρτητων** τροχιών που προκύπτουν από την εφαρμογή μιας πολιτικής μ

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Προσεγγιστικός Αλγόριθμος $TD(0)$ Learning (2/2)

Value Iteration $\rightarrow$ Temporal-Difference $TD(0)$ Learning

Εναλλακτικός αλγόριθμος **update** προκύπτει από την μακρόχρονη επαναληπτική σχέση:

$$J(i_n) := J(i_n) + \eta_n \left(\sum_{k=0}^{T-n-1} \gamma^k g(i_{n+k}, i_{n+k+1}) - J(i_n) \right) = J(i_n) + \eta_n \sum_{k=0}^{T-n-1} \gamma^k d_{n+k}$$

Τα **costs-to-go** εκτιμώνται σαν μέσοι όροι (**ensemble averages**) σε μεγάλο αριθμό M επαναλήψεων προσομοιώσεων με πολλαπλές επισκέψεις καταστάσεων i_n στο βήμα n κάποιας **trajectory**

$$J^\mu(i_n) = \mathbb{E} \left[\sum_{k=0}^{T-n-1} \gamma^k g(i_{n+k}, i_{n+k+1}) \right] = \mathbb{E}[c(i_n)] \cong J(i_n) = \frac{1}{M} \sum_M c(i_n)$$

όπου

$$c(i_n) \triangleq \sum_{k=0}^{T-n-1} \gamma^k g(i_{n+k}, i_{n+k+1})$$

Οι συναρτήσεις $J(i_n)$ υπολογίζονται με επαναλαμβανόμενες επισκέψεις της i_n σε παρατηρήσιμες (**observable**) τροχιές T βημάτων που παράγονται από προσομοιώσεις **Monte Carlo**

$$J(i_n) := J(i_n) + \eta_n (c(i_n) - J(i_n))$$

με αρχικές συνθήκες $J(i_n) = 0$ και **learning rate** $\eta_n = 1/n$, $n = 1, 2, \dots, T$

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Προσεγγιστικός Αλγόριθμος Q-Learning (1/2)

Policy Iteration → Q-Learning

Αλγόριθμος Υπολογισμού $Q^*(i, a)$ με Successive Approximations (**Robins-Monro**)

$$Q(i, a) := (1 - \eta)Q(i, a) + \eta \sum_{j=1}^N p_{ij}(a) \left[g(i, a, j) + \gamma \min_{b \in \mathcal{A}_j} Q(j, b) \right] \text{ για } \forall (i, a)$$

Από το όριο $Q^*(i, a)$ των επαναλήψεων προσδιορίζεται ο πίνακας βέλτιστης πολιτικής π με αντιστοίχιση

$$\mu^*(i) = \arg \min_{a \in \mathcal{A}_i} Q^*(i, a) \text{ για } i = 1, 2, \dots, N$$

- Προσδιορισμός πολιτικής βέλτιστης συμπεριφοράς (**off-policy behavior generation**) μέσω επεξεργασίας πολλαπλών **trajectories** (τροχιών) για δυνατά σενάρια αποφάσεων: **Q-Learning**
- Ορίζουμε $s_n \triangleq (i_n, a_n, j_n, g_n)$ στο βήμα n μιας **trajectory** όταν η κατάσταση του περιβάλλοντος οδηγείται σε μετάβαση $i_n \rightarrow i_{n+1} = j_n$ με απόφαση του agent a_n και **observed** κόστος μετάβασης $g_n = g(i_n, a_n, j_n)$
- Με βάση την καταγραφή των s_n σε εναλλακτικές **trajectories** ο αλγόριθμος **Q-Learning** οδηγεί το σύστημα στη μάθηση βέλτιστης πολιτικής σαν υλοποίηση του **policy iteration**
- **Προϋπόθεση:** Η i_n που προκύπτει σε μια **trajectory** πρέπει να είναι **fully observable**

Προσεγγιστικός Αλγόριθμος Q-Learning (2/2)

Στοχαστική Model-free Παραλλαγή με Προσομοίωση Τροχιών Monte Carlo

Για να αποφύγουμε γνώση των $p_{ij}(a)$ ορίζουμε τροχιά (**trajectory**) από αρχική κατάσταση i_0 μέχρι την i_n με προσομοίωση **Monte Carlo** εξέλιξης της συμπεριφοράς του περιβάλλοντος και εφαρμογή κάποιας **behavior policy**

Στο παρόν βήμα n ο **agent** εκτιμά τους **Q-factors** και τα αναμενόμενα **costs-to-go** $J_n(j)$ για καταστάσεις j που προκύπτουν με **greedy estimation policy** (μη ταυτιζόμενη με την **behavior policy** που δημιουργήσε την τροχιά της κατάστασης του περιβάλλοντος)

Η μέση τιμή (**average**) στον υπολογισμό των **Q-factors** αντί της μέσης προβλεπόμενης κατάστασης που απαιτεί γνώση των $p_{ij}(a)$ προσεγγίζεται από την θεώρηση μιας τροχιάς και σε συνέχεια υπολογισμό μέσων όρων πολλαπλών ανεξάρτητων τροχιών

Για ζεύγος $(i, a) = (i_n, a_n)$ επαναληπτικός αλγόριθμος υπολογίζει τα $Q_{n+1}(i, a)$ από $Q_n(i, a)$ ως εξής:

- $Q_{n+1}(i, a) = (1 - \eta_n)Q_n(i, a) + \eta_n[g(i, a, j) + \gamma J_n(j)]$
- $J_n(j) = \min_{b \in \mathcal{A}_j} Q_n(j, b)$ όπου $j = i_{n+1}$ η **επόμενη** κατάσταση της $i = i_n$
- $Q_{n+1}(i, a) = Q_n(i, a)$ για όλα τα υπόλοιπα ζεύγη $(i, a) \neq (i_n, a_n)$
- Με την πρόοδο των επαναλήψεων $Q_n(i, a) \rightarrow Q^*(i, a)$
- Η **learning parameter** η_n είναι φθίνουσα ως προς n , π.χ. $\eta_n = \alpha/(\beta + n)$ με α, β θετικά

Επειδή τροχιές με **greedy** αποφάσεις (**exploitation**) μπορεί να αγνοήσουν επιλογές καταστάσεων λόγω εκκίνησης από μια κατάσταση, απαιτείται προσομοίωση πολλαπλών **τροχιών** για επισκέψεις σε ευρύ φάσμα καταστάσεων (**exploration**). Το εύρος της αναζήτησης ενισχύεται με απόφαση **greedy** με πιθανότητα $(1 - \epsilon)$ ή άλλης με πιθανότητα ϵ

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Κατανεμημένη Υλοποίηση Ενισχυτικής Μάθησης

Μοντέλο Συνεργατικής Βελτιστοποίησης μέσω Πολλαπλών Αυτόνομων Agents

Η κατανεμημένη συνεργατική βελτιστοποίηση κωδικοποιήθηκε σαν **Multi-Agent Reinforcement Learning – MARL** από τον **Michael Littman** το 1994

<https://www2.cs.duke.edu/courses/spring07/cps296.3/littman94markov.pdf>

- Επέκταση του Δυναμικού Προγραμματισμού με συνεργασία (**cooperative zero-sum game**) 2+ αυτόνομων **agents**
- Κάθε agent παίρνει αποφάσεις προς βέλτιστες πολιτικές που επηρεάζονται από τις πολιτικές των αυτόνομων συνεργατών του σύμφωνα με μοντέλο **Markov (Stochastic) Game**
- Κατανεμημένη υλοποίηση αλγορίθμου **Q-Learning** με **ασύγχρονα updates** μεταξύ των **agents**
- Ορισμός των **Q-factors** σαν **minimax Q-factors** ώστε να εξαρτώνται και από τις αποφάσεις των συνεργαζομένων **agents**.
- Ο υπολογισμός των **minimax Q-factors** μπορεί να γίνεται με επαναληπτική εφαρμογή **Linear Programs** αλλά με σημαντική υπολογιστική επιβάρυνση. Πρακτικά και για συγκεκριμένες εφαρμογές μπορεί να είναι εξαιρετικά απλός ή να αντιμετωπιστεί με γρήγορους ευριστικούς αλγορίθμους

Εφαρμογή μεγάλης κλίμακας (**73,000 agents/routers**) στο **Border Gateway Protocol (BGP)** για δρομολόγηση προς τα **1,100,000 γνωστά δίκτυα** του παγκόσμιου **Internet**

Το παγκόσμιο **Internet** αποτελείται (6/2021) από ~1, 100, 000 γνωστά δίκτυα τελικούς προορισμούς (π.χ. Δίκτυο ΕΜΠ, IP: 147.102.0.0/16), οργανωμένα σε ~73, 000 Αυτόνομα Συστήματα (**Autonomous Systems, AS**) με διαχειριστική αυτονομία (π.χ. GRNET/ΕΔΙΤΕ, Autonomous System Number - **ASN 5408**)

Η δρομολόγηση εντός Αυτόνομης Κοινότητας γίνεται με βάση κεντρικά ρυθμιζόμενα πρωτόκολλα (**Interior Gateway Protocols – IGP**, π.χ. OSPF) ενώ μεταξύ των 73, 000 AS's μέσω γενικών πινάκων δρομολόγησης σε συνοριακούς δρομολογητές (**Border Gateways, Border Routers**) με καταχωρήσεις για όλα τα ~1, 100, 000 γνωστά δίκτυα του **Internet**

Η δημιουργία – ανανέωση των γενικών πινάκων δρομολόγησης (σε ηλεκτρονική μνήμη των Border Gateways) γίνεται με το Border Gateway Protocol – BGP (RFC 4271)

- Οι **Border Routers (Gateways)** των **AS** ανακοινώνουν (μέσω **BGP signaling**) στα 73, 000 **AS's** του **Internet** τα 1, 100, 000 δίκτυα – τελικούς προορισμούς τα οποία είτε ανήκουν σε αυτά ή είναι προσπελάσιμα (**reachable**) διαμέσου αυτών, με εκτιμήσεις κόστους (βάρους) βέλτιστων **inter-AS** δρόμων προς κάθε δίκτυο - προορισμό
- Οι **Border Gateways** υπολογίζουν αυτόνομα βέλτιστες διαδρομές προς όλους τους τελικούς προορισμούς με βάση τις προτιμήσεις (πολιτικές) των διαχειριστών τους, όποτε κρίνουν πως αλλαγές τοπολογίας ή πολιτικής ή επίδοσης επιβάλλουν ανανέωση δρόμων
- Ο κατανομημένος προσδιορισμός βέλτιστης δρομολόγησης ορίζει κόστη προς τους 1,100, 000 τελικούς προορισμούς βάση πληροφοριών **reachability** και μετρήσεων κόστους διασύνδεσης προς τα γειτονικά **AS**. Βασίζεται στον Αλγόριθμο **Bellman – Ford**

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Παράδειγμα Δυναμικού Προγραμματισμού: Δρομολόγηση BGP στο Internet - RFC 4271 (2/7)

Αλγόριθμος Distance Vector (Bellman – Ford)

BGP (Bellman – Ford)

- Οι συνοριακοί δρομολογητές (**Border Gateways**) κάθε Αυτόνομης Περιοχής (**AS**) εντοπίζουν τους βέλτιστους δρόμους (**shortest paths**) ενδιάμεσων και τελικού **AS** προς όλα τα γνωστά δίκτυα προορισμούς εκτελώντας αλγόριθμο βασισμένο στον δυναμικό προγραμματισμό (**dynamic programming**) που εισήγαγε ο **Bellman**
- Χρειάζεται γνώση διανυσμάτων κόστους (βαρών) των άμεσων συνδέσεων (**Inter AS Interfaces**) και εκτιμήσεις κόστους (αποστάσεις, **distance vectors**) προς όλα τα γνωστά δίκτυα προορισμούς στο **Internet** (**1,100,000+**, **7/2022**)
- Η βελτιστοποίηση βασίζεται σε καταναεμημένο αλγόριθμο **Bellman - Ford** που υλοποιείται μέσω σηματοδοσίας ανακοινώσεων (**BGP Announcements**) μεταξύ όλων των (**73,000+**, **10/2022**) Αυτόνομων Περιοχών (**AS**) του **Internet** με πληροφορίες δρομολόγησης και εκτιμήσεις κόστους
- Από τη σκοπιά του **Reinforcement Learning** το **BGP** μπορεί να θεωρηθεί καταναεμημένη επέκταση του Δυναμικού Προγραμματισμού με συνεργασία (**cooperative game**) **73,000** αυτόνομων **Agents**


Το **BGP** αποτελεί κύριο παράγοντα επιτυχίας της παγκόσμιας επανάστασης του **Internet**

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Παράδειγμα Δυναμικού Προγραμματισμού: Δρομολόγηση BGP στο Internet - RFC 4271 (3/7)

Δίκτυο (Γράφος) Αναφοράς Παραδείγματος, $N = 6$ Κόμβων

- Οι κόμβοι του γράφου παριστούν τα διάφορα **AS** του **Internet**
- Τα δίκτυα πηγής και προορισμού των χρηστών είναι ενσωματωμένα στους κόμβους (**AS**) **Source** – **Destination** του γράφου
- Τα κόστη των γραμμών του γράφου αφορούν και στις 2 κατευθύνσεις και εκτιμώνται από τους άμεσα συνδεόμενους κόμβους (**Border Gateways**) με βάση προτιμήσεις των διαχειριστών
- Στο παράδειγμα που ακολουθεί υπολογίζονται δένδρα ελαχίστων δρόμων (**shortest path trees**) από όλους τους κόμβους (**AS**) προς την **ρίζα** {6}
- Η επιλογή του ρόλου της ρίζας του δένδρου (πηγή ή προορισμός) έγινε αυθαίρετα. Οι αλγόριθμοι ισχύουν κατ' αναλογία για αντίστροφους ρόλους ρίζας



Υπολογισμός Δένδρου Ελάχιστων Δρόμων (Shortest Path Tree) προς {6}

Εφαρμογή Αλγορίθμου Q-Learning (*Off-policy*) με *Asynchronous Updates*

- $\{i\}$ Κατάσταση (**State**) του γράφου, κόμβος (**AS**) $i = 1, 2, \dots, N$ (στο παράδειγμα $N = 6$, μέχρι 80,000 στο **Internet**)
- $P^{(n)}(i)$ Απόφαση (**Action**): Επόμενος κόμβος (**AS**) από τον $\{i\}$ προς τον $\{6\}$, ενδιάμεσος ή τελικός στην επανάληψη (**Iteration**) n
- d_{ij} Κόστος (βάρος) γραμμής (i, j) στην επανάληψη n (**Transition Cost**) ρυθμιζόμενο από την πολιτική δρομολόγησης του $\{i\}$ ή/και απευθείας μετρήσεις των αμέσων γειτόνων $\{i, j\}$. Αν $d_{ij} = c, \forall (i, j) \Rightarrow \text{min hop routing}$
- $L^{(n)}(i)$ **Labels, Q-Factors** $L^{(n)}(i) \triangleq Q(i, P^{(n)}(i))$: Εκτιμήσεις ελάχιστου κόστους από τον $\{i\}$ προς τον $\{6\}$ στην επανάληψη n (ανανεώνονται **ασύγχρονα**, σύμφωνα με τις **πιο πρόσφατες εκτιμήσεις** ανάλογα με την σειρά εκτέλεσης των ανανεώσεων – **updates**). Οι τροχιές (**trajectories**) αφορούν στις επιλογές δρόμων από τον $\{i\}$ προς τον $\{6\}$ σε κάθε επανάληψη

Περιγραφή Αλγορίθμου Bellman – Ford

- Αρχικά έχουμε $L_i^{(0)} = \infty \forall i \neq 6, L_6^{(n)} = 0 \forall n$,
- Σε κάθε διαδοχική επανάληψη (**iteration**) $n = 1, 2, \dots$ και $\forall i$ ανανεώνουμε **ασύγχρονα** τις εκτιμήσεις ελάχιστου κόστους από την παρούσα κατάσταση προς τον προορισμό με βάση τις σχέσεις του Δυναμικού Προγραμματισμού σύμφωνα με τις πιο πρόσφατες εκτιμήσεις (**updates**) των $L_j^{(n)}$ για όλους τους άμεσους γείτονες j του i :

$$L_i^{(n+1)} = \min_j \{L_j^{(n)} + d_{ij}\} \forall i \neq 6$$

- Αν $L_i^{(n+1)} = L_i^{(n)} \forall i$ σταματάμε τον αλγόριθμο και προσδιορίζουμε τους βέλτιστους δρόμους από όλα τα $\{i\}$ προς τον προορισμό $\{6\}$ σύμφωνα με τις αποφάσεις $P^{(n)}(i)$ σαν **Shortest Path Tree** με ρίζα τον $\{6\}$
- Πολυπλοκότητα αλγορίθμου: $O(N^3)$

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Παράδειγμα Δυναμικού Προγραμματισμού: Δρομολόγηση BGP στο Internet - RFC 4271 (5/7)

Εκτέλεση Αλγορίθμου για Προορισμό {6}

Παράδειγμα: INITIAL LABELS: $L(1)=L(2)=\dots=L(5)=\infty$, $L(6)=0$



UPDATE ORDER 5,4,3,2,1

Iteration Number	Labels $L(n)$, Current Predecessor Node $P(n)$				
	$L(5), P(5)$	$L(4), P(4)$	$L(3), P(3)$	$L(2), P(2)$	$L(1), P(1)$
1	2 6	3 5	3 5	5 4	4 4
2	2 6	3 5	3 5	5 4	4 4


UPDATE ORDER 1,2,3,4,5

Iteration Number	Labels $L(n)$, Current Predecessor Node $P(n)$				
	$L(1), P(1)$	$L(2), P(2)$	$L(3), P(3)$	$L(4), P(4)$	$L(5), P(5)$
1	∞ -	∞ -	5 6	8 3	2 6
2	9 4	8 3	3 5	3 5	2 6
3	4 4	5 4	3 5	3 5	2 6
4	4 4	5 4	3 5	3 5	2 6

Η ταχύτητα σύγκλησης εξαρτάται από την σειρά ανανέωσης των Labels των κόμβων



Παράδειγμα Μάθησης - Ανακοίνωσης Δικτύου 135.207.0.0/16
(από παρουσίαση του *Timothy G. Griffin, AT&T Research, Paris 2002*)



ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Παράδειγμα Δυναμικού Προγραμματισμού: Δρομολόγηση BGP στο Internet - RFC 4271 (7/7)

Εικόνα των Δρόμων BGP προς το ntua.gr – 147.102.0.0/16 (22-10-2022)

<https://stat.ripe.net/widget/bgplay>

NTUA (AS: 3323)

GRNET (AS: 5408)

ΓΕΑΝΤ (AS: 21320)

ΓΕΑΝΤ Internet Feeds

- **LEVEL3 (AS: 3356)**
- **COGENT 174 (AS: 174)**
- **HURRICANE US (AS: 6939)**
- **NORDUnet (AS: 2603)**

