

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΕΡΓΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

**Εισαγωγικά περί Μηχανικής Μάθησης
Επισκόπηση Linear & Logistic Regression**

καθ. Βασίλης Μάγκλαρης

maglaris@netmode.ntua.gr

www.netmode.ntua.gr

Αίθουσα 02, Νέα Κτίρια ΣΗΜΜΥ

Τρίτη 1/3/2022

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Βιβλιογραφικές Αναφορές

1. Simon Haykin, “**Neural Networks & Learning Machines**”, 3rd Edition, Pearson Education, 2009
2. Simon Haykin, “**Νευρωνικά Δίκτυα & Μηχανική Μάθηση**”, 3η Έκδοση, Παπασωτηρίου, 2010
3. Bernhard Mehlig, “**Machine learning with neural networks**”, Cambridge Univ. Press 2021
<https://arxiv.org/pdf/1901.05639.pdf>
4. Μιχάλης Λουλάκης, “**Στοχαστικές Διαδικασίες**”, ΣΕΑΒ 2015
http://repfiles.kallipos.gr/html_books/9759/TOC.html
5. Βασίλης Μάγκλαρης, “**Σημειώσεις Μαθήματος Συστήματα Αναμονής**”, Συλλογή διαφανειών για το προπτυχιακό μάθημα της ΣΗΜΜΥ – ΕΜΠ, 2018
http://www.netmode.ntua.gr/courses/undergraduate/queues/documents/Queuing_Systems_2018.pdf
6. Kevin P. Murphy, “**Machine Learning: A Probabilistic Perspective**”, MIT Press, 2012
7. Ian Goodfellow, Yoshua Bengio, Aaron Courville, “**Deep Learning**”, MIT Press, 2016
<https://www.deeplearningbook.org/>
8. Daniel Jurafsky, James H. Martin, “**Speech and Language Processing: An Introduction to Natural Language Processing, Computational Linguistics & Speech Recognition**”, 3rd Edition draft, 2018
9. Andrew Ng, “**CS229 Lecture Notes**”, Stanford University, Fall 2018
<https://see.stanford.edu/materials/aimlcs229/cs229-notes1.pdf>
10. James Gareth, Daniela Witten, Trevor Hastie, Robert Tibshirani, “**An Introduction to Statistical Learning**”, 2nd Edition, Springer 2021 https://hastie.su.domains/ISLR2/ISLRv2_website.pdf
11. Richard Sutton, Andrew Barto, “**Reinforcement Learning: An Introduction**”, MIT Press, 2018
12. Christopher Bishop, “**Pattern Recognition & Machine Learning**”, Springer 2006
13. Tom Mitchell, “**Machine Learning**”, McGraw Hill 1997 <http://www.cs.cmu.edu/~tom/mlbook.html>
14. Frank Kelly, “**Reversibility and Stochastic Networks**”, Wiley, 1979
<http://www.statslab.cam.ac.uk/~frank/BOOKS/book/whole.pdf>
15. Sheldon Ross, “**Applied Probability Models with Optimization Applications**”, Dover, 1992

Στα υλικά του μαθήματος αναπαράγονται σχήματα από τις αναφορές [1], [3] και [4] χωρίς περεταίρω ειδική μνεία

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Περιγραφή Ύλης (1/2)

1. Επισκόπηση Μηχανικής Μάθησης: Επιβλεπόμενη, μη επιβλεπόμενη, ενισχυτική μάθηση. Σύνολα δεδομένων Training, Validation & Testing Datasets. Linear & Logistic Regression, προσδιορισμός παραμέτρων Νευρωνικών Δικτύων με επιβλεπόμενη μάθηση, Back-Propagation Algorithm, κανόνας του Hebb (ύλη βασισμένη στο κεφ. 1 της [1], στο κεφ. 1 της [3], στο κεφ. 1 της [7] και στην [9])
2. Μη Επιβλεπόμενη Μάθηση: K-Means Clustering, Ανάλυση Κυρίων Συνιστωσών (Principal Components Analysis - PCA), Self-Organizing Maps (SOM), Autoencoders (ύλη βασισμένη στα κεφ. 5 & 8 της [1] και στο κεφ. 10 της [3])
3. Βασικές Έννοιες Στατιστικής Μηχανικής στη Μηχανική Μάθηση: Αλυσίδες Markov, ταξινόμηση καταστάσεων, πιθανότητες μετάβασης, εξισώσεις Chapman - Kolmogorov, επαναληπτικότητα - παροδικότητα, αναλλοίωτες κατανομές, ασυμπτωτική συμπεριφορά (ύλη βασισμένη στο κεφ. 11 της [1], και στις [4], [5])
4. Μέθοδοι Monte Carlo προσομοίωσης αλυσίδων Markov, αλγόριθμος Metropolis - Hastings. Προσομοιωμένη Ανόπτηση (Simulated Annealing), δειγματοληψία Gibbs. Παραγωγικά Μοντέλα Μάθησης (Generative Models), Μηχανή Boltzmann, Restricted Boltzmann Machine (RBM), Δίκτυα Πεποίθησης Μεγάλου Βάθους (Deep Belief Nets - DBN) (ύλη βασισμένη στο κεφ. 11 της [1] και στο κεφ. 4 της [3])
5. Ενισχυτική Μάθηση και Δυναμικός Προγραμματισμός: Διαδικασίες Απόφασης Markov (Markov Decision Processes), κριτήριο βελτιστοποίησης Bellman (Bellman's Optimality Criterion), αλγόριθμοι βελτιστοποίησης Δυναμικού Προγραμματισμού (Policy Iteration & Value Iteration Algorithms). Προσεγγιστικές μέθοδοι δυναμικού προγραμματισμού, Q-Learning (ύλη βασισμένη στο κεφ. 12 της [1])

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Περιγραφή Ύλης (2/2)

6. Ενισχυτική Μάθηση για Δρομολόγηση στο Internet: Αλγόριθμος Bellman-Ford, Border Gateway Protocols (BGP) (ύλη βασισμένη στο μάθημα ΣΗΜΜΥ Ε.Μ.Π. «Διαχείριση Δικτύων – Ευφυή Δίκτυα» http://www.netmode.ntua.gr/courses/undergraduate/netman/2021-2022/NetMan_2021_11_01.pdf)
7. Αλγόριθμοι Πυρήνα και Διαχωρισιμότητα Προτύπων: Θεώρημα του Cover, εφαρμογές σε Radial-Basis Function (RBF) Networks, Υβριδική Μάθηση, Support Vector Machines (SVM) (ύλη βασισμένη στα κεφ. 5 & 6 της [1] και στο κεφ. 6 της [13])
8. Παραμετρική Πιθανοτική Ταξινόμηση, κανόνας Bayes, προσεγγιστικές μέθοδοι, αλγόριθμος Naïve Bayes. Μη-παραμετρικοί Ταξινομητές, K-Nearest Neighbors (KNN) (ύλη βασισμένη στο κεφ. 6 της [13] και στο κεφ. 5 της [7])
9. Δένδρα Αποφάσεων (Decision Trees): Αλγόριθμοι διαμόρφωσης CART (Classification And Regression Trees), Gini Index, Random Forests, Αλγόριθμοι Bagging (Bootstrap & aggregating (ύλη βασισμένη στο κεφ. 8 της [10])
10. Ακολουθιακά Μοντέλα και Αλγόριθμοι βασισμένοι σε Time-series & Speech Processing Datasets: Recurrent Neural Nets (RNN), δίκτυα Hopfield, Long-Short Term Memory (LSTM) Nets (ύλη βασισμένη στο κεφ. 15 της [1], στο κεφ. 2 της [3] και στο κεφ. 10 της [7])

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Μερικοί Θεμελιωτές του Κλάδου (1/2)

Thomas Bayes (1701 -1761): Συνδυαστικές Πιθανότητες, Στατιστικές Εκτιμήσεις

https://en.wikipedia.org/wiki/Thomas_Bayes



Johann Carl Friedrich Gauss (1777 -1855): Άλγεβρα, Θεωρία Αριθμών, Κατανομή Σφάλματος Παρατηρήσεων

https://en.wikipedia.org/wiki/Carl_Friedrich_Gauss



Josiah Willard Gibbs (1839 -1903): Στατιστική Μηχανική, Θερμοδυναμική

https://en.wikipedia.org/wiki/Josiah_Willard_Gibbs



Ludwig Boltzmann (1844 -1906): Στατιστική Μηχανική

https://en.wikipedia.org/wiki/Ludwig_Boltzmann



Andrey Markov (1856 -1922): Θεωρία Πιθανοτήτων, Στοχαστικές Διεργασίες

https://en.wikipedia.org/wiki/Andrey_Markov



Andrey Kolmogorov (1903 -1987): Θεωρία Πιθανοτήτων

https://en.wikipedia.org/wiki/Andrey_Kolmogorov



Richard Bellman (1920 - 1984): Εφαρμοσμένα Μαθηματικά, Δυναμικός Προγραμματισμός

https://en.wikipedia.org/wiki/Richard_E._Bellman



ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Μερικοί Θεμελιωτές του Κλάδου (2/2)

Nicholas Metropolis - Μητρόπουλος (1915 - 1999): Προσομοίωση Monte Carlo, Simulated Annealing
https://en.wikipedia.org/wiki/Nicholas_Metropolis



Donald Hebb (1904 - 1985): Νευροφυσιολογία, Κανόνες Μάθησης
https://en.wikipedia.org/wiki/Donald_O._Hebb



Frank Rosenblatt (1928 - 1972): Ψυχολογία, Τεχνητή Νοημοσύνη (AI), Νευρωνικά Δίκτυα, Perceptron
https://en.wikipedia.org/wiki/Frank_Rosenblatt



David Rumelhart (1942 - 2011): Ψυχολογία, AI, Back Propagation Algorithm
https://en.wikipedia.org/wiki/David_Rumelhart



John Hopfield (1933): Φυσική, Βιολογία, AI, Recurrent Neural Networks (RNN)
https://en.wikipedia.org/wiki/John_Hopfield



Geoffrey Hinton (1947): AI, Back Propagation Algorithm, Μηχανή Boltzmann, Deep Belief Networks
https://en.wikipedia.org/wiki/Geoffrey_Hinton



Vladimir Vapnik (1936): Στατιστική Μάθηση, Support Vector Machines (SVM)
https://en.wikipedia.org/wiki/Vladimir_Vapnik



Teuvo Kohonen (1934 - 2021): Self-Organizing Maps (SOM)
https://en.wikipedia.org/wiki/Teuvo_Kohonen



Εισαγωγικά περί Μηχανικής Μάθησης (1/5)

Λόγοι ανάπτυξης Μηχανικής Μάθησης:

- Η κατακλυσμαία ανάπτυξη υπολογιστικών υποδομών αποθήκευσης και επεξεργασίας δεδομένων, επιτρέπει σήμερα την υλοποίηση αλγορίθμων στατιστικής ανάλυσης και στοχαστικής βελτιστοποίησης με βάση ιστορικά στοιχεία δείγματος μάθησης
- Η αλματώδης συσσώρευση τεράστιου όγκου πολυδιάστατων δεδομένων (*big data*) με πολλά χαρακτηριστικά, απαιτεί την ανάπτυξη ευφυών αλγορίθμων εξόρυξης εκτιμήσεων, προβλέψεων και ταξινόμησης νεοεμφανιζόμενων δειγματικών στοιχείων
- Η κατανόηση μεθόδων μάθησης σε βιολογικά συστήματα οδηγεί σε αλγορίθμους τεχνητής νοημοσύνης για συμπλήρωση και ελεγχόμενη πρόβλεψη (ή/και δημιουργία) δειγματικών στοιχείων, συμπεριλαμβανομένων ακολουθιών και χρονοσειρών (στοχαστικών διαδικασιών, *stochastic processes*) με βάση παρεμφερή στατιστικά χαρακτηριστικά αποθηκευμένου δείγματος μάθησης

Ορισμός:

Το σύνολο μεθόδων αυτοματοποιημένης ανίχνευσης (*detection*), επεξεργασίας και αποθήκευσης προτύπων - σχεδίων δεδομένων (*data patterns*) μέσω διαδικασίας μάθησης (*learning phase*) από γνωστά *training sets* για γενίκευση σε *test sets* (*generalization*):

- *Συσχέτιση, ταξινόμηση και ομαδοποίηση* μεγάλου όγκου δεδομένων με επιλογή κυρίαρχων χαρακτηριστικών τους (*features, patterns*)
- *Αναγνώριση προτύπων* με βάση κύρια χαρακτηριστικά τους (*pattern recognition*)
- *Προσέγγιση συναρτήσεων* από ζεύγη τιμών δεδομένων
- *Προβλέψεις εμφάνισης* σύμφωνα με τα σχέδια που προέκυψαν
- *Στήριξη λήψης αποφάσεων* σε περιβάλλον αβεβαιότητας με χρήση εργαλείων θεωρίας πιθανοτήτων – στοχαστικών διαδικασιών, στατιστικής και βέλτιστου ελέγχου συστημάτων

Εισαγωγικά περί Μηχανικής Μάθησης (2/5)



Ορισμοί Συνόλων Δεδομένων (Datasets)

https://en.wikipedia.org/wiki/Training_validation_and_test_sets

- **Training Datasets:** Δείγμα (*sample*) παραδειγμάτων (σύνολο δειγματικών στοιχείων, *examples, sample points*) που χρησιμοποιείται στη διαδικασία **μάθησης** για ρύθμιση παραμέτρων ενός μοντέλου μηχανικής μάθησης με συγκεκριμένη διάρθρωση
- **Validation Datasets:** Δείγμα παραδειγμάτων με χαρακτηριστικά όμοια με του δείγματος μάθησης για **επικύρωση** της σύγκλισης της διαδικασίας μάθησης. Οδηγεί στη επιλογή παραμέτρων διάρθρωσης ενός μοντέλου αποφάσεων (*hyperparameter selection*) μέσω συγκρίσεων της ακρίβειας (*accuracy*) προτεινόμενων μοντέλων, ενώ ελέγχει περιορισμούς για **γενίκευση** (*generalization*) που μπορεί να οφείλονται σε υπερβολική ακρίβεια (*overfitting*) στα δεδομένα του *training dataset*. Το *validation dataset* μπορεί να παραλείπεται ή να είναι υποσύνολο του *training dataset* με επιλογή μικρότερου αριθμού στοιχείων (10 - 20%)
- **Test Datasets:** Δείγμα παραδειγμάτων που δεν χρησιμοποιήθηκαν στη διαδικασία μάθησης και εισάγονται σε τελικά ρυθμισμένο σύστημα. Αξιολογούν την ικανότητα **γενίκευσης** (*generalization*) των χαρακτηριστικών (*features*) που καθορίστηκαν κατά την μάθηση
- Σε περίπτωση που δεν ορίζεται *validation dataset*, η ακρίβεια και η ικανότητα γενίκευσης ενός μοντέλου που προκύπτει από το *training dataset* κρίνεται απευθείας μέσω του *test dataset*

Ορισμοί Συνόλων Δεδομένων (Datasets)

https://en.wikipedia.org/wiki/Training,_validation,_and_test_sets



Training Dataset (μπλε σημεία μάθησης)

- Λεπτομερής **κίτρινη** καμπύλη εκτίμησης με απόκλιση $MSE=4$
- Απλή **πράσινη** καμπύλη με απόκλιση $MSE=9$

Test Dataset (μπλε σημεία γενίκευσης)

- Απόκλιση από **κίτρινη** καμπύλη $MSE=15$ (από 4) **OVERFITTING**
- Απόκλιση από **πράσινη** καμπύλη $MSE=13$ (από 9)

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Εισαγωγικά περί Μηχανικής Μάθησης (4/5)

Ορισμοί Παραμέτρων και Υπερπαραμέτρων

https://en.wikipedia.org/wiki/Hyperparameter_optimization

- Οι ρυθμιζόμενοι παράμετροι (*parameters*) κατά τη φάση μάθησης αφορούν σε συγκεκριμένη δομή μοντέλου (π.χ. προσδιορισμός συναπτικών βαρών νευρωνικού δικτύου). Ορίζονται με επαναλήψεις για τη συγκεκριμενοποίηση του μοντέλου εισόδου/εξόδου ώστε να εξάγει ακριβή (κατά τεκμήριο) συμπεράσματα όταν τροφοδοτείται από τα δειγματικά στοιχεία μάθησης
- Παράμετροι που αφορούν στη δομή του μοντέλου (π.χ. αριθμός νευρώνων, στρώματα κρυφών νευρώνων) και σε κριτήρια σύγκλισης αναφέρονται σαν υπερπαραμέτροι (*hyperparameters*)
- Οι *hyperparameters* επιλέγονται με βάση την εμπειρία του σχεδιαστή ή/και με δοκιμαστικές επαναλήψεις της διαδικασίας μάθησης (*training*) και επικύρωσης (*validation*) για να βελτιωθεί η ακρίβεια (*accuracy*) της τελικής διάρθρωσης συστήματος μηχανικής μάθησης πριν τη φάση *testing*
- Συνήθεις μέθοδοι για αναζήτηση *hyperparameters* μέσω επαναλαμβανόμενων δοκιμών: *Exhaustive search*, *Grid search*, *random search*... ανάλογα με τον επιτρεπτό αριθμό δοκιμών του μοντέλου με ρυθμισμένες παραμέτρους στη διαδικασία μάθησης
- Η επιλογή *hyperparameters* αν δεν υπάρχει διάκριση υποσυνόλου *validation dataset* στο *training dataset* μπορεί να γίνεται και με επαναληπτικές δοκιμές σε *test datasets*

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Εισαγωγικά περί Μηχανικής Μάθησης (5/5)

Γενικές Κατηγορίες Συστημάτων Μηχανικής Μάθησης

- **Επιβλεπόμενη Μάθηση με Εκπαιδευτή - Supervised Learning**
 - Χρήση δεδομένων μάθησης με συνημμένες επιθυμητές αποκρίσεις εξόδου (*labeled training sample points*) που εκπαιδεύουν σε πρώτη φάση το σύστημα Μηχανικής Μάθησης μέσω εξωτερικού εκπαιδευτή για αναζήτηση απόκρισης (ταξινόμηση, πρόβλεψη) σε επόμενη φάση γενίκευσης με νέα δεδομένα εισόδου
- **Μάθηση χωρίς Εκπαιδευτή**
 - Μη Επιβλεπόμενη Μάθηση - **Unsupervised Learning** όπου το σύστημα αυτορυθμίζεται ανακαλύπτοντας από μόνο του ενδιαφέρουσες στατιστικές δομές (*stochastic features, patterns*) σε μεγάλο όγκο μη χαρακτηρισμένων δεδομένων (*unlabeled datasets*) ώστε να προκύπτουν μοντέλα, μέθοδοι επεξεργασίας, αποθήκευσης και ταξινόμησής, π.χ. σε ομάδες (*clusters*)
 - Ενισχυτική Μάθηση - **Reinforcement Learning** όπου το σύστημα αντιδρά σε σήματα επιβράβευσης/αποθάρρυνσης μέσω *agents* από το περιβάλλον εισόδου, προς το οποίο κοινοποιεί ενέργειές του (*actions*) που επηρεάζουν την εξέλιξη της κατάστασης του περιβάλλοντος για την επίτευξη μακροπρόθεσμου στόχου

Η επιβλεπόμενη μάθηση προσφέρει απόδοση, αξιοπιστία και ταχύτητα για προβλήματα που αφορούν σε αποφάσεις χειρισμού δεδομένων μετά από διαδικασία μάθησης αλλά απαιτεί **labeled learning data sets** που δεν είναι εύκολα διαθέσιμα

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

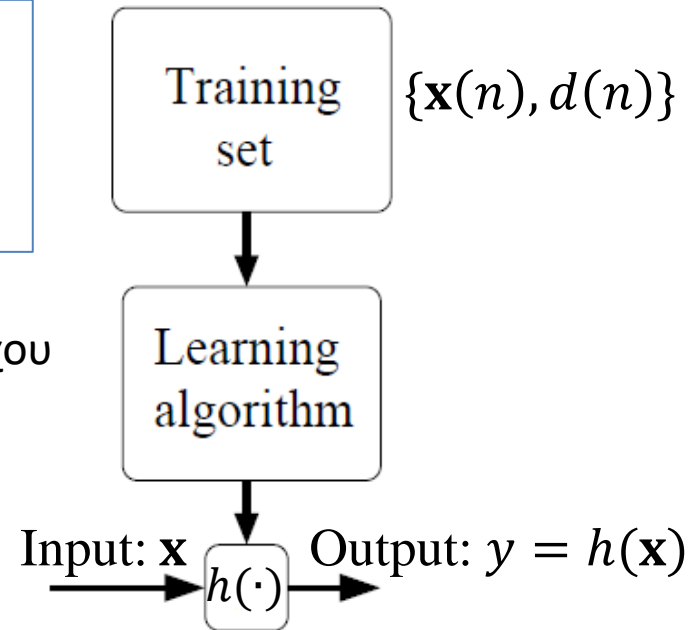
Γενικό Μοντέλο Επιβλεπόμενης Μάθησης - **Supervised Learning**

Βασισμένο στο Andrew Ng, "CS229 Lecture Notes", Stanford University, Fall 2018

- Στόχος του συστήματος είναι η αντιστοίχιση ενός δειγματικού στοιχείου εισόδου (**input sample point, example**) $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_m]^T$ σε τιμές εξόδου y που εκτιμούν επιθυμητές (**desired**) τιμές d (π.χ. πρόβλεψη ή ταξινόμηση). Τα στοιχεία x_i είναι αριθμητικές τιμές που κωδικοποιούν m ειδοποιά χαρακτηριστικά (**features**) του δειγματικού στοιχείου \mathbf{x}

Ζητείται ο προσδιορισμός της συνάρτησης εισόδου - εξόδου $y = h(\mathbf{x}) \cong d$ που προκύπτει από δείγμα μάθησης (**Training Set**) N **labeled** ζευγών $\{\mathbf{x}(n), d(n)\}$, $n = 1, 2, \dots, N$ γνωστών σε εξωτερικό εκπαιδευτή (**supervisor**)

- Η μορφή και οι παράμετροι της $h(\cdot)$ προσδιορίζονται με αλγόριθμο μάθησης που συγκλίνει σε προσέγγιση του στόχου της υπόθεσης για τα N στοιχεία του δείγματος μάθησης $d(n) \cong y(n) = h(\mathbf{x}(n))$
- Αν ο στόχος ικανοποιείται με μικρό αριθμό διακριτών επιλογών της y πρόκειται για πρόβλημα Ταξινόμησης, **Classification** (για δύο επιλογές έχουμε δυαδική ταξινόμηση)
- Αν η έξοδος y λαμβάνει συνεχείς τιμές, το πρόβλημα αναφέρεται σαν Παλινδρόμηση, **Regression**



ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ


Παράδειγμα Επιβλεπόμενης Μάθησης – Linear Regression

Βασισμένο στο Andrew Ng, "CS229 Lecture Notes", Stanford University, Fall 2018

- Ζητείται γραμμική συνάρτηση $h(x)$ που να προσεγγίζει την τιμή κατοικίας $y = h(x)$ με βάση την επιφάνεια x και εμπειρικά δεδομένα $\{\mathbf{x}(n), d(n)\}$, $n = 1, 2, \dots, N$ (**Training Sample**) για καταγραμμένες περιπτώσεις κατοικιών στην ίδια περιοχή

ΕΜΒΑΔΟΝ (square feet)	ΤΙΜΗ (1000\$)
2104	400
1600	330
2400	369
1416	232
3000	540
...	...

Ενδεικτικά Ζεύγη από $N = 47$ Περιπτώσεις



Γραμμική Παλινδρόμηση – Linear Regression: $y = h(x) = 0.1392x + 89.6$
Πρόβλεψη τιμής κατοικίας 2500 τετραγωνικών: \$437,000

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Προσδιορισμός Παραμέτρων Linear Regression (1/2)

- Το διάνυσμα του δειγματικού στοιχείου εισόδου $\mathbf{x} = [x_0 \ x_1 \ \dots \ x_m]^T$ ορίζεται με τιμές που κωδικοποιούν m χαρακτηριστικά (**features**) του: x_1, x_2, \dots, x_m με $x_0 \triangleq 1$ (**intercept term**)
- Το σύστημα linear regression προσδιορίζει τις παραμέτρους $\mathbf{w} = [w_0 \ w_1 \ \dots \ w_m]^T$ της συνάρτησης $y = h_{\mathbf{w}}(\mathbf{x}) = w_0 x_0 + w_1 x_1 + \dots + w_m x_m = \mathbf{w}^T \mathbf{x}$ ώστε η y να έχει μικρές **αποκλίσεις** εφαρμοζόμενη στο δείγμα μάθησης (**Training Set**) $\{\mathbf{x}(n), d(n)\}$, $n = 1, 2, \dots, N$
 - $\mathbf{x}(n)$: Διάνυσμα τιμών εισόδου (χαρακτηριστικών) στοιχείου μάθησης n (**regressors**)
 - $d(n)$: Τιμή εξόδου (απόκριση) στοιχείου μάθησης n (**regressand**)
 - $y(n) = h_{\mathbf{w}}(\mathbf{x}(n))$: Εκτίμηση εξόδου του συστήματος για διάνυσμα εισόδου $\mathbf{x}(n)$
 - $\varepsilon(n) = d(n) - y(n)$: Απόκλιση (**error**) εκτίμησης για το $\{\mathbf{x}(n), d(n)\}$, $n = 1, 2, \dots, N$
 - Οι $\mathbf{x}(n), d(n), \varepsilon(n)$ μπορούν να θεωρηθούν δειγματικές τιμές τυχαίων μεταβλητών
- Κοινό κριτήριο σύγκλησης αφορά στην ελαχιστοποίηση του μέσου τετραγωνικού σφάλματος (**Least Mean Square, LMS**) ως προς τις παραμέτρους \mathbf{w} της $h_{\mathbf{w}}(\mathbf{x})$ ή αντίστοιχα της συνάρτησης κόστους:

$$J(\mathbf{w}) \triangleq \frac{1}{2} \sum_{n=1}^N [\varepsilon(n)]^2 = \frac{1}{2} \sum_{n=1}^N [d(n) - h_{\mathbf{w}}(\mathbf{x}(n))]^2$$

- Παράδειγμα **Linear Regression** μίας μεταβλητής εισόδου x :

$$\mathbf{x} = [1 \ x]^T, \quad \mathbf{w} = [w_0 \ w_1]^T, \quad y = h_{\mathbf{w}}(\mathbf{x}) = \mathbf{w}^T \mathbf{x} = w_0 + w_1 x$$

$$J(\mathbf{w}) = \frac{1}{2} \sum_{n=1}^N [d(n) - (w_0 + w_1 x(i))]^2$$

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Προσδιορισμός Παραμέτρων Linear Regression (2/2)

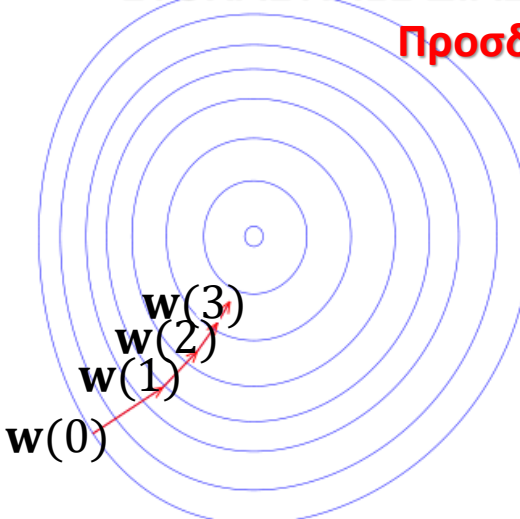
Απεικόνιση Σύγκλισης Gradient Descent:

Ελαχιστοποίηση της συνάρτησης $J(\mathbf{w})$, με παραμέτρους το διάνυσμα \mathbf{w} , μέσω διαδοχικής προσέγγισης στο βήμα $k \rightarrow k + 1$ προς την κλίση (Gradient) $\nabla J(\mathbf{w})$ σταθμισμένο κατά την *hyperparameter* α :

$$\mathbf{w}(k + 1) = \mathbf{w}(k) - \alpha \nabla J(\mathbf{w}(k))$$

Αν υπάρχει σύγκλιση: $\mathbf{w} = \lim_{k \rightarrow \infty} \mathbf{w}(k)$

Σημείωση: Για linear regression υπάρχει πάντα σύγκλιση



$\mathbf{w}(0)$
 $\mathbf{w}(1)$
 $\mathbf{w}(2)$
 $\mathbf{w}(3)$

Κανόνες Μάθησης LMS (Widrow-Hoff)

- **Batch Gradient Descent:** Προσδιορισμός του $\mathbf{w} = [w_0 \ w_1 \ \dots \ w_m]^T$ που ελαχιστοποιεί το σφάλμα $J(\mathbf{w})$ σε κάθε βήμα για **όλο** το δείγμα μάθησης $\{\mathbf{x}(n), d(n)\}$, $n = 1, 2, \dots, N$

$$w_j := w_j - \alpha \frac{\partial J(\mathbf{w})}{\partial w_j} = w_j + \alpha \sum_{n=1}^N [d(n) - h_{\mathbf{w}}(\mathbf{x}(n))] x_j(n), \quad j = 0, 1, 2, \dots, m \quad \forall i$$

- **Stochastic (Incremental) Gradient Descent, Stochastic Approximations:** Προσδιορισμός του \mathbf{w} με τυχαία (στοχαστική) διαδοχική εισαγωγή **στοιχείων** του δείγματος μάθησης $\{\mathbf{x}(n), d(n)\}$, $n = 1, 2, \dots, N$ μέχρι να ικανοποιηθεί κριτήριο σύγκλισης

$$w_j := w_j + \alpha [d(n) - h_{\mathbf{w}}(\mathbf{x}(n))] x_j(n), \quad j = 0, 1, 2, \dots, m \quad n = 1, 2, \dots, N$$

- Η στοχαστική μέθοδος δίνει συνήθως ικανοποιητικά αποτελέσματα με μικρή επιβάρυνση υπολογιστικών πόρων και **προτιμάται για μηχανική μάθηση**
- Το βήμα α στις επαναλήψεις ορίζει τον ρυθμό της μάθησης (**learning rate**). Για σταθεροποίηση της σύγκλισης μπορεί να μεταβάλλεται στην πορεία των επαναλήψεων π.χ. μεγάλη τιμή στα πρώτα βήματα, μικρότερη όσο πλησιάζουμε στη σύγκλιση

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Polynomial Regression: Πολυωνμική Προσέγγιση Χαρακτηριστικού

Βασισμένο στο Andrew Ng, "CS229 Lecture Notes", Stanford University, Fall 2018

- Γραμμική προσέγγιση (**Linear Regression**) μίας μεταβλητής εισόδου $\mathbf{x} = [1 \ x]^T$:

$$y = h_{\mathbf{w}}(\mathbf{x}) = w_0 + w_1x$$


- Προσέγγιση με γραμμικό πολυώνυμο **2^{ου} βαθμού**:

$$y = h_{\mathbf{w}}(\mathbf{x}) = w_0 + w_1x + w_2x^2$$

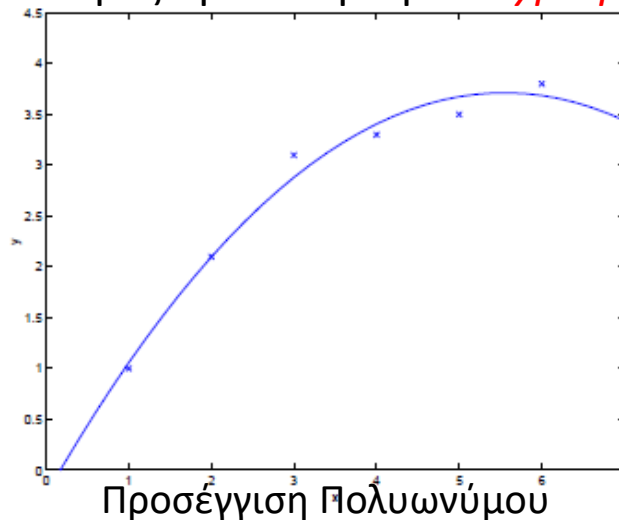
- Προσέγγιση με γραμμικό πολυώνυμο **K βαθμού** (*hyperparameter K*):

$$y = h_{\mathbf{w}}(\mathbf{x}) = \sum_{j=0}^K w_j x^j$$


Εμπειρικές δοκιμές προσδιορισμού *hyperparameter K*



K = 1
(*Underfitting*)



(OK)




(*Overfitting*)

Κίνδυνοι Υπεραπλούστευσης (*Underfitting*) & Υπερβολής (*Overfitting*)

Ταξινόμηση – Classification (1/2)

Βασισμένο στο Andrew Ng, "CS229 Lecture Notes", Stanford University, Fall 2018



$$g(z) = \frac{1}{1 + e^{-z}}$$

Logistic/Sigmoid Function

Δειγματικά στοιχεία \mathbf{x} με m διαστάσεις (χαρακτηριστικά, **features**)

Δυαδικές Κλάσεις Εξόδου (**Classes, Labels**) $y \in \{0,1\}$ ή $y \in \{-, +\}$

Training Set: $\{\mathbf{x}(n), d(n)\}, n = 1,2, \dots, N$

• Μοντέλο **Logistic Regression**: $h_{\mathbf{w}}(\mathbf{x}) = g(\mathbf{w}^T \mathbf{x}) = \frac{1}{1 + e^{-\mathbf{w}^T \mathbf{x}}}$

$$\mathbf{w}^T \mathbf{x} = \sum_{j=0}^m w_j x_j = w_0 + \sum_{j=1}^m w_j x_j$$

Οι πιθανότητες τυχαίας μεταβλητής εξόδου $y \in \{0,1\}$ υπό συνθήκη μεταβλητών εισόδου \mathbf{x} και με συνάρτηση **Logistic Regression** $h_{\mathbf{w}}(\mathbf{x}) = \frac{1}{1 + e^{-\mathbf{w}^T \mathbf{x}}}$ ακολουθούν κατανομή **Bernoulli** και οδηγούν σε εκτίμηση της εξόδου y μετά τον προσδιορισμό των παραμέτρων \mathbf{w} :

$$P(y = 1 | \mathbf{x}; \mathbf{w}) = h_{\mathbf{w}}(\mathbf{x}), \quad P(y = 0 | \mathbf{x}; \mathbf{w}) = 1 - h_{\mathbf{w}}(\mathbf{x})$$

$$\text{ή } p(y | \mathbf{x}; \mathbf{w}) = (h_{\mathbf{w}}(\mathbf{x}))^y (1 - h_{\mathbf{w}}(\mathbf{x}))^{1-y}$$

Κανόνας Εκτίμησης y :
 $y = 1$ αν $h_{\mathbf{w}}(\mathbf{x}) > 1/2$
 $y = 0$ αν $h_{\mathbf{w}}(\mathbf{x}) < 1/2$

Κριτήριο σύγκλησης λόγω μη γραμμικής $h_{\mathbf{w}}(\mathbf{x})$ προτιμάται της ελαχιστοποίησης του τετραγωνικού σφάλματος (**LMS**) η **μεγιστοποίηση** του λόγου πιθανοφάνειας (**Likelihood Ratio**) $L(\mathbf{w})$ των στοιχείων του συνόλου μάθησης $\{\mathbf{x}(n), d(n)\}, n = 1,2, \dots, N$. Θεωρούμε πως οι τιμές εξόδου $d(n)$ είναι ανεξάρτητες δυαδικές τυχαίες μεταβλητές για το δείγμα μάθησης $\mathbf{X} = [\mathbf{x}(1) \mathbf{x}(2) \dots \mathbf{x}(N)]$ και με παραμέτρους \mathbf{w} :

$$L(\mathbf{w}) \triangleq p\{(d(1), d(2), \dots, d(N)) | (\mathbf{X}; \mathbf{w})\} = \prod_{n=1}^N p\{(d(n) | (\mathbf{x}(n); \mathbf{w}))\}$$

Ταξινόμηση – Classification (2/2)

Βασισμένο στο Andrew Ng, "CS229 Lecture Notes", Stanford University, Fall 2018

- **Μοντέλο Logistic Regression (συνέχεια):**

$$L(\mathbf{w}) = \prod_{n=1}^N p\{(d(n)|(\mathbf{x}(n); \mathbf{w}))\} = \prod_{n=1}^N \{(h_{\mathbf{w}}(\mathbf{x}(n)))^{d(n)}(1 - h_{\mathbf{w}}(\mathbf{x}(n)))^{1-d(n)}\}$$

Αντί της μεγιστοποίησης του $L(\mathbf{w})$ μεγιστοποιούμε τον λογάριθμο $l(\mathbf{w}) = \log L(\mathbf{w})$:

$$l(\mathbf{w}) = \sum_{n=1}^N \{d(n) \log h_{\mathbf{w}}(\mathbf{x}(n)) + (1 - d(n)) \log(1 - h_{\mathbf{w}}(\mathbf{x}(n)))\}$$

Εφαρμόζουμε **Gradient Ascent** στο βήμα $k \rightarrow k + 1$ με **hyperparameter** α θετική:

$$\mathbf{w}(k + 1) = \mathbf{w}(k) + \alpha \nabla l(\mathbf{w}(k))$$

Για τον υπολογισμό της $\nabla l(\mathbf{w}(k))$ και την εφαρμογή του στοχαστικού προσεγγιστικού κανόνα (**Stochastic Gradient Ascent**) προσδιορισμού των παραμέτρων w_j με διαδοχική εφαρμογή στα στοιχεία $n = 1, 2, \dots, N$ του **Training Set** υπολογίζουμε την μερική παράγωγο $\frac{\partial}{\partial w_j} l(\mathbf{w}) = \dots = [d(n) - h_{\mathbf{w}}(\mathbf{x}(n))]x_j(n) \Leftrightarrow$

$$w_j := w_j + \alpha [d(n) - h_{\mathbf{w}}(\mathbf{x}(n))]x_j(n), \quad j = 1, 2, \dots, m$$

(ίδιας μορφής **Επαναληπτικός Κανόνας Μάθησης** με τον κανόνα **LMS**)

- **Μοντέλο Perceptron:** $h_{\mathbf{w}}(\mathbf{x}) = g(\mathbf{w}^T \mathbf{x})$

$$g(z) = \begin{cases} 1, & z \geq 0 \\ 0, & z < 0 \end{cases} \quad \text{Threshold Function}$$

Προκύπτει παρόμοιος **Επαναληπτικός Κανόνας Μάθησης** παραμέτρων w_j

$$w_j := w_j + \alpha [d(n) - h_{\mathbf{w}}(\mathbf{x}(n))]x_j(n), \quad j = 1, 2, \dots, m \quad \text{για} \quad n = 1, 2, \dots, N$$