

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΕΡΓΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Παραγωγικά Μοντέλα μη Επιβλεπόμενης Μάθησης:

- 1. Μηχανή Boltzmann**
- 2. Παραγωγικά (Generative) Στοχαστικά Νευρωνικά Δίκτυα**
- 3. Generative Adversarial Networks (GAN)**

καθ. Βασίλης Μάγκλαρης

maglaris@netmode.ntua.gr

www.netmode.ntua.gr

Αίθουσα 002, Νέα Κτίρια ΣΗΜΜΥ

Τρίτη 26/3/2024

Εφαρμογή Δειγματοληψίας Gibbs – Boltzmann Machine, BM (1/8)

(1985, Geoffrey Hinton & Terry Sejnowski)

Στόχος η προσέγγιση ελλιπματικού διανύσματος εισόδου (π.χ. **pattern completion** εικόνων) μέσω δημιουργίας διανύσματος εξόδου, στατιστικά συμβατού με **unlabeled** δείγμα μάθησης

Μια **Boltzmann Machine** (BM) περιλαμβάνει:

- K Visible και L Hidden Neurons
 - Συμμετρικές Συνάψεις $i \rightarrow j$: $w_{ji} = w_{ij}$, $w_{ii} = 0$
- εν δυνάμει μεταξύ όλων των νευρώνων της BM

Αποτελεί εξέλιξη του αναδρομικού δικτύου

Hopfield με νευρώνες σε **δυαδικές καταστάσεις**

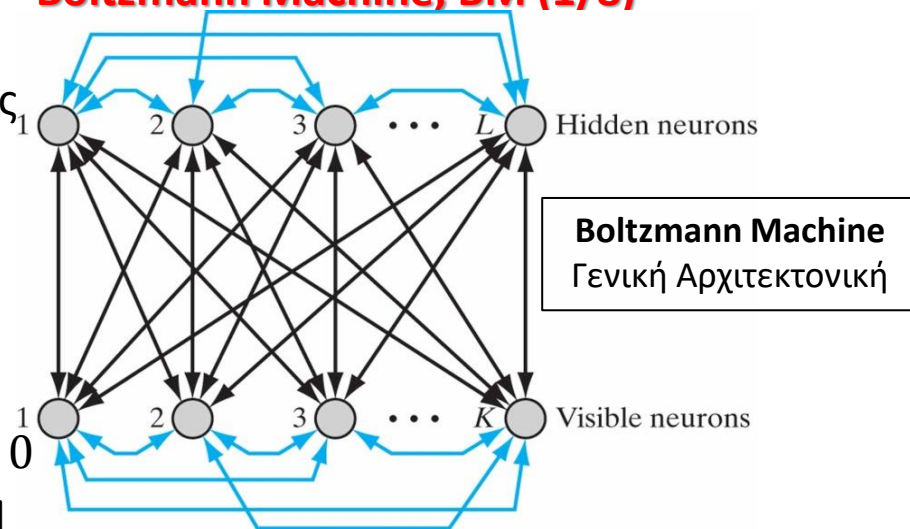
± 1 σύμφωνα με ορισμένες **πιθανότητες**

(**Stochastic Recurrent Network with Hidden**

Nodes). Το δίκτυο συγκλίνει με **μη επιβλεπόμενη**


μάθηση σε ισορροπία **Markov Random Field**:

- Δυαδικά παραδείγματα **μάθησης** εισάγονται στα **Visible Nodes** και με **gradient ascent** προσδιορίζονται συναπτικά βάρη και **τελικές καταστάσεις** των νευρώνων (**Visible & Hidden**)
- Δυαδικά στοιχεία **test** εισάγονται στα **Visible Nodes** και η BM τα αναπαράγει (**generates, samples**) σύμφωνα με τις στατιστικές ιδιότητες του **δείγματος μάθησης**



Νευρωνικό Δίκτυο Hopfield (1982, John Hopfield)

Δυαδικοί μη στοχαστικοί νευρώνες με αναδρομικές συμμετρικές συνάψεις, threshold activation και **supervised learning** για προσδιορισμό των $w_{ji} = w_{ij}$, $w_{ii} = 0$, συμβατών με το αξίωμα του **Hebb** σε κατάσταση ισορροπίας (τοπικό ελάχιστο της **ενέργειας του συστήματος**). Εφαρμογές ταξινόμησης - επεξεργασίας προτύπων (π.χ. ψηφιακών εικόνων)



Εφαρμογή Δειγματοληψίας Gibbs – Boltzmann Machine, BM (2/8)

Δειγματοληψία Gibbs - Bayesian Statistics

<https://jwmi.github.io/BMS/chapter6-gibbs-sampling.pdf>


- **Ορισμοί Sampling:**
 - Παραγωγή δειγματικών στοιχείων (**Sample Elements**) με στατιστικές ιδιότητες συμβατές με Δειγματικό Χώρο (**Sample Space**) → Δημιουργία ή/και εμπλουτισμός υποσυνόλου (**Δείγμα, Sample**) στοιχείων
 - Επιλογή δειγματικών στοιχείων (**Sample Elements**) του Δειγματικού Χώρου σε υποσύνολο (**Δείγμα, Sample**) για στατιστική ανάλυση που κατ' εκτίμηση γενικεύεται στον ευρύτερο χώρο (έρευνα προτιμήσεων πελατών, δημοσκοπήσεις...)
- **Δειγματοληψία Πολυδιάστατων Δειγματικών Χώρων: Gibbs Sampling**
 - Δημιουργία (συσχετισμένου) Δείγματος μέσω **Monte Carlo** προσομοιώσεων πολυδιάστατης διακριτής κατάστασης **Markov** με χρονοσταθερή κατανομή ισορροπίας που ορίζεται από τις πιθανότητες μετάβασης σε κάθε βήμα εξέλιξης: Τροποποίηση αλγορίθμου **Metropolis** για **διανυσματικές** καταστάσεις
 - Παράδειγμα Αλγορίθμου για **2 Διαστάσεις**: Η Δειγματοληψία της $\mathbf{X} = [X \ Y]^T$ με **Joint Probabilities** $P(X, Y)$ δημιουργεί n στοιχεία $\mathbf{x}(n) = [x(n) \ y(n)]^T$ σύμφωνα με πιο βατές υπό συνθήκη πιθανότητες (**Conditional Posterior Probabilities, Bayes**):
$$x(n) \sim P(X|y(n-1)) \text{ και } y(n) \sim P(Y|x(n))$$
 - Γενίκευση για **K Διαστάσεις**: Δειγματοληψία της $\mathbf{X} = [X_1 \ X_2 \ \dots \ X_K]^T$
 - $n = 0$: Αυθαίρετη αρχικοποίηση $\mathbf{x}(0) = [x_1(0) \ x_2(0) \ \dots \ x_K(0)]^T$
 - $n \rightarrow n + 1$: Κατά σειρά για $i = 1, \dots, K$ δημιουργείται η $x_i(n + 1)$ με πιθανότητα $P[X_i(n + 1) | \{x_1(n + 1) \ \dots \ x_{i-1}(n + 1) \ x_{i+1}(n) \ \dots \ x_K(n)\}]$

Εφαρμογή Δειγματοληψίας Gibbs – Boltzmann Machine, BM (3/8)

Παράδειγμα Δισδιάστατης Δειγματοληψίας Gibbs

<https://www.baeldung.com/cs/gibbs-sampling>

- Δειγματικός Χώρος 2 Διαστάσεων $[X \ Y]^T$ με **δυναμικές** Τυχαίες Μεταβλητές $x, y \in \{0,1\}$
- Οι συνδυασμένες πιθανότητες (**joint probabilities**) $P(X, Y)$ έχουν ως εξής:
 - $P(X = 1, Y = 1) = 0.2, P(X = 0, Y = 1) = 0.3$
 - $P(X = 1, Y = 0) = 0.4, P(X = 0, Y = 0) = 0.1$
- Ζητείται παραγωγή (**sampling**) n δειγματικών στοιχείων: $[x(n) \ y(n)]^T \sim P(X, Y)$
- **Direct Sampling:** Επαναλαμβάνουμε πειράματα **Monte Carlo** παραγωγής ομοιόμορφα κατανομημένων (ψευτο)τυχαίων αριθμών $0 < n \leq 1$ για προσδιορισμό ακολουθίας δειγματικών στοιχείων ανάλογα με την τιμή της n , π.χ. αν $0.2 < n \leq 0.6$ προκύπτει το δειγματικό στοιχείο $[1 \ 0]^T$



- **Gibbs Sampling:** Εναλλακτικά χρησιμοποιούμε τις **conditional probabilities (Bayes)**
 - $P(X = 1|Y = 1) = \frac{P(X=1,Y=1)}{P(Y=1)} = \frac{P(X=1,Y=1)}{P(X=1,Y=1)+P(X=0,Y=1)} = \frac{0.2}{0.2+0.3} = 0.4$
 - $P(X = 1|Y = 0) = 0.8, P(X = 0|Y = 0) = 0.2, P(Y = 1|X = 1) = 0.333,$
 $P(Y = 0|X = 1) = 0.666, P(Y = 1|X = 0) = 0.75, P(Y = 0|X = 0) = 0.25$

Εφαρμογή Αλγορίθμου Gibbs Sampling

- Αρχικοποίηση : $x(0) = 1$ $y(0) = 0$
- Βήμα 1 : $x(1) \sim P(X|y(0))$ $y(1) \sim P(Y|x(1))$
- Βήμα 2 : $x(2) \sim P(X|y(1))$ $y(2) \sim P(Y|x(2))$
- Βήμα n : $x(n) \sim P(X|y(n - 1))$ $y(n) \sim P(Y|x(n))$

Φάσεις Μάθησης Μηχανής Boltzmann

- **Θετική Φάση Μάθησης:** Τα στοιχεία του **δείγματος μάθησης** \mathcal{T} κλειδώνουν (**clamp**) σε δυαδικές καταστάσεις ± 1 των K **ορατών νευρώνων** με βάση τις τιμές γνωστών χαρακτηριστικών τους. Μέσω του προσδιορισμού των συναπτικών βαρών η **BM** κωδικοποιεί στους L **κρυφούς νευρώνες** στατιστικές ιδιότητες ανώτερης τάξεως (π.χ. συσχετίσεις) με οριακές πιθανότητες (**marginal distribution**) καταστάσεων **Gibbs** υπό τη συνθήκη κλειδωμένων καταστάσεων των K ορατών νευρώνων
- **Αρνητική Φάση Ελεύθερης Επεξεργασίας:** Σε δεύτερη φάση, οι νευρώνες (**ορατοί** και **κρυφοί**) αλληλεπιδρούν ελεύθερα χωρίς εξάρτηση από το δείγμα μάθησης \mathcal{T} και ορίζουν συναπτικά βάρη που οδηγούν τη **BM** προς καταστάσεις **θερμικής ισορροπίας** (**Gibbs**). Οι τελικές καταστάσεις των ορατών νευρώνων **παράγουν** (στην έξοδο) **νέα** δειγματικά στοιχεία με οριακές πιθανότητες χαρακτηριστικών συμβατές με το \mathcal{T}
- **Πολυπλοκότητα Αλγορίθμου:** Συνήθως απαιτείται μεγάλος αριθμός κρυφών νευρώνων **hyperparameter** $L \gg K$ για κωδικοποίηση σύνθετων στατιστικών ιδιοτήτων χαρακτηριστικών πολυμόρφου δείγματος, καθώς και πολλές επαναλήψεις για ικανοποιητική σύγκλιση των συμμετρικών συνάψεων $w_{ij} = w_{ji}$, $w_{ii} = 0$ μεταξύ όλων των $L + K$ νευρώνων
- **Αναλογία με Φυσιολογικά Νευρολογικά Συστήματα:** Ενίσχυση συνάψεων μεταξύ ενεργών νευρώνων (αξίωμα **Hebb**). **Θετική Φάση** ~ Ενεργή Εγκεφαλική Λειτουργία, **Αρνητική Φάση** ~ Επεξεργασία σε Κατάσταση Ύπνου (;)

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Εφαρμογή Δειγματοληψίας Gibbs – Boltzmann Machine, BM (5/8)

Ορισμοί

- **Κατάσταση Δικτύου:** Τυχαίο Διάνυσμά $\mathbf{X} \rightarrow \mathbf{x} = [x_1 \ x_2 \ \dots \ x_K \ \dots \ x_m]^T$, $m = L + K$
 $x_i \in \{-1, 1\} \triangleq \{OFF, ON\}$ όπου x_i η κατάσταση του **στοχαστικού** νευρώνα i
- **Κατάσταση των K Ορατών & L Κρυφών Νευρώνων:** $\mathbf{X}_\alpha \rightarrow \mathbf{x}_\alpha$, $\mathbf{X}_\beta \rightarrow \mathbf{x}_\beta$, $\mathbf{x} = (\mathbf{x}_\alpha, \mathbf{x}_\beta)$
- **Συναπτικά Βάρη $i \rightarrow j$:** $w_{ji} = w_{ij}$, $w_{ii} = 0$ (πιθανή εξωτερική επίδραση **bias** στον κόμβο j θεωρείται ότι εισάγεται από κόμβο 0 σε κατάσταση ON με βάρος w_{j0})
- **Ενέργεια Κατάστασης BM:** $E(\mathbf{x}) \triangleq -\frac{1}{2} \sum_i \sum_{j \neq i} w_{ji} x_i x_j$ για \mathbf{x} με στοιχεία $x_i \in \{-1, 1\}$
(αναλογία με θερμοδυναμική)
- **Πιθανότητες Θερμικής Ισορροπίας:** $P(\mathbf{X} = \mathbf{x}) = \frac{1}{Z} \exp\left(-\frac{E(\mathbf{x})}{T}\right)$, κατανομή **Gibbs/Boltzmann**
- **Κατάσταση των K Ορατών Νευρώνων:** $\mathbf{X}_\alpha \rightarrow \mathbf{x}_\alpha = [x_1 \ x_2 \ \dots \ x_K \ \dots \ x_K]^T$
Η κατάσταση του ορατού νευρώνα i αντιστοιχεί σε δυαδικό χαρακτηριστικό (**feature**) του στοιχείου εισόδου/εξόδου i με πιθανότητα να είναι ON ίση με $P(x_i = 1)$

<https://www.cs.toronto.edu/~hinton/csc321/readings/boltz321.pdf>

<https://youtu.be/5jaBneYd5lg>

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Εφαρμογή Δειγματοληψίας Gibbs – Boltzmann Machine, BM (6/8)

- Συμβάντα (Events) για Διανυσματικό Δείγμα με m Διαστάσεις:

Για τυχαίο στοιχείο $[X_1 = x_1 \ X_2 = x_2 \ \dots \ X_j = x_j \ \dots \ X_m = x_m]^T$ ορίζουμε τα **events**

$A: (X_j = x_j)$, $B: (X_1 = x_1, \dots, X_{j-1} = x_{j-1}, X_{j+1} = x_{j+1}, \dots, X_m = x_m)$ και

$C: (X_1 = x_1, \dots, X_j = x_j, \dots, X_m = x_m)$ το joint event των A και B

Σε θερμική ισορροπία και για X_j που προκύπτουν από τη δειγματοληψία **Gibbs** έχουμε:

$$P(C) = P(A, B) = \frac{1}{Z} \exp \left(\frac{1}{2T} \sum_i \sum_{j \neq i} w_{ji} x_i x_j \right)$$

$$P(B) = \sum_A P(A, B) = \frac{1}{Z} \sum_{x_j} \exp \left(\frac{1}{2T} \sum_{i \neq j} \sum_j w_{ji} x_i x_j \right)$$

- Υπό Συνθήκη Πιθανότητες Μεταβάσεων:


Δεδομένου ότι x_i, x_j παίρνουν τις τιμές ± 1 η υπό συνθήκη πιθανότητα $P(A|B)$ απλοποιείται:

$$P(A|B) = \frac{P(A, B)}{P(B)} = \frac{1}{1 + \exp \left(-\frac{x_j}{T} \sum_{i \neq j} w_{ji} x_i \right)}$$

$$P(X_j = x | \{X_1 = x_1, \dots, X_{j-1} = x_{j-1}, X_{j+1} = x_{j+1}, \dots, X_m = x_m\}) = \varphi \left(\frac{x}{T} \sum_{i=1, i \neq j}^m w_{ji} x_i \right)$$

όπου $\varphi(\cdot)$ η σιγμοειδής (**logistic**) συνάρτηση $\varphi(v)$

Η $P(A, B)$ προκύπτει σαν αποτέλεσμα της δειγματοληψίας **Gibbs** από αρχική κατάσταση $\mathbf{x}(0)$ με διαδοχικές επισκέψεις $\mathbf{x}(n) \rightarrow \mathbf{x}(n+1)$ λαμβάνοντας υπόψη τις πιο πρόσφατες ανανεώσεις των $x_i(n)$ και διαδοχικά μειώνοντας την θερμοκρασία $T \rightarrow 0$ (**Simulated Annealing**)



Εφαρμογή Δειγματοληψίας Gibbs – Boltzmann Machine, BM (7/8)

Κανόνας Μάθησης Boltzmann

Εφαρμογή κριτηρίου Maximum Likelihood ή Log Likelihood

Το διάνυσμα της κατάστασης \mathbf{x} αποτελείται από τη συρραφή δύο υποσυνόλων: Το υποσύνολο των καταστάσεων των ορατών νευρώνων \mathbf{x}_α και των κρυφών νευρώνων \mathbf{x}_β με πιθανότητες που θεωρούμε πως συγκλίνουν σε οριακές πιθανότητες θερμικής ισορροπίας **Gibbs**

Η λειτουργία της **BM** προχωρά σε δύο φάσεις:

- **Θετική Φάση** που καθορίζεται από τις συνθήκες κλειδώματος (**clamping**) καταστάσεων των ορατών νευρώνων στα παραδείγματα του δείγματος μάθησης \mathcal{J}
- **Αρνητική Φάση** όπου το δίκτυο λειτουργεί αυτόνομα χωρίς εισόδους από το περιβάλλον

Από τον ορισμό των συναπτικών βαρών w_{ji} (στοιχεία της μήτρας \mathbf{w} όλου του δικτύου) προκύπτουν οι οριακές πιθανότητες ισορροπίας **Gibbs** των **ορατών** καταστάσεων $P(\mathbf{X}_\alpha = \mathbf{x}_\alpha)$ ώστε να προσεγγίζουν την κατανομή του \mathcal{J} . Αν έχουμε πολλά στοιχεία στο \mathcal{J} μπορούμε να θεωρήσουμε ότι οι καταστάσεις \mathbf{X}_α είναι **ανεξάρτητα** τυχαία διανύσματα με συνολική πιθανότητα ισορροπίας το **παραγοντικό γινόμενο** $\prod_{\mathbf{x}_\alpha \in \mathcal{J}} P(\mathbf{X}_\alpha = \mathbf{x}_\alpha)$

Αν θεωρήσουμε τον λογάριθμο $L(\mathbf{w})$ του γινομένου έχουμε

$$L(\mathbf{w}) = \log \prod_{\mathbf{x}_\alpha \in \mathcal{J}} P(\mathbf{X}_\alpha = \mathbf{x}_\alpha) = \sum_{\mathbf{x}_\alpha \in \mathcal{J}} \log P(\mathbf{X}_\alpha = \mathbf{x}_\alpha)$$

Οι $P(\mathbf{X}_\alpha = \mathbf{x}_\alpha)$ συμπεριλαμβάνουν τις πιθανότητες των καταστάσεων $\mathbf{x} = (\mathbf{x}_\alpha, \mathbf{x}_\beta)$, $\forall \mathbf{x}_\beta$:

$$P(\mathbf{X}_\alpha = \mathbf{x}_\alpha) = \frac{1}{Z} \sum_{\mathbf{x}_\beta} \exp\left(-\frac{E(\mathbf{x})}{T}\right), \quad Z = \sum_{\mathbf{x}} \exp\left(-\frac{E(\mathbf{x})}{T}\right)$$

Εφαρμογή Δειγματοληψία Gibbs – Boltzmann Machine, BM (8/8)

Κανόνας Μάθησης Boltzmann

Εφαρμογή κριτηρίου Maximum Likelihood ή Log Likelihood (συνέχεια)

Προκύπτει επομένως για τον λογάριθμο του παραγοντικού γινομένου

$$L(\mathbf{w}) = \sum_{\mathbf{x}_\alpha \in \mathcal{J}} \left(\log \sum_{\mathbf{x}_\beta} \exp \left(-\frac{E(\mathbf{x})}{T} \right) - \log \sum_{\mathbf{x}} \exp \left(-\frac{E(\mathbf{x})}{T} \right) \right), \quad E(\mathbf{x}) = -\frac{1}{2} \sum_i \sum_{j \neq i} w_{ji} x_i x_j$$

Παραγωγίζοντας ως προς τα συναπτικά βάρη w_{ji} έχουμε

$$\frac{\partial L(\mathbf{w})}{\partial w_{ji}} = \frac{1}{T} \sum_{\mathbf{x}_\alpha \in \mathcal{J}} \left(\sum_{\mathbf{x}_\beta} P(\mathbf{X}_\beta = \mathbf{x}_\beta | \mathbf{X}_\alpha = \mathbf{x}_\alpha) x_j x_i - \sum_{\mathbf{x}} P(\mathbf{X} = \mathbf{x}) x_j x_i \right) \triangleq \frac{1}{T} (\rho_{ji}^+ - \rho_{ji}^-)$$

Το ρ_{ji}^+ υποδηλώνει τον μέσο ρυθμό ενεργοποίησης (**firing rate**) ή τη συσχέτιση (**correlation**) μεταξύ των καταστάσεων των νευρώνων $j \leftrightarrow i$ στη **Θετική Φάση** και το ρ_{ji}^- τη συσχέτιση (**correlation**) μεταξύ των καταστάσεων των νευρώνων $j \leftrightarrow i$ στη **Αρνητική Φάση**

Ο κανόνας μάθησης Boltzmann (**Boltzmann Learning Rule**) μεγιστοποιεί το $L(\mathbf{w})$ με τη μέθοδο του **gradient ascent** με σταθερό βήμα (**hyperparameter**) ϵ :

$$\Delta w_{ji} = \epsilon \frac{\partial L(\mathbf{w})}{\partial w_{ji}} = \eta (\rho_{ji}^+ - \rho_{ji}^-)$$

Η **learning rate** $\eta = \frac{\epsilon}{T}$ μεταβάλλεται σε διαδοχικές επαναλήψεις **Simulated Annealing** αντιστρόφως ανάλογα με τη μειούμενη T . Τα βάρη ανανεώνονται με βάση όλα τα στοιχεία του δείγματος μάθησης (**batch mode**) με μεγάλη πολυπλοκότητα και αργή σύγκλιση \Rightarrow

ΑΝΑΓΚΗ ΑΠΛΟΠΟΙΗΣΗΣ ΔΙΚΤΥΟΥ \rightarrow RESTRICTED BOLTZMANN MACHINE (RBM)

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Στατιστική Ταξινόμηση: **Generative & Discriminative Models**

Παραδοσιακό Διακριτικό Μοντέλο (Discriminative Model) Στατιστικής Ταξινόμησης

Observable Input Data: x **Target Output Labels:** y

Απ' ευθείας εκτίμηση $P(y|x)$ από δεδομένα του δείγματος μάθησης και ανάθεση της πιθανότερης y σε data x με βάση τις εμφανίσεις της y **υπό συνθήκη** x που μετρήθηκαν στη φάση της (**επιβλεπόμενης**) μάθησης, π.χ. **Logistic Regression** και **Back-Propagation Algorithm**

Παραγωγικό Μοντέλο (Generative Model) Στατιστικής Ταξινόμησης

Observable Input Data: x **Target Output Labels:** y

Εκίμηση $P(x, y)$ με βάση **συνδυασμένες** στατιστικές παραδοχές εμφάνισης των x και y , υπολογισμός υπό συνθήκη πιθανοτήτων $P(y|x) = \frac{P(x,y)}{P(x)}$, $P(x) = \sum_y P(x, y)$ από κανόνα **Bayes** και ανάθεση της πιθανότερης y σε data x . Τα ζεύγη x, y **δημιουργούνται** σύμφωνα με τις εμπειρικές $P(x, y)$ όπως αυτές εκτιμήθηκαν από το δείγμα μάθησης ώστε να προσεγγίζουν τα στατιστικά χαρακτηριστικά συγκεκριμένων εφαρμογών ταξινόμησης δεδομένων

Παράδειγμα: $x \in \{1,2\}, y \in \{0,1\}$ (https://en.wikipedia.org/wiki/Generative_model)

$P(x, y)$	$y = 0$	$y = 1$
$x = 1$	1/2	0
$x = 2$	1/6	2/6

\Rightarrow

$P(y x)$	$y = 0$	$y = 1$
$x = 1$	1	0
$x = 2$	2/6	4/6

$$P(x = 1) = 1/2, P(x = 2) = 3/6 = 1/2$$

Προτιμάται για περιπτώσεις που τα δεδομένα παρουσιάζουν ελλείψεις (π.χ. κενά σε εικόνες ή δυσδιάκριτα σήματα φωνής) τις οποίες το σύστημα μάθησης καλείται να μαντέψει με βάση μοντέλα στατιστικών **συσχετίσεων** χαρακτηριστικών τους, π.χ. **Boltzmann Machine**

Στατιστική Προσέγγιση: Generative & Discriminative Models (1/2)

Γενίκευση Παραγωγικού Μοντέλου (Generative Model)

<https://openai.com/blog/generative-models/>

$p(x)$: Κατανομή των στοιχείων του δείγματος μάθησης (**Training Sample**) $\{x_1, x_2, \dots, x_n\}$

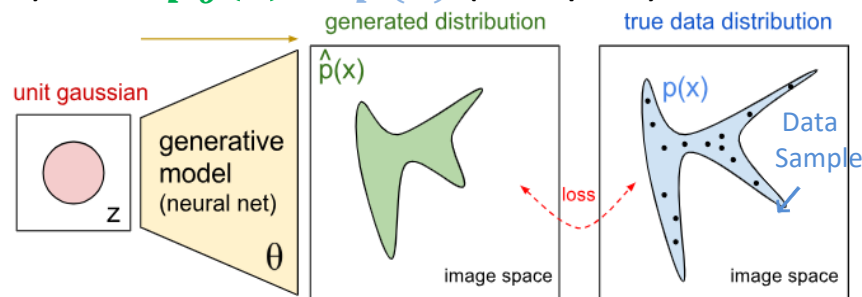
$\hat{p}_\theta(x)$: Κατανομή των εικονικών στοιχείων του παραγόμενου δείγματος (**Generated Sample**)

στην έξοδο νευρωνικού δικτύου παραμέτρων θ με αυθαίρετο δείγμα εισόδου, π.χ. 100

τυχαίοι αριθμοί με κανονική κατανομή, **Gaussian Sample Z**

Διαδικασία Μάθησης: Ρύθμιση παραμέτρων θ νευρωνικού δικτύου με βάση δεδομένα

μάθησης (**Training Sample**) ώστε $\hat{p}_\theta(x) \rightarrow p(x)$ (συνήθως κατά **Kullback-Leibler**)



Μετρικές Ομοιότητας Κατανομών $p(x), q(x)$

- **Divergence Kullback-Leibler (KL)** (1951):

$$D_{KL}(P||Q) = \sum_{x \in \mathcal{X}} P(x) \log \frac{Q(x)}{P(x)}$$

(εφαρμόζεται σε **Boltzmann Machine**)


<https://skymind.ai/wiki/restricted-boltzmann-machine>

- **Expectation-Maximization (EM) Algorithm** :

Επαναλήψεις δύο σταδίων για προσδιορισμό λανθανουσών (**latent**) παραμέτρων:

(π.χ. προσδιορισμός ποσοστών μείξης τυχαίων μεταβλητών από 2 ανεξάρτητα δείγματα Gauss)

https://en.wikipedia.org/wiki/Expectation%20%93maximization_algorithm



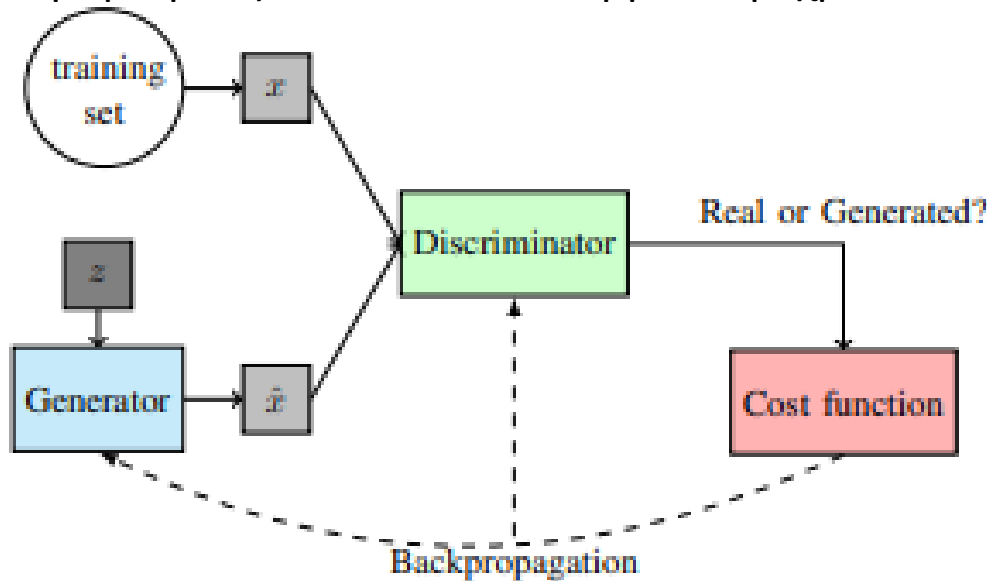
Στατιστική Προσέγγιση: Generative & Discriminative Models (2/2)

Generative Adversarial Networks - GAN (2014 Ian Goodfellow et.al.)

<https://arxiv.org/pdf/1406.2661.pdf>

Συνδυασμός ανεξάρτητης επεξεργασίας από δύο παίκτες σε *zero-sum adversarial min-max game* μεταξύ *παραγόμενου εικονικού δείγματος* και *αληθινού δείγματος*. Η *μάθηση* βασίζεται σε δυο βαθιά νευρωνικά δίκτυα τύπου Multilayer Perceptron - *MLP*:

- **Generator (G)** που με είσοδο *latent random variables* z (π.χ. *Gauss*) δημιουργεί στην έξοδο $G(z)$ εικονικό παραγόμενο (*generated*) δείγμα \hat{x} με κατανομή $p_{\theta}(\hat{x})$
 - **Discriminator (D)** που προσπαθεί να ταξινομήσει με *επιβλεπόμενη μάθηση* τη διαφορά μεταξύ *αληθινών δεδομένων μάθησης* $x \sim p(x)$ και *εικονικών δεδομένων* $\hat{x} \sim p_{\theta}(\hat{x})$
- Όσο ο **D** καταλαβαίνει τη διαφορά (έξοδος *Generated*), ο παίκτης **G** τροποποιεί τις παραμέτρους του και επαναλαμβάνει μέχρι να τον εξαπατήσει (έξοδος *Real*)



Cost Functions (Loss) for D - G Game:

$$\mathbf{D}: \max \left\{ \log D(x) + \log \left(1 - D(G(z)) \right) \right\}$$

maximize probability \hat{x} classified as fake

$$\mathbf{G}: \min \left\{ \log \left(1 - D(G(z)) \right) \right\}$$

minimize probability \hat{x} classified as fake

Εφαρμογές: Computer vision, virtual reality, computer graphics, interactive games, scientific simulations,