

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΕΡΓΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

**Στοχαστικές Μηχανές Μη Επιβλεπόμενης Μάθησης:
Παραγωγικά Μοντέλα - Generative Models**

- 1. Boltzmann Machine & Logistic Belief Nets**
- 2. Restricted Boltzmann Machine (RBM) - Deep Belief Nets**

καθ. Βασίλης Μάγκλαρης

maglaris@netmode.ntua.gr

www.netmode.ntua.gr

Video Conference μέσω Cisco Webex

Πέμπτη 23/4/2020

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Εφαρμογή Δειγματοληψίας Gibbs – Boltzmann Machine, BM (1/6) (επανάληψη)

Γενικά περί Μηχανής Boltzmann

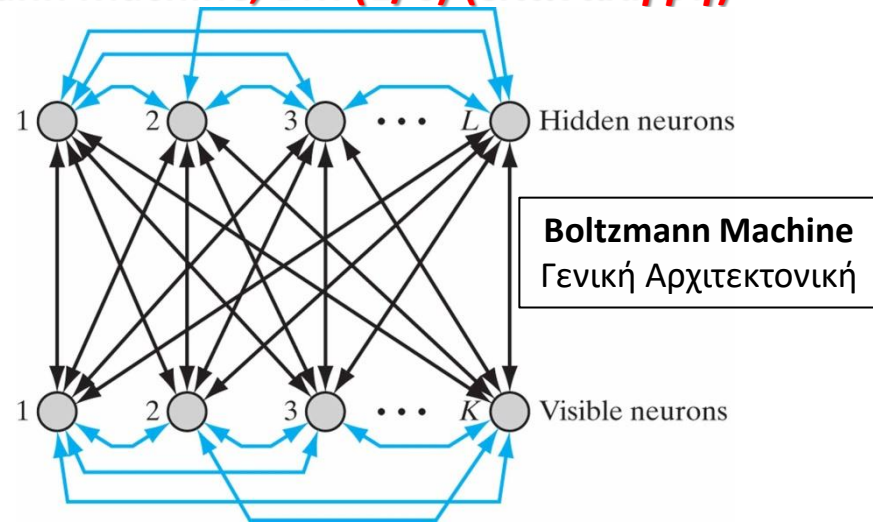
(1985, **Geoffrey Hinton** & **Terry Sejnowski**)

Εξέλιξη του δικτύου **Hopfield** με δυαδικές καταστάσεις και αναδρομικές συμμετρικές συνάψεις με στοχαστικά χαρακτηριστικά (**Stochastic Recurrent Networks with Hidden Nodes**). Στόχος η συμπλήρωση **ελλειμματικών** διανυσμάτων εισόδου σε στοιχεία εξόδου με στατιστικές ιδιότητες ισορροπίας συμβατές με το δείγμα μάθησης (**pattern completion**)

Μια MB περιλαμβάνει:


- Δύο διακριτά στρώματα K **Visible** και L **Hidden Neurons** με δυαδικές καταστάσεις ± 1
- Συμμετρικές Συνάψεις $w_{ij} = w_{ji}$, $w_{ii} = 0$ εν δυνάμει μεταξύ όλων των νευρώνων της **BM**

Η μη επιβλεπόμενη μάθηση ξεκινά με **δείγμα μάθησης** που κλειδώνει στα **Visible Nodes** και μέσω **gradient ascent** προσδιορίζει συναπτικά βάρη και καταστάσεις όλων των νευρώνων (**Visible & Hidden**). Όταν **ελλειμματικό** στοιχείο από **δείγμα test** κλειδώνεται σε υποσύνολο των **Visible Nodes**, η **BM** εκτιμά το **πλήρες δειγματικό στοιχείο** στην κατάσταση των **Visible Nodes**



Νευρωνικό Δίκτυο Hopfield (1982, **John Hopfield**)

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



Φάσεις Μάθησης Μηχανής Boltzmann

- **Θετική Φάση Μάθησης:** Τα στοιχεία του δείγματος μάθησης κλειδώνουν (**clamp**) δυαδικές καταστάσεις των **ορατών νευρώνων** με βάση τις πιθανότητες 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 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 δείγμα μάθησης
- **Πολυπλοκότητα Αλγορίθμου:** Συνήθως απαιτείται μεγάλος αριθμός κρυφών νευρώνων $L \gg K$ 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 **Hebbs**). **Θετική Φάση** ~ Ενεργή Εγκεφαλική Λειτουργία, **Αρνητική Φάση** ~ Επεξεργασία σε Κατάσταση Ύπνου (;)

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Εφαρμογή Δειγματοληψίας Gibbs – Boltzmann Machine, BM (3/6) (επανάληψη)

Ορισμοί

- **Κατάσταση Δικτύου:** Τυχαίο Διάνυσμά $\mathbf{X} \rightarrow \mathbf{x} = (x_1, x_2, \dots, x_K, \dots, x_m)^T$, $m = L + K$
 $x_i \in \{-1, 1\} \triangleq \{OFF, ON\}$ η κατάσταση του 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 $j \rightarrow i$:** $w_{ij} = w_{ji}$, $w_{ii} = 0$ (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/Boltzmannn**

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Εφαρμογή Δειγματοληψίας Gibbs – Boltzmann Machine, BM (4/6) (επανάληψη)

- Σύνολα Γεγονότων (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 σύνολα

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

$$C = A, B = \{X_1 = x_1, \dots, X_m = x_m\}$$

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

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

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

- 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**)



Κανόνας Μάθησης Boltzmann

Εφαρμογή κριτηρίου Maximum Likelihood ή Log Likelihood

Το διάνυσμα της κατάστασης \mathbf{x} αποτελείται από τη συρραφή δύο υποσυνόλων: Τις καταστάσεις των ορατών νευρώνων \mathbf{x}_α και των κρυφών νευρώνων \mathbf{x}_β με οριακές πιθανότητες θερμικής ισορροπίας **Gibbs**

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

- **Θετική Φάση** που καθορίζεται από τις συνθήκες κλειδώματος (clamping) καταστάσεων του στα δειγματικά στοιχεία μάθησης του περιβάλλοντος \mathcal{J}
- **Αρνητική Φάση** όπου το δίκτυο λειτουργεί αυτόνομα χωρίς εισόδους από το περιβάλλον

Με δεδομένα τα συναπτικά βάρη w_{ji} , στοιχεία της μήτρας \mathbf{w} όλου του δικτύου, ορίζονται οι πιθανότητες **ορατών** καταστάσεων $P(\mathbf{X}_\alpha = \mathbf{x}_\alpha)$. Αν έχουμε πολλά στοιχεία μάθησης στο \mathcal{J} , μπορούμε να θεωρήσουμε ότι οι καταστάσεις \mathbf{X}_α είναι **ανεξάρτητα** τυχαία διανύσματα και η συνολική τους πιθανότητα δίνεται από το **παραγοντικό γινόμενο** $\prod_{\mathbf{x}_\alpha \in \mathcal{J}} P(\mathbf{X}_\alpha = \mathbf{x}_\alpha)$

Αν θεωρήσουμε τον λογάριθμο του γινομένου $L(\mathbf{w})$ 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 όλων των καταστάσεων $\mathbf{x} = (\mathbf{x}_\alpha, \mathbf{x}_\beta)$ με σταθερό το υποσύνολο των κλειδωμένων ορατών καταστάσεων \mathbf{x}_α :

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

Κανόνας Μάθησης Boltzmann

Εφαρμογή κριτηρίου Maximum Likelihood ή Log Likelihood (**συνέχεια**)

Προκύπτει επομένως για τον λογάριθμο του παραγοντικού γινομένου

$$L(\mathbf{w}) = \sum_{\mathbf{x}_\alpha \in \mathcal{J}} \left(\log \sum_{\mathbf{x}_\beta} \exp\left(-\frac{E(\mathbf{x})}{T}\right) - \log \sum_{\mathbf{x}} \exp\left(-\frac{E(\mathbf{x})}{T}\right) \right)$$

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**:

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

Όπου $\eta = \frac{\epsilon}{T}$ η **learning rate parameter** η οποία μεταβάλλεται στις επαναλήψεις του **Simulated Annealing**. Τα βάρη ανανεώνονται με βάση όλα τα στοιχεία του δείγματος μάθησης (**batch mode**) με μεγάλη πολυπλοκότητα και αργή σύγκλιση \Rightarrow **ΑΝΑΓΚΗ ΑΠΛΟΠΟΙΗΣΗΣ ΔΙΚΤΥΟΥ**

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 χαρακτηριστικά συγκεκριμένων εφαρμογών ταξινόμησης δεδομένων

Παράδειγμα: $x \in \{1,2\}, y \in \{0,1\}$ (βάση του 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 |

⇒

| $P(y x)$ | $y = 0$ | $y = 1$ |
|----------|----------|------------|
| $x = 1$ | 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**

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

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

Γενίκευση Παραγωγικού Μοντέλου (Generative Model)

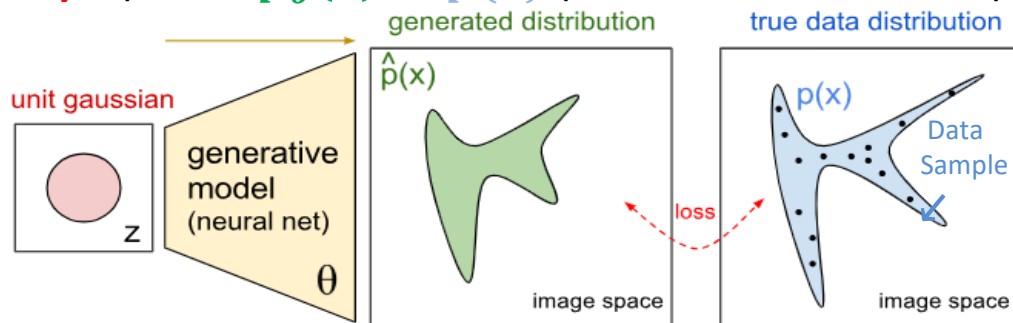
<https://openai.com/blog/generative-models/>

$p(x)$: Κατανομή των στοιχείων του αληθινού δείγματος (**Data 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 $\hat{p}_\theta(x) \rightarrow p(x)$ (κατά **Kullback-Leibler**)



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


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

Επαναλήψεις δύο σταδίων για προσδιορισμό παραμέτρων: (1) **Expectation** συνάρτησης Log-Likelihood, (2) **Maximization**
(χρησιμοποιείται ευρύτατα σε **Μηχανική Μάθηση**)

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

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

(εφαρμόζεται σε **Boltzmann Machine**, <https://skymind.ai/wiki/restricted-boltzmann-machine>)



ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

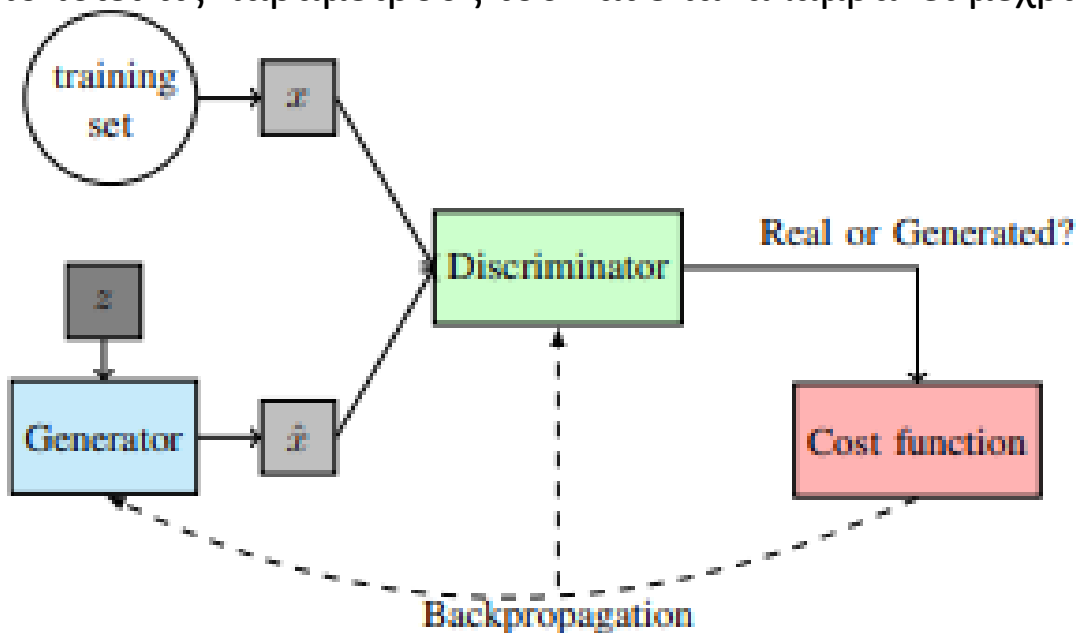
Στατιστική Προσέγγιση: Generative & Discriminative Models (2/2)

Generative Adversarial Networks - GAN (2010 *Olli Niemitalo*, 2014 *Ian Goodfellow*)

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

- **Generator** που με είσοδο *latent random variables* z (π.χ. *Gauss*) δημιουργεί στην έξοδο εικονικό παραγόμενο (*generated*) δείγμα \hat{x} με κατανομή $p_{\theta}(\hat{x})$
- **Discriminator** 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 *Discriminator* καταλαβαίνει τη διαφορά (έξοδος *Generated*), ο παίκτης *Generator* τροποποιεί τις παραμέτρους του και επαναλαμβάνει μέχρι να τον εξαπατήσει (έξοδος *Real*)



Εφαρμογές:

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

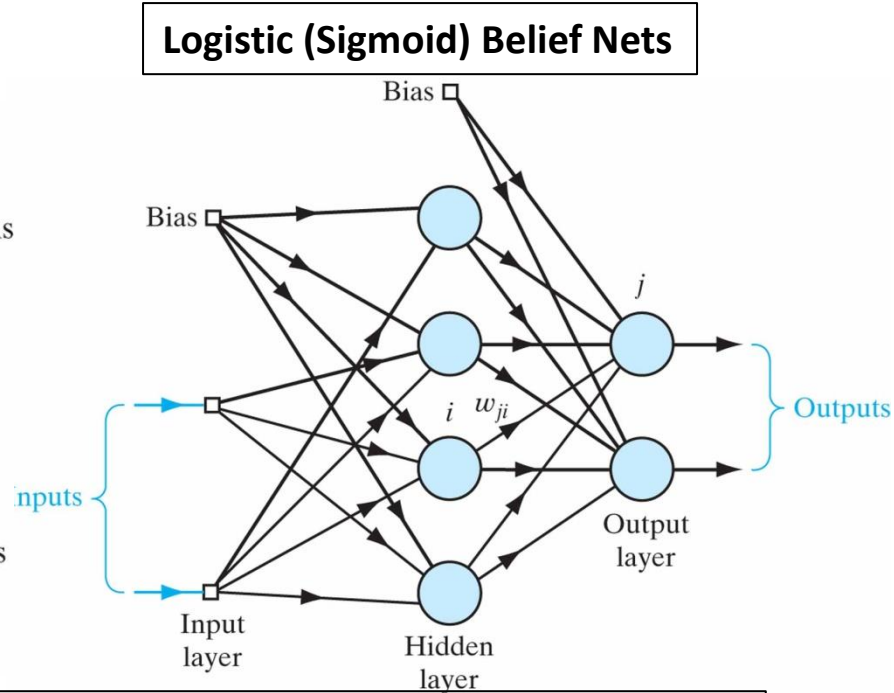
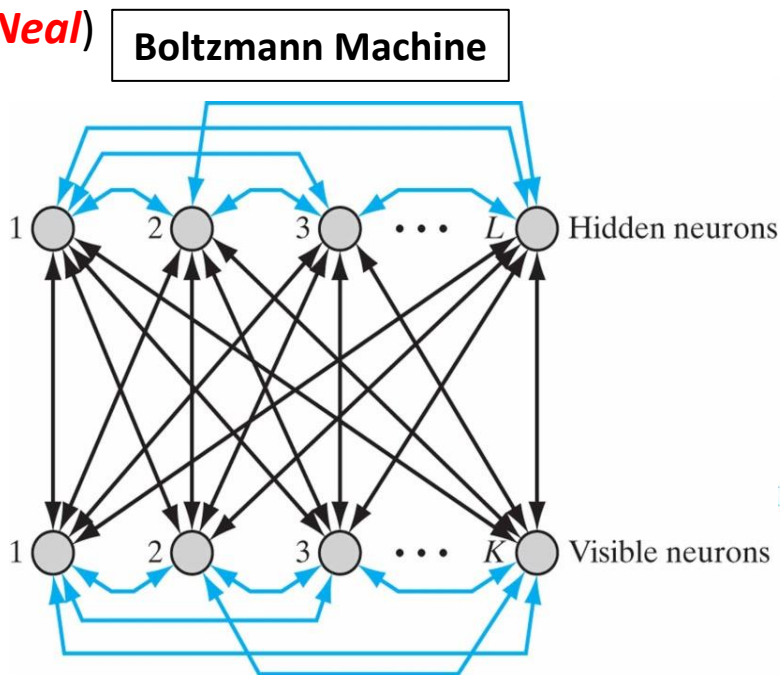
ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Generative Stochastic Neural Networks

Geoffrey Hinton, "Tutorial on Deep Belief Nets" 2007 NIPS (Neural Information Processing Systems) Conference <https://www.cs.toronto.edu/~hinton/nipstutorial/nipstut3.pdf>

Generative Deep Neural Networks με Διαδικούς (ON/OFF) Στοχαστικούς Νευρώνες

- **Στόχοι:** (1) Εκτίμηση (συμπερασματολογία, **inference**) μη παρατηρήσιμων συνιστωσών κατάστασης, (2) Παραγωγή (**generation**) εικονικών δεδομένων συμβατών με κατανομή δείγματος μάθησης
- Διασύνδεση με **συμμετρικούς** νευρώνες \Rightarrow **Boltzmann Machine** (1983, **Geoffrey Hinton & Terry Sejnowski**)
- Διασύνδεση σε **Κατευθυντικό** γράφο χωρίς κύκλους \Rightarrow **Logistic (Sigmoid) Belief Nets** (1992, **Radford Neal**)




Δυσκολίες μάθησης (ρύθμιση συνάψεων κρυφών επιπέδων), αργή σύγκλιση

ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Restricted Boltzmann Machine (RBM) (1/6)

Harmonium (1986, *Paul Smolensky*) → RBM (2006, *Geoffrey Hinton*)

- Στοχαστικοί νευρώνες 2 επιπέδων (**ορατό, κρυφό**), συμμετρικές συνάψεις, καταστάσεις $\{0,1\}$
- Οι καταστάσεις των ορατών νευρώνων κωδικοποιούν παρατηρήσιμα χαρακτηριστικά (*observable features*) δείγματος εισόδου/εξόδου, ενώ του κρυφού επίπεδου κωδικοποιούν κρυφές ιδιότητες (*latent features*)
- Νευρώνες του ίδιου επιπέδου: **Ασύνδετοι** ⇒ Οι καταστάσεις κρυφών νευρώνων είναι **ανεξάρτητες** τυχαίες μεταβλητές υπό την συνθήκη των καταστάσεων των ορατών νευρώνων
- Συνάρτηση ενεργοποίησης νευρώνων: Σιγμοειδής (*logistic*) συνάρτηση $\varphi(v) = \frac{1}{1+\exp(-v)}$
- Οι καταστάσεις των νευρώνων οδηγούνται σε ισορροπία σε επαναλαμβανόμενα διπλά **βήματα Gibbs** $t = 0,1,2, \dots, k$ για κάθε δειγματικό στοιχείο μάθησης $\in \mathcal{T}$. Κάθε βήμα περιλαμβάνει: (1) τη παραγωγή τιμών από **όλα** τα visible neurons → hidden neurons σε πρώτο πέρασμα και (2) σε επόμενο πέρασμα από **όλα** τα hidden neurons → visible neurons
- Τα συναπτικά βάρη ανανεώνονται μετά την είσοδο όλων των στοιχείων του \mathcal{T} (*batch mode*)



Η διαδικασία μάθησης συνήθως επαναλαμβάνεται σε εποχές (*epochs*) με βάση το ίδιο σύνολο δειγματικών στοιχείων (*batch*) με πιθανή αλλαγή της σειράς τους

Πλεονέκτημα RBM από Boltzmann Machine:

Η μη ύπαρξη διασύνδεσης μεταξύ νευρώνων του ίδιου επιπέδου επιτρέπει τη γρήγορη παραδειγματικών στοιχείων συμβατών με δεδομένα μάθησης

Restricted Boltzmann Machine (RBM) (2/6)

Αλγόριθμος μάθησης σε RBM – Contrastive Divergence (**Geoffrey Hinton** 2002)

<https://www.cs.toronto.edu/~hinton/absps/guideTR.pdf>, <https://christian-igel.github.io/paper/TRBMAI.pdf>

Ορισμοί Δυαδικών Καταστάσεων $\{0,1\}$:

Συνιστώσα v_i του $\mathbf{x}_\alpha^{(t)}$: Κατάσταση **ορατού** (*visible*) νευρώνα i στο βήμα t , $v_i = \begin{cases} 1 & (ON) \\ 0 & (OFF) \end{cases}$

Συνιστώσα h_j του $\mathbf{x}_\beta^{(t)}$: Κατάσταση **κρυφού** (*hidden*) νευρώνα j στο βήμα t , $h_j = \begin{cases} 1 & (ON) \\ 0 & (OFF) \end{cases}$

Ζητούμενο: Προσδιορισμός Συναπτικών Βαρών $w_{ij} = w_{ji}$ μεταξύ ορατών και κρυφών νευρώνων ώστε στη σύγκλιση ($t \rightarrow \infty$) να δημιουργηθούν καταστάσεις v_i του $\mathbf{x}_\alpha^{(t)}$ με

κατανομή όμοια κατά **Kullback-Leibler (KL)** με αυτή του δείγματος μάθησης $\mathbf{x}_\alpha^{(0)} \in \mathcal{J}$

$$P(\mathbf{x}_\alpha^{(t)}) = \frac{1}{Z} \sum_{\mathbf{x}_\beta^{(t)}} \exp\left(-\frac{E(\mathbf{x}^{(t)})}{T}\right), E(\mathbf{x}^{(t)}) = E(\mathbf{x}_\alpha^{(t)}, \mathbf{x}_\beta^{(t)}) = -\sum_{i,j} v_i h_j w_{ij}, -\frac{\partial E(\mathbf{x}^{(t)})}{\partial w_{ij}} = v_j h_i$$

Αλγόριθμος: Για όλα τα στοιχεία $\mathbf{x}_\alpha^{(0)}$ του δείγματος (ή *batch*) μάθησης επαναλαμβάνονται βήματα $t = 1, 2, 3 \dots k$ διπλής παραγωγής διανυσμάτων καταστάσεων $\mathbf{x}_\alpha^{(t)}, \mathbf{x}_\beta^{(t)}$:

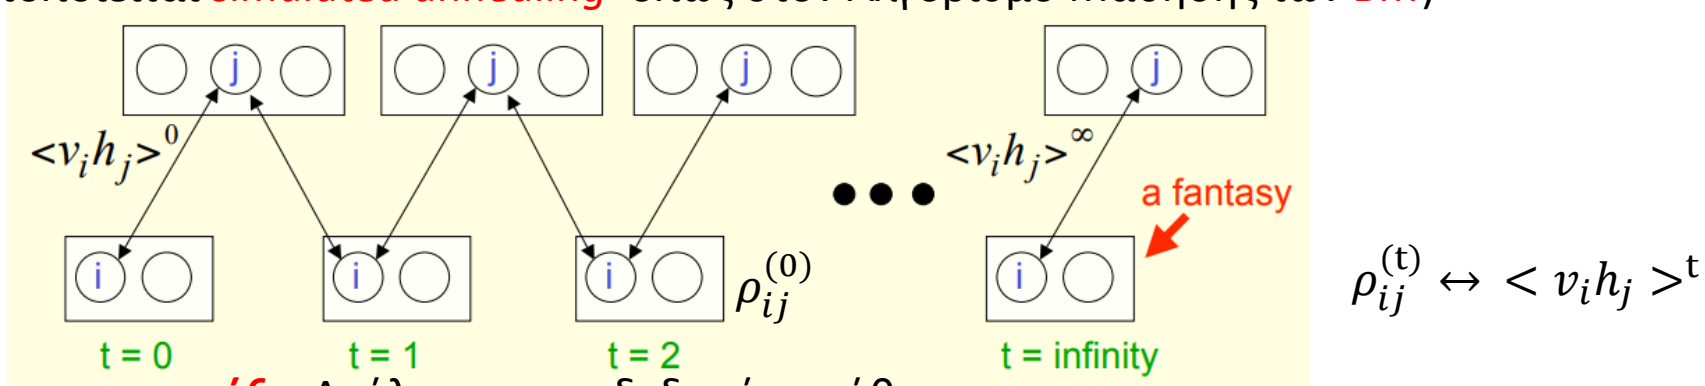
- Εκκίνηση $t = 0$ με κλείδωμα των καταστάσεων των ορατών νευρώνων σε **δειγματικά στοιχεία μάθησης** $\mathbf{x}_\alpha^{(0)} \in \mathcal{J}$ και στο επόμενο πέρασμα (*pass*) παραγωγή των $\mathbf{x}_\beta^{(0)}$
- Σε κάθε βήμα $t = 1, 2, 3 \dots k$ πραγματοποιείται παράλληλη ανανέωση με δειγματοληψία **Gibbs** των $\mathbf{x}_\alpha^{(t)}$ με δεδομένες όλες τις $\mathbf{x}_\beta^{(t-1)}$ και παραγωγή των $\mathbf{x}_\beta^{(t)}$ από τις $\mathbf{x}_\alpha^{(t)}$
- Από τις $\mathbf{x}_\alpha^{(0)}, \mathbf{x}_\alpha^{(k)}$ υπολογισμός διαφοροποιήσεων Δw_{ij} των συναπτικών βαρών, της συνεισφοράς του $\mathbf{x}_\alpha^{(0)}$ στη μεγιστοποίηση του λογαρίθμου του λόγου πιθανοφάνειας $L(\mathbf{w})$

Restricted Boltzmann Machine (RBM) (3/6)

Αλγόριθμος μάθησης σε RBM – Contrastive Divergence (*Geoffrey Hinton* 2002)

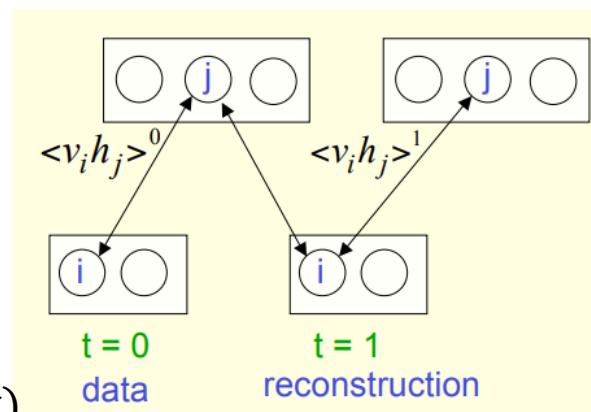
<http://www.cs.utoronto.ca/~hinton/absps/nccd.pdf>

Κριτήριο: Μεγιστοποίηση του λόγου πιθανοφάνειας $L(\mathbf{w}) = \sum_{\mathbf{x}_\alpha \in \mathcal{J}} \log P(\mathbf{X}_\alpha = \mathbf{x}_\alpha)$ με βήματα προς *Gradient Ascent* $\frac{\partial L(\mathbf{w})}{\partial w_{ij}} = \rho_{ij}^{(0)} - \rho_{ij}^{(k)}$ όπου $\rho_{ij}^{(0)}$ και $\rho_{ij}^{(k)}$ οι μέσες συσχετίσεις των νευρώνων i, j κατά την εκκίνηση $t = 0$ και την τελική σύγκλιση $t = k \rightarrow \infty$ (όπως στις *Boltzmann Machines - BM* αλλά χωρίς εξάρτηση από τη θερμοκρασία T αφού δεν πραγματοποιείται *simulated annealing* όπως στον Αλγόριθμο Μάθησης των *BM*)



Προσέγγιση στη πράξη: Ανάλογα με τα δεδομένα μάθησης (αριθμός στοιχείων δείγματος, αντιπροσωπευτικότητα, παρατηρήσιμα χαρακτηριστικά - *features* που καθορίζουν τους ορατούς νευρώνες) και τον αριθμό κρυφών νευρώνων που καθορίζουν *latent features* μπορεί να αρκούν λίγα βήματα k αντί των πολλών για κατευθύνσεις μεγιστοποίησης $\rho_{ij}^{(0)} - \rho_{ij}^{(\infty)}$

Μέγιστη απλούστευση: $k = 1$, $\Delta w_{ij} = \varepsilon (\rho_{ij}^{(0)} - \rho_{ij}^{(1)})$
 προσέγγιση *Contrastive Divergence* αντί μεγιστοποίησης του $L(\mathbf{w})$



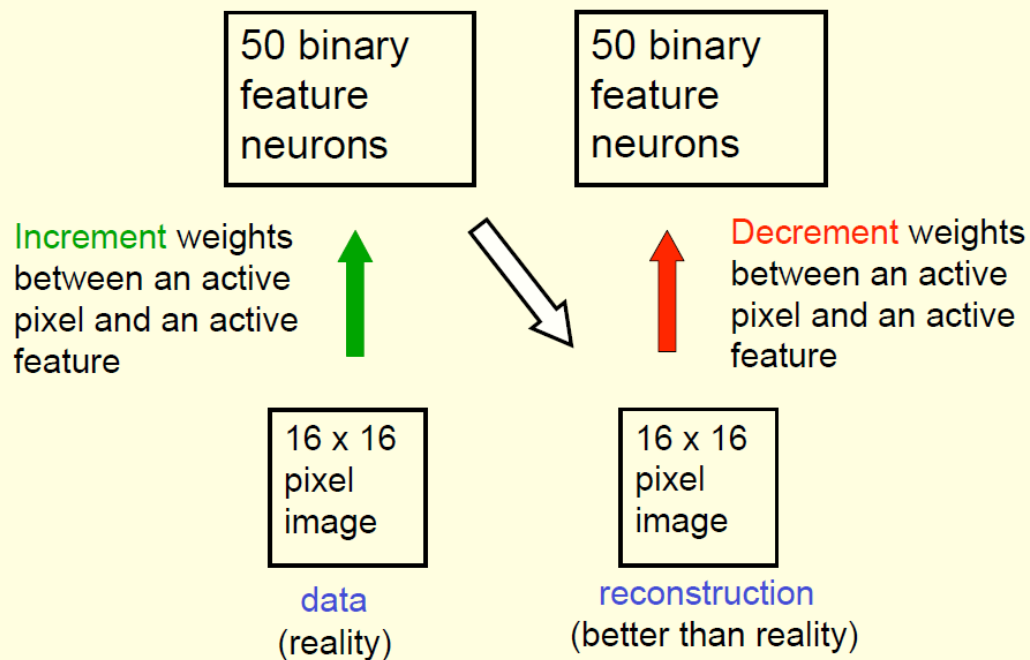
ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Restricted Boltzmann Machine (RBM) (4/6)

Geoffrey Hinton, "Tutorial on Deep Belief Nets" 2007 NIPS (Neural Information Processing Systems) Conference <https://www.cs.toronto.edu/~hinton/nipstutorial/nipstut3.pdf>

Παραγωγή εικονικού δειγματικού στοιχείου από δείγμα χειρόγραφων αριθμών $16 \times 16 = 256$ pixels (features) κωδικοποιημένα με 1 bit (άσπρο – μαύρο) μέσω RBM από 50 hidden neurons (50×256 binary feature neurons)

How to learn a set of features that are good for reconstructing images of the digit 2




ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Restricted Boltzmann Machine (RBM) (5/6)

Geoffrey Hinton, "Tutorial on Deep Belief Nets" 2007 NIPS (Neural Information Processing Systems) Conference <https://www.cs.toronto.edu/~hinton/nipstutorial/nipstut3.pdf>

The final 50 x 256 weights



Each neuron grabs a different feature.

Geoffrey Hinton, "Tutorial on Deep Belief Nets" 2007 NIPS (Neural Information Processing Systems) Conference <https://www.cs.toronto.edu/~hinton/nipstutorial/nipstut3.pdf>

Προβλήματα γενίκευσης από υπεραπλούστευση διαδικασίας μάθησης:
Λανθασμένη αναπαραγωγή χειρόγραφου αριθμού **3** από RBM με δείγμα μάθησης αποκλειστικά με χειρόγραφα στοιχεία αριθμού **2**

How well can we reconstruct the digit images from the binary feature activations?

Data
↓
Reconstruction from activated binary features
↓



New test images from the digit class that the model was trained on

Data
↓
Reconstruction from activated binary features
↓



Images from an unfamiliar digit class (the network tries to see every image as a 2)


ΣΤΟΧΑΣΤΙΚΕΣ ΔΙΑΔΙΚΑΣΙΕΣ & ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ ΣΤΗ ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Deep Belief Nets

Μάθηση των Deep Belief Nets (2007, *Geoffrey Hinton*)

Αποτελείται από στοίβα πολλαπλών ιεραρχικών στρωμάτων συνδεδεμένων νευρώνων:

1. **Ορατό Στρώμα Εισόδου (*Visible Layer*)** που αρχικά **κλειδώνει** σε δειγματικά στοιχεία μάθησης και μετά τη σύγκλιση παράγει ορατό δειγματικό στοιχείο (***generated visible state***)
2. **Ιεραρχικά Κρυφά Στρώματα (*Hidden Layers*)** που κωδικοποιούν στατιστικά χαρακτηριστικά - ***features*** (και στατιστικά χαρακτηριστικά χαρακτηριστικών - ***features of features***) που προκύπτουν από το δείγμα μάθησης (λογική **pendemonium**, 1958 ***Selfridge***)
3. Στο σχήμα με 3 Κρυφά Στρώματα, τα ανώτερα (**h2 & h3**) αποτελούν ***Restricted Boltzmann Machines*** (harmonium) με το **h2** να παίζει ρόλο ορατού στρώματος. Τα δύο κατώτερα (visible **data** & **h3**) διαμορφώνουν ***Κατευθυντικό Γράφο*** (**Logistic Belief Net**)



Φάση Μάθησης (bottom-up)

- Το στρώμα data συντονίζει το h1 με βάση το training sample
- Το h1 ενεργοποιεί το RBM (h2, h3)

Φάση Παραγωγής Δείγματος (sample generation)

- Η RBM (h2, h3) παράγει δείγμα ισορροπίας Gibbs με ***πολλαπλές διαδοχικές επαναλήψεις*** (κύριος λόγος καθυστέρησης)

Τελική Φάση Συνολικής Ανανέωσης Καταστάσεων (top-down)

- Τα κατώτερα στρώματα h1 και data συντονίζονται με το δείγμα ισορροπίας σε μία τελική επανάληψη