

# Uczenie nienadzorowane


## Autoenkodery

## Modele generatywne

# Uczenie nienadzorowane

- Uczenie **nadzorowane** (*supervised*) - dane wejściowe **X** posiadają spodziewane wyjście (etykiety) (**X, Y**)
- Uczenie **nienadzorowane** (*unsupervised*) używa wyłącznie danych wejściowych **X**. Dane bez etykiet są powszechnie występujące.
  - trening automatycznie wykrywa istotne cechy w danych,
  - modeluje rozkład prawdopodobieństwa danych
- Modele sieci:
  - autoenkodery (AE)
  - Restricted Boltzman Machines (RBM)
  - GAN
- Zastosowanie:
  - kodowanie sygnału, wykrywanie istotnych cech, usuwanie szumu i rekonstrukcja sygnału
  - generowanie sygnałów
  - inicjowanie głębokich sieci DNN (stacked autoencoders)

# Autoenkodery




- autoenkodery uczą się odtwarzać sygnał wejściowy
- warstwy pośrednie kodują specyficzne cechy danych
- kompresja stratna - wymagamy aby model nie był jednostkowym odwzorowaniem
- AE uczą się reprezentacji danych (ekstrakcja cech), modelują rozkład prawdopodobieństwa sygnału
- koder i dekodek mogą być sieciami neuronowymi, całość uczona wsteczną propagacją błędów

# Autoenkodery

Encoder:

$$\mathbf{h} = f(\mathbf{x})$$
$$= \sigma(\mathbf{W}\mathbf{x} + \mathbf{b})$$



Decoder:

$$\hat{\mathbf{x}} = g(\mathbf{h})$$
$$= \sigma(\mathbf{W}'\mathbf{h}(\mathbf{x}) + \mathbf{b}')$$

- **Autoencoder** - sieć jednokierunkowa, której celem jest rekonstrukcja sygnału wejściowego
- warstwa ukryta **h**: koduje sygnał wejściowy, detektor cech, skompresowana reprezentacja danych
- często wymaga się aby  $\mathbf{W}' = \mathbf{W}^T$ , współdzielone wagi kodera i dekodera

# Koszt rekonstrukcji

## Funkcja rekonstrukcji $L(\mathbf{x}, \hat{\mathbf{x}})$

- MSE dla danych wejściowych rzeczywistych

$$L(\mathbf{x}, \hat{\mathbf{x}}) = \frac{1}{2} \sum_k (\hat{x}_k - x_k)^2$$

– liniowa aktywacja warstwy wyjściowej  $\hat{\mathbf{x}} = \mathbf{W}'\mathbf{h} + \mathbf{b}'$


- Cross Entropy dla danych wejściowych binarnych

$$L(\mathbf{x}, \hat{\mathbf{x}}) = - \sum_k (x_k \log \hat{x}_k + (1 - x_k) \log (1 - \hat{x}_k))$$

- trening wsteczną propagacją błędu
- ograniczenia zapobiegające tworzeniu odwzorowania jednostkowego: niekompletny AE, regularyzowany AE, kurczliwy AE, ...

## Niekompletny autokoder

- **Niekompletny AE** (*undercomplete*) - rozmiar warstwy **h** mniejszy od rozmiaru wejścia,
- kompresja sygnału do rozmiaru **h**
- dla liniowego dekodera wynik jest równoważny z PCA, wagi neuronów tworzą składowe główne maksymalizujące wariancję
- Przykład: input-output: 32x32 (1024 piksele) , hidden (code size): 32



## Regularyzowany AE


- wielkość **h** decyduje o pojemności sieci i jakości odwzorowania. Dla niekompletnych AE jest ograniczenie zwiększania rozmiaru warstwy ukrytej
- **Nadkompletny** AE (*overcomplete*) gdy rozmiar **h** większy od rozmiaru sygnału wejściowego **x**,
  - brak kompresji
  - nie gwarantują uzyskania wartościowych reprezentacji bez dodania odpowiedniej regularyzacji wymuszającej odpowiednią reprezentację w **h** (np. rzadkość)
- **Rzadki autoencoder** z czynnikiem kary za brak rzadkiej reprezentacji

$$L(\mathbf{x}, \hat{\mathbf{x}}) + \lambda \sum |h_i|$$

- w celu uzyskania rzadkich aktywacji można też użyć ReLU (Glorat, 2011)

# Autoenkoder z odszumianiem (DAE)

- **Denoise autoencoder (DAE)** usuwa szum (lub inne zniekształcenia) sygnału wejściowego.
- Sygnał wejściowy  $\tilde{x}$  jest zniekształconą kopią  $x$
- AE uczy się odtwarzać oryginalny sygnał bez deformacji



# Kurczliwy AE

- **Contractive autoencoder (CAE)**


$$L(\mathbf{x}, \hat{\mathbf{x}}) + \lambda \|\nabla_{\mathbf{x}} \mathbf{h}(\mathbf{x})\|_F^2$$

- kara za dużą zmienność reprezentacji przy zmianie sygnału (norma Frobeniusa)

$$\|\nabla_{\mathbf{x}} \mathbf{h}(\mathbf{x})\|_F^2 = \sum_i \sum_j \left( \frac{\partial h_i(x)}{\partial x_j} \right)^2$$

## Wariacyjny AE

- **Variational autoencoders (VAE)** jawnie modeluje rozkład gęstości danych, kodowana reprezentacja to parametry funkcji gęstości, np.  $\sigma_i, \mu_i$  rozkładu normalnego  $N(\mu_i, \sigma_i)$



- sygnał wejściowy dekodera jest próbkowany z rozkładu określonego przez parametry warstwy kodującej
- model generatywny - umożliwia próbkowanie danych wyjściowych, tworzenie nowych sygnałów o charakterystyce zbliżonej do danych treningowych

## Kullback–Leibler divergence


- czynnik regularyzujący, dodawany do funkcji kosztu (np. MSE), wymuszający odpowiedni rozkład danych w warstwie kodującej (KL divergence), np. preferujący rozkład  $N(0, 1)$

$$\sum_{i=1}^n \sigma_i^2 + \mu_i^2 - \log(\sigma_i) - 1$$


- osiąga minimum dla  $\sigma_i = 1, \mu_i = 0$
- wymusza rozkład zakodowanych danych w centrum przestrzeni ukrytej, minimalizacja kosztu rekonstrukcji konkuruje z regularyzacją próbując rozdzielić grupy różnych danych

# VAE na MNIST

wizualizacja danych  
treningowych w 2 wymiarowej  
warstwie ukrytej kodera





generowanie cyfr dla siatki  
15x15 wartości 2 wymiarowej  
warstwy ukrytej dekodera



Architektura: Input-512-2- $(\mu, \sigma)$ -2-512-Output

# Interpolowanie i generowanie pojęć

Arytmetyka w przestrzeni zmiennych utajonych




Różnica pomiędzy pojęciami  
może być dodana do innego  
pojęcia

Środek między wektorami  $\mu$   
koduującymi pojęcia

# Ukryta reprezentacja pojęć

- wyuczona reprezentacja danych koduje pojęcia
- arytmetyczne operacje na wektorach kodujących odpowiadają relacjom semantycznym pomiędzy pojęciami



# Przykład: generowanie twarzy

Wejście



Rekonstrukcja




Losowe



👉 Deep Feature Consistent Variational Autoencoder


## Inne typy autoenkoderów

- Convolutional AE, dekodler jest symetryczną do enkodera siecią dekonwolucyjną




- sequence-to-sequence AU z użyciem jednostek rekurencyjnych (np. LSTM)
- głębokie autoenkodery - więcej warstw sprzyja kompresji danych o złożonych rozkładach
- stacked autoencoders - tworzenie głębokich sieci z uczonych sekwencyjnie autoenkoderów (metoda inicjalizacji)


# Deep Convolutional Autoencoder



deconvolution  
transpozycja splotu




unpooling



*Omid E. David, Nathan S. Netanyahu, DeepPainter: Painter Classification Using Deep Convolutional Autoencoders*

# Przykład: Sketch-RNN

Sequence-to-Sequence Variational Autoencoder do trenowania reprezentacji rysowania odręcznego




 Draw Together with a Neural Network

David Ha, Douglas Eck, A Neural Representation of Sketch Drawings

# Restricted Boltzman Machine

- **Restricted Boltzman Machines (RBM)** (Hinton 2000), wcześniej Harmonium (P. Smolensky, 1986), to szczególny przypadek Maszyny Boltzmana
- stochastyczna sieć neuronowa modelująca rozkład prawdopodobieństw wejść
- *restrictive* - brak połączeń wewnątrz warstwy
- algorytm uczenia: *contrastive divergence* (Hinton)



Źródło grafiki: Wikipedia

## Budowa RBM


- binarne jednostki umieszczone w dwóch warstwach: widzialnej  $\mathbf{v}$  i ukrytej  $\mathbf{h}$
- sygnał wejściowy podawany do jednostki widzialnej  $\mathbf{v} = \mathbf{x}$
- energia układu

$$E(\mathbf{x}, \mathbf{h}) = - \sum a_i x_i - \sum b_i h_i - \sum \sum x_i w_{ij} h_j$$

gdzie  $w_{ij}$  to wagi połączeń między warstwami,  $a_i$  i  $b_i$  to wyrazy wolne związane z warstwą widzialną i ukrytą

- prawdopodobieństwo rozkładu

$$p(\mathbf{x}, \mathbf{h}) = \frac{1}{Z} e^{-E(\mathbf{x}, \mathbf{h})}$$



src: <https://kwonkyo.wordpress.com/>

# RBM

- prawdopodobieństwo marginalne

$$P(\mathbf{x}) = \frac{1}{Z} \sum_{\mathbf{h}} e^{-E(\mathbf{x}, \mathbf{h})}$$

- brak połączeń wewnątrz warstw, więc stany w warstwach są niezależne

$$P(\mathbf{h}|\mathbf{x}) = \prod_{j=1}^n P(h_j|\mathbf{x}), \quad P(\mathbf{x}|\mathbf{h}) = \prod_{i=1}^m P(x_i|\mathbf{h})$$

$$P(h_i = 1|\mathbf{x}) = \sigma(\mathbf{w}_i \mathbf{x} + b), \quad P(x_k = 1|\mathbf{h}) = \sigma(\mathbf{h}^T \mathbf{w}_k + c)$$

# Contrastive divergence CD

- cel treningu: maksymalizacja prawdopodobieństwa  $P(\mathbf{x})$


$$L = \frac{1}{N} \sum \log P(\mathbf{x})$$

- algorytm optymalizacji *Contrastive divergence* (Hinton)
  - dla każdego  $\mathbf{x}$  wejściowego wygeneruj  $\mathbf{x}'$  z  $k$  krotnego samplowania Gibbsa
  - aktualizacja


$$\Delta \mathbf{W} = \epsilon(\mathbf{x}\mathbf{h}^T - \mathbf{x}'\mathbf{h}'^T)$$

$$\Delta \mathbf{a} = \epsilon(\mathbf{x} - \mathbf{x}'), \quad \Delta \mathbf{b} = \epsilon(\mathbf{h} - \mathbf{h}')$$

- w praktyce  $k = 1$  daje dobre rezultaty




# Filtry RBM na MNIST



*Erhan, Bengio, (2010) Why Does Unsupervised Pre-training Help Deep Learning?*


# Stacked autoencoders



- Sygnał na wyjściu warstwy ukrytej autoenkodera staje się wejściem kolejnego autoenkodera
- Hierarchia reprezentacji: pierwsza warstwa koduje najprostsze warstwy, kolejne bardziej ogólne relacje, itd.
- Podobna architektura z wielowarstwowym RBM to Deep Belief Networks (DBN)




# Deep Belief Networks (DBN)

- DBN (Teh, Hinton 2006)  
wielowarstwowy RBM,
- uczy się głębokiej, hierarchicznej reprezentacji danych, każda kolejna warstwa analizuje sygnał widoczny w warstwie ukrytej poprzedniego RBM
- uczenie zachłanne: kolejne warstwy dodawane i uczone pojedynczo
- pierwszy efektywny model głęboki
- to nie jest sieć jednokierunkowa



src: <http://deeplearning.net/tutorial/DBN.html>

# Inicjalizacja sieci DNN




## 1. Greedy layer-wise pre-training:

- trening nienadzorowany autoenkodera wsteczną propagacją
- usuwamy warstwę wyjściową (dekoder) i uczymy kolejny AE, którego wejściem jest sygnał z warstwy ukrytej poprzedniego AE przy niezmiennych wartościach wag w poprzednich warstwach
- powtarzamy procedurę dla każdej kolejnej warstwy

## 2. fine tuning: dodajemy w pełni połączoną warstwę wyjściową (lub kilka warstw) i uczymy całą sieć w sposób nadzorowany

# Filtry DBN na MNIST

pre-training






Erhan, Bengio, (2010) Why Does Unsupervised Pre-training Help Deep Learning?

fine tune

# Filtry DBN na MNIST



without pre-training



*Erhan, Bengio, (2010) Why Does Unsupervised Pre-training Help Deep Learning?*

# Pre-training DNN


Pre-trening poprawia generalizację, działa jak regularyzacja




*Erhan, Bengio, (2010) Why Does Unsupervised Pre-training Help Deep Learning?*

# Głębokie autoenkodery

- dodatkowa warstwa ukryta zwiększa możliwości enkodera w odwzorowaniu kodu (uniwersalny aproksymator jest w stanie nauczyć się dowolnego kodowania)
- dodanie warstw pozwala zmniejszyć złożoność reprezentacji trudnych problemów
- głębokie AE pozwalają uzyskać większą kompresję (Hinton 2006)
- niekompletne głębokie AE - żadna warstwa ukryta nie powinna być mniejsza niż warstwa kodująca



# Pretraining dla głębokich AE




- RBM używany do inicjacji kodera i dekodera

*G. Hinton, R. Salakhutdinov, Reducing the Dimensionality of Data with Neural Networks, Science 2006*

# Kompresja obrazów: Deep AE vs. PCA


**Fig. 2.** (A) Top to bottom: Random samples of curves from the test data set; reconstructions produced by the six-dimensional deep autoencoder; reconstructions by "logistic PCA" (8) using six components; reconstructions by logistic PCA and standard PCA using 18 components. The average squared error per image for the last four rows is 1.44, 7.64, 2.45, 5.90. (B) Top to bottom: A random test image from each class; reconstructions by the 30-dimensional autoencoder; reconstructions by 30-dimensional logistic PCA and standard PCA. The average squared errors for the last three rows are 3.00, 8.01, and 13.87. (C) Top to bottom: Random samples from the test data set; reconstructions by the 30-dimensional autoencoder; reconstructions by 30-dimensional PCA. The average squared errors are 126 and 135.



G. Hinton, R. Salakhutdinov, *Reducing the Dimensionality of Data with Neural Networks*, Science 2006

# Projekcja do 2D (dwa neurony kodujące)


MNIST: PCA vs. Deep AE (784-1000-500-250-2)



*G. Hinton, R. Salakhutdinov, Reducing the Dimensionality of Data with Neural Networks, Science 2006*

## Projekcja do 2D (dwa neurony kodujące)


Wizualizacja dokumentów: architektura 2000-500-250-125-2



*G. Hinton, R. Salakhutdinov, Reducing the Dimensionality of Data with Neural Networks, Science 2006*

# Generative Adversarial Network (GAN)

*Goodfellow 2014*



src: <https://deeplearning4j.org/generative-adversarial-network>

# Generative Adversal Network (GAN)

- GAN (Goodfellow 2014) - dwie sieci (generująca i oceniająca) rywalizujące ze sobą w grze o sumie zerowej
- model GAN uczy się generować dane o właściwościach zbliżonych do zbioru treningowego, np. zdjęć o realistycznych cechach
- sieć **oceniająca** (dyskryminująca, np. CNN) stara się odróżnić prawdziwy sygnał od wygenerowanego przez sieć generującą
- sieć **generująca** (np. sieć dekonwolucyjna) tworzy sygnał z pewnego rozkładu starając się „oszukać” sieć oceniającą, trening dąży do maksymalizacji błędu dyskryminacji
- obie sieci uczone wsteczną propagacją, sieć generująca tworzy coraz bardziej realistyczne obrazy, sieć oceniająca specjalizuje się w rozróżnianiu coraz subtelniejszych różnic pomiędzy obrazami prawdziwymi i wygenerowanymi

## Trening GAN

Funkcja kosztu dyskryminatora - binarna entropia krzyżowa (spodziewana odpowiedź 1 dyskryminatora dla obrazu prawdziwego)

$$L_D = -\frac{1}{2}\mathbb{E}_{\mathbf{x} \sim p_{\text{data}}(\mathbf{x})} \log D(\mathbf{x}) - \frac{1}{2}\mathbb{E}_{\mathbf{z} \sim p_z(\mathbf{z})} \log(1 - D(G(\mathbf{z})))$$

gdzie  $p_{\text{data}}(\mathbf{x})$  rozkład danych prawdziwych,  $p_z(\mathbf{z})$  rozkład danych generowanych

Funkcja kosztu generatora


$$L_G = -\frac{1}{2}\mathbb{E}_z \log D(G(\mathbf{z}))$$

maksymalizuje prawdopodobieństwo popełnienia błędu przez dyskryminator (spodziewana odpowiedź 1 dyskryminatora dla obrazu fałszywego)

# DCGAN - deep conv GAN

*Denton et al., 2015*

Generowanie obrazów wysokiej rozdzielczości



*Goodfellow, Deep Learning, 2016*

# SRGAN - super resolution GAN





Figure 4: Architecture of Generator and Discriminator Networks. Size of each convolutional layer (n) and stride (s) indicated for each convolutional layer.

# StyleGAN

## Generator



*T. Karras, S. Laine, T. Aila (2019) A Style-Based Generator Architecture for Generative Adversarial Networks*

## Inne zastosowania

- rekonstrukcja obrazów 3D ze zdjęć
- generowanie tekstu, synteza mowy, ...
- modyfikacje obrazów: zmiana twarzy, mimiki, fryzury, postarzanie osób na zdjęciach
- transfer stylu
- generowanie scen w grach wideo, zwiększanie rozdzielczości tekstur
- bezpieczeństwo: podnoszenie skuteczności algorytmów w wykrywaniu ataków cybernetycznych, wykrywanie fałszerstw, wykrywanie anomalii
- generowanie dane na potrzeby uczenia maszynowego
- generowanie obrazów z tekstu, generowanie nagrań wideo
-  [Curated list of awesome GAN applications and demo](#)