

RNN


Sieci rekurencyjne i
modelowanie sekwencji

Modelowanie sekwencji

$$F(\mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_t; \theta) = \mathbf{y}$$


- Dane sekwencyjne lub zależne od czasu: sygnał audio, tekst, ruch obiektów, EEG, ...
- Modelowanie sekwencji: generowanie tekstu (chatboty), generowanie muzyki, etykietowanie obrazów, sterowanie ruchem robota, ...
- Przetwarzanie sekwencji: maszynowe tłumaczenie, rozpoznawanie mowy, rozpoznawanie pisma, przetwarzanie strumieni wideo, ...
- Klasyfikacja sygnałów czasowych, wykrywanie wzorców w sekwencjach, predykcja (np. przewidywanie notowań giełdowych)

Modelowanie sekwencji



- *one-to-one*: pojedynczy sygnał wejściowy produkuje pojedynczy sygnał wyjściowy, brak informacji o sekwencji
- *one-to-many*: pojedyncze wejście generuje sekwencję na wyjściu, np. opis obrazów
- *many-to-one*: sekwencja wejściowa produkuje pojedynczy sygnał wyjściowy, np. klasyfikacja tekstów

Modelowanie sekwencji




many-to-many: wejście i wyjście sekwencyjne

- bez dopasowania ramek, długość sekwencji wejściowej jest różna od długości sekwencji wyjściowej, np. tłumaczenie maszynowe, rozpoznawanie mowy
- z dopasowaniem ramek (*alignment*), np. etykietowanie ramek wideo, klasyfikacja fonemów w sygnale mowy (model akustyczny)

Modelowanie sekwencji sieciami jednokierunkowymi

Sieci MLP: dodanie **stałego kontekstu** do wejścia,
przykład: 2 ramki z lewej i prawej (poprzednie i przyszłe wektory wejściowe)



$$\hat{\mathbf{x}}^t \leftarrow [\mathbf{x}^{t-2}, \mathbf{x}^{t-1}, \mathbf{x}^t, \mathbf{x}^{t+1}, \mathbf{x}^{t+2}]$$



- zwiększenie wymiaru wejściowego istotnie zwiększa złożoność modelu, więc potrzebna jest większa liczba próbek uczących
- modelowanie tylko zależności krótkiego zasięgu (*short term memory*)

Uczenie sekwencji z MLP i CNN

Sieci CNN: spłot względem wymiaru czasu, stały kontekst odpowiada wielkości efektywnego pola recepcyjnego w wymiarze czasu.




TDNN (Waibel, 1987), *time-delay neural network*, model ze spłotem 1D w domenie czasu.


Źródło grafik: Steve Renals, *Machine Learning Practical — MLP Lecture 9*
Alexander Waibel, *Phoneme Recognition Using Time-Delay Neural Networks*, 1987.

Przykłady

Model akustyczny, rozpoznawanie fonemów z nagrań audio



Analiza sygnałów EEG, CNN + widma EEG




Nurse, E., Mashford, B. S., Yepes, A. J., Kiral-Kornek, I., Harrer, S., & Freestone, D. R. (2016). Decoding EEG and LFP Signals using Deep Learning: Heading TrueNorth

RNN - Sieci rekurencyjne


- **Sieci jednokierunkowe** używają jedynie kontekstu o skończonej długości, nie są w stanie wykryć zależności w dłuższych okresach czasu (*long-term*)
- **Sieci rekurencyjne (RNN)** posiadają połączenia do wcześniejszych warstw, wyjście w chwili t zależy od stanu z czasu $t - 1$

Sieć jednokierunkowa



Neural Network


Sieć rekurencyjna Elmana



Neural Network

Stan ukryty jednostek RNN

$$\mathbf{h}^t = f(\mathbf{h}^{t-1}, \mathbf{x}^t; \theta)$$




- neurony z połączeniami rekurencyjnymi działają jak pamięć - potencjalnie są w stanie modelować relacje występujące z dowolnie długim odstępem czasowym (nieskończony kontekst)

$$\mathbf{h}^t = g(\mathbf{x}^t, \mathbf{x}^{t-1}, \dots, \mathbf{x}^1)$$

- wektor $\mathbf{h}^t$ (aktywacje neuronów warstwy rekurencyjnej) tworzy skompresowaną reprezentację sekwencji
- stan początkowy $\mathbf{h}^0$ może być interpretowany jako dodatkowy sygnał wejściowy, typowo inicjowany zerami

Rozwinięcie rekurencji w czasie




Rozwinięcie sieci RNN do postaci sieci jednokierunkowej, gdzie wagi połączeń są współdzielone.


Głębokie uczenie - że od pierwszego sygnału $\mathbf{x}^1$ do wyjścia $\mathbf{h}^t$ jest wiele warstw

Efektywność kodowania

- Sieć RNN z rekurencją w warstwach ukrytych spełnia wymagania **uniwersalnej maszyny Turinga**
- Ilość parametrów opisujących stan **h** ma wpływ na wielkość pamięci ale nie musi zależeć od długości sekwencji




pełny model sekwencji, ilość parametrów $O(k^\tau)$



RNN, stan obecny zależy pośrednio od stanów z przeszłości, ilość parametrów stała względem długości sekwencji $O(1)$

Sieć z jedną warstwą rekurencyjną



$$o_i^{(t)} = \text{softmax}_i \left(\sum_{r=1}^k v_{ir} h_r^{(t)} + b_i \right)$$

$$h_i^{(t)} = \sigma \left(\sum_{j=1}^d u_{ij} x_j^{(t)} + \sum_{r=1}^k w_{ir} h_r^{(t-1)} + c_i \right)$$

To samo zwięźlej w zapisie macierzowym

$$\mathbf{o}^{(t)} = \text{softmax} \left(\mathbf{V} \mathbf{h}^{(t)} + \mathbf{b} \right)$$

$$\mathbf{h}^{(t)} = \sigma \left(\mathbf{U} \mathbf{x}^{(t)} + \mathbf{W} \mathbf{h}^{(t-1)} + \mathbf{c} \right)$$

$\mathbf{x}^{(t)} \in \mathbb{R}^d$ sygnał wejściowy w chwili t


$\mathbf{U} \in \mathbb{R}^{d \times k}$, $\mathbf{W} \in \mathbb{R}^{k \times k}$

d ilość wejść sieci

k ilość neuronów w warstwie ukrytej

Wsteczna propagacja w czasie

Rozwinięta sieć odpowiada głębokiej sieci jednokierunkowej ze współdzielonymi wagami $\mathbf{W}$, $\mathbf{V}$, $\mathbf{U}$




BPTT *backpropagation through time* - trening za pomocą wstecznej propagacji sieci „rozwiniętej w czasie”, odbywa się analogicznie jak w jednokierunkowych sieciach.

Aktualizacja wagi w chwili t wymaga:

- całej historii sygnałów przeszłych $\mathbf{x}^1, \dots, \mathbf{x}^t$
- historii stanów neuronów $\mathbf{h}^1, \dots, \mathbf{h}^t$ i ich pochodnych $\mathbf{h}'^1, \dots, \mathbf{h}'^t$

Wsteczna propagacja w czasie



Funkcja kosztu dla całej sekwencji:

$$L\left(\{\mathbf{x}^{(1)}, \mathbf{x}^{(2)}, \dots, \mathbf{x}^{(\tau)}\}, \{\mathbf{y}^{(1)}, \mathbf{y}^{(2)}, \dots, \mathbf{y}^{(\tau)}\}\right) = \frac{1}{\tau} \sum_{t=1}^{\tau} L^{(t)}$$


$L^{(t)}$ - koszt w kroku t (np. cross-entropy) zależny od $\mathbf{x}^{(1)}, \dots, \mathbf{x}^{(t)}$

$$\partial_w L = \sum_{t=1}^{\tau} \partial_w L\left(y^{(t)}, o^{(t)}\right)$$


Aktualizacje wag są akumulowane dla sygnału błędu propagowanego w kolejnych krokach czasu

Przykład: CharRNN

- model języka oparty na znakach
- wejście to sekwencja znaków, każdy znak to wektor o długości równej ilości znaków w alfabecie
- RNN modeluje rozkład prawdopodobieństwa wystąpienia następnego znaku w sekwencji $f(x(t)) \rightarrow x(t+1)$




Wsteczna propagacja w czasie




- Rozwinięta w czasie sieć tworzy głęboką sieć neuronową ze wszystkimi tego konsekwencjami (zanikający gradient dla relacji odległych w czasie, wybuchający gradient)
- Obliczenia dla długich sekwencji są kosztowne
- Nie zawsze potrzebujemy informacji z odległej przeszłości
- **Truncated BPTT** - ograniczenie długości sekwencji wstecznej propagacji do stałej wartości T (np. $T = 20$). Gradient z dalszej przeszłości $t - T - 1$ równy 0

Pojedyncze wyjście na końcu sekwencji




Sieć produkuje wyjście po obejrzeniu całej sekwencji,
np. klasyfikacja wpisów w portalach społecznościowych
(tzw. analiza sentymentów)

Pojedyncze wejście generujące sekwencję



- Sieć produkuje sekwencję wyjść przy prezentacji stałego wzorca (np. etykietowanie zdjęć, opis sceny)
- Sygnał wejściowy x pełni rolę kontekstu
- Modelowanie sekwencji $y^t = f(y^{t-1}; x)$

Dwukierunkowa sieć RNN



Sieci dwukierunkowe RNN łączą warstwy z rekurencją zależną od sygnału przeszłego $\mathbf{h}$ z rekurencją zależną od przyszłego sygnału $\mathbf{g}$


Schuster, Mike, and Kuldip K. Paliwal. "Bidirectional recurrent neural networks." Signal Processing, 1997

Dwukierunkowa sieć RNN

- informacja z przyszłości może zawierać istotną informację, np. dźwięki kolejnych fonemów (koartykulacja), znaczenie słów w zdaniu
- wyjścia sieci w dowolnym momencie zależą od całej sekwencji wejściowej, możliwe tylko uczenie *offline*
- zastosowanie: rozpoznawanie mowy (Graves, 2008, 2009), bioinformaryka (Baldi, 1999), rozpoznawanie pisma (Liwicki, Marcus, 2007)
- dla obrazów 2D możliwe zastosowanie sieci 4 kierunkowych, co pozwala modelować odległe relacje, jednak nie są one tak wydajne w tych zastosowaniach jak CNN

Model Encoder-Decoder

Transformacja $\mathbf{x}^{(1)}, \mathbf{x}^{(2)}, \dots, \mathbf{x}^{(n_x)} \Rightarrow \mathbf{y}^{(1)}, \mathbf{y}^{(2)}, \dots, \mathbf{y}^{(n_y)}$



Sutskever et al (2014). "Sequence to Sequence Learning with Neural Networks", NIPS.

K Cho et al (2014). "Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation", EMNLP.

Model Encoder-Decoder

seq2seq (Sutskever, 2014) to dwie sieci RNN uczone jednocześnie:


- **enkoder** (reader, input) przetwarza sekwencję wejściową generując kontekst C
- **dekoder** (writer, output) zależnie od kontekstu C generuje sekwencję wyjściową
- wielkość kontekstu C może ograniczyć zdolność sieci do reprezentacji dalekich w czasie relacji
- dodanie uwagi (*attention model*, Bahdanan, 2015) - uwzględnienie w C więcej informacji z enkodera, które skalują wyjścia dekodera

Model Encoder-Decoder z systemem uwagi




- **enkoder** dwukierunkowa sieć RNN, przetwarza całą sekwencję, generuje wektory stanów w kolejnych chwilach $\mathbf{h}_i$
- kontekst uwagi $\mathbf{c}$ jest średnią ważoną stanów, wagi a_i podlegają uczeniu i są unormowane

$$\mathbf{c} = \sum_{i=0}^T a_i \mathbf{h}_t \quad a_i = \frac{\exp e_i}{\sum_j \exp e_j}$$


- mechanizm uwagi waży wpływ kontekstu w wybranym momencie sekwencji wejściowej
- **dekoder** emuluje przeszukiwanie sekwencji wejściowej podczas transkrypcji



seq2seq z mechanizmem uwagowym




Deep RNN




Wielowarstwowe RNN - kolejne warstwy tworzą hierarchię reprezentacji (Graves, 2013)

Problemy uczenia głębokich sieci RNN

- znikający gradient dla odległych w czasie relacji (zanika wykładniczo z czasem), rozwiązaniem LSTM
- niestabilność uczenia - eksplodujący gradient, rozwiązanie: przycinanie gradientu i regularyzacja
- **gradient clipping** - ograniczenie wartości gradientu dla wszystkich wymiarów w mini-batchu, może zmienić kierunek spadku gradientu
- **norm clipping**: jeśli $\|g\| > \nu$ to $g \leftarrow \frac{g\nu}{\|g\|}$



Long Short-Term Memory



Sepp Hochreiter, Jürgen Schmidhuber, „Long short-term memory”, 1997

LSTM

kandydat nowego stanu

$$\mathbf{z}^t = g(\mathbf{W}_z \mathbf{x}^t + \mathbf{R}_z \mathbf{y}^{t-1} + \mathbf{b}_z)$$

bramka wejściowa

$$\mathbf{i}^t = \sigma(\mathbf{W}_i \mathbf{x}^t + \mathbf{R}_i \mathbf{y}^{t-1} + \mathbf{b}_i)$$

bramka zapominania

$$\mathbf{f}^t = \sigma(\mathbf{W}_f \mathbf{x}^t + \mathbf{R}_f \mathbf{y}^{t-1} + \mathbf{b}_f)$$

stan wewnętrzny


$$\mathbf{c}^t = \mathbf{i}^t \odot \mathbf{z}^t + \mathbf{f}^t \odot \mathbf{c}^{t-1}$$

bramka wyjściowa

$$\mathbf{o}^t = \sigma(\mathbf{W}_o \mathbf{x}^t + \mathbf{R}_o \mathbf{y}^{t-1} + \mathbf{b}_o)$$

sygnał wyjściowy

$$\mathbf{y}^t = \mathbf{o}^t \odot h(\mathbf{c}^t)$$



Sepp Hochreiter, Jürgen Schmidhuber, „Long short-term memory”, 1997

LSTM


- LSTM niweluje wpływ zanikania gradientu, dzięki czemu pozwala mapować odległe w czasie relacje
- wprowadza dodatkową wewnętrzną jednostkę stanu $\mathbf{c}$
- stan $\mathbf{c}^t$ zależy w sposób liniowy od stanu poprzedniego $\mathbf{c}^{t-1}$ (liniowa rekurencja), więc nawet przy bardzo długich rekurencjach gradient ma szansę nie zaniknąć (*long-term memory*)
- iloczyn Hadamarda $\mathbf{x} \odot \sigma(\mathbf{y})$ (po współrzędnych), realizacja bramki wyłączającej/włączającej sygnał $\mathbf{x}$
- bramki wejściowa, wyjściowa i bramka zapominania sterują zapamiętywanymi informacjami, zależą od sygnału wejściowego i stanu poprzedniego
- funkcja różniczkowalna - można uczyć metodami spadku gradientu i wsteczną propagacją

LSTM

- bramka wejściowa ma wpływ na to jaki sygnał zostanie zapisany w jednostce stanu $\mathbf{c}$
- bramka zapominania steruje wpływem poprzedniego stanu $\mathbf{c}^{t-1}$ na obecny stan $\mathbf{c}^t$
- bramka wejściowa i zapominania wpływają na to co umieszczane jest i co jest usuwane ze stanu
- bramka wyjściowa steruje ilością informacji przepływającą ze stanu wewnętrznego do wyjścia jednostki, pozwala np. zachować na później informacje, które w tym momencie nie są istotne

Gated Recurrent Unit

- GRU (Kyunghyun Cho et al., 2014) brak jednostki wewnętrznej c i bramki wyjściowej
- bramki: resetu r_t i aktualizacji z_t
- mniej parametrów względem LSTM, porównywalna jakość wyników dla wielu problemów



Źródło: https://en.wikipedia.org/wiki/Recurrent_neural_network


Gated Recurrent Unit

$$\mathbf{z}^t = \sigma(\mathbf{W}_z \mathbf{x}^t + \mathbf{U}_z \mathbf{h}^{t-1} + \mathbf{b}_z)$$

$$\mathbf{r}^t = \sigma(\mathbf{W}_r \mathbf{x}^t + \mathbf{U}_r \mathbf{h}^{t-1} + \mathbf{b}_r)$$

$$\tilde{\mathbf{h}}^t = \tanh(\mathbf{W}_h \mathbf{x}^t + \mathbf{U}_h (\mathbf{r}^t \circ \mathbf{h}^{t-1}) + \mathbf{b}_h)$$

$$\mathbf{h}^t = (1 - \mathbf{z}^t) \circ \mathbf{h}^{t-1} + \mathbf{z}^t \circ \tilde{\mathbf{h}}^t$$




- stan proponowany $\tilde{\mathbf{h}}^t$, dla $\mathbf{r}^t = 0$ sprowadza się do warstwy MLP
- bramka aktualizacji $\mathbf{z}^t$ określa stopień wpływu poprzedniego stanu $\mathbf{h}^{t-1}$ oraz obecnego stanu proponowanego $\tilde{\mathbf{h}}^t$
- bramka resetu odpowiada za relacje krótkie w czasie a bramka aktualizacji - za długie

Connectionist Temporal Classification

- CTC to metoda modelowania sekwencji oraz nazwa funkcji kosztu, znajduje zastosowanie, gdy sekwencja wejściowa $\mathbf{x}_1, \dots, \mathbf{x}_T$ nie posiada dostępnego dopasowania ramek (*alignementu*) z sygnałem wyjściowym $\mathbf{y}_1, \dots, \mathbf{y}_K$. Długość sekwencji wejściowej T jest dłuższa od sekwencji wyjściowej ($T > K$), np. transkrypcja tekstu na podstawie nagrań audio
- wyjście softmax uzupełnione o dodatkową etykietę 'blank'
 $\mathcal{L}' = \mathcal{L} \cup \{blank\}$
- prawdopodobieństwo $P(\mathbf{y}'|\mathbf{x})$ zaobserwowania sekwencji etykiet (ścieżki) $\mathbf{y}'$ o długości T

$$P(\mathbf{y}'|\mathbf{x}) = \prod_{t=1}^T P(y'_t|\mathbf{x})$$



Connectionist Temporal Classification

CTC poszukuje sekwencji etykiet o największej wiarygodności $P(\mathbf{y}|\mathbf{x})$ marginalizując po wszystkich możliwych ścieżkach $\mathbf{y}'$ z blankiem

$$p(\mathbf{y}|\mathbf{x}) = \sum_{\mathbf{y}' \in \mathcal{M}^{-1}(\mathbf{y})} P(\mathbf{y}'|\mathbf{x})$$

gdzie $\mathcal{M}$ mapuje sekwencję etykiet o długości T do sekwencji krótszej poprzez usunięcie wszystkich blanków i powtarzających się etykiet, np.: $\mathcal{M}(a - ab -) = \mathcal{M}(-aa - -abb) = aab$

Funkcja kosztu

$$L = - \sum \log p(\mathbf{y}|\mathbf{x})$$


Graves, A., Fernández, S., Gomez, F., Schmidhuber, J., Connectionist temporal classification: labeling unsegmented sequence data with recurrent neural networks. 2006.

Connectionist Temporal Classification (CTC)


Deep Speech - CTC

No alignment needed!

$$\begin{array}{c} P(_ _ \text{TH} _ _ _ _ \text{E} _ _ _ _ \text{C} _ _ \text{AAA} _ _ \text{TT} _ _ _) \\ + \\ \vdots \\ + \\ P(_ \text{T} _ _ \text{H} _ _ \text{EE} _ _ _ _ \text{C} _ _ \text{AA} _ _ \text{T} _ _ _) \end{array} \quad \left. \vphantom{\begin{array}{c} P(_ _ \text{TH} _ _ _ _ \text{E} _ _ _ _ \text{C} _ _ \text{AAA} _ _ \text{TT} _ _ _) \\ + \\ \vdots \\ + \\ P(_ \text{T} _ _ \text{H} _ _ \text{EE} _ _ _ _ \text{C} _ _ \text{AA} _ _ \text{T} _ _ _) \end{array}} \right\} P(\text{THE} \text{---} \text{CAT} \text{---})$$




Predykcja CTC




- trening z CTC generuje sekwencję pików etykiet (fonemów) przedzielonych etykietą 'blank'
- w treningu z alignementem stosuje się funkcję kosztu CrossEntropy, przesunięcie granic fonemu względem poprawnego dopasowania powoduje błąd nawet gdy fonem jest poprawnie przewidziany
- wyjście CTC może być wykorzystane bezpośrednio (bez konieczności dalszego przetwarzania) do transkrypcji

Automatyczne rozpoznawanie mowy



Źródło grafiki: <https://www.esat.kuleuven.be/psi/spraak/theses/08-09-en/MDT.php>


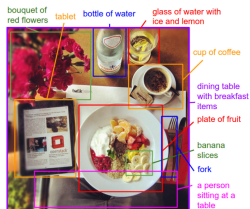
Przykład: Deep Speech 2



Read Speech			
Test set	DS1	DS2	Human
WSJ eval'92	4.94	3.60	5.03
WSJ eval'93	6.94	4.98	8.08
LibriSpeech test-clean	7.89	5.33	5.83
LibriSpeech test-other	21.74	13.25	12.69

Amodei, Dario, et al. "Deep speech 2: End-to-end speech recognition in english and mandarin."(2015).

NeuralTalk - generator opisów zdjęć



Multimodal Recurrent Neural Network NeuralTalk2

Karpathy A., Fei-Fei L. „Deep Visual-Semantic Alignments for Generating Image Descriptions”, 2015