


# RNN (Recurrent neural network)

- Rozwiązywanie problemu wejścia o zmiennej dTugosći
- Główna idea - użycie tej samej macierzy wag  $W$  w wielu krokach



# Bardziej dokładny schemat modelu (językowego)

$x_i$  - słowa, zapisane jako

one-hot-encoding

"word embedding"

[ przedstawienie wektorowe ]

$$e_i = E x_i$$


stan ukryty

$h(0)$  - stan początkowy,  
najczęściej wektor zer

$$h(i) = \sigma(W_h h(i-1) + W_e e(i) + b_1)$$

stan wyjściowe

$$y(i) = \text{softmax}(U h(i) + b_2)$$



# Zalety i wady RNN

## Zalety:

- Wejście może być dowolnie długie
- W teorii w czasie  $t$  może mieć informacje z wielu kroków wcześniej
- Ta sama macierz  $W$  używana jest każdym kroku
  - ilość parametrów do trenowania nie zależy od długości wejścia
  - stałość tego jak traktujemy wejście

## Wady:

- Często rekurencyjne sprawia że obliczenia są długie
- W praktyce w czasie  $t$  model "nie pamięta" zbyt dalekiej przeszłości

# Trenowanie RNN

- Duże wejście → np. Książka, tekst z Wikipedii
- Przepuszczamy przez RNN i obliczamy  $\hat{y}(i)$  dla każdego kroku
- Funkcja kosztu - Entropia krzyżowa

Dla jednego kroku:

$$J(t)(\theta) = CE(y(i) - \hat{y}(i)) = - \sum_{w \in V} y_w(t) \log \hat{y}_w(t) = - \log \hat{y}_{x(t+1)}(t)$$

one-hot

Całkowity koszt:

$$J(\theta) = \frac{1}{T} \sum_{t=0}^T J(t)(\theta) = -\frac{1}{T} \sum_{t=0}^T \log \hat{y}_{x(t+1)}(t)$$


W praktyce nie przetwarzamy przez cały tekst na raz, tylko obliczamy  $J(\theta)$  dla mniejszego podzbioru (np. 16 zdań), obliczamy gradienty, aktualizujemy wagi i kontynuujemy.

# Back propagation

$$\frac{\partial J(t)}{\partial W_n} = \sum_{i=1}^t \frac{\partial J(t)}{\partial W_n}|_i \quad \leftarrow \text{"Backpropagation through time"}$$

- Problem  $\rightarrow$  jak zdanie / tekst jest zbyt długie to trwałośc to dugo!
- rozwiążenie  $\rightarrow$  "ucięta" backpropagacja w czasie, przechodzimy w tym nie przez całe zdanie, ale przez 2 gory ustaloną liczbę kroków, np 20

# Problem znikającego/wybuchającego gradientu



Obliczymy gradient  $J(h)(\theta)$  względem  $h(1)$ , przy pomocy metody Łancucha:

$$\frac{\partial J(h)(\theta)}{\partial h(1)} = \frac{\partial h(2)}{\partial h(1)} \cdot \frac{\partial h(3)}{\partial h(2)} \cdot \frac{\partial h(4)}{\partial h(3)} \cdot \frac{\partial J(h)(\theta)}{\partial h(4)}$$

→ Wielokrotne mnożenie → małe liczby zmaks do 0

→ duże liczby eksplodują

Przykład dla  $\sigma(x) = x$  (funkcja identycznościowa)

$$h(t) = \sigma(w_h h(t-1) + w_x x(t) + b_1)$$

$$\frac{\partial h(t)}{\partial h(t-1)} = \text{diag}(\sigma'(w_h h(t-1) + w_x x(t) + b_1)) w_h = I w_h = w_h$$

↓

$$\frac{\partial J(i)}{\partial h(j)} = \frac{\partial J(i)}{\partial h(i)} \cdot \prod_{j < t \leq i} \frac{\partial h(t)}{\partial h(t-1)} = \frac{\partial J(i)}{\partial h(j)} \cdot (w_h)^l \quad [i-j=l]$$


$\uparrow$  może mieć wykładniczo

dla  $w_h$  t.j.ie wartości własne  $\lambda_1, \dots, \lambda_n < 1$ : [warunek dostateczny alle niekonieczny]

$$\frac{\partial J(i)}{\partial h(j)} (w_h)^l = \sum_{i=1}^n c_i (\lambda_i)^l q_i \approx 0 \text{ dla dużych } l$$

[Dla bardziej skomplikowanych σ zbiega się samo tylko dla  $\lambda_i < \gamma$ ]  
 które zależy od tego jakie wybieramy σ

# Skutki znikającego gradientu



- Wpływ odległego sygnału zniknie bo wtedy wielkości gradientów mogą być zupełnie różne
- Model nie potrafi "przenieść" informacji z dalekiej przeszłości

## Przykład:

"Kiedy Asia chciała wydrukować bilet, okazało się że nie ma tuszu w drukarce. Asia poszła do sklepu kupić toner, był akurat na promocie.

Wprowadziła nowy toner do drukarki i wydrukowała \_\_\_\_"


25 kroków różiny! → zmieniający gradient sprawia, że wpływszane "bilety" z tek. dawnego jest znakomity i nie potrafimy

"zapamiętać" informacji z dalejego przeszłości

# Skutki eksplodującego gradientu

$$\theta^{\text{new}} = \theta^{\text{old}} + \alpha \underbrace{\nabla_{\theta} J(\theta)}_{\text{gradient}}$$

- jak gradient jest zbyt duży, to robimy zbyt duże kroki i biegamy




# Rozwiążenie problemu eksplodującego gradientu

- "zmniejszenie kroku przy zachowaniu kierunku chodzenia"

Pseudokod:

- $\hat{g} \leftarrow \frac{\partial \varepsilon}{\partial \theta}$
- if  $\|\hat{g}\| > \tau$  then  
 $\hat{g} \leftarrow \frac{\tau}{\|\hat{g}\|} \hat{g}$
- end if

# Generowanie tekstu przez RNN



Wartości wylosowania  
 w 1. kroku traktujemy  
 jako 2. element wejścia  
 itd.