

Ασκήσεις μελέτης της 22^{ης} διάλεξης

22.1. Θέλουμε να χρησιμοποιήσουμε το ανατροφοδοτούμενο νευρωνικό δίκτυο (RNN) των διαφανειών 4 και 5, για να αναγνωρίζουμε ονόματα προσώπων, οργανισμών και τοποθεσιών. Χρησιμοποιούμε ετικέτες (κατηγορίες) B-I-O, όπως στην άσκηση 21.1, άρα 7 κατηγορίες (όχι τρεις). Το μέγεθος του λεξιλογίου είναι $|V| = 100.000$. Κάθε ένθεση λέξης (word embedding) είναι ένα διάνυσμα 300 διαστάσεων. Το κρυφό επίπεδο (η κατάσταση του RNN) αποτελείται από 500 νευρώνες, δηλαδή το \vec{h}_i είναι διάνυσμα 500×1 . Ποιες είναι οι διαστάσεις των $E, \vec{e}_i, W^{(h)}, W^{(e)}, W^{(o)}, \vec{o}_i$; Αιτιολογήστε τις απαντήσεις σας.

Απάντηση: Ο πίνακας E περιέχει (ως στήλες) τις ενθέσεις των 100.000 λέξεων του λεξιλογίου. Κάθε ένθεση λέξης είναι διάνυσμα (στήλη) 300 διαστάσεων. Άρα ο E έχει διαστάσεις 300×100.000 .

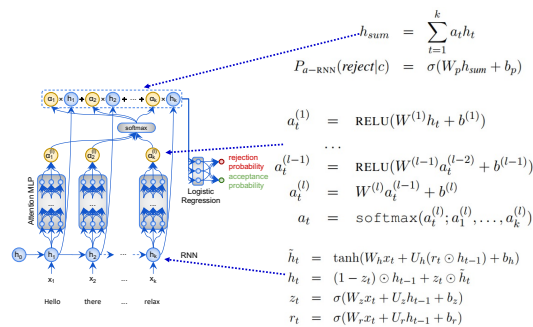
Το διάνυσμα \vec{e}_i είναι η ένθεση (embedding) της i -στής λέξης της εισόδου (π.χ. μιας πρότασης), άρα είναι διαστάσεων 300×1 . Το ίδιο συμπέρασμα προκύπτει και από την παρατήρηση ότι ο πολλαπλασιασμός $E\vec{x}_i$ επιστρέφει την i -στή στήλη του πίνακα E .

Ο πίνακας $W^{(h)}$ έχει διαστάσεις 500×500 , ενώ ο πίνακας $W^{(e)}$ έχει διαστάσεις 500×300 , ώστε τα $W^{(h)}\vec{h}_{i-1}$ και $W^{(e)}\vec{e}_i$ να έχουν τις ίδιες διαστάσεις (500×1), να μπορούν να προστεθούν ($W^{(h)}\vec{h}_{i-1} + W^{(e)}\vec{e}_i$) και η νέα κατάσταση $\vec{h}_i = \tanh(W^{(h)}\vec{h}_{i-1} + W^{(e)}\vec{e}_i)$ να έχει πάλι διαστάσεις 500×1 , όπως η προηγούμενη κατάσταση \vec{h}_{i-1} . Η \tanh εφαρμόζεται σε κάθε στοιχείο του διανύσματος $W^{(h)}\vec{h}_{i-1} + W^{(e)}\vec{e}_i$, χωρίς να αλλάζει τις διαστάσεις του.

Ο πίνακας $W^{(o)}$ έχει διαστάσεις 7×500 , ώστε ο πολλαπλασιασμός $W^{(o)}\vec{h}_i$ να παράγει διάνυσμα 7×1 με έναν πραγματικό αριθμό για κάθε κατηγορία. Η softmax στον υπολογισμό $\vec{o}_i = \text{softmax}(W^{(o)}\vec{h}_i)$ μετατρέπει τους αριθμούς αυτούς σε κατανομή πιθανότητας (μία πιθανότητα για κάθε κατηγορία), χωρίς να αλλάζει τις διαστάσεις του $W^{(o)}\vec{h}_i$. Επομένως το \vec{o}_i έχει και αυτό διαστάσεις 7×1 .

22.2. (α) Στο νευρωνικό δίκτυο των διαφανειών 19–21 («RNN with deep self-attention»), οι **καταστάσεις** h_1, h_2, \dots, h_k του RNN είναι διανύσματα **128 διαστάσεων** (η κάθε μία). Τα **κρυφά επίπεδα** (1), ..., ($l - 1$) του Attention MLP έχουν **64 νευρώνες** το καθένα και οι έξοδοι των κρυφών επιπέδων είναι $a_t^{(1)}, \dots, a_t^{(l-1)}$. Το **επίπεδο εξόδου** του Attention MLP έχει **έναν μόνο νευρώνα** με έξοδο $a_t^{(l)}$. **Τι διαστάσεις θα έχουν οι πίνακες $W^{(1)}, W^{(2)}, \dots, W^{(l)}$ και τα διανύσματα $b^{(1)}, b^{(2)}, \dots, b^{(l)}$; Αιτιολογήστε σύντομα τις απαντήσεις σας.**

RNN with deep self-attention



J. Pavlopoulos, P. Malakasiotis and I. Androutsopoulos, "Deeper Attention to Abusive User Content Moderation", EMNLP 2017, <http://nlp.cs.aueb.gr/pubs/emnlp2017.pdf>

Διαστάσεις των $W^{(1)}, W^{(2)}, \dots, W^{(l)}$ και αιτιολόγηση:

Απάντηση: Ο πίνακας $W^{(1)}$ θα έχει διαστάσεις 64×128 , ώστε να μετατρέπει το κάθε διάνυσμα h_1, h_2, \dots, h_k (τις καταστάσεις του RNN), που έχουν διαστάσεις 128×1 το

καθένα, σε διανύσματα 64×1 , δηλαδή σε διανύσματα με τόσες συνιστώσες όσοι οι νευρώνες του επιπέδου (1) του MLP. Το κάθε παραγόμενο διάνυσμα 64×1 είναι η έξοδος $a_t^{(1)}$ (για $t = 1, \dots, k$) του επιπέδου (1) του MLP, όταν το MLP εφαρμόζεται στην αντίστοιχη κατάσταση h_t του RNN.

Οι πίνακες $W^{(2)}, \dots, W^{(l-1)}$ θα έχουν διαστάσεις 64×64 , ώστε να μετατρέπουν τα διανύσματα διαστάσεων 64×1 που παράγει ο $W^{(1)}$ σε διανύσματα πάλι 64×1 , δηλαδή σε διανύσματα με τόσες διαστάσεις όσοι οι νευρώνες των επιπέδων (2), ..., $(l-1)$ του MLP. Το κάθε παραγόμενο διάνυσμα 64×1 είναι η έξοδος $a_t^{(2)}, \dots, a_t^{(l-1)}$ του επιπέδου (2), ..., $(l-1)$, αντίστοιχα, του MLP.

Ο πίνακας $W^{(l)}$ θα έχει διαστάσεις 1×64 (δηλαδή θα είναι ένα διάνυσμα-γραμμή), ώστε να μετατρέπει το κάθε διάνυσμα 64×1 που παράγει ο $W^{(l-1)}$ σε έναν πραγματικό αριθμό (εκφυλισμένο διάνυσμα 1×1), δηλαδή να παράγει τους πραγματικούς αριθμούς $a_1^{(l)}, \dots, a_k^{(l)}$ της διαφάνειας 21.

Διαστάσεις των $b^{(1)}, b^{(2)}, \dots, b^{(l)}$ και αιτιολόγηση:

Απάντηση: Το $b^{(1)}$ θα είναι ένα διάνυσμα 64×1 , ώστε να προστίθεται στο διάνυσμα 64×1 που παράγει ο πολλαπλασιασμός $W^{(1)}h_t$ (για $t = 1, \dots, k$) και να παράγει το διάνυσμα $a_t^{(1)}$, που είναι επίσης διαστάσεων 64×1 . (Κάθε συνάρτηση ενεργοποίησης, εδώ η ReLU, δεν αλλάζει τις διαστάσεις του διανύσματος στο οποίο εφαρμόζεται, απλά εφαρμόζεται σε κάθε στοιχείο του διανύσματος.)

Ομοίως τα $b^{(2)}, \dots, b^{(l-1)}$ θα είναι το καθένα ένα διάνυσμα 64×1 , ώστε να προστίθεται στο διάνυσμα 64×1 που παράγει ο πολλαπλασιασμός $W^{(2)}a_t^{(1)}, \dots, W^{(l-1)}a_t^{(l-2)}$ αντίστοιχα (για $t = 1, \dots, k$) και να παράγονται τα διανύσματα $a_t^{(2)}, \dots, a_t^{(l-1)}$, αντίστοιχα, που είναι επίσης διαστάσεων 64×1 το καθένα.

Το $b^{(l)}$ θα είναι ένας πραγματικός αριθμός (εκφυλισμένο διάνυσμα 1×1), ώστε να προστίθεται στον πραγματικό αριθμό που παράγει ο πολλαπλασιασμός $W^{(l)}a_t^{(l-1)}$ (για $t = 1, \dots, k$) και να παράγονται οι πραγματικοί αριθμοί $a_1^{(l)}, \dots, a_k^{(l)}$ της διαφάνειας 21.

(β) Θέλουμε να χρησιμοποιήσουμε το νευρωνικό δίκτυο των διαφανειών 19–21, τώρα για να κατατάξουμε tweets (που αναφέρονται σε ένα προϊόν) στις κατηγορίες c_1 (θετική γνώμη), c_2 (αρνητική γνώμη), c_3 (ουδέτερη γνώμη), c_4 (θετική και αρνητική γνώμη μαζί). Κάθε tweet θα κατατάσσεται σε ακριβώς μία κατηγορία. Αντικαθιστούμε τον τύπο $P_{a-RNN}(\text{reject}|c) = \sigma(W_p h_{sum} + b_p)$ με τον παρακάτω τύπο που θα πρέπει να παράγει (στο αριστερό του μέρος) ένα διάνυσμα $p \in \mathbb{R}^4$, το οποίο θα περιέχει τις πιθανότητες (κατά το νευρωνικό δίκτυο) το εισερχόμενο tweet να ανήκει σε κάθε μία από τις τέσσερις κατηγορίες. Συμπληρώστε το δεξί μέρος του τύπου, αναφέροντας τις διαστάσεις κάθε πίνακα και διανύσματος που θα εμφανίζεται στο δεξί μέρος του τύπου. Αιτιολογήστε σύντομα την απάντησή σας.

Νέος τύπος:

$$p = \underline{\hspace{10cm}} \in \mathbb{R}^4$$

Απάντηση:

Ο νέος τύπος θα είναι ο ακόλουθος.

$$p = \text{softmax}(W_p h_{sum} + b_p)$$

Ο πίνακας W_p θα έχει διαστάσεις 4×128 , ώστε να μετατρέπει το διάνυσμα h_{sum} (το οποίο έχει διαστάσεις 128×1 , αφού είναι άθροισμα των καταστάσεων του RNN) σε διάνυσμα τεσσάρων πραγματικών αριθμών, τους οποίους κατόπιν η softmax μετατρέπει σε κατανομή πιθανότητας (τέσσερις αριθμούς, τον καθένα μεταξύ 0 και 1, με άθροισμα 1).

Το b_p θα είναι διάνυσμα 4×1 , ώστε να προστίθεται στο διάνυσμα 4×1 που παράγει ο πολλαπλασιασμός $W_p h_{sum}$.

22.3. Write down the equations for a modified version of the “RNN with deep self-attention” (slides 19–21), where the uni-directional RNN with GRU cells is replaced by a stacked bi-directional RNN with GRU cells. Use the notation $\text{GRU}(h_{t-1}, \tau_t)$ to denote the new state of a GRU cell with previous state h_{t-1} and input τ_t .

Answer: At the first layer of the GRU RNN, we have (for $t = 1, \dots, k$):

$$\vec{h}_t^{(1)} = \text{GRU}(\vec{h}_{t-1}^{(1)}, x_t)$$

$$\overleftarrow{h}_t^{(1)} = \text{GRU}(\overleftarrow{h}_{t+1}^{(1)}, x_t)$$

$$h_t^{(1)} = [\vec{h}_t^{(1)}; \overleftarrow{h}_t^{(1)}]$$

where $\vec{h}_0^{(1)}$ is the initial state of the left-to-right GRU RNN of the first layer, $\overleftarrow{h}_{k+1}^{(1)}$ is the initial state of the right-to-left GRU RNN of the first layer, ‘;’ denotes concatenation, and x_1, \dots, x_k are the word embeddings of the input word sequence.

Similarly, at the m -th layer of the GRU RNN:

$$\vec{h}_t^{(m)} = \text{GRU}(\vec{h}_{t-1}^{(m)}, h_t^{(m-1)})$$

$$\overleftarrow{h}_t^{(m)} = \text{GRU}(\overleftarrow{h}_{t+1}^{(m)}, h_t^{(m-1)})$$

$$h_t^{(m)} = [\vec{h}_t^{(m)}; \overleftarrow{h}_t^{(m)}]$$

The other equations remain as on slide 21.

22.4. Modify the equations of the neural network of the previous exercise to support *multi-label classification*, i.e., cases where the same text (e.g., tweet) may belong in multiple classes (labels). As a twist, use a separate *label-specific self-attention-head* for each class, which will produce a different distribution of attention scores $a_{c,1}, \dots, a_{c,k}$ (where k is again the length of the input text, counted in words) and a different $h_{sum,c}$ for each class c . Feed the $h_{sum,c}$ of each class c to a separate (different per class) dense layer with a sigmoid to produce the probability that the input text should be assigned class c .

Answer: Let \mathcal{C} be the set of possible classes (labels). We modify the self-attention MLP of slides 19–21, so that $a_t^{(l)} \in \mathbb{R}^{|\mathcal{C}|}$, i.e., $a_t^{(l)}$ is now a vector (not a scalar) containing $|\mathcal{C}|$ attention scores $a_{1,t}, \dots, a_{|\mathcal{C}|,t}$ for word position t , one for each possible class. To achieve this,

we modify the dimensions of $W^{(l)}$ and $b^{(l)}$ of layer l of the self-attention MLP, to be $|C| \times d$ and $|C|$, respectively, where d is the dimensionality of the previous layer $a_t^{(l-1)}$.

The softmax of slides 19–21 is now applied *label-wise*, on the attention scores of a particular class, i.e., for each possible class c :

$$a_{c,t} = \text{softmax}\left(a_{c,t}^{(l)}; a_{c,1}^{(l)}, \dots, a_{c,k}^{(l)}\right) = \frac{\exp(a_{c,t}^{(l)})}{\sum_{t'=1}^k \exp(a_{c,t'}^{(l)})}$$

We form a separate weighted sum $h_{sum,c}$ for each possible class c :

$$h_{sum,c} = \sum_{t=1}^k a_{c,t} h_t^{(M)}$$

where M is the number of stacked GRU RNNs of the previous exercise, and we feed each $h_{sum,c}$ to a separate dense layer (a transposed vector really, why?) $W_{p,c}$ with bias term $b_{p,c}$ per class c , to compute the probability of the corresponding class:

$$P(c|x_1, \dots, x_k) = \sigma(W_{p,c} h_{sum,c} + b_{p,c})$$

The other equations of the neural network remain as in the previous exercise.

(b) Couldn't we use a single (shared) self-attention-head (and a single h_{sum}) for all the classes? What would change in that case in the equations above? What is the advantage of using a separate *label-specific* self-attention-head for each class?