ЗАСТОСУВАННЯ МАШИННОГО НАВЧАННЯ ДЛЯ РОЗУМІННЯ І ВИКОРИСТАННЯ ТЕКСТУ. МЕТОДИ WORD2VEC

ВИКОНАВ:
СТУДЕНТ ГРУПИ МПМ-1
СТЕПАНЮК Д. А.

НАУКОВИЙ КЕРІВНИК:
БОГАТИРЬОВ О. О.

СЛОВА-ВЕКТОРИ

- Слова-вектори (word vectors) - це чисельні уявлення слів, що зберігають семантичний зв'язок між ними. Наприклад, для вектора cat (кішка) одним з найбільш близьких буде слово dog (собака). Однак векторне подання слова pencil (олівець) буде досить сильно відрізнятися від вектора cat.

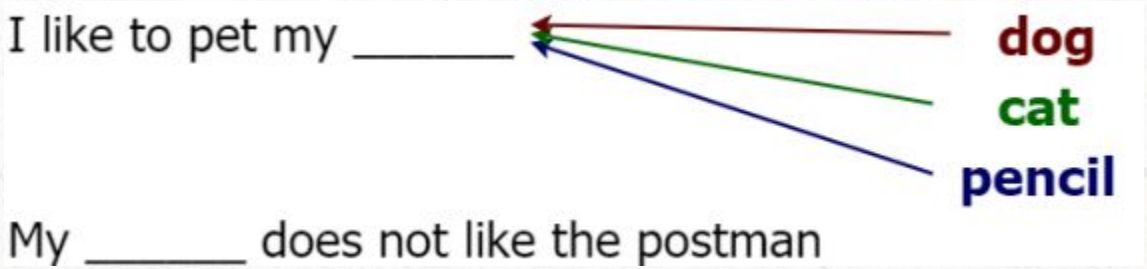

ЗАСТОСУВАННЯ WORD2VEC

- Векторні уявлення слів використовуються в багатьох областях:
- Моделювання мов;
- Чат-боти;
- Машинний переклад;
- Питально-відповідні системи;

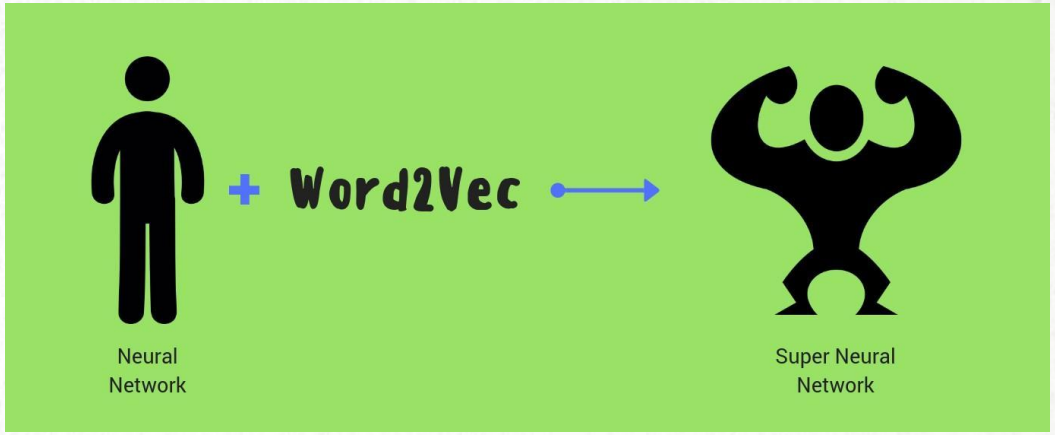

ПРОЦЕС СТОВРЕННЯ ВЕКТОРІВ СЛІВ

1. Створити кортежі даних в форматі [вхідне слово, вихідне слово]
2. Створити модель, яка на вхід і вихід отримує one-hot вектори;
3. Визначити функцію втрат, яка вгадує вірне слово, щоб оптимізувати модель;
4. Визначити якість моделі, переконавшись, що схожі слова мають схожі векторні уявлення.

ЗАГАЛЬНА МОДЕЛЬ

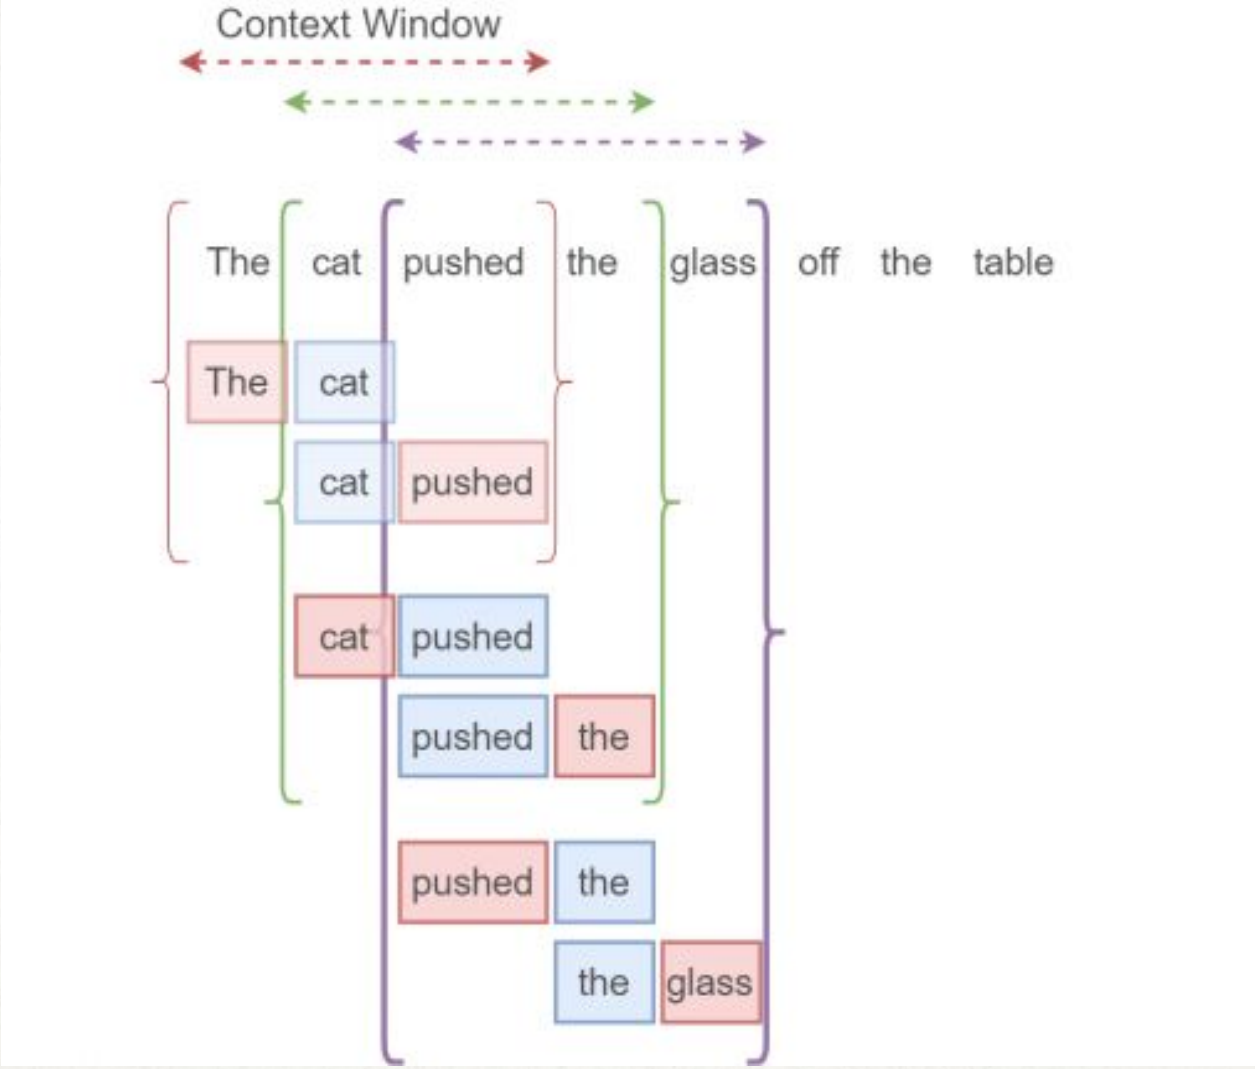

НЕОБХІДНІ ДАНІ ДЛЯ РОБОТИ АЛГОРИТМУ

- набір вхідних one-hot векторів;
- набір вихідних one-hot векторів (після навчання);
- embedding layer;
- нейромережа.

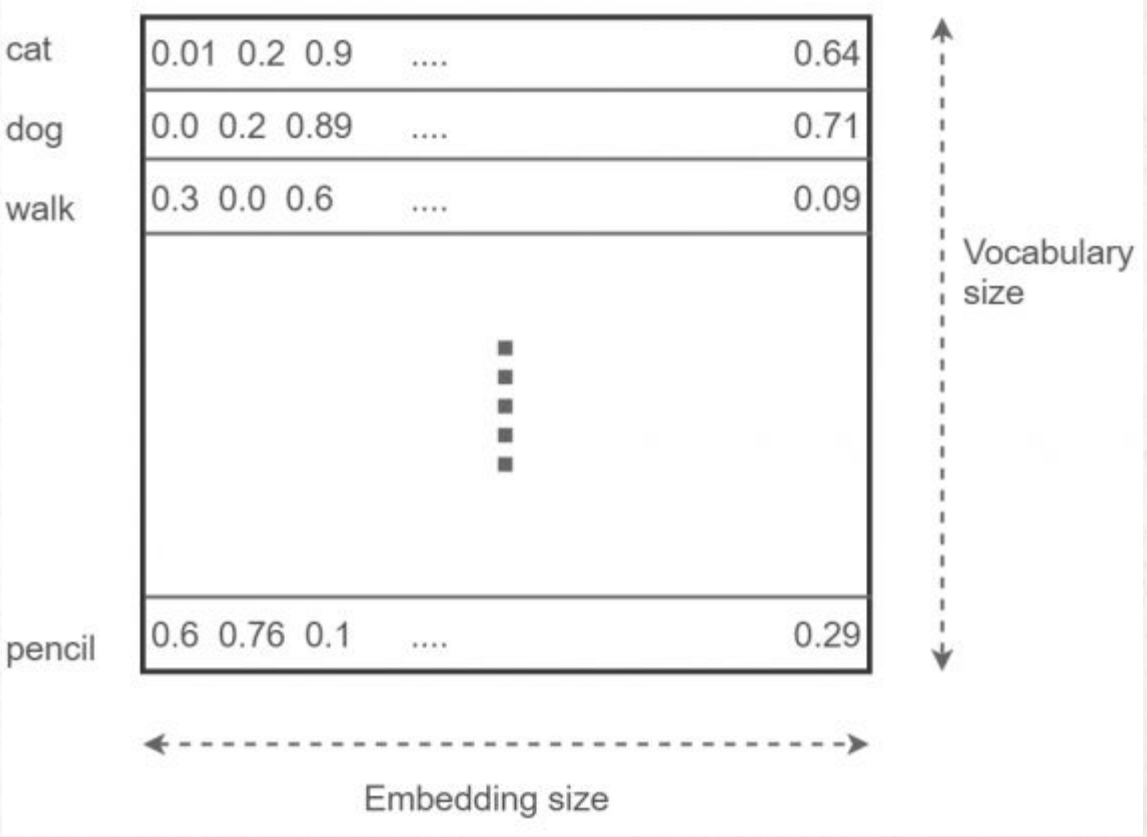

ЗАГАЛЬНА КАРТИНА АЛГОРИТМУ

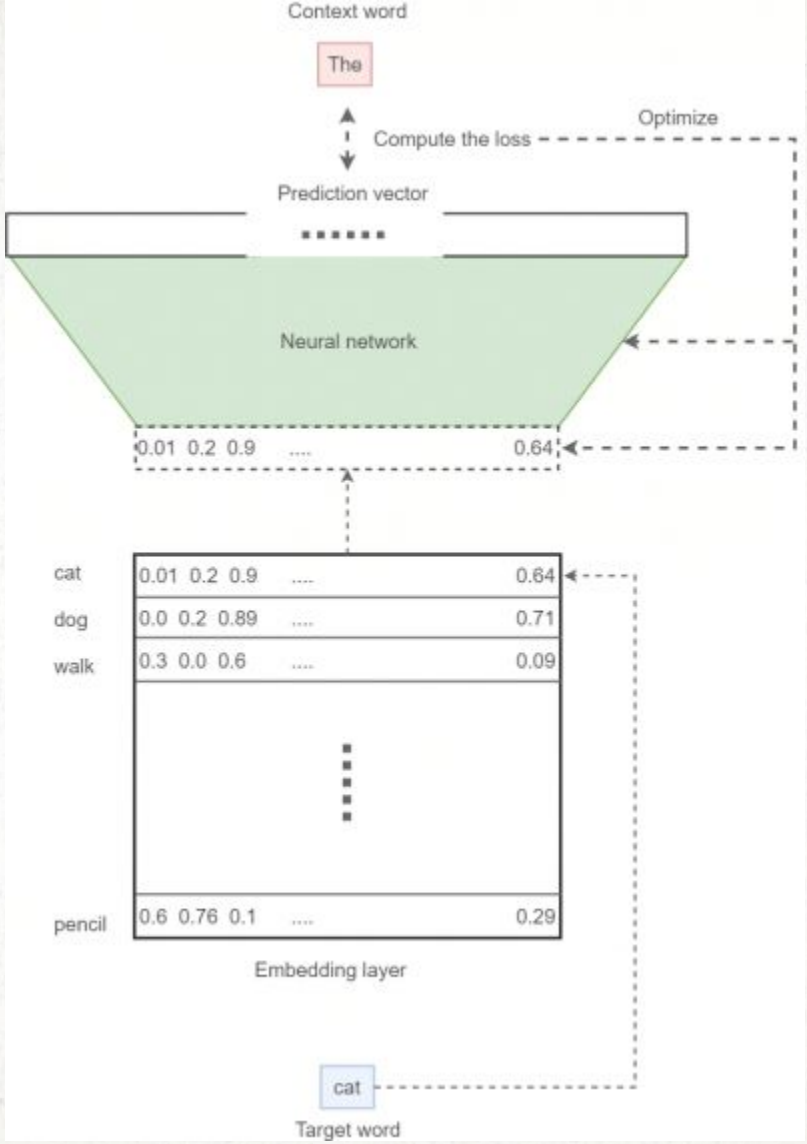

ФУНКЦІЯ ВТРАТ

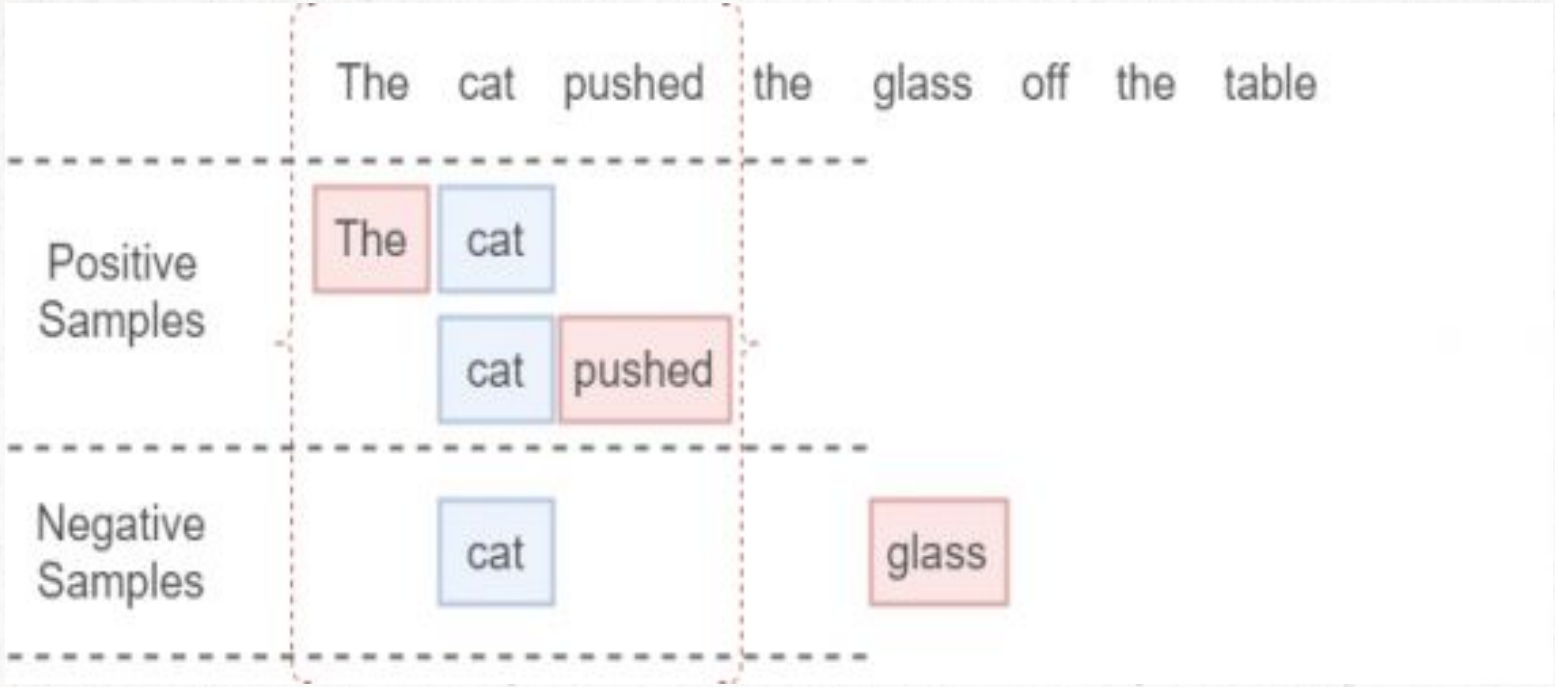

ЗАПУСК АЛГОРИТМУ

```
num_steps = 250001

session = tf.InteractiveSession()

# Initialize the variables in the
graph

tf.global_variables_initializer().run()

print('Initialized')

average_loss = 0

for step in range(num_steps):
batch_data, batch_labels = generate_batch( batch_size,
window_size)
 feed_dict = {train_dataset : batch_data, train_labels :
batch_labels}
   _, l = session.run([optimizer, loss], feed_dict=feed_dict)
if (step+1) % 5000 == 0:
    if step > 0:
     average_loss = average_loss / 5000

    print('Average loss at step %d: %f' % (step+1,
average_loss))
    average_loss = 0
```

РЕЗУЛЬТАТИ РОБОТИ АЛГОРИТМУ

Average loss at step 225000: 2.410598
Average loss at step 230000: 2.410446
Average loss at step 235000: 2.414872
Average loss at step 240000: 2.412652
Average loss at step 245000: 2.420230
Average loss at step 250000: 2.408468

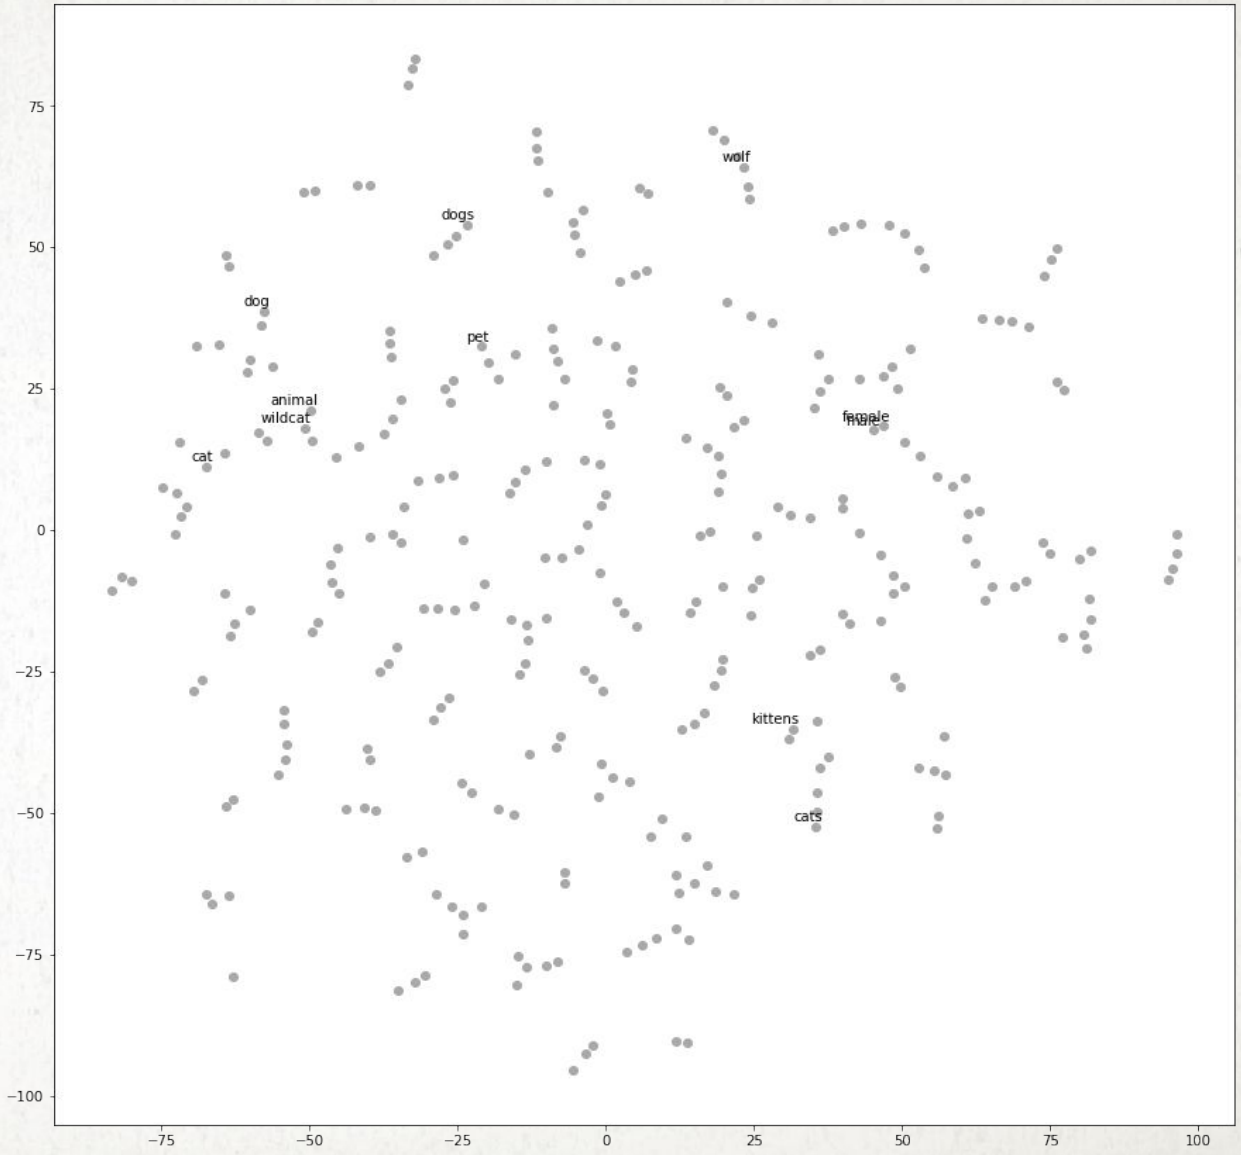

ДЯКУЮ ЗА УВАГУ!