

ДОДАТОК А

Графічний матеріал атестаційної роботи

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
ХАРКІВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ РАДІОЕЛЕКТРОНІКИ
ФАКУЛЬТЕТ КОМП'ЮТЕРНОЇ ІНЖЕНЕРІЇ ТА УПРАВЛІННЯ
КАФЕДРА КІТС

Модель згорткової мережі для мультіагентної кооперації

Магістрант гр. КІТм-19-1
Науковий керівник

Тельний М.А.
проф. Аксак Н. Г.

Харків 2020

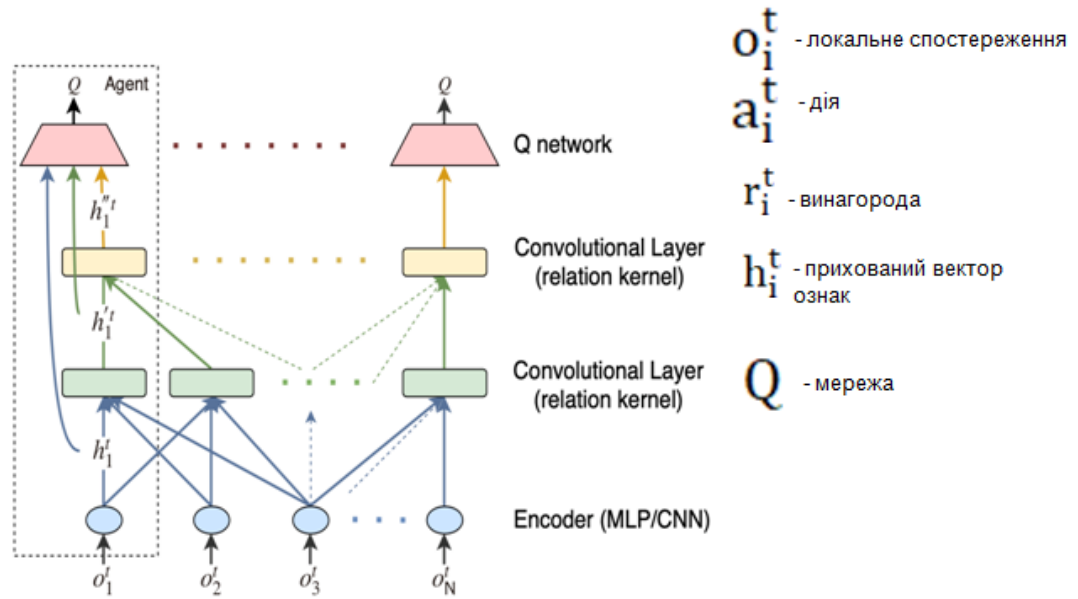
Мета роботи

Метою атестаційної роботи є розробка моделі згорткової мережі для мультіагентної кооперації.

Для досягнення даної мети необхідно вирішити наступні задачі:

- проаналізувати та розглянути сучасні роботи та публікації для визначення актуальності роботи;
- визначити сфери використання, переваги, нелодіки та перспективи розвитку нейронних мереж та мультіагентних систем;
- розглянути сучасні методи розробки нейронних мереж;
- провести аналіз моделей мультіагентної кооперації;
- реалізувати модель згорткової мережі для мультіагентної кооперації.

Структура DGN



3

Згортка графів

На кожному кроці кортеж

$$(O, A, O', R, C)$$

зберігається у буфері відтворення B .

де $O = \{o_1, \dots, o_N\}$, $A = \{a_1, \dots, a_N\}$, $O' = \{o'_1, \dots, o'_N\}$, $R = \{r_1, \dots, r_N\}$, $C = \{C_1, \dots, C_N\}$.

Потім випадково відбирається міні-партію зразків s з буфера B і мінімізуються втрати

$$L(\theta) = \frac{1}{S} \sum_s \frac{1}{N} \sum_{i=1}^N (y_i - Q(O_i, a_i; \theta))^2 \quad (1)$$

де $y_i = r_i + \gamma \max_{a'} Q(O_i, a'; \theta')$. $O_i \subset O$ позначає сукупність спостережень усіх агентів у рецептивних полях i , γ - коефіцієнт знижки, модель параметризована по θ .

Відношення між i та $j \in E$, обчислюється як

$$a_{ij}^m = \frac{\exp(\tau \cdot W_q^m h_i \cdot (W_k^m h_j)^T)}{\sum_{e \in E_i} \exp(\tau \cdot W_q^m h_i \cdot (W_k^m h_e)^T)} \quad (2)$$

де τ - коефіцієнт масштабування.

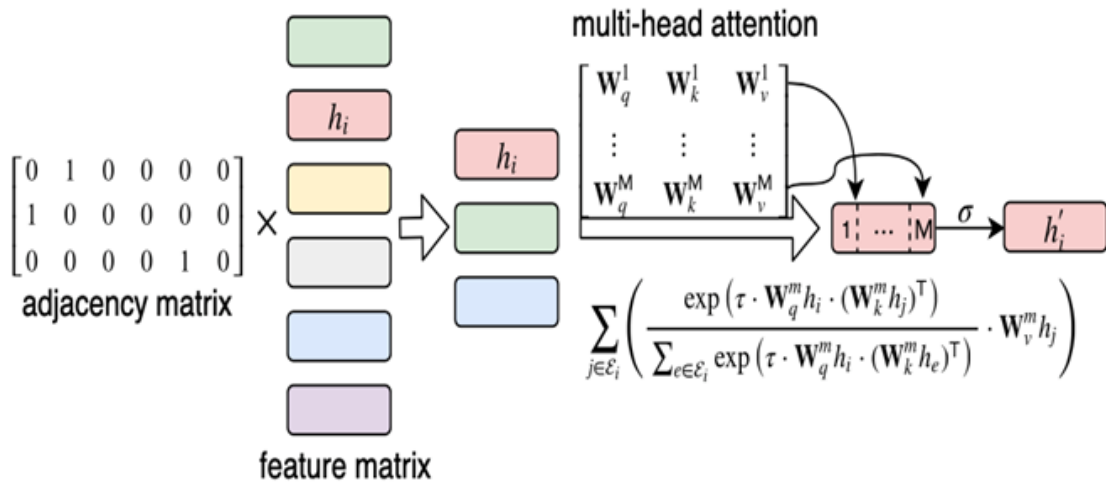
Вихід згорткового шару

є

$$h'_i = \sigma(\text{Concat}[\sum_{j \in E_i} a_{ij}^m W_v^m h_j, \forall m \in M]) \quad (3)$$

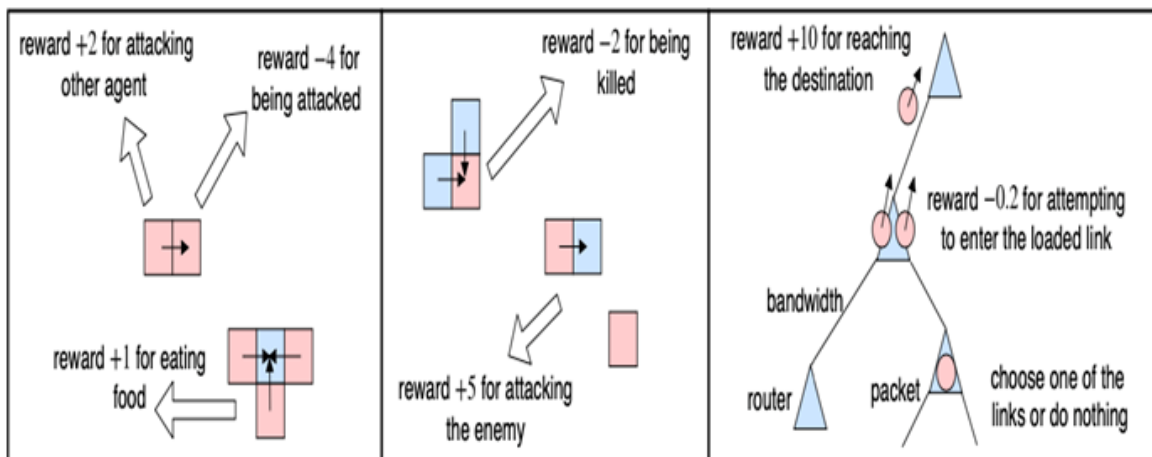
4

Обчислення згорткового шару



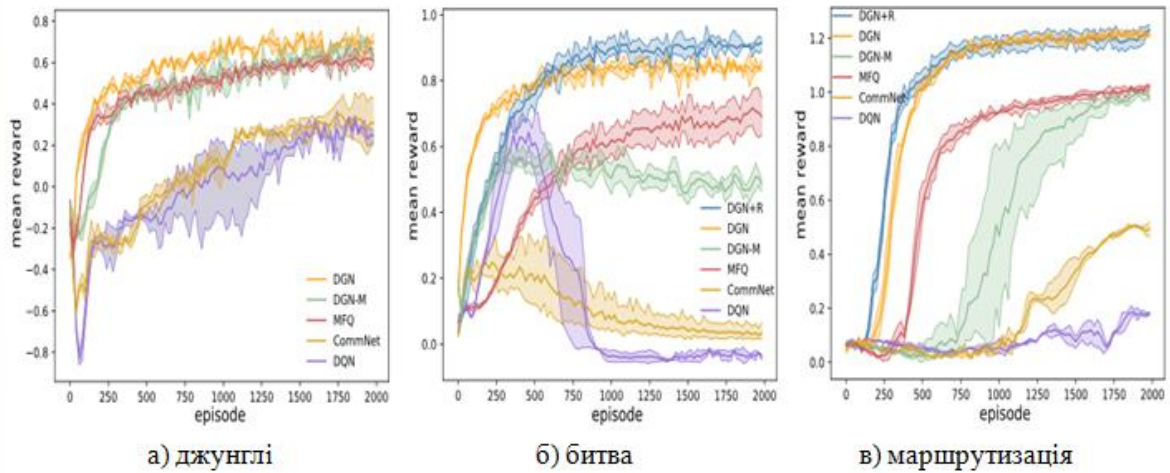
5

Ілюстрація експериментальних сценаріїв



6

Навчання моделі з точки зору середньої винагороди



7

Результати експериментів

Таблиця.1 – Ілюстрація середньої винагороди

(N,L)		DGN	DGN-M	MFQ	CommNet	DQN
(20,12)	meanreward	0.70	0.66	0.62	0.30	0.24
	#attacks	0.91	1.89	2.74	5.44	7.35
(50,12)	meanreward	0.67	0.63	0.57	0.27	0.20
	#attacks	0.91	1.88	3.13	6.35	9.02

Таблиця2 – Середня винагорода, вбивства, смерті та коефіцієнт вбивства-смерті

	DGN+R	DGN	DGN-M	MFQ	CommNet	DQN
meanreward	0.91	0.84	0.50	0.70	0.03	-0.03
#kills	220	208	121	193	7	2
#deaths	97	101	84	92	27	74
Kill-death ratio	2.27	2.06	1.44	2.09	0.26	0.03

Таблиця3 – Середня винагорода, середня затримка пакетів даних та пропускна здатність

(N,L)		Floyd	Floyd with BL	DGN+R
(20,20)	mean reward delay throughput			1.23
		6.3	8.7	8.0
		3.17	2.30	2.50
(40,20)	mean reward delay throughput			0.86
		6.3	13.7	9.8
		6.34	2.91	4.08
(40,20)retrained	mean reward delay throughput			0.94
		6.3	13.7	10.2
		6.34	2.91	3.92

8

Результати експериментів

Таблиця.4 – Середня винагорода, середня затримка пакетів даних та пропускна здатність

(N,L)		DGN	DGN-M	MFQ	CommNet	DQN
(20,20)	mean	1.21	0.99	1.02	0.49	0.18
	reward	8.1	9.8	9.4	18.6	46.7
	delay	2.47	2.04	2.13	1.08	0.43
	throughput					
(40,20)	mean	0.83	0.70	0.78	0.39	0.12
	reward	10.0	12.7	11.8	23.5	83.6
	delay	4.00	3.15	3.39	1.70	0.49
	throughput					
(40,20) retrained	mean	0.90	0.78	0.76	0.35	0.05
	reward	10.5	12.2	12.8	21.2	112.2
	delay	3.81	3.27	3.12	1.86	0.35
	throughput					

9

Висновки

- В ході виконання магістерської роботи був зроблений обзор та аналіз сучасних робіт та публікацій за тематикою згоркових нейронних мереж в мультиагентній кооперації та в результаті проведенних досліджень була розроблена модель згорткової мережі для мультиагентної кооперації.
- Також були розглянуті сучасні методи розробки нейронних мереж, проведений аналіз моделей мультиагентної кооперації.
- Розроблена модель на мові Python за допомогою інструментів TensorFlow та Keras. З їх допомогою довелося створити модель, яка розпізнає зображення з точністю 83%.

13

ДОДАТОК Б

Реалізація моделі

```
import numpy
from keras.models import Sequential
from keras.layers import Dense, Dropout, Flatten, BatchNormalization,
Activation
from keras.constraints import maxnorm
from keras.layers.convolutional import Conv2D, MaxPooling2D
from keras.utils import np_utils
from keras.datasets import cifar10

# fix random seed for reproducibility
seed = 21
numpy.random.seed(seed)

# load data
(X_train, y_train), (X_test, y_test) = cifar10.load_data()

# normalize inputs from 0-255 to 0.0-1.0
X_train = X_train.astype('float32')
X_test = X_test.astype('float32')
X_train = X_train / 255.0
X_test = X_test / 255.0

# one hot encode outputs
y_train = np_utils.to_categorical(y_train)
y_test = np_utils.to_categorical(y_test)
num_classes = y_test.shape[1]

# Create the model
model = Sequential()

model.add(Conv2D(32, (3, 3), input_shape=X_train.shape[1:], padding='same'))
model.add(Activation('relu'))
model.add(Dropout(0.2))
model.add(BatchNormalization())

model.add(Conv2D(64, (3, 3), padding='same'))
model.add(Activation('relu'))
model.add(MaxPooling2D(pool_size=(2, 2)))
model.add(Dropout(0.2))
model.add(BatchNormalization())

model.add(Conv2D(64, (3, 3), padding='same'))
model.add(Activation('relu'))
model.add(MaxPooling2D(pool_size=(2, 2)))
model.add(Dropout(0.2))
model.add(BatchNormalization())

model.add(Conv2D(128, (3, 3), padding='same'))
model.add(Activation('relu'))
model.add(Dropout(0.2))
model.add(BatchNormalization())

model.add(Flatten())
model.add(Dropout(0.2))
```

```
model.add(Dense(256, kernel_constraint=maxnorm(3)))
model.add(Activation('relu'))
model.add(Dropout(0.2))
model.add(BatchNormalization())
model.add(Dense(128, kernel_constraint=maxnorm(3)))
model.add(Activation('relu'))
model.add(Dropout(0.2))
model.add(BatchNormalization())
model.add(Dense(num_classes))
model.add(Activation('softmax'))

epochs = 25
optimizer = 'Adam'

model.compile(loss='categorical_crossentropy', optimizer=optimizer,
metrics=['accuracy'])

print(model.summary())

model.fit(X_train, y_train, validation_data=(X_test, y_test), epochs=epochs,
batch_size=64)

# Final evaluation of the model

scores = model.evaluate(X_test, y_test, verbose=0)
print("Accuracy: %.2f%%" % (scores[1]*100))
```

ДОДАТОК В

Результат друку

```

Results:
Layer (type) Output Shape Param #
=====
conv2d_1 (Conv2D) (None, 32, 32, 32) 896
-----
activation_1 (Activation) (None, 32, 32, 32) 0
-----
dropout_1 (Dropout) (None, 32, 32, 32) 0
-----
batch_normalization_1 (Batch Normalization) (None, 32, 32, 32) 128
-----
conv2d_2 (Conv2D) (None, 32, 32, 64) 18496
-----
activation_2 (Activation) (None, 32, 32, 64) 0
-----
max_pooling2d_1 (MaxPooling2D) (None, 16, 16, 64) 0
-----
dropout_2 (Dropout) (None, 16, 16, 64) 0
-----
batch_normalization_2 (Batch Normalization) (None, 16, 16, 64) 256
-----
conv2d_3 (Conv2D) (None, 16, 16, 64) 36928
-----
activation_3 (Activation) (None, 16, 16, 64) 0
-----
max_pooling2d_2 (MaxPooling2D) (None, 8, 8, 64) 0
-----
dropout_3 (Dropout) (None, 8, 8, 64) 0
-----
batch_normalization_3 (Batch Normalization) (None, 8, 8, 64) 256
-----
conv2d_4 (Conv2D) (None, 8, 8, 128) 73856
-----
activation_4 (Activation) (None, 8, 8, 128) 0
-----
dropout_4 (Dropout) (None, 8, 8, 128) 0
-----
batch_normalization_4 (Batch Normalization) (None, 8, 8, 128) 512
-----

```

```
flatten_1 (Flatten) (None, 8192) 0
-----
dropout_5 (Dropout) (None, 8192) 0
-----
dense_1 (Dense) (None, 256) 2097408
-----
activation_5 (Activation) (None, 256) 0
-----
dropout_6 (Dropout) (None, 256) 0
-----
batch_normalization_5 (Batch Normalization) (None, 256) 1024
-----
dense_2 (Dense) (None, 128) 32896
-----
activation_6 (Activation) (None, 128) 0
-----
dropout_7 (Dropout) (None, 128) 0
-----
batch_normalization_6 (Batch Normalization) (None, 128) 512
-----
dense_3 (Dense) (None, 10) 1290
-----
activation_7 (Activation) (None, 10) 0
=====
Total params: 2,264,458
Trainable params: 2,263,114
Non-trainable params: 1,344
```

