

**Логвін А.О.**

Харківський національний університет радіоелектроніки

## ТИПИ ГЕНЕРАТИВНИХ НЕЙРОННИХ МЕРЕЖ

Розкрито основні типи генеративних нейронних мереж та окреслено поняття генеративної моделі. Наголошується, що глибокогенеративні моделі сформовано за рахунок комбінації генеративних моделей і глибоких нейронних мереж. Наведено математичну складову частину набору даних для реалізації генеративних нейронних мереж, описано процес навчання мереж і вимоги до нього. Як типи генеративних мереж визначається класифікація трьох напрямів: варіаційний автоенкодер, генеративні змагальні мережі й авторегресивні мережі. Наведено переваги та недоліки кожного типу. Варіаційний автоенкодер має структуру кодуювальника-декодера за допомогою імовірнісних графічних моделей, де нижня межа максимізується на логарифмічній ймовірності даних, генеративні змагальні мережі мають структуру генератора-дискримінатора через змагальну навчальну гру, в якій зразки даних генеруються безпосередньо, а авторегресивні мережі будуються на принципі факторизації спільного розподілу даних в умовних розподілах, моделюючи кожний окремий вимір з урахуванням попередніх вимірювань. Підкреслено, що у разі дієвого навчання варіаційний автоенкодер може виступати у двох варіаціях: як потужна дієва генеративна модель і як ефективне середовище навчання уявлення для природної мови. Генеративна змагальна мережа виступає ефективним механізмом для генерації зображень, що працює на базі двох мереж: генератора для синтезу та дискримінатора для розрізнення зображень.

**Ключові слова:** генеративна мережа, генеративна модель, нейронна мережа, навчання, масштабованість, генерація зображень.

**Постановка проблеми.** Одним із основних напрямів штучного інтелекту є розробка алгоритмів і методів, які наділяють комп'ютери здатністю синтезувати дані, що спостерігаються в навколишньому світі. Щоразу, коли дослідники створюють модель, котра імітує цю здатність, модель називається генеративною. Якщо в цій моделі задіяні глибокі нейронні мережі, то вона є глибокогенеративною моделлю (DGM). Як окрема гілка методів самостійного навчання у глибокому навчанні DGM спеціально зосереджені на характеристиці процесів генерації даних.

**Аналіз останніх досліджень і публікацій.** За останнє десятиліття чимало як зарубіжних, так і вітчизняних учених здійснили відкриття у сфері генеративних нейронних мереж.

І.В. Гарячевська та С.Ю. Мовенко [1] дослідили процес розробки та впровадження нейронних мереж для прогнозування. Авторами здійснено розробку моделей прогнозування часових рядів для отримання якомога точнішого прогнозу споживання та вироблення електроенергії з урахуванням використання альтернативних джерел енергії.

Л.І. Коротка [2] навела визначення функціональної підсистеми раціонального вибору архітектури нейронної мережі. Авторка запропонувала інформаційну підсистему, яка дозволяє обрати архітектуру слоїстої нейронної мережі та

визначитися з її параметрами: кількістю шарів, функцією активації, кількістю епох, похибкою мережі, кроком навчання.

У [3] розкрито сучасні інформаційні технології: штучні нейронні мережі, нечітку логіку, генетичні алгоритми, указані шляхи використання цих технологій і наведено приклади розв'язання практичних завдань.

В.М. Мельник, К.В. Мельник і Б.В. Шульга [4] дослідили питання ідентифікації емоцій людини за допомогою нейронної мережі на основі Keras і TensorFlow. Авторами наведено результати досліджень визначення емоцій людини за допомогою нейронних мереж.

Johannes Linder, Nicholas Bogard Alexander, V. Rosenberg, Georg Seelig [5] розкрили моделі глибоких нейронних мереж разом із оптимізацією стилю градієнтного підйому, які демонструють перспективу для проектування послідовностей. Створені послідовності, однак, можуть застрягти в локальних мінімумах і часто мають низьку різноманітність. Тут автори запропонували розробити мережі глибоких досліджень (DEN), клас генеративних моделей, що максимізують активацію та мінімізують вартість нейронної мережі шляхом градієнтного спуску. Використовуючи DEN, науковці спроектували сигнали поліаденілювання з більш ніж у 10 разів вищими шансами відбору,

ніж найкращі шаблони, сформовані градієнтним підйомом, визначили регулюючі послідовності сплайсингу, які, як передбачається, призведуть до високодиференціального сплайсингу між клітинними лініями.

Jason Brownlee [6] описав генеративну змагальну мережу (GAN). Автор називає генеративну змагальну мережу типом архітектури нейронної мережі для генеративного моделювання. Генеративне моделювання передбачає використання моделі для генерування нових прикладів, котрі правдоподібно походять із наявного розподілу зразків, наприклад, створення нових фотографій, подібних, але особливо відмінних від набору даних наявних фотографій.

Також варто відзначити роботи таких вчених, як К.В. Мельник, В.М. Мельник, Ю.Ю. Коптюк [7], Д.А. Гончаров [8], В.Ю. Саган [9], Vikas P. Deshpande, Robert F. Erbacher, Chris Harris [10], Graham P. [11], A. Radford, L. Metz, S. Chintala [12], M. Mirza, S. Osindero [13], X. Chen, Y. Duan, R. Houthoof, J. Schulman, I. Sutskever, P. Abbeel [14], A. Odena, C. Olah, J. Shlens [15], A. Makhzani, J. Shlens, N. Jaitly, I. Goodfellow [16], Dumoulin, I. Belghazi, B. Poole, O. Mastropietro, A. Lamb, M. Arjovsky, A. Courville [17], D. Ulyanov, A. Vedaldi, V. Lempitsky [18], A.B.L. Larsen, S.K. Snderby, H. Larochelle, O. Winther [19] та ін.

Однак, незважаючи на всю масштабність наявних наукових досліджень, питання типів генеративних нейронних мереж залишається відкритим і потребує детального опрацювання.

**Постановка завдання.** Мета статті – розкрити основні типи генеративних нейронних мереж.

**Виклад основного матеріалу дослідження.** Основні види генеративних моделей діляться на три фундаментальні класи: Optimus – це перша

великомасштабна мовна модель варіаційного автоенкодера (VAE), що демонструє можливості DGM, наступна за тенденцією попередньо навчених мовних моделей. FQ-GAN вирішує проблеми масштабності з генерацією зображень у генеративні змагальні мережі (GAN). Prevalent – перший попередньо навчений універсальний агент для візуальної та мовної навігації.

Генеративні моделі мають довгу історію у традиційному машинному навчанні, і їх часто відрізняють від іншого основного підходу – дискримінаційних моделей. Із розвитком глибокого навчання нове сімейство методів, що називаються глибокими генеративними моделями (DGM), формуються за рахунок комбінації генеративних моделей і глибоких нейронних мереж. Оскільки нейронні мережі, які використовуються як генеративні моделі, мають ряд параметрів, менших, ніж обсяг даних, на яких вони навчаються, є особлива властивість, що стосується тільки DGM. DGM змушені виявляти й ефективно засвоювати сутність даних, щоб їх генерувати.

Математично для набору даних прикладів  $\{x_i | x_i \in \mathbb{R} \langle \sup \rangle \langle em \rangle D \langle /em \rangle \langle /sup \rangle, i = 1, \dots, N\}$ , як зразки з істинного розподілу даних  $q(x)$ , мета DGM – побудувати глибокі нейронні мережі з параметрами  $\theta \in \mathbb{R} \langle \sup \rangle \langle em \rangle P \langle /em \rangle \langle /sup \rangle$ , щоб описати розподіл  $p(x)$  так, що параметри  $\theta$  можна навчити, щоб гарантувати  $p_\theta(x)$  кращу відповідність  $q(x)$ . Всі DGM використовують одну і ту саму базову настройку й описану вище властивість DGM, але вони розрізняються способами вирішення проблеми.

Згідно з таксономією OpenAI існують три популярні типи генеративних мереж: VAE, GAN і авторегресивні мережі. Кожен із них докладно описаний в табл. 1.

Таблиця 1

Типи генеративних нейронних мереж

Тип	Ключове поняття	Плюси	Мінуси
Варіаційний автоенкодер	Структура кодувальника-декодера за допомогою імовірнісних графічних моделей, де нижня межа максимізується на логарифмічній імовірності даних.	Одночасно виконує генерацію і логічний висновок із моделюванням прихованих змінних	Зразки зображень, згенеровані VAE, мають тенденцію бути трохи розмитими
Генеративні змагальні мережі	Структура генератора-дискримінатора через змагальну навчальну гру, в якій зразки даних генеруються безпосередньо	Створює різкі зразки зображень	Складніше оптимізувати через нестабільну динаміку тренування
Авторегресивні мережі	Факторизується спільний розподіл даних в умовних розподілах, моделюючи кожний окремий вимір з урахуванням попередніх вимірювань.	Просте і стабільне навчання, що забезпечує найкращу логарифмічну ймовірність	NLM неефективні під час вибірки і не можуть легко забезпечити низькорозмірні функції

Перехід від дрібномасштабних до великомасштабних глибинних генеративних моделей у всіх трьох типах можливий. Завдяки багаторічним зусиллям по розвитку їх теоретичних принципів DGM тепер відносно добре вивчені на малих вибірках. Згадана вище властивість DGM передбачає, що моделі будуть нормально працювати за умов:  $P < N * D$ . Це було підтверджено в багатьох роботах [5; 10]. Однак в останні роки здійснено величезний прогрес завдяки попередньому навчанню великих моделей на масивних даних (у контексті наведеного вище рівняння  $N$  різко збільшується).

Дослідники з OpenAI вважають, що генеративні моделі – один із найбільш багатообіцяючих підходів до досягнення мети – наділити комп'ютери розумінням навколишнього світу. Відповідно до цього в 2018 р. дослідники з Open AI розробили генеративне попереднє навчання (GPT), авторегресійну нейронну мовну модель (NLM), навчену на різноманітному корпусі немаркованого тексту, з подальшим точним налаштуванням для кожного конкретного завдання, що демонструє значно поліпшену продуктивність.

Optimus – перша великомасштабна глибоко прихована модель змінної для природної мови, яка попередньо підготовлена з використанням пропозицій – рівневі (варіаційні) завдання автоенкодера на великому текстовому корпусі.

Попередньо навчені мовні моделі значно покращилися в рішенні безлічі завдань обробки природної мови. PLM часто навчаються передбачати слова на основі їхнього контексту в масивних текстових даних, а вивчені моделі можна налаштувати для адаптації до різних завдань. PLM зазвичай можуть грати дві різні ролі: загальний кодувальник, такий як BERT і Roberta, і потужний декодер, такий як GPT-2 та Megatron. Іноді обидва завдання можуть бути виконані в одному уніфікованому середовищі, наприклад, в UniLM, BART і T5. У цих моделях відсутнє явне моделювання структур у компактному прихованому просторі, що ускладнює управління генерацією та поданням природної мови на основі семантики рівня пропозицій.

За ефективного навчання варіаційний автоенкодер (VAE) може бути як потужною генеративною моделлю, так і ефективним середовищем навчання уявлення для природної мови. Представляючи пропозиції в низькорозмірному латентному просторі, VAE дозволяють легко маніпулювати пропозиціями, використовуючи відповідні компактні векторні уявлення (наприклад, гладку

регуляризацію ознак, задану попередніми розподілами) і керовану генерацію пропозицій за допомогою інтерпретованих прихованих векторних операторів. Незважаючи на привабливі теоретичні переваги, наявні мовні віртуальні інтерфейси часто будуються з використанням неглибоких мережових архітектур, таких як дворівневі LSTM. Це обмежує можливості моделі та призводить до неоптимальної продуктивності. Коли надається великий обсяг даних, виверти DGM можуть зламатися, якщо використовується неглибокий VAE.

$$p(x) = \prod_{t=1}^T p_{\theta}(x_t | x_{<t}) \quad (1)$$

$$p_{\theta}(x | z) = \prod_{t=1}^T p_{\theta}(x_t | x_{<t}, z) \quad (2)$$

Для довгого речення  $T, x = [x_1, \dots, x_T]$ , авторегресійний NLM генерує поточний токен  $x_t$  за умови токенів попереднього слова  $x \langle sub \rangle < t \langle /sub \rangle$ , як показано в рівнянні 1 вище, існує обмежена можливість для генерації, яка повинна керуватися семантикою більш високого рівня. GPT-2, мабуть, найвідоміший приклад NLM, попередньо навчений роботі з великими обсягами тексту. VAE генерує  $x_t$ , що зумовили обидва токени попереднього слова  $x \langle sub \rangle < t \langle /sub \rangle$  і прихована змінна  $z$ , як показано у рівнянні 2. Прихований  $z$  визначає семантику високого рівня (тобто «схему») пропозиції, таку як час, теми або тональність, направляючи процес послідовного декодування для заповнення деталей схеми. Декодер  $\theta$  суміщений з енкодером  $\phi$ . VAE вивчає параметри, максимізуючи нижню межу логарифмічної ймовірності даних.

Архітектура Optimus показана на рис. 1а, щоб допомогти навчанню системи, ініціалізуємо кодер за допомогою BERT та ініціалізуємо декодер за допомогою GPT-2. Вихідна ознака токена [CLS] використовується для отримання прихованої змінної  $z$ . Щоб полегшити  $z$  при декодуванні GPT-2 без повторного навчання wag із нуля вивчаємо дві схеми, ілюстровані на рис. 1б. У першій схемі  $z$  грає роль додаткового вектора пам'яті для декодера. У другій схемі  $z$  додається на нижній шар вбудовування декодер і безпосередньо використовується в кожному кроці декодування. Емпірично виявлено, що перша, заснована на пам'яті схема працює краще. Щоб запобігти проблемі зникнення KL, використовуємо циклічний графік відпалу і методи розмірного порогу. Як новий тип PLM, запропонований Optimus показує кращі результати, демонструючи свої унікальні переваги порівняно з наявними PLMs.




Рис. 1. (а) архітектура Optimus, що складається з кодувальника і декодера, та (б) впровадження прихованого вектора

Optimus вивчає більш гладкий простір і більш розділені шаблони об'єктів, ніж BERT (рис. 2а та 2б нижче). Це дозволяє Optimus забезпечити кращу продуктивність класифікації та більш швидку адаптацію, ніж BERT, при використанні як функціонального підходу (магістральна мережа заморожується й оновлюється тільки класифікатор), оскільки це дозволяє Optimus підтримувати і використовувати латентну структуру,

вивчену в ході попереднього навчання. На рис. 2с показані результати з різним числом позначених зразків для кожного класу в цьому наборі даних Yelp review, Optimus показує набагато кращі результати у сценаріях із низьким рівнем обчислень (налаштування на основі функцій).

GAN – популярна модель для генерації зображень. Вона складається з двох мереж – генератора для безпосереднього синтезу підроблених зразків, що імітують реальні зразки, та дискримінатора для розрізнення реальних зразків ( $x$ ) і підроблених зразків ( $x^{\wedge}$ ). Ці дві мережі навчаються у змагальному порядку, щоб підроблений розподіл даних міг відповідати реальному розподілу даних.

Зіставлення ознак – це важливий спосіб, який переводить завдання зіставлення розподілу даних GANs у задачу зіставлення розподілу у просторі ознак дискримінатора. Це вимагає, щоб статистика ознак (моменти першого або другого порядку), оцінена із сукупності як підроблених, так і реальних вибірок, була подібною. На практиці ці статистичні дані об'єктів оцінюються за

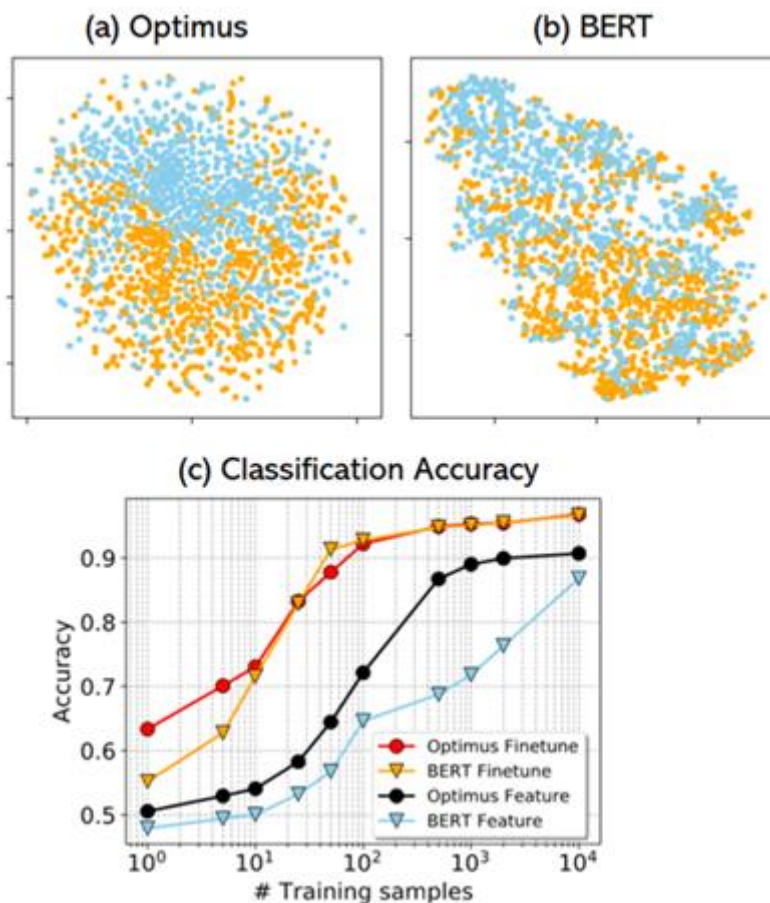


Рис. 2. (а) і (б) візуалізація простору ознак із використанням tSNE для Optimus і BERT відповідно. Пропозиції з різними мітками відображаються в різних кольорах; с) результати з різними маркувальними даними

допомогою міні-пакетів в безперервному просторі об'єктів. Оскільки набір даних стає багатим і складнішим (наприклад, із більшою високою роздільною здатністю), якість оцінки на основі міні-пакетів стає поганою, оскільки дисперсія оцінки велика для фіксованого розміру пакета. Ця проблема є особливо серйозною для GANs, оскільки індукований підроблений вибірковий розподіл генератора завжди змінюється при навчанні, що створює нову проблему в масштабуванні GANs для великомасштабних налаштувань.

Для вирішення цієї проблеми пропонується квантування ознак (FQ) для дискримінатора, яке представляє зображення у квантовому, а не в безперервному просторі. Нейромережева архітектура FQ-GAN показана на рис. 3а, FQ вводиться в дискримінатор стандартних GANs. Він обмежує безперервні об'єкти заданим набором значень, зокрема центроїдами об'єктів зі словника.

Оскільки як справжні, так і помилкові зразки можуть вибирати свої уявлення тільки з обмежених елементів словника, FQ-GAN побічно виконує зіставлення об'єктів. Це можна проілюструвати за

допомогою прикладу візуалізації на рис. 3б, де показані справжні об'єкти (h) і підроблені функції  $h \sim$  квантованими в ті самі центроїди (найближчі центроїди представлені в тому самому кольорі в цьому прикладі). Використовуємо поновлення ковзної середньої для реалізації словника E. Це гарантує, що словник містить набір центроїдів, які узгоджуються з останніми функціями в навчанні.

Запропонована методика FQ може бути легко підключена до наявних моделей GAN із невеликими обчислювальними витратами в навчанні. Експериментальні результати показують, що запропонований FQ-GAN може поліпшити якість формування зображень базових методів із великим запасом за різними завданнями, включаючи три репрезентативні моделі GAN за дев'ятьма критеріями:

BigGAN для генерації зображень. BigGAN, представлений Google DeepMind у 2018 р., є, мабуть, найбільшою моделлю GAN;

StyleGAN для синтезу особи. StyleGAN, представлений NVIDIA у грудні 2018 р., може генерувати високоякісні зображення, які виглядають як




Рис. 3. (а) архітектура FQ-GAN: FQ доданий як новий шар у дискримінаторі стандартних GANs; (б) пошук словника як неявного зіставлення об'єктів

Примітки: точки одного кольору становлять безперервні об'єкти, які квантовані в один і той самий центр ваги (представлений великими колами). Справжні об'єкти (квадрат) і підроблені об'єкти (трикутник) змушені спільно використовувати один і той самий центр ваги після FQ

портрети людей. Він побудований на прогресивних GANs, але дає дослідникам більше контролю над конкретними візуальними особливостями;

U-GAT – це додаток для безконтрольного перетворення зображень. Це сучасний метод передачі стилю зображення, який з’явився на ICLR 2020. На п’яти контрольних наборах даних видно, що FQ значно покращує продуктивність і показує кращу оцінку сприйняття людини.

**Висновки.** Розкрито типи генеративних нейронних мереж, які сформовано за рахунок ком-

бінації генеративних моделей і глибоких нейронних мереж. За подальшого розуміння образів і мови на семантичному рівні наступним кроком є наділення агента здатністю до дії для виконання завдання з мультимодальними вхідними даними. Навчання навігації у візуальному середовищі, дотримуючись інструкцій природною мовою, є однією з основних задач на шляху до цієї мети. В ідеалі потрібно навчити універсальний агент один раз і дозволити йому швидко адаптуватися до різних завдань.

#### Список літератури:

1. Гарячевська І.В., Мовенко С.Ю. Розробка штучних нейронних мереж для прогнозування споживання електроенергії. *Вісник Херсонського національного технічного університету*. 2018. № 3 (1). С. 250–259.
2. Коротка Л.І. Функціональна підсистема раціонального вибору архітектури нейронної мережі. *Вісник Херсонського національного технічного університету*. 2017. № 3 (1). С. 55–59.
3. Дранишников Л.В. Д72 Інтелектуальні методи в управлінні : навчальний посібник. Кам’янське : ДДТУ, 2018. 416 с.
4. Мельник В.М., Мельник К.В., Шульга Б.В. Дослідження моделювання ідентифікатора емоцій людини за допомогою загорткової нейронної мережі з використанням Keras. *Комп’ютерно-інтегровані технології: освіта, наука, виробництво*. 2019. № 36. С. 109–122.
5. Мельник К.В., Мельник В.М., Коптюк Ю.Ю. Дослідження методів розпізнавання зображень на основі нейронних мереж. *Комп’ютерно-інтегровані технології: освіта, наука, виробництво*. 2019. № 35. С. 161–165.
6. Linder, J., Bogard, N., Rosenberg, A.B., Seelig, G. A Generative Neural Network for Maximizing Fitness and Diversity of Synthetic DNA and Protein Sequences. *Cell Systems*. <https://www.sciencedirect.com/science/article/pii/S2405471220301927> – !Vol. 11. Issue 1. P. 49–62.e16
7. Brownlee J. 18 Impressive Applications of Generative Adversarial Networks (GANs) in Generative Adversarial Networks Tweet Share. 2019. URL: <https://machinelearningmastery.com/impressive-applications-of-generative-adversarial-networks/> (дата звернення: 10.12.2020).
8. Гончаров Д.А. Програмні засоби розпізнавання акустичної інформації в сенсорних мережах : дис. ... магістра зі спец. 123. Київ : КПІ, 2018. 122 с.
9. Саган В.Ю. Система аналізу біомедичних сигналів для контролю стану водіїв : дис. ... магістра зі спец. 122. Київ : КПІ, 2018. 122 с.
10. Vikas P. Deshpand. An Evaluation of Naive Bayesian Anti-Spam Filtering Techniques. Proceedings of the 2007 IEEE Workshop on Information Assurance United States Military Academy, West Point, 2007. NY 20–22 June. URL: <http://digital.cs.usu.edu/~erbacher/publications/Bayes-Vikas2.pdf> (дата звернення: 10.12.2020).
11. Graham P. A Plan for Spam. 2002. URL: <http://www.paulgraham.com/spam.html> (дата звернення: 10.12.2020).
12. Radford A., Metz L., Chintala S. 5 “Unsupervised representation learning with deep convolutional generative adversarial networks,” in International Conference on Learning Representations, 2016. URL: <https://arxiv.org/abs/1511.06434> (дата звернення: 10.12.2020).
13. Mirza M., Osindero S. Conditional Generative Adversarial Nets. arXiv e-prints, p. arXiv:1411.1784, Nov. 2014. URL: <http-s://arxiv.org/abs/1411.1784> (дата звернення: 10.12.2020).
14. Chen X., Duan Y., Houthoof R., Schulman J., Sutskever I., Abbeel P. Infogan: Interpretable representation learning by information maximizing generative adversarial nets,” in Advances in Neural Information Processing Systems 29, 2016, pp. 2172–2180. URL: <http://papers.nips.cc/paper/6399-infogan-interpretation-learning-by-information-maximizing-generative-adversarial-nets.pdf> (дата звернення: 10.12.2020).
15. Odena A., Olah C., Shlens J. Conditional image synthesis with auxiliary classifier GANs. *Proceedings of the 34th International Conference on Machine Learning*, Vol. 70. P. 2642–2651.
16. Makhzani A., Shlens J., Jaitly N., Goodfellow I. Adversarial autoen-coders. *International Conference on Learning Representations*. 2016. URL : <http://arxiv.org/abs/1511.05644> (дата звернення: 10.12.2020)
17. Dumoulin V., Belghazi I., Poole B., Mastropietro O., Lamb A., Arjovsky M., Courville A. Adversarially learned inference. *International Conference on Learning Representations*. 2017. URL: <https://arxiv.org/abs/1606.00704> (дата звернення: 10.12.2020).

18. Ulyanov D., Vedaldi A., Lempitsky V. It takes (only) two: Adversarial generator-encoder networks. *AAAI Conference on Artificial Intelligence*. 2018. URL: <https://www.aaai.org/ocs/index.php/AAAI/AAAI18/paper/view/16568> (дата звернення: 10.12.2020).

19. Larsen A.B.L., Snderby S.K., Larochelle H., Winther O. Autoencoding beyond pixels using a learned similarity metric. *Proceedings of The 33rd International Conference on Machine Learning*. 2016. P. 1558–1566. URL: <http://proceedings.mlr.press/v48/larsen16.htm> (дата звернення: 10.12.2020).

### **Lohvin A.O. TYPES OF GENERATIVE NEURAL NETWORKS**

*The main types of generative neural networks are revealed and the concept of generative model is outlined. It is emphasized that deep generative models are formed due to a combination of generative models and deep neural networks. The mathematical component of the data set for the implementation of generative neural networks is given, and the process of learning networks and requirements to it is described. The classification of three directions is defined as types of generative networks: variational autoencoder, generative adversarial networks and auto regressive networks. The advantages and disadvantages of each type are given and the main, key direction of implementation is emphasized. It is noted that the variational autoencoder has an encoder-decoder structure using probabilistic graphical models, where the lower limit is maximized on the logarithmic probability of data, generative adversarial networks have the structure of a discriminator generator through a competitive training game in which data samples are generated directly and autoregressive networks are built. the principle of factorization of the joint distribution of data in conditional distributions, modeling each individual dimension taking into account previous measurements. It is emphasized that in the case of effective learning, the variational autoencoder can act in two variations, as a powerful effective generative model and as an effective learning environment for natural language. The generative competition network is an effective mechanism for generating images, which works on the basis of two networks: a generator for synthesis and a discriminator for image resolution.*

**Key words:** generative network, generative model, neural network, learning, scalability, image generation.