

Автоматичне виявлення браку виробництва з використанням напівкерovanого навчання

У роботі запропоновано підхід до розпізнавання дефектів у тканинах з використанням навчанням з перенесенням та напівкерovanого навчання. Запропонований підхід використовує переднавчену на базі зображень Imagenet нейронну мережу MobileNetV2 та застосовано техніки навчання з перенесенням та напівкерovanого навчання для побудови класифікатора.

Задача виявлення дефектів з використанням напівкерovanого навчання.

Задача виявлення дефектів є актуальною у аерокосмічній промисловості. Незнищючий контроль (англ. Non-destructive control, NDT) - один з основних способів виявлення дефектів у виробництві. У аерокосмічній промисловості частіше за все використовують такі методи знищюючого контролю[1], як рідкісний пенетрат, магнетичний, вихрового струму, ультразвуковий, радіографічний (рентгенівське і гамма-випромінювання), візуальний/оптичний, звуковий/резонансний, інфрачервоної термографії. Більшість таких систем використовує або експертну оцінку, або оцінку з використанням детерміністичних алгоритмів, таких як експертні системи[2] для виявлення дефектів. Наразі існують нові підходи до оцінки результатів з використанням технологій штучного інтелекту. Ми пропонуємо підхід до виявлення дефектів візуальним/оптичним методом з використанням штучного інтелекту на основі методів напівкерovanого навчання.

Розглянемо задачу виявлення дефектів як задачу багатокласової класифікації, де кожен клас є типом дефекту. Задача багатокласової класифікації припускає що існує множина пар об'єкт-клас $X \times Y$ яка утворює ймовірнісний простір P . Необхідно маючи скінченну множину спостережень $X_m = \{(x_1, y_1), \dots, (x_m, y_m)\}$ побудувати функцію-апроксиматор $f(x) \approx P(y|x)$, $x \in X, y \in Y$.

Для розв'язання задачі використаємо технології штучного інтелекту на основі напівкерovanого навчання та навчання з перенесення.

Напівкерované навчання - вид машинного навчання, у якому використовується відносно малий маркований набір даних $L = \{(x_1, y_1), \dots, (x_m, y_m)\}$ та великий набір немаркованих даних $U = \{x_1, x_2, \dots, x_n\}$, $|L| < |U|$, які мають однакову функцію щільності вірогідностного розподілу. При навчанні моделі використовуються як маркований так і немаркований набір даних для побудови функції-класифікатора $f(x) \approx P(y|x)$. Інтуїція полягає у тому, що алгоритм навчання може отримати додаткові знання про істинний розподіл з немаркованого набору даних.

Використання напівкерованого навчання дозволяє значно знизити необхідну кількість маркованих даних. Оскільки для маркування зображень необхідна експертна оцінка, маркування великих наборів даних є нерациональним. Напівкероване навчання дозволяє підвищити точність класифікації навіть на малих наборах маркованих даних.

Навчання з перенесенням дозволяє адаптувати існуючий розв'язок $T = \{X, f(x)\}$, де X - простір функцій, а $f(x)$ моделює розподіл $P(y|x)$ до задачі $T' = \{X', g(x')\}$, де $X \neq X'$, $f(x) \neq g(x')$. Іншими словами, навчання з перенесенням дозволяє перенести знання, які були отримані при розв'язку однієї задачі на іншу задачу, що на практиці дозволяє значно пришвидшити процес навчання.

Побудова багатокласового класифікатора для виявлення браку у тканинах.

Для побудови класифікатора було обрано архітектуру згорточної нейронної мережі MobileNetV2, яка розроблялась спеціально для роботи на пристроях з обмеженою кількістю обчислювальних ресурсів, що робить її гарним кандидатом для використання у мікрокомп'ютерних системах, які є поширеними у автоматичних системах керування.

Для використання навчання з перенесенням, було взято навчену на наборі даних Imagenet версію нейронної мережі, після чого шари, що відповідають за класифікацію, було видалено. Замість них було додано шари усередненого пулінгу, шар викиду і два повноз'єднаних шари з 256 та 3 нейронами, які сформували нову голову класифікації класифікатора.

Для навчання нейронної мережі було обрано датасет “fabric defect dataset”[3]. Детальна інформація про датасет наведена у таблиці 1.

Таблиця 1.

Інформація про датасет

Розмір датасету	Кількість класів	Розмір тренувальної вибірки	Розмір перевіркової вибірки
310	3	270	30

Цей датасет містить екземпляри браку виробництва тканини трьох типів - горизонтальні та вертикальні ушкодження та дірки. Датасет складається з оригінальних фотографій та масок ушкоджень, отриманих за допомогою перетворення посилення контрасту зображення та заміни кольорової схеми на чорно-білу. Приклад зображення там маски наведено на рис. 1




Рис. 1 - Знімок тканини (зверху) і результуюча маска (знизу)

Зображення рівномірно розділені між трьома класами у тренувальній та валідаційній вибірках - 90 екземплярів кожного класу у тренувальній і 10 екземплярів кожного класу у валідаційній.

Для побудови напівкерowanego класифікатора використовувалась модель навчання вчитель-студент з регуляризацією консистентності.

Обидві моделі навчались у два етапи - на першому етапі ваги основної моделі виключаються з навчальних параметрів і навчається лише класифікуюча голова протягом 30 епох. Після цього виконується тонке налаштування - ваги основної моделі включаються до навчальних параметрів і навчаються 10 додаткових епох з пониженою швидкістю навчання

Оскільки початковий набір є маркованим, для напівкерowanego навчання створюються дві тренувальні вибірки з оригінальної маркованої шляхом видалення міток для 50% екземплярів зберігаючи баланс міток у класах.

Результати

У результаті тренування класичним керowanym навчанням було досягнуто валідаційної точності 87.10% на першому етапі тренування і 88.71% на етапі налаштування. Точність моделі у процесі навчання зображено на рис. 2.



Рис. 2 - Точність при навчанні керованої моделі

Як видно з графіку точності, етап точного налаштування може як погіршити так і покращити точність класифікатора, тому важливо встановити низьку швидкість навчання.

При тренуванні напівкерованим навчанням класифікатор досяг остаточної точності на першому етапі тренування. Точність класифікатора впала на ~12% і становить 75.81% при зменшенні маркованого набору даних на 50%. Графік точності при навчанні наведено на рис. 3.



Рис. 3 - Точність при навчанні напівкерованої моделі

Висновки

У роботі було розглянуто підхід до виявлення дефектів у автоматизованих системах виробництва технологічними процесами виробництва тканини з використанням напі керованого навчання та навчання з перенесенням. Навіть на відносно малому наборі даних було досягнуто прийнятної точності як з повністю керованим (88.71%) так і з напівкерованим (75.81%) підходами до навчання. Використання навчання з переносом значно пришвидшує процес навчання і додатково підвищує точність моделі. Розглянутий підхід є простим у навчанні та розгортанні і може бути легко застосованим до практичних задач виявлення дефектів на виробництві за умови наявності відповідного набору даних.

Список літератури

1. Khan MM. Non-destructive testing applications in commercial aircraft maintenance. Journal of Nondestructive Testing. 1999. Vol 4.
2. Almond, DP., Angioni SL., Pickering SG. A case for NDT expert systems based on the development of the Thermographic NDE Advisory and Guidance System. Insight - Non-Destructive Testing and Condition Monitoring, Vol 59, Number 9, September 2017, pp. 473-478(6)
3. G.P.P.D. Bandara, K.P.T.K. Bandara, R.A.T.K.Ranatunga, B.K.D.V.Vimarshana, fabric defect dataset, 2020, <https://www.kaggle.com/datasets/rmshashi/fabric-defect-dataset>