

WPROWADZENIE

Podczas gdy branża turystyczna jest zaniepokojona pojawieniem się sztucznej inteligencji (AI), zmiana jest na lepsze. Przemysł lotniczy, jeśli chodzi o sztuczną inteligencję, jest często oskarżany o pozostawanie w tyle w porównaniu z innymi branżami. Jednak sztuczna inteligencja wprowadza rewolucyjne zmiany w podejściu firmy do danych, operacji i przepływu przychodów w branży. Czołowe firmy lotnicze na całym świecie już wykorzystują sztuczną inteligencję do poprawy efektywności operacyjnej i zwiększenia zadowolenia klientów. Wprowadzenie sztucznej inteligencji w liniach lotniczych i operatorach lotniczych znacznie obniżyło różne koszty operacyjne, sugerując zoptymalizowane wykorzystanie flot i operacji. Jednym z najważniejszych elementów podróży lotniczych jest obsługa klienta, która zaczyna się od momentu, w którym pasażer zaczyna myśleć o rezerwacji lotu, a nie dopiero po przybyciu na lotnisko. Dlatego linie lotnicze zastanawiają się, w jaki sposób wdrożenie sztucznej inteligencji może zmniejszyć i zminimalizować wpływ wszelkich zakłóceń na wrażenia pasażerów i ich działalność. Linie lotnicze wykorzystują teraz sztuczną inteligencję do przewidywania, ile artykułów spożywczych i napojów będzie potrzebnych podczas różnych lotów, zarówno poprawiając komfort pasażerów, jak i minimalizując ilość odpadów. Sztuczna inteligencja jest wykorzystywana przez kilka linii lotniczych do analiz predykcyjnych, automatycznego planowania, reklam ukierunkowanych i analizy informacji zwrotnych od klientów, aby poprawić wrażenia pasażerów w ich liniach lotniczych. Astrobiolodzy z NASA mają nadzieję, że uczenie maszynowe pomoże znaleźć dane, które mogą być zbierane przez przyszłe teleskopy i obserwatoria. Sztuczna inteligencja jest szczególnie ważna, ponieważ te duże zbiory danych z obserwacji szwów będą bardzo hałaśliwe i rzadkie. Technologia wraz ze sztuczną inteligencją zbliża nas coraz bliżej gwiazd i planet. Ten aspekt badania danych jest ważny dla naszego codziennego życia oraz w ulepszaniu wielu obszarów, takich jak transport i nawigacja. Robot ze sztuczną inteligencją wspomaga proces zbierania i przetwarzania tych danych tak, aby można je było wykorzystać w niezbędnych obszarach. Ponieważ sztuczna inteligencja wciąż ewoluuje i rozszerza się, firmy dostrzegają duże zmiany w swojej dziedzinie. Znane marki inwestują w technologię AI, aby ulepszać swoje produkty i usługi, aby lepiej służyć swoim klientom.

SZTUCZNA INTELIGENCJA W IDENTYFIKACJI PASAŻERÓW LINII LOTNICZYCH


Wdrażanie sieci neuronowych (NN) opartych na sztucznej inteligencji w lotnictwie cywilnym z powodzeniem zmienia dzisiejszą branżę transportu lotniczego. Wiodące na świecie linie lotnicze stosują tę technologię w swoich dziedzinach usług, aby poprawić wydajność obsługi klienta i jednocześnie, aby poprawić ogólne wrażenia klienta z linią lotniczą. Uznając współczesne obawy o bezpieczeństwo lotnictwa cywilnego na całym świecie, obecne postępowe technologie, takie jak sztuczna inteligencja, mogą uutorować drogę do bezpiecznego transportu lotniczego, przydatnego zarówno dla cywilów, jak i wojskowych. Punkty kontroli bezpieczeństwa na lotniskach, takie jak kioski, mogą być dobrze zaprojektowane z wykorzystaniem sztucznej inteligencji połączonej z zaawansowanym uczeniem maszynowym, mechatroniką, zdolnościami przetwarzania ludzkiego języka i technologiami biometrycznymi (takimi jak odciski palców, źrenice i rozpoznawanie twarzy). Omawiając biometrię, rozpoznawanie twarzy można wdrożyć do identyfikacji tożsamości klienta, doświadczenia zawodowego i celu pobytu w kraju. Celem opracowania takiej technologii byłoby ułatwienie przepływu pasażerów przez kiosk przy jednoczesnym zapewnieniu maksymalnego bezpieczeństwa. Konieczność opracowania zaawansowanej technologii kontroli bezpieczeństwa można uznać po uświadomieniu sobie, że w nadchodzących dziesięcioleciach liczba pasażerów ma się podwoić. Według Międzynarodowego Zrzeszenia Przewoźników Lotniczych (IATA) można oczekiwać, że liczba pasażerów (na głowę) wzrośnie dwukrotnie w porównaniu z obecną liczbą klientów, do około

8,2 miliarda aktywnych użytkowników usług w 2037 roku. Co więcej, złożona roczna stopa wzrostu (CAGR) ma wzrosnąć o 3,5% rocznie, prowadząc do większej liczby zatłoczonych/pośpiesznych lotnisk

ROZPOZNAWANIE TWARZY

Technologia rozpoznawania twarzy wykorzystuje punkty węzłowe na twarzy osoby, aby zweryfikować tożsamość klienta. Algorytm ten może być używany do kontroli bezpieczeństwa i dopasowywania pasażerów do ich bagażu za pomocą inteligentnych tagów identyfikacyjnych, takich jak RFID. Moduł algorytmu rozpoznawania twarzy można zainstalować na poręcznych dronach, które mają dostęp do obszarów o ograniczonym dostępie na lotnisku dla nieuprawnionego personelu. Co więcej, użyteczność tego modułu można wykorzystać do opisanie i zaimplementowania innego algorytmu, który wykorzystuje detekcję ruchu i jednolity kolor do rozpoznawania personelu lotniska. Od 2000 roku poczyniono ogromne wysiłki, aby zautomatyzować proces rozpoznawania i śledzenia ludzi. Technologia rozpoznawania twarzy w połączeniu ze sztuczną inteligencją wykazała akceptowalne wyniki w środowiskach in situ/kontrolowanych. Jednak wyniki te są niejednoznaczne, gdy technologia ma radzić sobie z codziennymi sytuacjami. Typowym przykładem w tym kryterium jest porównanie nierozpoznanej twarzy z twarzą już zidentyfikowanej osoby. Di Sciascio omawia rozwiązanie problemu poprzez kategoryzację charakterystycznych właściwości na opisy cech wysokiego i niskiego poziomu. Charakterystyki wysokiego poziomu obejmują właściwości zawarte w odrębnych i unikalnych cechach zawartych w obiektach na obrazie. Niskopoziomowe cechy obrazu obejmują wizualne opisy obrazu, takie jak kolory, odcień, kontrast, jasność itp. Di Sciascio twierdzi, że nowy system rozpoznawania twarzy powinien opierać się na rozpoznawaniu opisów cech wysokiego poziomu, ponieważ są one nieodłączne i trwałe. opis na obrazie. Z drugiej strony, opis cech niskiego poziomu zmienia się nieustannie wraz ze zmianą kontrastu kolorów, jasności obrazu itp. Po 2000 roku podjęto wiele prób opracowania światowej klasy systemu rozpoznawania twarzy. Jednym z powszechnych systemów rozpoznawania twarzy jest analiza głównych komponentów (PCA). Metoda PCA kompiluje specjalne, charakterystyczne relacje przestrzenne między cechami terenu twarzy, na przykład linią szczęki, nosem, oczodołami, łukiem brwiowym itp. Jednak w celu opracowania ulepszanego, zaawansowanego i dokładnego systemu rozpoznawania twarzy wykorzystywane są sieci neuronowe (CNN). W tym algorytmie uczenia maszynowego system wykorzystuje opis charakterystyki wysokiego poziomu. Osoba na zdjęciu jest rozpoznawana całkowicie na podstawie poszczególnych części ciała i pełnego opisowego obrazu osoby. Zróżnicowane części ciała i pełny obraz osoby badanej są liniowo połączone ze sobą i mają dosyć warstwy multipołączeń, aby wytworzyć ostateczną reprezentację, jeśli obraz jest kwestionowany. Nowy i ulepszony system CNN zapewnia nam 800-pikselową/wymiarową reprezentację obiektu obrazu. CNN jest wystarczająco sprawny, aby nauczyć się lokalnych charakterystycznych opisów wysokiego poziomu z obrazu wejściowego. Archetypowy model klasyfikatora CNN składa się z losowo naprzemiennych sekwencji warstw splotowych i podpróbek do wyszukiwania cech i ekstrakcji w ostatniej warstwie. Wielkość szablonu warstwy splotowej ma postać macierzy 5×5 , a wielkość szablonu podwarstwy to macierz 2×2 . Obraz wejściowy jest rozwiązywany i akceptowany w rozdzielczości macierzy 23×32 . Zbiór F1 składa się z sześciu numerów statystycznych map cech, a trzecia warstwa F3 składa się z 12 numerów statystycznych map cech. Pozostałe zestawy F1 i F4 mają taką samą ilość map cech statystycznych jak F1 i F3. Po przetworzeniu przez cztery warstwy powierzchniowe obraz wejściowy przechodzi teraz przez macierz strzałek w celu uzyskania wektora wyjściowego o wymiarach 240×1 . Na koniec wektor ten jest analizowany przez ostatnią warstwę modułu, która jest włączona przez algorytm NN. Ta warstwa klasyfikuje wektor wejściowy na 30 różnych klas. W zestawie warstw splotowych, F4 i ostatniej warstwie sieci NN, klasy są w pełni połączone. Ponadto klasyfikator CNN jest całkowicie wyszkolony maszynowo przy użyciu algorytmu wstecznej propagacji błędów w trybie wsadowym; ma to na celu ułatwienie uczenia maszynowego

obejmującego uczenie się masek splotowych C1 i C2 w powierzchniowych warstwach oraz uczenie się połączeń między różnymi warstwami w klasyfikatorze NN. Rysunek 1 przedstawia projekt CNN.



Technologia rozpoznawania twarzy jest wykorzystywana do weryfikacji tożsamości klientów i dopasowywania pasażerów do ich bagażu za pośrednictwem kiosków. Rozpoznawanie twarzy, jak każde inne potężne narzędzie, może być wykorzystywane zarówno w dobrych, jak i złych celach. Dzięki doskonałym sieciom NN i chipom system staje się inteligentniejszy, zwiększając dostępną moc, co z kolei pozwala na zwiększenie liczby warstw, umożliwiając lepszą inteligencję. Tworzy to pętlę pozytywnego sprzężenia zwrotnego.


SZTUCZNA INTELIGENCJA W IDENTYFIKACJI BAGAŻU LOTNICZEGO

Bezpieczeństwo bagażu również odgrywa kluczową rolę w ochronie lotniska. W latach 80. i 90. rozbudowa infrastruktury lotniczej, takiej jak lotniska i obiekty kontroli ruchu lotniczego, nie szła w parze z rosnącym ruchem lotniczym. Spowodowało to brak równowagi w łańcuchu podaży i popytu, co ostatecznie doprowadziło do przepełnienia portów lotniczych. Przepełnione lotniska nie zwracały uwagi na kwestie bezpieczeństwa bagażu personelu. Było to niebezpieczne, ponieważ mogło utworzyć drogę do działalności przestępczej na wysokim szczeblu lotniczej, takiej jak przemyt nielegalnych substancji lub przedmiotów, porwanie i przetrzymywanie pasażerów cywilnych jako zakładników, rozbój, nielegalny transport nielegalnych materiałów wybuchowych bez nadzoru eksperta przewożenie nieautoryzowanych broni lub ostrych narzędzi obiekty w kabinie samolotu itp. W następstwie zamachu terrorystycznego w Nowym Jorku z 11 września 2001 r. lotniska stały się jeszcze bardziej zatłoczone w związku z niepokojem związanym z bezpieczeństwem wewnętrznym. Dlatego identyfikacja bagażu pasażerskiego miała ogromne znaczenie dla bezpieczeństwa pasażerów cywilnych i aktywów lotniczych. Władze coraz bardziej zdawały sobie sprawę z konieczności identyfikacji pasażerów połączonej z identyfikacją bagażu. Stany Zjednoczone zwiększyły wysiłki w zakresie skanowania pasażerów i bezpieczeństwa do tego stopnia, że pasażerom często kazano się „rozebrać”, aby upewnić się, że podróżowanie jest bezpieczne. Jednak środki podjęte przez władze były dalece niewystarczające, aby zapobiec kolejnemu atakowi terrorystycznemu na terenie Stanów Zjednoczonych. Rzeczywistość była taka, że z ponad miliarda walizek codziennie w samych Stanach Zjednoczonych skanowano 3,8 miliona walizek. Najnowsza technologia dostępna w tym czasie w kraju zapewniała możliwość skanowania około 120-540 worków na godzinę, czyli dwóch pełnych ładunków na godzinę. Aby zapewnić dobrze zapewnione bezpieczeństwo, potrzebna była bardziej niezawodna, szybka i wyrafinowana technologia kontroli bezpieczeństwa w celu identyfikacji pasażerów i bezpieczeństwa bagażu. W tamtych czasach, przed tragedią z 11 września, na całym świecie do skanowania bagażu używano zwykłych aparatów rentgenowskich. Odpowiedzialność za identyfikację

nieparzystych przedmiotów w bagażu spoczywającym w rękach fachowców, uważność personelu oraz możliwości i wydajność maszyny skanującej. Większość skanerów rentgenowskich została zaprojektowana tak, aby identyfikować niektóre niebezpieczne obiekty tylko na podstawie ich kształtu, przepuszczalności promieniowania rentgenowskiego i współczynnika odbicia. Jednak maszyny te w konsekwencji nie zidentyfikowały materiałów niebezpiecznych, na co wskazuje sposób, w jaki handlarze narkotyków zdołali uniknąć władz i przemyścić produkty przy niewiele większym wysiłku niż wcześniej. Większość zagrożeń łatwo wymykała się protokołom bezpieczeństwa tylko z powodu niezdolności maszyny do zidentyfikowania nowego zagrożenia, dla których nie został zaprogramowany. Wszystkie technologie kontroli bezpieczeństwa odpowiedzialne za kontrolę bagażu powinny spełniać szereg kryteriów, w tym (ale nie wyłącznie):

- i. Zadowalający poziom dokładności rozpoznawania, identyfikacji i kategoryzacji obiektów.
- ii. Szybkie/szybkie działanie w celu sprawdzenia zatorów na lotniskach.

Wszystkie dotychczasowe badania i prace literaturowe w kontekście rentgenowskiej kontroli bagażu są całkowicie oparte na modelu worka wizualnych słów (BoVW), biorąc pod uwagę fakt, że wciąż istnieje znacznie większa potrzeba imperialnych dowodów w zakresie udowodnienia, że maszyny potrafią automatycznie rozpoznawać i kategoryzować różne obiekty w oparciu o zagrożenie, jakie stwarzają. Jednak problem ten może zostać rozwiązany poprzez włączenie BoVW z zaawansowanym i najnowocześniejszym algorytmem CNN do rentgenowskich badań przesiewowych i obrazowania bagażu. CNN i BoVW można łączyć ze sobą w sposób liniowy za pomocą klasyfikatora maszyn wektorów nośnych (SVM). Głębokie konwolucyjne sieci neuronowe (DCNN) są szeroko wykorzystywane w wielu zastosowaniach komputerowej chromatografii, wizji i obrazowania. Wcześniej, jak widzieliśmy, używaliśmy CNN w narzędziach do identyfikacji pasażerów na posterunku kontroli bezpieczeństwa na lotnisku iw kioskach. Głębokie NN zostały najpierw zaproponowane przez Krizhevsky'ego. Sieci DCNN są takie same jak normalne CNN, ale są głębsze i szersze, mają bardziej liniowe połączenia i są bardziej wielowarstwowe niż normalne CNN. Rysunek 2 przedstawia architekturę DCNN.



Sieci DCNN mają ponad cztery lub pięć warstw podstawowych z filtrami recepcyjnymi 11×11 i trzema warstwami fc w przeciwieństwie do normalnych sieci CNN, które mają tylko około czterech warstw. Sieci te zapewniają nam wysoki poziom bezpieczeństwa, ponieważ sieci DCNN charakteryzują się wysokim stopniem parametryzacji. Jednak użycie i użyteczność przerw w połączeniach i ukrytych neuronów jest usuwana w przetwarzaniu i obróbce danych obrazowych, aby uniknąć nadmiernej parametryzacji i dopasowania rzadkich zmiennych neuronowych, tak że wydajność całej maszyny zależy od podwarstw podstawowych elementów sieci. Co więcej, obecność przeparametryzowanych przerw w sieci i wolnych neuronów ma tendencję do zmniejszania lub degradacji odporności obecnych sieci na przeciążenie w obrębie liniowej maszyny operacyjnej. Podobnie usuwanie, a następnie

redukcja przerw w sieci i wolnych neuronów prowadzi do powstania systemu nieliniowego, który jest zdecydowanie bardziej złożony do zrozumienia i działania. W związku z tym potrzebne było nowatorskie podejście (funkcja aktywacji), aby ulepszyć DCNN pod kątem wynikającej z tego nieliniowości. W konsekwencji do istniejącego algorytmu wprowadzono ReLU (wyprostowaną jednostkę liniową). W kontekście sztucznej inteligencji i jej subdyscypliny, sieci SSN i wyprostowanych sieci NN, prostownica jest „funkcją aktywacji” definiowaną ogólnie przez dodatnią część jego matematycznego argumentu:

$$f(x) = x^+ = \max(0, x)$$

gdzie x jest wejściem do neuronu. Jest to również znane jako funkcja rampy i jest analogiczne do prostowania półfalowego w elektrotechnice. Każda jednostka, która korzysta z takiego prostownika, jest znana jako wyprostowana jednostka liniowa (ReLU). Praca dotycząca ReLU w DCNN została w dużej mierze wykonana przez Zeilera i Fergus. Po przeprowadzonych pracach zaprojektowali podobny wariant modelu z mniejszymi i krótszymi podatnymi polami. Kolejnego postępu w dziedzinie DCNN dokonali Simonyan i Zisserman (VGG) w ref. W pracy pokazano znaczenie głębokości sieci NN z maskami konwolucyjnymi ułożonymi w pola receptywne sortowania 3×3 z krokiem/tempem jedności. Istnieją dwie główne korzyści z używania małych macierzy obrazów wejściowych: po pierwsze, zwiększają nieliniowość systemu poprzez usunięcie przerw w sieci, a po drugie, zmniejszają ogólną liczbę parametrów w algorytmie w maszynie, co sprawdza przeparametryzowanie zmienne i związane z nimi ograniczenia. Obserwacje empiryczne wykazały, że użycie małych macierzy wejściowych obrazów 3×3 , o głębokości nośnej 10–20 warstw, może znacznie zapewnić lepszą wydajność i efektywność algorytmu systemu. Dalsze zagrożenie przeparametryzacji można zmniejszyć, stosując DCNN z faktoryzacjami 50, 101 i 152 filtrów, które są ułożone w mniejsze macierze wejściowe, takie jak 1×1 i 3×3 filtry.

SZTUCZNA INTELIGENCJA W ZADOWOLENIU KLIENTÓW LINII LOTNICZYCH

Sztuczna inteligencja może również stać się ścieżką, przez którą linie lotnicze łączą się ze swoimi klientami. Interfejsy użytkownika (UI) witryn internetowych wykorzystują teraz sztuczną inteligencję, która próbuje dostosować położenie przycisków, czcionki, układy itp. strony internetowej w odpowiedzi na to, gdzie klient wydaje się najczęściej klikać. Są to tak zwane inteligentne interfejsy użytkownika (IUI). Wraz z tym naturalnie pojawiają się obawy, czy oznacza to, że maszyna wpływa na decyzje, które użytkownik najprawdopodobniej podejmie. Chociaż to prawda, wygeneruje to znacznie silniejsze zaangażowanie użytkowników. Siatka jest najnowszym przykładem produktu, który miał na celu dostosowanie stron internetowych za pomocą uczenia maszynowego. IBM Watson Assistant i inne oprogramowanie może już odpowiadać na pytania zadane przez klienta (które interpretuje za pomocą NLU (zrozumienia języka naturalnego)), przeszukując bazy danych w poszukiwaniu informacji i może kierować szczególnie złożone pytania do rzeczywistych przedstawicieli klienta. Oszczędza to czas i pieniądze dla organizacji na dłuższą metę. Chatbot firmy Dubai Electricity and Water Authority, mRammas, odpowiedział na ponad 1,2 miliona zapytań klientów w 2019 roku. Spośród technologii wymienionych, chatboty są najbardziej wszechobecne. Dwie popularne metody tworzenia działającego chatbota podane są w poniższych podrozdziałach:

a. Przetwarzanie języka naturalnego (NLP)

Składa się z NLU i generowania języka naturalnego (NLG). W przypadku NLU sztuczna inteligencja analizuje tekst od użytkownika i przekształca go w mieszankę tego, co uważa za istotne dane. Normalizuje dane wprowadzane przez użytkownika, korygując typowe błędy gramatyczne, dzięki

czemu może działać wydajnie. Rozbija ten tekst na „tokeny” i sprawdza, czy te terminy można pogrupować w rodziny słów, na podstawie których może go zinterpretować. Są one klasyfikowane jako „intencje” (wskazanie, czego chce użytkownik) i „podmioty” (informacje uzupełniające). Może zidentyfikować adres lub jeśli klient jest podekscytowany, a następnie przekazać chat przedstawicielowi ludzkiemu. W przypadku NLG AI najpierw określa, jakie informacje należy zawrzeć w tekście. Następnie porządkuje układ tekstu. Łączy zdania, które mogą zawierać zbędne terminy, aby ułatwić czytanie, i dokonuje wyborów dotyczących leksykonu użytego do opisu pojęcia, np. „duży” lub „duży”. Ważne jest również generowanie wyrażenia odsyłającego. Wyrażenie odsyłające to takie, które jest używane w odniesieniu do miejsca, rzeczy lub wydarzenia, np. „3 km na zachód od A” kontra „2 km na zachód od B”, gdzie B jest mniej znanym punktem orientacyjnym między A a miejscem docelowym NLG można utworzyć, po prostu trenując algorytm uczenia maszynowego na dużych zestawach danych z odpowiednim tekstem napisanym przez człowieka.

b. Dopasowywanie wzorów

Tutaj program po prostu wyszukuje wzorce w danych wejściowych i szuka wcześniej wprowadzonych pytań, które są do niego podobne, a następnie wysyła odpowiednie odpowiedzi. Można to łatwo osiągnąć za pomocą języka AIML (Artificial Intelligence Markup Language), dialektu XML. Można również wykorzystać sztuczną inteligencję do monitorowania usług, z których użytkownik będzie chętniej korzystał i zwiększyć ich widoczność w interfejsie użytkownika. SITA Smart Path to produkt, który był teraz używany w testach zarówno przez Lufthansę, jak i British Airways, i który skrócił o połowę czas wejścia na pokład z 40 minut do zaledwie 20. Automatyzuje proces wejścia na pokład poprzez identyfikację twarzy pasażera po porównaniu go z odprawą celną oraz dane dotyczące ochrony granic.

SZTUCZNA INTELIGENCJA W BEZPIECZEŃSTWIE I KONSERWACJI STATKÓW POWIETRZNYCH

Sztuczna inteligencja może odgrywać zakulisową rolę w bezpieczeństwie klientów poprzez zastosowania w operacjach konserwacyjnych i naprawczych. Konserwacja jest jedną z pięciu głównych przyczyn opóźnień samolotów, więc oszczędność czasu i zapobieganie nieplanowanym przeglądom to inwestycja dla linii lotniczych. Pomysł też nie jest specjalnie nowy. Według statystyk amerykańskiego Biura Transportu konserwacja spowodowała około 302 opóźnień w 2019 roku. Prowadzi to do dużych strat finansowych dla samolotów.

Posiadanie sztucznej inteligencji, która może planować i planować zadania związane z konserwacją, jest inwestycją dla samolotu pasażerskiego. Oczekuje się, że do roku 2021 około 80% przemysłu lotniczego i obronnego będzie pod wpływem decyzji opartych na sztucznej inteligencji na każdym szczeblu departamentu. Najczęściej stosowane techniki sztucznej inteligencji to wnioskowanie oparte na przypadkach (CBR), algorytm genetyczny (GA), NN, system oparty na wiedzy (KBS) i logika rozmyta (FL). KBS to jedno z najstarszych podejść do zarządzania utrzymaniem ruchu. CBR to sposób na dodanie umiejętności uczenia się do systemu wspomagania decyzji (DSS) i diagnozowania błędów. GA pomaga w rozwiązywaniu skomplikowanych procesów obliczeniowych w celu optymalizacji problemów. NN jest również używany do diagnozowania usterek, ale także do konserwacji predykcyjnej. FL zajmuje się niepewnością w sekcji konserwacji predykcyjnej. Istnieją już działające produkty firm Rolls-Royce i Airbus, które ułatwiają konserwację predykcyjną, tj. ukierunkowanie na części zagrożone i planowanie serwisowania w oparciu o dokładniejsze szacunki trwałości części. Przeanalizujmy jeden przykład, aby zobaczyć, co AI może osiągnąć w utrzymaniu. Skywise, z Airbusa, najpierw uzyskuje dostęp do historycznych danych obsługowych samolotu lub floty samolotów. Czujniki są instalowane we wszystkich samolotach w wrażliwych miejscach, takich jak silnik, aby uzyskać w czasie rzeczywistym dane o tym, jak bardzo zmniejszyła się żywotność części po każdym użyciu. Dane są przesyłane do

Skywise i analizowane po locie. Na przykład może zauważyć powolną zmianę ogólnego ciśnienia pompy hydraulicznej w czasie, a następnie oznakować część i powiadomić linię lotniczą, że chociaż może trwać przez kolejne pięć lotów, awaria w kolejnych dziesięciu jest bardzo prawdopodobna. Jeśli problem wydaje się szczególnie poważny, system może również wysłać wiadomość w środku. Pozwala to liniom lotniczym poświęcić więcej czasu na obsługę techniczną statku powietrznego i w międzyczasie przydzielić kolejny lot do przewozu klientów. Oprogramowanie wyświetli również dokładną instrukcję i procedurę naprawy, korzystając ze zdigitalizowanych instrukcji konserwacji. Odpowiednik firmy Honeywell, Honeywell Forge (dawniej GoDirect Connected Maintenance), zgłasza wskaźnik braku usterek (gdy zgłoszona część nie posiada żadnych usterek) o 1,5% i 35% zmniejszenie zakłóceń operacyjnych. Sztuczna inteligencja jest również wykorzystywana bardziej bezpośrednio, ponieważ zarządzają robotami konserwacyjnymi i naprawczymi. Robot projektowy CAIRE firmy Lufthansa Technik jest w stanie sprawdzać wzmocnione kompozyty na poszyciu samolotu pod kątem uszkodzeń, a następnie samodzielnie dokonywać napraw. Robot skanuje uszkodzenie, identyfikuje kształt złącza szalunkowego i potrzebną ścieżkę frezowania, wycina uszkodzoną część, a następnie zastępuje ją warstwami naprawczymi. Innym zastosowaniem sztucznej inteligencji jest analiza pogody, która usprawnia podejmowanie decyzji dotyczących lotów. Delta Airlines niedawno wprowadziła na rynek zastrzeżone oprogramowanie, które wykorzystuje uczenie maszynowe do tworzenia hipotetycznych wyników w oczekiwaniu na zakłócenia na dużą skalę spowodowane pogodą. Uczy się na podstawie wpływu zakłóceń pogodowych, aby z czasem lepiej je symulować. Innym świetnym przykładem jest system zapobiegania przekroczeniu pasa startowego firmy Airbus. System oblicza, czy w danym momencie można bezpiecznie wylądować samolotem o długości pasa startowego. Jest to obliczane zarówno dla warunków mokrej, jak i suchej drogi startowej. Oblicza je na podstawie szeregu parametrów statycznych i dynamicznych, w tym pozycji, typu samolotu i silnika, masy, prędkości względem ziemi, temperatury powietrza na zewnątrz, rzeczywistej i skalibrowanej prędkości lotu, wiatru, środka ciężkości oraz bieżącej konfiguracji klap/klap. Może nawet powiedzieć pilotom, aby używali maksymalnej siły hamowania, jeśli uzna, że ryzyko przekroczenia pasa startowego jest zbyt duże. Thales używa systemu z obsługą sztucznej inteligencji o nazwie TopSkySimDebrief do szkolenia kontrolerów ruchu lotniczego. „Elektroniczny asystent instruktora” monitoruje wszystko, od tętna ucznia po to, na czym skupia się jego wzrok podczas symulacji, a nawet rytm głosu. Zaalarmuje instruktora, jeśli uzna, że dana osoba zachowuje się inaczej niż jej linia bazowa. Spark Cognition opracował rozwiązanie wykorzystujące sztuczną inteligencję do przewidywania awarii komponentów. Monitoruje układy mechaniczne samolotu. Może również zalecić działania naprawcze, które należy podjąć w przypadku awarii. Głównym priorytetem projektanta jest poprawa efektywności paliwowej samolotu. Francuska firma Safety Line opracowała narzędzie wykorzystujące sztuczną inteligencję do optymalizacji parametrów lotu w celu zwiększenia zużycia paliwa. Zużycie paliwa jest największe, gdy samolot jest w trybie wznoszenia. Więc improwizuje profile wznoszenia samolotu. Firma Garmin wprowadziła „Telligence”, sterowany głosem system szklanego kokpitu inspirowany sztuczną inteligencją. Za pomocą przycisku i polecenia głosowego pilot może dostroić częstotliwość; zmienić ekran wyświetlacza; i uzyskać dane o ruchu drogowym, dane o wietrze itp. Zamiast odwracać uwagę na różne zadania, mogą bardziej skupić się na lataniu. Nietrudno zauważyć, że sztuczna inteligencja w sektorze bezpieczeństwa w lotnictwie to już nie tylko hasło, którym ludzie opisują przyszłość, ale technologia, która już tu jest.


WPLYW SZTUCZNEJ INTELIGENCJI NA ZDALNE WYKRYWANIE

Teledetekcja jest przydatnym narzędziem do przeprowadzania analiz geograficznych. Ułatwiło to badanie i modelowanie głębi wiedzy o Ziemi i jej atmosferze. Obejmuje ogromną ilość badań w zakresie analiz spektralnych, przestrzennych i czasowych. W ciągu ostatnich kilku lat wpływ AI stał się tematem dyskusji. Sztuczna inteligencja z biegiem czasu udowodniła swoją skuteczność na wielu różnych

obszarach. Elon Musk, właściciel Space X i Tesli, odważył się wprowadzić koncepcję sztucznej inteligencji w swoich samochodach dla publiczności. Jest używany w programie wizyjnym i planistycznym autopilota. Pojazd rejestruje obrazy w sposób ciągły. Uczy się, rozumie i znajduje natychmiastowe rozwiązanie w trudnych czasach. Podobnie zdjęcia satelitarne zawierają wiele informacji, które należy zrozumieć i przeanalizować. Trudno jest uzyskać informacje za pomocą równań matematycznych dla każdego piksela na obrazie. Jest to czasochłonne, a dokładność wyników nie będzie gwarantowana. Za pomocą algorytmów uczenia maszynowego dane można łatwo podzielić i posortować zgodnie z wymaganiami. Ułatwia cały proces teledetekcji. W różnych sekcjach teledetekcji pojawiają się coraz to nowsze podejścia. Uczenie wielokierunkowe (ML), uczenie transferowe (TL), uczenie częściowo nadzorowane (SSL), uczenie aktywne (AL) itp., to kilka niedawno wprowadzonych podejść do uczenia maszynowego, które zostały podjęte w kierunku teledetekcji. ML i SL są ze sobą powiązane. ML zajmuje się wyodrębnianiem cech, które są nieliniowe i zmniejszają wymiary; tj. dane wysokowymiarowe są konwertowane na dane niskowymiarowe przy zachowaniu stałego współczynnika jakości. SSL modeluje strukturę danych ML. TL aktualizuje zbiór danych o użytkowaniu terenu na podstawie czasowego wyniku zbioru danych na podstawie istniejącego pliku szkoleniowego, podczas gdy AL wykorzystuje zaktualizowane pliki szkoleniowe. Uczenie maszynowe zdecydowanie poprawiło obszary, takie jak klasyfikacja obiektów, wykrywanie i ekstrakcja, kodowanie i przetwarzanie na pokładzie itp.

KLASYFIKACJA

Klasyfikacja jest podzielona na dwie podkategorie: (a) nadzorowana (SC) i (b) nienadzorowana (UC). SC wykorzystuje koncepcje AI, takie jak NN i SVM. W przypadku klasyfikacji tworzona jest klasa do sortowania obiektów. Aby wygenerować klasę dla sklasyfikowanego modelu, wykorzystuje informacje oznaczone jako piksel (px). Na przykład klasą może być zestaw budynków, zestaw dróg lub zestaw typów roślinności. Każda klasa jest oznaczona kolorem. Klasy są różnicowane na podstawie wartości każdego piksela użytego do zdefiniowania klasy. Każda klasa uwzględnia region zainteresowania (ROI) (tj. punkty zainteresowania px należące do tej klasy). Punkty te pomagają w określeniu granic klasy. Wykorzystując wspomniane wcześniej koncepcje, SVM pomaga wektoryzować granicę klasy. Kategoryzuje ROI według zdefiniowanych klas. Następnie sieć NN wykrywa klasy na podstawie wprowadzonych danych treningowych. Rysunek 15.3 przedstawia klasyfikację mapy na podstawie różnych zdefiniowanych klas.




Wizualizacja i monitorowanie podobnego obszaru zainteresowania (AOI) to problem, z którym boryka się UC. Istnieje wiele sposobów na wykonanie UC. Kilka z nich to NN, SVM i oparte na regułach. Te trzy sposoby są podstawowymi podejściami do przeprowadzenia UC. Podejścia te są objęte jednym

terminem „algorytm grupowania”. Jest to powszechna metoda analizy statystycznej używana w aplikacjach UC. Pierwszym krokiem do wygenerowania mapy UC jest grupowanie rozmyte. Aby wykorzystać zależność elementu przestrzennego, grupowanie rozmyte łączy się z optymalizacją wielokryterialną. Następnym krokiem jest regularyzacja kontekstowa (CR). Wykorzystuje metody takie jak fuzja informacji z wielu źródeł, realizacja projekcji, hierarchiczne grupowanie.

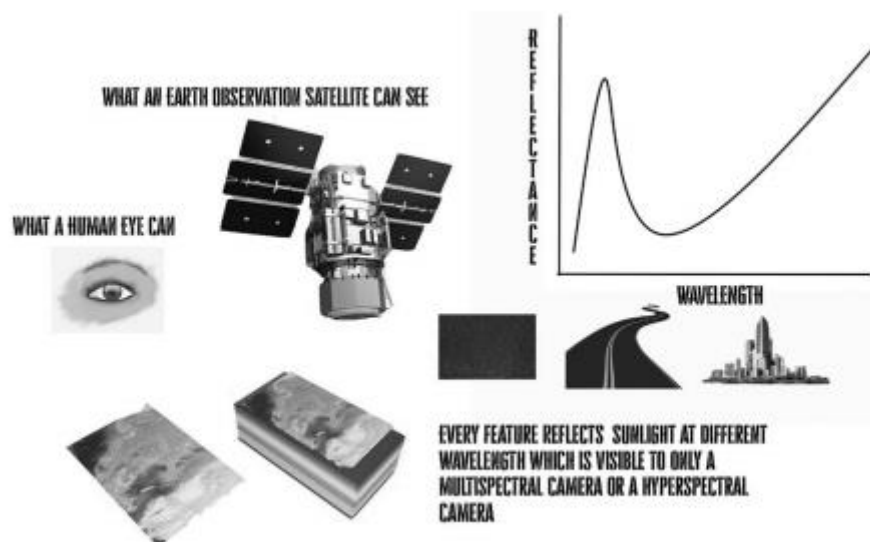
ZMIANA WYKRYWANIA

Każdy satelita krążący wokół Ziemi generuje szereg czasowy. Szeregi czasowe generowane są przez algorytm zaprogramowany do analizy danej klasy. Każdy wygenerowany szereg czasowy może dać wgląd w wykrywanie zmian w klasie. Im większy szereg czasowy, tym większy byłby wymagany czas i moc przetwarzania. Istnieją podejścia bezpośrednie, takie jak analiza wektora zmian (CVA), odejmowanie obrazu itp. Jednak podejścia te są czasochłonne. Za pomocą algorytmów NN i Kernela ułatwia proces wykrywania zmian w długim okresie, biorąc pod uwagę SC i UC obrazów oraz wykrywa zmiany dla odpowiednich klas. Rysunek.4 przedstawia wykrywanie zmian między trzema różnymi mapami tego samego obszaru.




Ekstrakcja funkcji

Satelitarne zestawy danych mają duże rozmiary, wymagany jest dłuższy czas przetwarzania, a obecność szumów wpływa na jakość produktu. Każde pasmo zbioru danych ma znaczenie. Zamiast wydobywać każdy kawałek informacji z obrazu, podejście uczenia maszynowego może wyodrębnić tylko wymagane informacje. Skraca to czas potrzebny do przetworzenia zestawu danych. Wybór funkcji wykorzystuje podejście GAs lub SVM w celu wyeliminowania niepożądanych funkcji. Wyodrębnianie cech wykorzystuje podejścia liniowe, takie jak PCA i regresja częściowej najmniejszych kwadratów (PLS). Rysunek 5 przedstawia ekstrakcję cech za pomocą długości fal pochłoniętego promieniowania.



PRZETWARZANIE OBRAZU NA ORBICIE

Zdolność do autonomicznego procesu na pokładzie jest trendem w satelicie obserwacji Ziemi (EOS), gdzie satelity mogą myśleć niezależnie. UoSat był pierwszym satelitą, który miał autonomiczny procesor na pokładzie. Obecnie Europejska Agencja Kosmiczna i Narodowa Agencja Aeronautyki i Przestrzeni Kosmicznej, największe światowe agencje kosmiczne, rozwinęły zdolność autonomicznego przetwarzania na pokładzie w swoich satelitach: na przykład mały projekt satelitarny dla autonomii na pokładzie (PROBA) opracowany przez ESA i algorytm dla Autonomicznej Nauki- oprogramowanie do eksperymentów rzemieślniczych NASA dla misji TechSat-21. Zamiast tego satelita Earth Observation-1 wykorzystał ten algorytm, gdy misja TechSat-21 została przerwana. Najczęstsze funkcje wbudowanego procesora to (a) kompresja obrazu, (b) analiza obrazu i (c) wybór obrazu. Z tej trójki najważniejsza jest kompresja obrazu. Obrazy uchwycone przez satelity EO mają bardzo duży rozmiar danych. Kompresja skraca czas pobierania poprzez zmniejszenie rozmiaru. Używa stratnych lub bezstratnych. Lossy to kompresja o bardzo wysokim współczynniku, podczas gdy bezstratna kompresuje obraz bez utraty współczynnika jakości. Autonomiczna zdolność może funkcjonować do analizowania, wykrywania i klasyfikowania obiektów zgodnie z określonymi wymaganiami; na przykład musisz wykryć ilość roślinności na swoim obszarze. Wbudowany procesor można zaprogramować do wstępnego przetwarzania obrazów zarejestrowanych przez satelitę. Następnie procesor pokładowy wykonuje obliczenia, aby uzyskać dane statystyczne i porównać je z danymi treningowymi, aby znaleźć procent trafności. Jeśli obrazy przechwycone przez czujnik nie spełniają wymagań, zostaną natychmiast odrzucone. Jeśli spełniają wymagania, wbudowany procesor może przetworzyć analizę i przygotować obraz do pobrania. Rysunek 6 przedstawia PROBA (L) ESA i Earth Observation-1 (R) NASA



(a)



(b)

SZTUCZNA INTELIGENCJA W DYNAMICE STATKÓW KOSMICZNYCH

Istnieje wiele powodów wprowadzenia sztucznej inteligencji do statków kosmicznych. Pierwszym jest oczywiście monitorowanie stanu statku kosmicznego i środowiska; działa w dowolnym momencie. To informuje o dalszych działaniach i czy załoga (jeśli w ogóle) i statek kosmiczny są bezpieczne. Drugi to planowanie i harmonogramowanie. Optymalizacja czasu operacji zwiększa wydajność, a sieci NN z ich zdolnością do wykrywania drobnych relacji między parametrami są do tego dobrze przystosowane. Sztuczną inteligencję można również zastosować podczas realizacji tych planów, aby zapewnić, że wyniki są zgodne z oczekiwaniami i wykorzystać podsystemy statku kosmicznego, gdy tylko coś się nie powiedzie. Skutkuje to zmniejszonym obciążeniem załogi i nową równowagą odpowiedzialności między załogą, personelem naziemnym i pojazdem. Orientacja i kontrola orbity są wymagane w przypadku satelitów i teleskopów obserwacyjnych, dzięki czemu można je zawsze nakierować na cel. Manewry reorientacyjne są zwykle wykonywane przez algorytmy sterowania oparte na momentach zakłócających. Jednak podczas operowania satelitami wokół asteroid, momenty zakłócenia grawitacyjne są nieznane, a pole grawitacyjne może być nieliniowe. W takich przypadkach można użyć sieci NN, które działają w celu aproksymacji funkcji nieliniowych i momentów zakłócających w czasie rzeczywistym. Algorytmy wzmacniania neuronowego mogą być wykorzystywane do projektowania kontrolerów orbity, które maksymalizują efektywność zawisu wokół małych obiektów poprzez modelowanie problemu sterowania jako problem decyzyjny Markowa i implementację algorytmów bezpośredniego wyszukiwania polityk w celu znalezienia potencjalnych schematów sterowania dla utrzymania stacji orbitalnej. Sztuczna inteligencja może być również wykorzystywana do optymalizacji tras eksploracji kosmosu, aby zmaksymalizować wydajność paliwową lub zminimalizować czas potrzebny. Najpierw przyjrzymy się niektórym technikom wykorzystującym optymalizację ewolucyjną i ich zastosowaniom. Poniższe techniki są przydatne do optymalizacji dla pojedynczego celu.

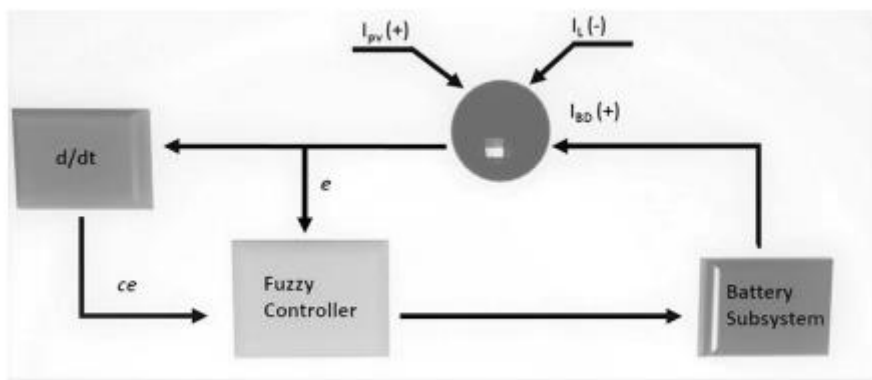
a. Ewolucja różniczkowa: Jest to odmiana GA, która jest używana do nieliniowych i nieróżnicowalnych ciągłych funkcji przestrzennych, takich jak transfery statków kosmicznych z napędem chemicznym, gdzie sekwencje wielokrotnych przyrostów prędkości impulsowej muszą być ustalone.

b. Optymalizacja roju cząstek: jest to metoda, w której cząsteczka reprezentuje możliwe rozwiązanie problemu. Wiele cząstek zmierza w kierunku tego, co obecnie uważa się za obszar najlepiej dopasowany spośród wszystkich cząstek (jest on aktualizowany pod koniec każdego cyklu) w przestrzeni wyszukiwania rozwiązania. Z każdym cyklem zbliża się coraz bardziej do prawdziwie optymalnego rozwiązania, ale nie ma gwarancji, że zostanie znalezione najbardziej zoptymalizowane rozwiązanie. Jest używany w połączeniu z różnicowymi algorytmami ewolucji, aby znaleźć globalnie optymalne rozwiązania konsekwentnie dla scenariuszy transferu Ziemia-Mars.

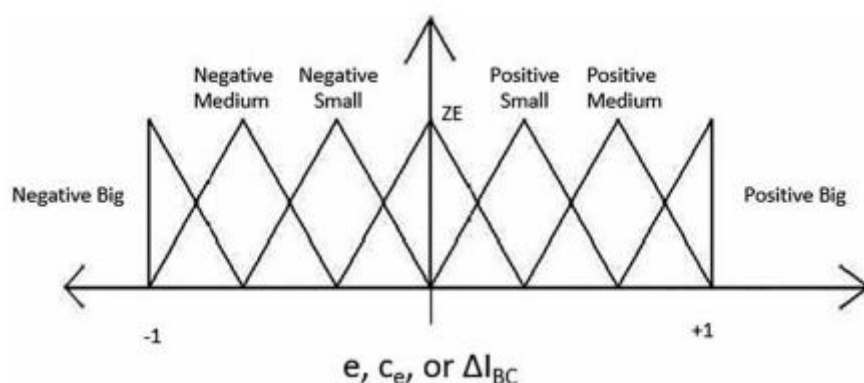
c. Strategia ewolucji macierzy kowariancji: modyfikuje macierz kowariancji problemu, aby zapewnić większe prawdopodobieństwo, że wynikowe rozwiązanie jest bliższe wcześniej znalezionym „użytecznym” rozwiązaniom.

d. Optymalizacja kolonii mrówek: Jak sama nazwa wskazuje, działa podobnie do sposobu, w jaki kolonia mrówek szuka pożywienia; „feromony” są odrzucane w taki sposób, że bardziej obiecująca ścieżka możliwych rozwiązań do zbadania ma wyższy priorytet, a „odległość” do każdego z tych miejsc docelowych może zmniejszyć priorytet dowolnej ścieżki.

Optymalizacja jednocelowa to potężne narzędzie, ale należy pamiętać, że czasami parametry, które próbujemy zoptymalizować, mogą ze sobą kolidować. Załóżmy na przykład, że chce się zbudować raketę i zminimalizować wagę, ale także zmaksymalizować ilość przewożonego paliwa. Prowadzi to do tematu optymalizacji wielokryterialnej. Wymaga to koncepcji efektywności Pareto. W systemie o efektywności Pareto konfiguracja jest taka, że nie ma żadnego wzmocnienia, które można by stworzyć w jednym parametrze bez powodowania straty w innym. Front Pareto jest zatem zbiorem wszystkich możliwych konfiguracji w celu stworzenia systemu efektywnego w Pareto. Mówi się, że system jest zdominowany przez Pareto, jeśli nadal można go ulepszyć, aby stworzyć system naprawdę wydajny w Pareto. Do optymalizacji sekwencji przelotów planetarnych, minimalizując czas lotu i zużycie paliwa, zastosowano algorytm genetyczny sortowania niezdominowanego II (NGSA-II). Uczenie maszynowe, stosowane w połączeniu z tymi ewolucyjnymi metodami optymalizacji, umożliwia praktyczne obliczenia w czasie rzeczywistym, na przykład poprzez zastosowanie sieci NN do znalezienia początkowo optymalnych warunków w algorytmach inteligencji roju dla transferu międzyplanetarnego, redukując zazwyczaj długi czas zbieżności, przy użyciu maszyn SVM. Wykazano, że głębokie uczenie można trenować na podstawie informacji zwrotnej o optymalnej sytuacji w nieliniowych, deterministycznych systemach w czasie ciągłym, takich jak lądowanie statku kosmicznego. Wydaje się, że systemy te mogą nawet nauczyć się podstawowych zasad systemu, który modelują, jak równania Hamiltona-Jacobiego-Bellmana. Można to rozszerzyć o uzyskanie przez system optymalnej ścieżki przejścia z orbity Ziemi na Marsa. Nawet systemy zasilania można teraz zautomatyzować za pomocą sztucznej inteligencji, korzystając z sieci ANN lub sterowników logiki rozmytej. Fuzzifation przypisuje stopnie przynależności do danych wejściowych w ramach określonych funkcji przynależności. Zasady przypisywania członkostwa mogą zależeć od kilku zmiennych. Oznacza to, że sterownik logiki rozmytej może być zastosowany zarówno do sytuacji z wieloma wejściami – wiele wyjść, jak i z jednym wejściem – pojedyncze wyjście. Defuzzifier mapuje wyjściowe rozmyte zestawy do wyraźnych wartości wyjściowych. Przyjrzyjmy się możliwemu projektowi systemu zasilania opartego na ogniwach słonecznych. Wykorzystuje dwa wejścia dla sterownika logiki rozmytej: pierwsze to sygnał błędu wskazujący różnicę między generowaniem wyjścia a obciążeniem odniesienia, a drugie to pochodna tego sygnału błędu. Wyjściem regulatora jest zmiana prądu ładowania akumulatora. Schemat blokowy proponowanego sterownika z logiką rozmytą pokazano na rysunku 7.



Standardowe trójkątne funkcje przynależności są wybierane jako wejście i wyjście sterownika logiki rozmytej w kategoriach: ujemna duża, ujemna średnia, ujemna mała, 0, dodatnia mała, dodatnia średnia i dodatnia duża. Trójkątne funkcje przynależności od Negatywnego Dużego do Pozytywnego Dużego są pokazane na rysunku 8.



Zaproponowano sterowanie NN wykorzystujące propagację wsteczną do obsługi jednostek sterujących mocą, które kontrolują, czy system jest w szczytowej mocy lub czy znajduje się w stanie zaćmienia, na podstawie zmiany prądu akumulatora. Jest to pożądane, ponieważ nie musisz podawać algorytmowi samouczącemu się danych dotyczących działania systemu. Po prostu pozwól mu obserwować relacje między parametrami poprzez symulacje, a sam się nauczy. Wejściowymi parametrami sieci są tutaj prąd obciążenia i sygnał błędny, a sieć wyjściowa to zmiana prądu akumulatora.

PERSPEKTYWY NA PRZYSZŁOŚĆ

Sztuczna inteligencja wprowadzi nowy świat, w którym odprawa na lotniskach odbywa się bez słowa i w ciągu kilku minut. Świat, w którym zapytania i usługi każdego pasażera są obsługiwane z łatwością. W tym idealnym świecie drony potrafiące teraz w pełni odróżnić wrogów od cywilów będą współpracować z żołnierzami, prawie jak przedłużenie batalionu. Ich zautomatyzowana konserwacja i optymalizacja zużycia paliwa uwolni czas żołnierzy na wykonywanie swojej pracy i skoncentrowanie się na terażniejszości. AI będzie monitorować przestrzeń powietrzną, zapewniając całkowitą jasność co do tego, czy nadlatujący dron jest wrogi czy przyjazny. Satelity będą mapować nowe światy, identyfikując teren i potencjalne miejsca lądowania, aby ułatwić ludziom eksplorację Układu Słonecznego. Roboty pozbędą się pracowitości i utrzymają siedliska, takie jak ISS czy nasze przyszłe kolonie planetarne, utrzymując je w doskonałym stanie. Rakiety będą transportować ludzi tylko z opcjonalnymi danymi wejściowymi, aby przenieść ich z jednego miejsca do drugiego. Statystyki dotyczące pasażerów będą dostępne na wyciągnięcie ręki przez linie lotnicze, w tym czas podróży „od drzwi do drzwi” i sposób podróży, co pozwoli im zoptymalizować wrażenia pasażerów. Projektanci samolotów będą mogli

przeprowadzać projekty generatywne, przeprowadzając wiele iteracji produktu, aby zmaksymalizować wydajność. Samoloty będą w stanie identyfikować zagrożenia za pomocą widzenia maszynowego. Abyśmy żyli na tym świecie, wymagałoby wielu udoskonaleń w naszym rozumieniu sztucznej inteligencji, z których każde wspierało następne. Im więcej osób zainteresuje się zastosowaniami AI, tym szybszy rozwój przemysłu lotniczego.

WNIOSEK

W przemyśle lotniczym sztuczna inteligencja jest dokładnie badana w komercyjnych sektorach przemysłu lotniczego i jest szeroko wdrażana w kilku obszarach, w tym w obsłudze klienta, na lotniskach i w lotach. Chociaż główne komercyjne linie pasażerskie dość wcześnie przyjęły sztuczną inteligencję, nadal istnieje duży potencjał do zbadania innowacji i automatyzacji. Do tej pory widzieliśmy, że dzięki technologii AI nastąpił ogromny wzrost poziomu bezpieczeństwa i obsługi lotniczej, rozwiązań samoobsługowych, doświadczenia klienta z automatyzacją, a także optymalizacji pracy pracowników. Sztuczna inteligencja przyniosła również znaczny poziom zysków i oszczędności, ponieważ umożliwia liderom branży podejmowanie świadomych decyzji poprzez inteligentne wykorzystanie danych przed podjęciem decyzji dotyczących pozycjonowania na rynku i cen. Sztuczna inteligencja przedstawiła kilka możliwości w dziedzinie lotnictwa i kosmonautyki, ponieważ wciąż znajduje się w bardzo wczesnej fazie, zwłaszcza biorąc pod uwagę rygorystyczny poziom środków bezpieczeństwa, które muszą być utrzymane w tak ściśle regulowanej branży. Każda opracowywana technologia lub system musi być w szerokim zakresie walidowany i certyfikowany, a często może nie zostać zatwierdzony przez międzynarodowe procesy FAA, dlatego wymagane są doskonałe metody weryfikacji, aby sztuczna inteligencja mogła osiągnąć swój maksymalny potencjał. Inną poważną barierą, którą przemysł kosmiczny musi pokonać, są obawy o prywatność danych i praktyki w zakresie cyberbezpieczeństwa, które należy należycie uwzględnić podczas opracowywania jakichkolwiek systemów dla sztucznej inteligencji. Ponieważ zastosowania sztucznej inteligencji w przemyśle kosmicznym i lotniczym stale się rozszerzają, coraz więcej konkurentów i liderów chętnie wdraża te rozwiązania oparte na sztucznej inteligencji. Chociaż szersza adopcja sztucznej inteligencji wymaga znacznych nakładów i wysiłków, na całym świecie przyjmuje się, że ta innowacyjna technologia ma znaczny potencjał, który może w dużej mierze zoptymalizować produkcję, zapewnić zwiększoną wydajność, a także skutecznie radzić sobie z awariami.